

カラー・蛍光画像の入力と深層学習による安価・小型で高精度な「種子用大豆」選別機の開発

A rapid, easy and accurate classification system of soybean seeds using multi-input convolutional neural networks with color and UV-induced fluorescence images input

研究代表者 新潟大学自然科学系農学部 助教 斎藤嘉人

Yoshito Saito

In soybean production, there is a need for an inexpensive and simple sorting method that can be used by a single farmer. The purpose of this study is to identify soybean defects by inputting two types of images: color and UV-induced fluorescence images. Color and fluorescent images of soybean seeds were respectively taken by white and UV LED with a wavelength of 365 nm, and visually labeled into four categories. For classification, the multi-input convolutional neural network (CNN) models were constructed using three patterns of pre-trained networks. The classification accuracy of each model was evaluated on test data consisting of 20% of the total data. The classification accuracy of the model with simultaneous input of color and fluorescent images was 93.9%, which was more than 6.0 pt higher than that of the model with monochromatic and fluorescent images.

要旨

大豆生産では、一農家が利用できる安価で簡便な選別方法が必要とされている。本研究では、カラー画像および紫外線蛍光画像の2種類の画像の入力による大豆の欠陥判別を目的とした。大豆種子のカラー画像と励起波長 365 nm の蛍光画像をそれぞれ撮影し、4 カテゴリに視覚的にラベル付けを行った。分類には、3 パターンの事前学習済みネットワークを用いて CNN モデルを構築した。各モデルの分類精度は、全データの 20% からなるテストデータで評価され、カラー・蛍光画像同時入力モデルの分類精度は、単色画像や蛍光画像入力モデルよりも 6.0 pt 以上高い 93.9% を示した。

1. 背景

世界で最も重要な農作物の一つである大豆 (*Glycine max* (L.) Merr.) は、世界人口の増加に伴い広く注目されている。大豆は代表的な畑作物であり、収量確保と環境保全を両立させるためには、病害虫による生産段階でのロスをできるだけ減らす必要がある。

大豆の安定供給を阻害する要因の一つが、雑草や病害虫による収穫前の段階でのロスであり、現状、雑草との競合により、生育期間中に大豆生産可能量の約 37% が失われると報告されている¹⁾。近年、農業生産による環境負荷の観点から、大豆の狭畝栽培が提案されているが²⁾、雑草を隙間なく覆うためには種子の発芽率をほぼ 100% に揃える必要がある。

そのため、機械による損傷やカビ、ウイルス、その他の化学的欠陥のある大豆種子を播種前に正確に除去する種子用大豆選別技術が求められる。

大豆の手選別には膨大な時間と労力を要するため、選別機の利用が不可欠である。現在、大豆種子には、種子の形状や大きさに基づく機械選別と、種皮の色情報に基づく色彩選別の二つが主流である。機械選別では、一定サイズのふるいで夾雑物を除去し、緩やかな傾斜のある搬送ベルトを用いて転がらない割れ粒や欠陥粒も除去し、最終的に異なるサイズのふるいを通すことで、大粒、中粒、小粒に選別される。一方、色彩選別は、機械選別では選別できないウイルスや病気、害虫による欠陥粒を選別するために使用される。これらの欠陥は、種皮に現れる病斑などの色の情報や、種皮のしわ寄り、裂皮状態などの外観情報として現れる特徴がある。特に大豆栽培では、ウイルスや病害大豆の混入を徹底的に防ぐ必要がある。現在、色彩選別機は大型で高価であり、各地域の営農地で一部の施設にしか導入されていない。そのため各農家は大豆を色彩選別機が導入されている施設へ大豆を運び、選別後持ち帰る形式をとることが多いが、一つの色彩選別機で様々な品種の大豆を処理するため、別品種とのコンタミネーションが起るなどのリスクが存在する。そのため、各農家単位で導入できる小型かつ安価な種子用大豆選別機の開発が必要とされる。

