

## 深層学習を用いたカキの水分ストレス状態の定量的解析の検討 Quantitative Analysis of Moisture Stress Condition of Persimmon Using Deep Learning

○岡山貴史\*, 山本純之\*, 木村匡臣\*, 片山裕貴\*, 松野裕\*

Atsushi Okayama, Atsushi Yamamoto, Masaomi Kimura, Yuki Katayama,  
and Yutaka Matsuno

1. はじめに 奈良県五條西吉野地域では、国営や県営事業として農地造成や灌漑施設の整備を通じて、営農の効率化や地域の活性化を図ってきた。その結果、現在では造成団地を中心としたカキの優良産地となっている。当地域では、灌水の順番が灌漑区域内のブロックごとに決められており、その時間帯のみ灌水可能なブロックローテーションとなっている。与えられた時間帯に灌水をするか否かの判断は、一般的に樹体状況、中でも特に葉の状態を俯瞰して行われることが多く、農家の経験と勘に頼るところが大きい。また、複数の離れた圃場を管理している農家にとっては、その移動の労力が大きな負担となっている。そこで本研究では、視覚的な判断の代替として、深層学習の一種である画像識別に有効な畳み込みニューラルネットワーク(CNN)に着目し、カキの樹体画像から灌水が必要か否かの判断と土壌水分量の把握の可能性を検討した。

2. 手法 対象地は奈良県五條西吉野地域の造成団地の栃原 I 団地と平原団地とした。対象品種は渋柿の‘刀根早生’である。各団地内に 2 カ所、計 4 台の定点カメラと 1 カ所、計 2 台の土壌水分センサーを設置し、灌水を行う期間中の 2022 年 6 月 30 日 - 10 月 6 日に 1 時間間隔で栃原 I 団地は 2544 枚、平原団地は 2538 枚の計 5082 枚の画像を取得した。つづいて、樹体が土壌中の水分を吸収するまでの時間差を考量して画像取得時間の 5 時間前の土壌水分と時期別の好適土壌水分範囲から灌水必要の有無に分類した。時期別の好適土壌水分範囲は、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)および土壌水分曲線から算出した。その際、9-10 月における好適範囲を pF3.0 から初期しおれ点である pF3.7 までとした。6-10 月の各範囲の下限值である pF2.7, 3.7 を土壌水分に変換し基準値とした。分類の基準を Table 1-a に示す。学習モデルには、畳み込み層 3 層の CNN モデルを使用した。入力項目として、分類した 2 種類の画像を用い、出力項目は灌水必要の有無の二値とした。検証用データには、灌水必要の有無において各 200 枚ずつ、各団地 400 枚の計 800 枚とし、それ以外を学習用データとした。分類モデルの評価方法には再現率と適合率があるが、再現率を重視すると誤判定が多くなり、逆に適合率を重視すると判定の

**Table 1. Classification criteria for input images**

a. Classification by irrigation required or not

	6-8月	9-10月
灌水必要有TD	$X < 29$	$X < 21.7$
灌水必要無TD	$X > 29$	$X > 21.7$
灌水必要有HD	$X < 24.1$	$X < 16.6$
灌水必要無HD	$X > 24.1$	$X > 16.6$

b. Classification by Soil Moisture Content

TD1	$X < 28$
TD2	$28 \leq X < 32$
TD3	$32 \leq X$
HD1	$X < 22$
HD2	$22 \leq X < 24$
HD3	$24 \leq X$

\* X : soil moisture content (%)

\* TD : Tochihara-danchi

\* HD : Heibara-danchi

\*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 灌水判断

見逃しが多くなる欠点がある。そこで両者のバランスを考慮した評価指標である F 値を採用した (式 1)。F 値は 1 に近いほど精度がよいことを示す。

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

次に、Table 1-b に示す基準により各団地の土壤水分を分類した。また、各基準とも学習用データと検証用データは 7:3 - 8:2 の割合で学習した。最後に特徴量を可視化し、判断の基準を確認した。

### 3. 結果・考察

灌水必要の有無における学習結果を Table 2 に示す。灌水必要の有無における検証データ各 400 枚において、灌水必要有は 380 枚、灌水必要無は 387 枚が正しく分類された。F 値は灌水必要の有と無の両方とも 0.96 であり、灌水必要の有無における分類精度は高かった。

また、土壤水分による各団地の学習結果を Table 3 に示す。栃原団地は、TD1 と TD2 では各 200 枚の検証データのうち 193 枚と 186 枚が正しく分類できており F 値も 0.9 以上である。しかし、TD3 は 40 枚のうち 22 枚と半分しか正しく分類できず、F 値も 0.7 と低かった。平原団地では、HD2 は 200 枚の検証データのうち 191 枚、HD3 は 100 枚のうち 95 枚が正しく分類され、F 値も 0.89、0.95 であった。しかし、HD1 は 100 枚のうち 65 枚しか正しく分類できず、F 値も 0.76 と低かった。学習において基準ごとの枚数に偏りがあるため、今後のデータ収集の継続とさらなる検討が必要である。

画像判断の基準を確認するため、特徴量画像を作成した。特徴量画像では葉が注目されていることはみとれるが、具体的にどのような形態的特徴が判定に影響しているのかは今後の課題である。また、画像内に空や地面などの葉以外が多く映りこんでいると判断に影響していると思われるため、今後は定点カメラの設置位置などの工夫が必要である。

### 4. まとめ

CNN を用いて樹体画像から灌水必要有無の判断と土壤水分の推定は可能であることが示されたが、葉のしおれなどの形態的特徴を判断基準としていることは明確には示されなかった。今回は定点カメラによる一定方向の画像で学習と検証を行ったため、様々な角度からの画像も使用する必要がある。また、定点カメラにおいて、葉以外が多く映らないように設置するなどの工夫をし、学習が困難な条件や判断基準などを把握していく予定である。土壤水分による分類で学習した結果、おおむね学習はできているが、枚数が少ない基準の場合は精度が低いため、学習用画像の蓄積が課題である。

Table 2. Model training results by irrigation required or not

	灌水必要有_予測	灌水必要無_予測
灌水必要有_正解	380	20
灌水必要無_正解	13	387
F値	0.96	0.96

Table 3. Model training results by Soil Moisture Content

・ Tochiyara-danchi

	TD1_予測	TD2_予測	TD3_予測
TD1_正解	193	7	0
TD2_正解	13	186	1
TD3_正解	1	17	22
F値	0.95	0.91	0.70

・ Heibara-danchi

	HD1_予測	HD2_予測	HD3_予測
HD1_正解	65	31	4
HD2_正解	7	191	2
HD3_正解	0	5	95
F値	0.76	0.89	0.95