

Klasifikasi Kematangan Daun Selada Berdasarkan Fitur Warna Menggunakan *K-Nearest Neighbors*

Ananta Dwi Prayoga Alwy
Universitas Negeri Makassar
Makassar, Indonesia
ananta.alwy01@gmail.com

Fhatiah Adiba
Universitas Negeri Makassar

Makassar, Indonesia
adibahfatiah@unm.ac.id
Bukhari Naufal Nur Ag
Universitas Negeri Makassar
Makassar, Indonesia
bukhari.asrullah@gmail.com

Andi Baso Kaswar
Universitas Negeri Makassar
Makassar, Indonesia
a.baso.kaswar@unm.ac.id
Silvia Andriani
Universitas Negeri Makassar
Makassar, Indonesia
silviandriani12@gmail.com

Abstract— Selada adalah salah satu jenis daun sayur yang paling banyak dibudayakan. Daun Memiliki ciri khas warnanya masing-masing. Daun sendiri akan mengalami perubahan warna ketika sudah matang atau memasuki masa panennya. Berdasarkan perbedaan warna ini petani atau masyarakat yang menanam tanam selada melakukan panen. Namun, Cara ini memiliki kekurangan karena mata manusia memiliki keterbatasan dalam membedakan warna sehingga selada yang dipanen terkadang masih belum masanya atau sudah melewati masa panennya. Maka dari itu dibuatlah suatu sistem pengolahan citra digital untuk dapat mengklasifikasikan kematangan daun selada dengan metode dan proses yang tepat. Penelitian ini mengusulkan Klasifikasi Kematangan Daun Selada Berdasarkan Fitur Warna Menggunakan *K-Nearest Neighbor*. Dalam Penelitian ini digunakan 40 citra latih dan 20 citra uji daun selada. Proses dan Metode yang diusulkan yaitu, akuisisi citra, preprocessing, segmentasi dengan metode thresholding dan operasi morfologi, dan terakhir tahap klasifikasi dengan *K-Nearest Neighbor*. Berdasarkan hasil pengujian, diperoleh tingkat akurasi sebesar 95%. Diharapkan sistem ini dapat membantu petani selada dan dapat menjadi standar untuk menciptakan sistem yang lebih baik.

Kata kunci — Citra, *K-Nearest Neighbors*, Selada, Warna

I. PENDAHULUAN

Selada adalah tanaman yang masuk ke dalam famili *Compositae*. Selada sendiri merupakan sayuran yang populer karena sering dikonsumsi sebagai pelengkap makanan karena memiliki warna, tekstur, dan aroma yang menyegarkan. Dalam proses pemanenan tanaman selada dilakukan dengan cara membedakan warna daunnya atau dengan mencicipi langsung daun seladanya[1]. Selada sendiri merupakan salah satu jenis daun yang paling banyak dipilih untuk dibudidayakan untuk dikonsumsi. Dengan meningkatnya tingkat budidaya selada, maka diperlukan metode yang dapat membantu proses budidaya daun selada.

Objek dapat dikenali dan diidentifikasi dengan benar berdasarkan warnanya. Ketika melihat berbagai objek manusia dapat membedakannya dengan cara membedakan warna objek. Pada umumnya kematangan daun selada ditentukan oleh warna, usia, atau ukurannya. Namun, mendeteksi kematangan daun selada dengan cara membedakan warna-nya secara langsung masih belum akurat dikarenakan terkadang warna daun yang dilihat itu serupa tapi sebenarnya berbeda warna. Cara lain yang sering digunakan untuk mendeteksi kematangan selada yaitu dengan cara mencicipi langsung daun selada. Namun, cara ini akan merusak daun selada. Dari permasalahan yang telah dibahas, maka dibutuhkan suatu sistem dimana citra daun selada dapat diolah dengan metode *image processing* untuk mengetahui kematangan daun selada tanpa harus mengurangi kualitasnya.