近年、分光や画像処理技術、機械学習・深層学習の劇的な進歩により、農産物の自動選別技術が可能

になった³⁾。大豆の欠陥分類に関する先行研究では、カラー画像と機械学習⁴⁾や深層学習⁵⁾を組み合わせた外部欠陥分類が行われている。大豆の欠陥分類に関する他の先行研究の一つに、背景照明付きの透過画像を用いたものが報告されている⁶⁾。さらに、可視カラー画像だけでなく、近赤外 (NIR) を利用したマルチスペクトル画像も石豆の検出に使用されている⁷⁾。

さらに近年では、紫外励起による蛍光反応を利用することで、カラー画像では捉えることができない蛍光物質の存在や、農作物表面の微小な傷や欠陥を検出できることが示されている。先行研究では、Liら (2019)⁸⁾ が、紫外線励起を用いたハイパースペクトル蛍光イメージングによるダイズ苗の発芽率予測を報告している⁸⁾。また、自家蛍光分光イメージングも、さまざまな化学的屬性に基づく大豆種子の品質評価に利用されている⁹⁾。ハイパースペクトルイメージングは、0~20nmの微細なバンド間隔で撮影されるため情報量が豊富である反面、カメラが高価でありデータ量も膨大であるため、安価で簡便な装置としての実装には適さない。一方、紫外線励起蛍光画像を可視RGBカラー画像として解析することで、柑橘類表面の欠陥個所の特定や、イチゴの腐敗予測、魚類の鮮度予測などが報告されている¹⁰⁻¹³⁾。このように、通常のカラー画像に加え、紫外線励起蛍光のRGB画像を入力することで、ハイパースペクトル画像に比べ価格および計算負荷のコストを抑えた欠陥種別の判別ができると期待される。しかしながら、紫外励起蛍光画像を用いた大豆の欠陥種別の分類を報告した事例は未だない。

カラー画像と蛍光画像の両方に基づいて大豆の外観不良を分類するためには、深層学習モデルの活用が前提となる。先行研究のひとつに、木の幹と葉の画像を用いて樹種を分類するための同時入力畳み込みニューラルネットワーク (CNN) モデルを確立したものが¹⁴⁾。この研究では、樹木の幹と葉の画像に対して、事前に学習させたCNNを用いて特徴抽出を行い、抽出した特徴量をサポートベクターマシンによる学習に用いた。その結果、木の幹や葉のみを用いて学習させたネットワークと比較して分類精度が向上し、CNNモデルに2種類の画像を用いることの可能性が示された。

そこで本研究では、カラー画像と蛍光画像を入力とした同時入力CNNモデルによる大豆種子の欠陥種別の分類を目的とした。まず、収穫された日本産大豆を人の目によって選別し、その後、カラーカメラ、白色LED、波長365nmの紫外LEDから構成されるイメージングシステムを用いて、大豆のカラー画像と蛍光画像を撮影した。取得された画像に対して画像解析を行い、事前に学習させたネットワークを用いて同時入力CNN分類モデルを構築し、分類精度を検証した。

2. 試料および実験方法

2.1 供試試料

本研究では、新潟大学フィールド科学教育研究センター (村松ステーション) にて2022年10月に収穫された日本大豆 (品種: 'トヨコマチ') を対象とした。収穫後、莢や枝、塵といった夾雑物を除去し、常温で含水率約15%まで乾燥させた。供試した種子の重量は約800gであった。

収穫後、大豆を人間の目視により、正常、しわ、裂皮、欠陥の4カテゴリに選別した。欠陥のカテゴリには、病害、カビ、虫害などが含まれる。

2.2 画像撮影装置の構築および画像取得方法

本研究で構築した画像撮影装置を図1に示す。画像撮影装置の正面からの模式図を図1(a)に、側面からの模式図を図1(b)に示す。

カラー画像の撮影には白色LED (LDL2-80X16SW2, CCS) を、蛍光画像の撮影には波長365nmの紫外LED (LDL-71X12UV2-365-N, CCS) をそれぞれ用いた。撮影時には、白色LEDとカメラレンズの前に偏光フィルターを設置し、大豆表面からの鏡面反射光を除去した。また、カメラレンズにはカットオフ波長390nmのUVカットフィルターを取り付け、蛍光画像中の紫外線反射光の検出を防止した。カメラには一眼レフのカラーカメラ (EOS kiss x7, Canon) を用い、画像の高解像度化のため焦点距離70mmのマクロレンズ (DG MACRO, SIGMA) を用いた。

