

深層学習を用いたカキ栽培における灌水判断手法の開発 Development of Irrigation Decision Method for Persimmon Using Deep Learning

○岡山貴史*, 山本純之*, 木村匡臣*, 松野裕*

Atsushi Okayama, Atsushi Yamamoto, Masaomi Kimura and Yutaka Matsuno

1. はじめに 奈良県五條西吉野地域はカキの優良産地であり、国営事業により灌水設備が整備された地域である。ここでは灌漑区域内のブロックごとに灌水の順番が決められており、その時間帯のみ灌水可能なブロックローテーションが実施されている。与えられた時間帯に灌水をするか否かの判断は、農家による樹体状況、中でも特に葉の状態を俯瞰して行われることが多く、経験則に頼るところが大きい。そこで本研究では、視覚的な判断の代替として、画像識別に有効な深層学習の一種である畳み込みニューラルネットワーク(CNN)に着目し、定点カメラ画像と多様な角度からのデジタルカメラ画像の2種類の画像を用いて灌水判断の可能性を検討した。

2. 手法 対象地は奈良県五條吉野地域の造成団地の栃原I団地と平原団地内の各1圃場(栃原, 平原)とした。栽培品種は渋柿の‘刀根早生’である。2022年および2023年に各団地内に2カ所、計4台の定点カメラを設置して、灌水期である6月から9月に1時間間隔で栃原は4198枚、平原は4370枚を取得し、現地でデジタルカメラにより栃原は85枚と平原は145枚を撮影した。また、各団地内に1カ所、計2台の土壌水分センサーより体積含水率を取得した。根から葉までの水の移動時間を考量して画像取得時間の5時間前の体積含水率をpF値に変換し、鴨田(1987)における時期別好適pF範囲(4-5月:pF2.0 - 2.5, 6-8月:pF2.2 - 2.7, 9-10月:pF3.0以上)より「灌水が必要な場合」と「灌水が不必要な場合」に分類した(Table 1)。なお、9-10月の好適pF範囲の上限は初期しおれ点である3.7とした。学習モデルは3層のCNNモデルを使用した。入力項目は分類した画像を用い、出力項目は灌水必要・不必要の二値とした。最初に定点カメラ画像のみを用いて各団地と2団地混合の計3モデルを構築した。検証用データには、栃原は「灌水必要」400枚、「灌水不必要」500枚、平原では「灌水必要」560枚、「灌水不必要」620枚の画像を用い、それ以外を学習用データとした。評価には正答率とF値(式1)を用いた。F値は分類モデルの評価指標の再現率や適合率の欠点である見逃しや誤判定を考慮した指標であり、1に近いほど精度がよいことを示す。

Table 1. Classification criteria by Irrigation or not for input images.

	6-8月	9-10月
灌水必要有	$X > 2.7$	$X > 3.7$
灌水必要無	$X \leq 2.7$	$X \leq 3.7$

* X : pF values

$$F \text{ 値} = \frac{(2 \times \text{再現率} \times \text{適合率})}{(\text{再現率} + \text{適合率})} \quad (\text{式 1})$$

次に各団地の定点カメラ画像を学習させた「定点モデル」とそこにデジカメ画像を追加学習させた「定点+デジカメモデル」の2種類のモデルにおいて、デジカメ画像に対する精度を評価した。検証には分類ごとに各10枚の計20枚を用いた。

最後に Grad-CAM により特徴量画像の作成し、モデルの判断基準を確認した。

*近畿大学大学院農学研究科 Graduate School of Agriculture, Kindai University

キーワード：畑地灌漑 カキ CNN 画像

3. 結果・考察 構築した3つの定点モデルの正答率を Fig. 1 に示す。栃原では「灌水必要」と「不必要」ともに90%以上であり、F値はそれぞれ0.93, 0.94であった。平原では、「灌水必要」と「不必要」は80%以上であり、F値はそれぞれ0.87, 0.88であった。一方、2団地混合モデルの正答率は、「灌水必要」は88.1%と高かったが、「不必要」は57.1%と半分程度の正答率であり、F値はそれぞれ0.74, 0.68であった。このことから、構築したモデルは各圃場に特化したものであるため混合モデルの精度は各団地に比べ低かったと考えられる。圃場数の増加によりカキの共通な特徴を把握でき、精度向上につながるであろう。また、誤判定画像においては樹体全体を撮影した画像の割合が高かった。

次にデジカメ画像における正答率を Fig. 2 に示す。栃原では、定点モデルでは「灌水必要」は40%、「不必要」は20%であり、定点+デジカメモデルでは40%、50%であった。平原では、定点モデルでは「灌水必要」は70%、「不必要」は80%であり、定点+デジカメモデルでは「灌水必要」は60%、「不必要」は70%であった。栃原ではデジカメ画像を学習に加えた場合、精度は向上し、平原ではあまり変わらなかった。しかし、学習と検証に使用したデジタル画像は枚数が少ないため、今後のデータ収集の継続とさらなる検討が必要である。

最後に特徴量画像を用いてモデルの判断基準を確認した結果、カメラからの葉の距離が近い場合や葉の裏面を判断基準としていることが示唆された。

4. まとめ 本研究では、CNNを用いて樹体画像からの灌水判断の可能性が示唆された。特徴量画像より撮影距離が近い葉や葉の裏面を判断基準としていることが考えられ、一方、誤判定の画像では樹体全体を写したものが多かったことから、画像撮影に工夫が必要である。以上より、今後はこれらを考慮して定点カメラの設置場所の工夫やデジカメ画像を蓄積し、モデルの実用化に向けた精度の検証をしていく予定である。

参考文献：鴨田福也：果樹の施設栽培における環境制御，園芸学会シンポジウム講演要旨，pp1-8, 1987.
謝辞：生研支援センターの「戦略的スマート農業技術の開発・改良」によって実施された。

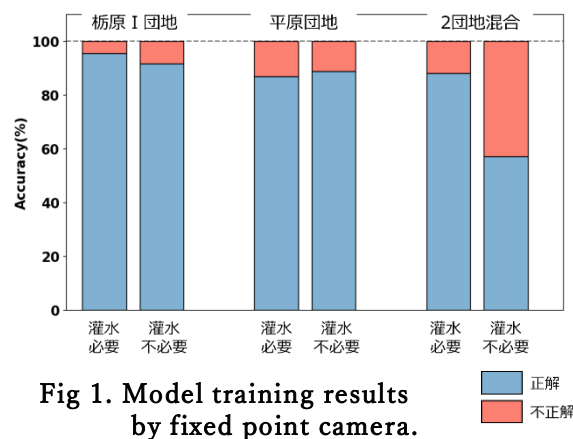


Fig. 1. Model training results by fixed point camera.




Fig. 2. Model evaluation with digital images.