Penelitian sistem penentuan kematangan selada dengan menggunakan berbagai metode pengolahan citra telah banyak dilakukan seperti, Penelitian mengenai Sistem Deteksi Kondisi Daun Selada Berdasarkan Citra Menggunakan Metode *Convolutional Neural Network* (CNN) berdasarkan warna daun dari kuning hingga cokelat. Dalam penelitian data latih dan data uji memiliki akurasi sebesar 90% dan 10% ini dikarenakan peneliti tidak melakukan proses segmentasi dan melakukan klasifikasi secara langsung[2]. Selanjutnya, penelitian mengenai Deteksi Kematangan Daun Selada (*Lactuca Sativa L*) Berbasis Android Menggunakan Nilai RGB Citra yang membagi tingkat kematangan daun selada menjadi tiga yakni belum matang, matang dan terlalu matang. Penelitian ini menggunakan metode *Color Blob Detection* dengan hasil akurasi sebesar 82% pada jarak 20 cm, 78% pada jarak 15 cm, dan 80% pada jarak 10 cm. Variasi akurasi ini terjadi karena adanya perbedaan cahaya yang ditangkap oleh kamera[1].

Terdapat juga penelitian yang menggunakan metode *K-Nearest Neighbor* sebagai klasifikasinya seperti pada penelitian yang berjudul Seleksi Pegawai dan Dosen UMRI Berbasis *E-Recruitment* Menggunakan Metode *K-Nearest Neighbors*. Dalam penelitian ini pelamar yang memiliki tingkat nilai kemiripan $\geq 80\%$ yang akan diikutsertakan pada tes berikutnya[3]. Kemudian, ada juga penelitian yang menggunakan K-NN untuk mengklasifikasi efektivitas penjualan vape pada “Lombok Vape On”[4]. Dalam penelitian ini didapatkan tingkat akurasi sebesar 86.48% dan AUC sebesar 0.874[4].


Dari beberapa penelitian di atas, nilai akurasi klasifikasi semakin tidak akurat karena metode dan prosedur yang tidak tepat, dan dimungkinkan untuk mengklasifikasikan kematangan daun selada menggunakan metode data mining yang dikombinasikan dengan pengolahan citra digital. Dasar karakteristik warna dengan metode dan prosedur preprocessing citra yang tepat. Hal ini memungkinkan produsen untuk membedakan tingkat kematangan dengan lebih akurat.

Pada penelitian ini, kami mengusulkan klasifikasi kematangan daun selada berdasarkan fitur warna menggunakan *K-Nearest Neighbors*. Klasifikasi tingkat kematangan terdiri dari 2 tingkat kematangan yaitu matang dan belum matang. Metode yang diusulkan dengan 5 tahap yaitu, akuisisi citra, preprocessing citra, segmentasi dengan metode thresholding pada ruang warna LAB, operasi morfologi, ekstraksi warna RGB Objek Citra, dan Klasifikasi dengan *K-Nearest Neighbors*.

Adapun tujuan penelitian ini adalah untuk mengembangkan teknik budidaya tanaman Selada, meningkatkan produktivitas dengan menggunakan metode *K-Nearest Neighbors* terkait pengolahan citra digital, dan mempermudah petani dalam mengklasifikasikan kematangan daun selada.

II. METODOLOGI PENELITIAN


Penelitian ini memiliki metode yang terdiri dari tiga tahapan utama dalam akuisisi citra: preprocessing, segmentasi, dan klasifikasi. Pada fase preprocessing diterapkan operasi transformasi citra ke warna CIELAB, tahapan segmentasi dengan metode Thresholding pada ruang warna LAB, Operasi morfologi dengan menerapkan dilasi, erosi, *closing*, *filling holes*, dan *area open*, kemudian menggunakan *K-Nearest Neighbors* untuk tahap klasifikasinya.



Gambar 1 Bagan Tahap Klasifikasi

A. Akuisisi Citra

Pada tahapan pengumpulan data dilakukan metode akuisisi citra dengan mengambil citra analog yang diubah menjadi citra digital oleh kamera. Pada proses tersebut, digunakan kamera DSLR dengan jarak kamera ke objek setinggi 30 cm. Pengaturan kamera yang digunakan sebagai berikut: resolusi 1980x1080, iso 1600, shutter speed 25, Kemudian sebagai background menggunakan kain hitam, dan meja yang memiliki tinggi 30cm. Proses akuisisi citra dapat dilihat pada Gambar 2.