1枚の画像につき、合計24粒 (縦6粒、横4粒) の大豆をLED照明エリア内に均一に配置した。F値は5.6、ISO感度は800に設定し、シャッタースピー

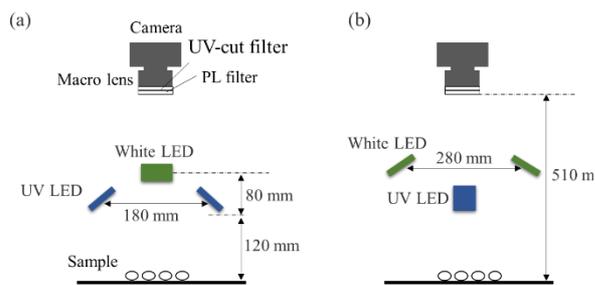


図1 画像撮影装置の(a)正面および(b)側面方向の模式図

ドはカラー画像が 1/30 秒、蛍光画像が 1/20 秒とし、画像サイズは 5184×3456 ピクセルであった。

2.3 画像解析方法

代表的なカラー原画像と蛍光原画像をそれぞれ図 2(a)と図 2(b)に、画像解析の手順を図 2(c)に示す。本研究の解析には、MATLAB (MATLAB R2023a, MathWorks, USA) とノートパソコン (LEVEL-15FR170-i7-TARX, iiyama, Japan) を使用した。CPU は第 11 世代 Intel® Core™ i7-11800H (Intel, 米国), GPU は GeForce RTX 3070 (NVIDIA, 米国) を使用した。

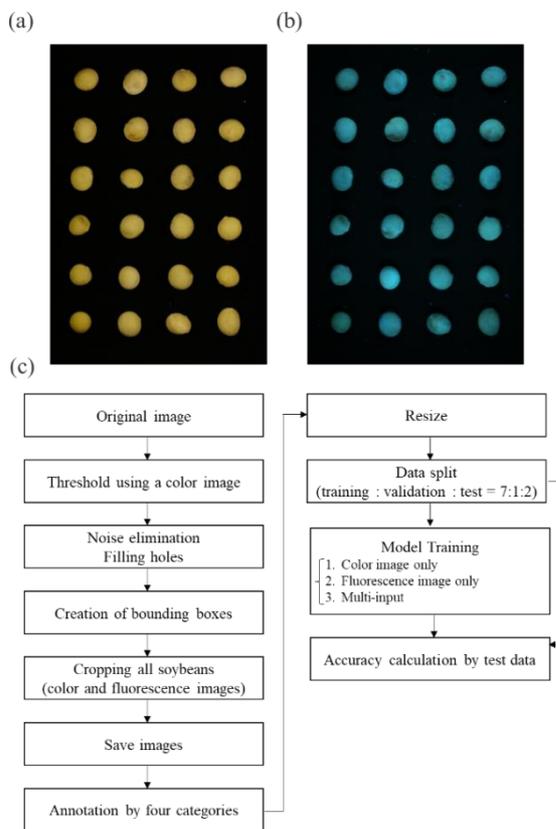


図2 代表的な(a)カラー画像, (b)蛍光画像, (c)画像解析の手順

図2(a)と図2(b)に示す2種類の画像を取り込んだ後、大津の2値化¹⁵⁾を適用させ、カラー画像から閾値画像を求めた。大豆の粒以外の背景ノイズの除去、および大豆の粒上の穴埋めと領域連結を行い、各粒のバウンディングボックスを取得し、粒ごとに画像のトリミングを行った。切り出された大豆画像は4つのカテゴリ (normal, wrinkled, peeled, diseased) にラベル付けを行い、同じ粒でカラー画像と蛍光画像が対応するように命名し保存した。

2.4 同時入力 CNN によるクラス分類

本研究は、AlexNet¹⁶⁾, ResNet-18¹⁷⁾, EfficientNet¹⁸⁾ の転移学習によるモデル構築を行い、結果を比較した。ネットワークの概要を図3に示す。

図3に示すように、本研究ではカラー画像と蛍光画像の2種類の画像を入力した。入力画像は前述の3つの事前学習済みバックボーンネットワークを用いて畳み込まれた。一連の畳み込みで得られた特徴量を連結し、全結合層とソフトマックス層を用いて分類を行った。これらの特徴の連結方法は、先行研究¹⁹⁾を参考にした。バックボーンの初期重みとバイアスは、事前学習値を用いて設定した。2つの入力を連結した後の完全連結層の初期重みは Glorot (Xavier としても知られる) として初期化され、バイアスは0に初期化された。

これらのネットワークの設定は、MATLAB の DeepNetworkDesigner を使用して行った。このアプリケーション内で作成されたネットワークは、本研究におけるトレーニングの検証のためにエクスポートされ保存された。これらのネットワークのトレーニングには、主に MATLAB の Deep Learning Toolbox を使用した。

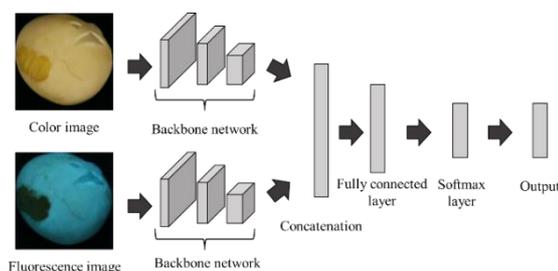


図3 本研究で分類に利用した同時入力ネットワークの構成様式。カラー画像と蛍光画像の両方を入力とし、それぞれのクラスを予測した。

図 2(c)に示すように、入力画像は各ネットワークに画像が収まるようにリサイズされ、利用可能な画像は 7:1:2 の割合でランダムにトレーニング、検証、テストセットに分けられた。各モデルには、同一のトレーニングデータ、バリデーションデータ、テストデータを使用した。

構築された深層学習モデルの精度評価は、テストデータに対して行われた。真のラベルと予測ラベルに基づいて混同行列を作成し、分類精度を評価した。学習に使用されるハイパーパラメータは、グリッド探索によって探索され、最適化された。初期学習率は 1.0×10^{-4} , 5.0×10^{-5} , 1.0×10^{-5} の 3 パターンを採用し、ミニバッチサイズは 8 と 16、エポック数は 5 と 10 とした。ハイパーパラメータの組み合わせは 12 通りである。これらの組み合わせの中で学習を行い、検証データで最も精度の高いモデルを選択した。この選択されたモデルをテストデータの検証に使用し、分類結果を得た。オプティマイザには Adam を用いた。

3. 結果と考察

3.1 大豆の外部欠陥判別モデル

すべてのモデルで得られた分類結果を表 1 に示す。「Color image only」, 「Fluorescence image only」では、それぞれカラー画像のみ、蛍光画像のみで分類を行った場合の結果である。同時入力 CNN モデルの結果は、「Both color and fluorescence image」と表示されている。テスト精度は、学習パラメータの組み合わせの中で検証精度が最も高い組み合わせの結果を表に示している。

検証の結果、ResNet-18 を用いた場合、RGB 画像と蛍光画像の両方を用いた手法が 93.9% と最も高いテスト精度を達成した。また、本研究で得られた分

表 1 各画像入力による深層学習で得られた大豆の外部欠陥の判別における精度の結果

Input image	Backbone	Accuracy (%)	
		Validation data	Test data
Color image only [Saito et al., 2023]	AlexNet	84.8	86.7
	ResNet-18	84.2	87.4
	EfficientNet	85.9	87.9
Fluorescence image only [Saito et al., 2023]	AlexNet	77.7	81.1
	ResNet-18	87.0	87.6
	EfficientNet	82.9	85.1
Both color and fluorescence image (Ours)	AlexNet	88.6	89.1
	ResNet-18	94.0	93.9
	EfficientNet	94.3	92.2

類精度は、RGB 画像のみ、蛍光画像のみを用いた場合と比較して、使用するネットワークによらず検査精度の向上が見られた。特に、ResNet-18 を用いた場合の精度は 93.9% に達し、カラー画像のみを用いた場合と比較して 6.5 pt 向上した。このように、RGB 画像と蛍光画像の両方を入力として深層学習ネットワークを学習させることが精度向上に寄与することがわかった。

AlexNet

	Defect	Normal	Peeled	Wrinkle
Defect	275	4	3	1
Normal	13	139	2	11
Peeled	6	4	119	1
Wrinkle	6	24	5	123
	Defect	Normal	Peeled	Wrinkle

Predicted Class

ResNet-18

	Defect	Normal	Peeled	Wrinkle
Defect	279	4		
Normal	4	149	4	8
Peeled		3	123	4
Wrinkle		13	5	140
	Defect	Normal	Peeled	Wrinkle

Predicted Class

EfficientNet

	Defect	Normal	Peeled	Wrinkle
Defect	280	3		
Normal	9	134	7	15
Peeled		1	121	8
Wrinkle		9	5	144
	Defect	Normal	Peeled	Wrinkle

Predicted Class

図 4 同時入力 CNN による大豆の外部欠陥の分類結果を示す各モデルの混同行列

図4は、それぞれのモデルを用いて大豆を分類した結果得られた混同行列である。縦と横のラベルは、それぞれ実際のクラスと予測されたクラスを示す。図4に示すように、「Defect」の分類精度は、すべてのモデルの中で総じて高かった。例として、「Defect」ラベルと「Normal」ラベルの典型的な画像を図5に示す。図5に示すように、「Normal」ラベルのサンプルは365 nmの波長で励起されることにより青白い蛍光を示すが、「Defect」ラベルのサンプルはほとんど蛍光を發さず黒いテクスチャーを示す。「Normal」ラベルの青白い蛍光色は、波長375 nmで励起すると大豆表面に観察される酸化生成物に由来すると考えられる²⁰⁾。図5(a)に示すように、欠陥のある部分に蛍光がないのは、ウイルスによる生理的障害で、大豆固有の蛍光物質の産生が阻害されているためと考えられる。

一方、「Normal」と「Wrinkled」、「Peeled」と「Wrinkled」の間では、誤分類が頻繁に観察された。誤分類された画像については次節で述べる。

3.2 誤分類された画像

図6に誤分類の例を示す。図6(a)では、「Wrinkled」とラベル付けされ、「Normal」と分類された画像を示し、図6(b)では、「Wrinkled」とラベル付けされ、「Peeled」と分類された画像を示す。図4の混同行列に示すように、このような誤分類のパターンが頻発している。

図6(a)の誤分類は、大豆の端にしわが観察され、蛍光画像で強調されなかったため、分類が困難になったと考えられる。一方、図6(b)に示すような場合

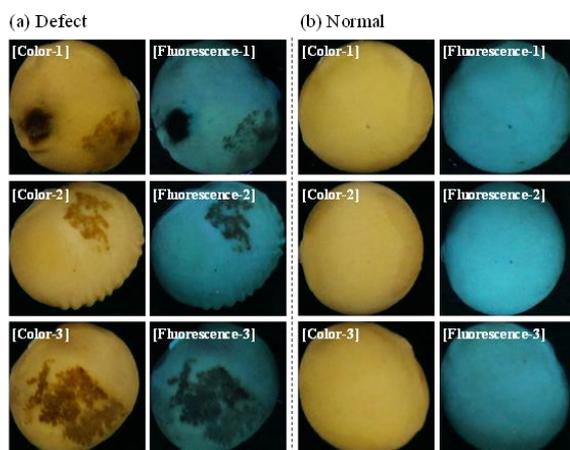


図5 (a) 「Defect」ラベルと(b) 「Normal」ラベルの典型的な異なる3種類のカラー画像と蛍光画像を示す。

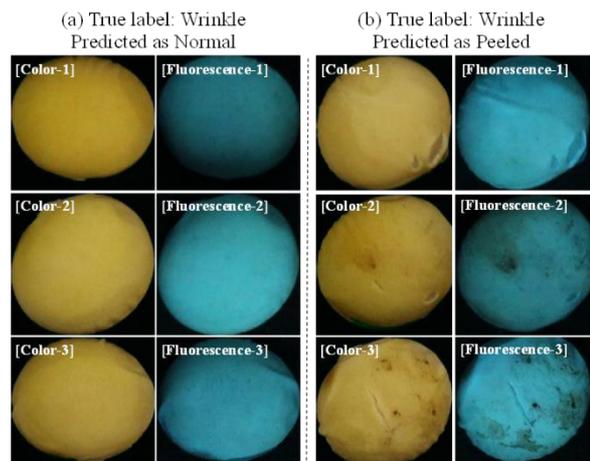


図6 誤分類された大豆画像の典型例。左図(図6(a))は、真のラベル「Wrinkled」が「Normal」と誤分類された例を示す。右図(図6(b))は、真ラベル「Wrinkled」が「Peeled」と誤分類された例

は、しわに加え裂皮等の外部欠陥も同時に大豆表面に含まれていたためである。

一つの大豆に二種類以上の外部欠陥が混在している場合や、蛍光画像で対象となる欠陥が強調されていない場合には、正確な分類が困難であることが確認された。さらに、この方法の欠点として、二つの入力を受け取るため、ネットワークのサイズとトレーニングの計算時間がかかることが挙げられる。カラー画像のみ、あるいは蛍光画像のみといった単一の入力に比べ、ネットワークのサイズは約2倍となるため、ネットワークの軽量化が望まれる。Sarmaら(2022)²¹⁾は、手のジェスチャーを撮影した動画のRGB情報とオプティカルフローによるモーションテンプレート(OFMT)の2つの入力を用いてジェスチャーを分類している。ここでは、静止画像の代わりに様々な角度からの豊富な情報を含む動画を用いている。今回の研究では、各大豆の画像は上側からしか撮影されていないため、各大豆サンプルを下側など異なる角度から撮影することで、大豆の外観不良の分類はより正確になると考えられる。従って、今後の研究として、大豆の外観不良を分類するために、大豆の外観不良を分類機で撮影し、その映像をもとに分類を行うことが考えられる。

4. 結論

本研究では、大豆の外観欠陥を分類するために、カラー画像と蛍光画像の2種類の画像を入力とする

新しい同時入力畳み込みニューラルネットワーク (CNN) モデルを構築した。画像処理システムを用いて、励起波長 365 nm で大豆の蛍光画像を撮影したところ、「Normal」ラベルの大豆では青白い蛍光が観察されたが、「Defect」ラベルの大豆では蛍光が少なく、暗い画像として観察された。同時入力 CNN モデルは、3 種類の事前学習済みネットワークを用いて構築された：AlexNet, ResNet-18, EfficientNet の 3 種類をバックボーンとして同時入力 CNN モデルを構築し、カラー画像のみ、蛍光画像のみを入力としたモデルと比較した。その結果、同時入力 CNN モデルは、一般に単一画像入力よりも高い分類精度を示した。テストデータに対する最高精度は ResNet-18 が得た 93.9% であり、これは単一入力モデルよりも 6.0 pt 以上高い精度であった。これらの結果から、カラー画像と蛍光画像の 2 つの入力を用いた深層学習は、大豆の外観不良の分類に利用できる可能性があることが示された。

発表論文・書籍

- [1] カラーおよび紫外励起蛍光画像を入力とした深層学習による大豆の外部欠陥判別, 斎藤嘉人, 宮川璃空, 村井匠, 小畑悠, 板倉健太, 佐藤翼, AI・データサイエンス論文集(4) 215-222 2023 年 11 月
- [2] Encyclopedia of Smart Agriculture Technologies, Yoshito Saito (担当:分担執筆, 範囲:Fluorescence Spectroscopy and Imaging Technologies), Springer International Publishing 2023 年 5 月 (ISBN:9783030891237)
- [3] Encyclopedia of Smart Agriculture Technologies, Keiji Konagaya, Yoshito Saito (担当:共著, 範囲:Modeling Postharvest Quality of Horticultural Products), Springer International Publishing 2023 年 2 月 (ISBN: 9783030891237)

口頭発表

- [1] カラーおよび紫外励起蛍光画像を入力とした深層学習による大豆の外部欠陥判別, 斎藤嘉人, 宮川璃空, 村井匠, 小畑悠, 板倉健太, 佐藤翼, 第 4 回 AI・データサイエンスシンポジウム 2023 年 11 月 16 日
- [2] 自家蛍光特性に基づく大豆の品種間差の評価, 斎藤嘉人, 大竹憲邦, 長谷川英夫, 農業環境工学関連学会 2023 年合同大会 2023 年 9 月 7 日
- [3] 大豆表面の欠陥種別に応じた蛍光特性の評価, 村井匠, 宮川

璃空, 小畑悠, 斎藤嘉人, 農業環境工学関連学会 2023 年合同大会 2023 年 9 月 7 日

- [4] カラー及び蛍光の画像特徴量に基づく大豆の外部欠陥の判別, 宮川璃空, 村井匠, 小畑悠, 斎藤嘉人, 農業環境工学関連学会 2023 年合同大会 2023 年 9 月 7 日

参考文献

- (1) Oerke, E.-C. : Crop losses to pests. The Journal of Agricultural Science, Vol. 144, No. 1, pp. 31–43. 2006.
- (2) Wells, M. S., Reberg-Horton, S. C., Mirsky, S. B. : Cultural Strategies for Managing Weeds and Soil Moisture in Cover Crop Based No-Till Soybean Production. Weed Science, Vol. 62, No. 3, pp. 501–511, 2014.
- (3) Bhargava, A., Bansal, A. : Fruits and vegetables quality evaluation using computer vision. A review. Journal of King Saud University-Computer and Information Sciences, Vol. 33, No. 3, pp. 243–257, 2018.
- (4) de Medeiros, A. D., Capobiango, N. P., da Silva, J. M., da Silva, L. J., da Silva, C. B. and dos Santos Dias, D. C. F. : Interactive machine learning for soybean seed and seedling quality classification. Scientific Reports, Vol. 10, pp. 11267, 2020.
- (5) Zhao, G., Quan, L., Li, H., Feng, H., Li, S., Zhang, S., Liu, R. : Real-time recognition system of soybean seed full-surface defects based on deep learning. Computers and Electronics in Agriculture, Vol. 187, pp. 106230, 2021.
- (6) Momin, M. A., Yamamoto, K., Miyamoto, M., Kondo, N., Grift, T. : Machine vision based soybean quality evaluation. Computers and Electronics in Agriculture, Vol. 140, pp. 452–460, 2017.
- (7) Hu, X., Yang, L., Zhang, Z. : Non-destructive identification of single hard seed via multispectral imaging analysis in six legume species. Plant Methods, Vol. 16, pp. 116, 2020.
- (8) Li, Y., Sun, J., Wu, X., Chen, Q., Lu, B., Dai, C. : Detection of viability of soybean seed based on fluorescence hyperspectral and CARS-SVM-AdaBoost model. Journal of Food Processing and Preservation, Vol. 43, No. 12, pp. e14238, 2019.
- (9) Barboza da Silva, C., Oliveira, N. M., de Carvalho, M. E. A., de Medeiros, A. D., de Lima Nogueira, M., dos Reis, A. R. : Autofluorescence-spectral imaging as an innovative method for rapid, non-destructive and reliable assessing of soybean seed quality. Scientific Reports, Vol. 11, pp. 17834, 2021.
- (10) Abamba Omwange, K., Saito, Y., Firmanda Al Riza, D., Zichen, H., Kuramoto, M., Shiraga, K., Ogawa, Y., Kondo, N., Suzuki, T. : Japanese dace (*Tribolodon hakonensis*) fish freshness estimation using front-face fluorescence spectroscopy coupled with chemometric analysis. Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy, Vol. 276, pp. 121209, 2022.
- (11) Huang, Z., Omwange, K. A., Tsay, L. W. J., Saito, Y., Maai, E., Yamazaki, A., Nakano, R., Nakazaki, T., Kuramoto, M., Suzuki, T., Ogawa, Y., Kondo, N. : UV excited fluorescence image-based non-destructive method for early detection of strawberry (*Fragaria × ananassa*) spoilage. Food Chemistry, Vol. 368, pp. 130776, 2021.
- (12) Huang, Z., Omwange, K. A., Saito, Y., Kuramoto, M., Kondo, N. : Monitoring strawberry (*Fragaria × ananassa*) quality changes during storage using UV-excited fluorescence imaging. Journal of Food Engineering, Vol. 353, pp. 111553, 2023.

- (1 3) Momin, Md. A., Kondo, N., Ogawa, Y., Ido, K., Ninomiya, K. :
Patterns of Fluorescence Associated with Citrus Peel Defects.
Engineering in Agriculture, Environment and Food, Vol. 6, No. 2,
pp. 54–60, 2013.
- (1 4) Itakura, K., Hata, T., Hosoi, F. : Tree Species Classification Using
Leaf and Tree Trunk Images, Proc. of the IGARSS 2020 - 2020
IEEE International Geoscience and Remote Sensing Symposium.
Presented at the IGARSS 2020, pp. 4339–4342, 2020.
- (1 5) Otsu, N. : A threshold selection method from gray-level histograms.
IEEE transactions on systems, man, and cybernetics, Vol. 9, No.1,
pp. 62–66, 1979.
- (1 6) Krizhevsky, A., Sutskever, I., Hinton, G. E. : Imagenet
classification with deep convolutional neural networks.
Communications of the ACM, Vol. 60, No. 6, pp. 84–90, 2017.
- (1 7) He, K., Zhang, X., Ren, S., Sun, J. : Deep residual learning for
image recognition, Proc. of the IEEE Conference on Computer
Vision and Pattern Recognition. pp. 770–778, 2016.
- (1 8) Tan, M., Le, Q. : EfficientNet: Rethinking Model Scaling for
Convolutional Neural Networks. Proc. of the 36th International
Conference on Machine Learning, PMLR, pp. 6105–6114, 2019.
- (1 9) Ke, R., Li, W., Cui, Z., Wang, Y. : Two-Stream Multi-Channel
Convolutional Neural Network (TM-CNN) for Multi-Lane Traffic
Speed Prediction Considering Traffic Volume Impact.
Transportation research board, Vol.2647, No. 4, 2019.
- (2 0) Dan K., Yamato Y., Imada S., Sugie M. : Estimation of Aging of
Soybean Seeds by Measurement of Delayed Fluorescence after
Irradiating with UV-excited Light. Journal of Science and High
Technology in Agriculture, Vol. 26, No. 3, pp. 154–159, 2014.
- (2 1) Sarma, D., Kavyasree, V., Bhuyan, M. K. : Two-stream fusion
model using 3D-CNN and 2D-CNN via video-frames and optical
flow motion templates for hand gesture recognition. Innovations in
Systems and Software Engineering, 2022.