Gambar 2 Akuisisi Citra



Gambar 3 Daun Selada

B. Preprocessing

Preprocessing dimulai dengan membaca dataset citra selada dengan menggunakan 2 tingkat kematangan yaitu matang dan belum matang yang dibagi menjadi data latih dengan masing-masing tingkat kematangan sebanyak 20 citra dan data uji dengan 10 citra pada masing-masing tingkat kematangan dengan *background* berwarna hitam pada masing-masing citra.

C. Konversi Citra RGB ke LAB

Tahap selanjutnya dengan mengkonversikan citra berwarna RGB ke citra dengan ruang warna LAB untuk mendapatkan range warna hijau daun selada. Konversi warna RGB ke warna LAB menggunakan konversi warna RGB ke XYZ dengan (1).

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 0.607 & 0.174 & 0.200 \\ 0.299 & 0.587 & 0.114 \\ 0.00 & 0.066 & 1.116 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (1)$$

Konversi warna XYZ ke LAB dapat menggunakan (2-6) :

$$L^* = 116 (Y/Y_n)^{1/3} - 16, \text{ for } Y/Y_n > 0.008856 \quad (2)$$


$$L^* = 903.3 Y/Y_n, \text{ for another } Y/Y_n > 0.008856 \quad (3)$$

$$a^* = 500 (f(X/X_n) - f(Y/Y_n)) \quad (4)$$


$$b^* = 200 (f(Y/Y_n) - f(Z/Z_n)) \quad (5)$$

$$f(x) = \begin{cases} x^{\frac{1}{3}} & x > 0.008856 \\ 7.787x + \frac{16}{116} & x \leq 0.008856 \end{cases} \quad (6)$$

Ruang Warna LAB adalah ruang warna yang hanya dapat digambarkan dalam ruang tiga dimensi. Dimana irisan komponen L merepresentasikan *Luminance* Gambar dan komponen A dan B merepresentasikan warna *Chromatic*. Berdasarkan Gambar, dapat dilihat bahwa sumbu L^* merepresentasikan kecerahan dengan nilai 0(gelap) ke 100(cerah). $+A^*$ adalah sumbu merah, $-A^*$ adalah sumbu hijau, $+B^*$ adalah sumbu kuning, dan $-B^*$ adalah sumbu biru(Setyawan dkk., 2018).



Gambar 4 Ruang Warna LAB




Gambar 5 Hasil Konversi Citra ke LAB

D. Segmentasi Citra

Proses segmentasi citra dilakukan dengan menggunakan metode thresholding. Dimana citra LAB pada sumbu warna chromatic B akan diolah pada tahap segmentasi ini. Berdasarkan warna pada sumbu B inilah kemudian dilakukan metode Otsu Thresholding.

1) Ekstraksi Komponen B dari Citra LAB

Tahapan awal dari segmentasi citra adalah dengan mengekstrak komponen warna B dari citra LAB. Komponen B ini dipilih karena melambangkan warna hijau pada daun selada. Hasil ekstraksi komponen B ini sudah memiliki warna citra biner. Citra dibawah memperlihatkan komponen B pada citra LAB daun selada.




Gambar 6 Hasil Konversi Citra ke LAB

2) Thresholding Terhadap Komponen B

Thresholding adalah teknik segmentasi citra yang memisahkan objek dari latar belakang suatu citra berdasarkan perbedaan gelap-terangnya. Area citra yang cenderung gelap dibuat lebih gelap (hitam sempurna dengan nilai intensitas 0), dan area citra yang cenderung lebih terang dibuat lebih terang (putih ideal dengan nilai intensitas 1). Oleh karena itu, hasil dari proses segmentasi thresholding adalah citra biner dengan nilai intensitas piksel 0 atau 1. Setelah citra tersegmentasi atau objek telah berhasil dipisahkan dari latar belakang, citra biner yang dihasilkan dapat digunakan. Gunakan sebagai *mask* untuk proses *cropping* agar citra aslinya keluar tanpa background atau dengan background yang bisa diubah-ubah[5].

$$f_0(x, y) = \begin{cases} T1, f_1(x, y) \leq T1 \\ T2, f_2(x, y) \leq T2 \\ T3, f_3(x, y) \leq T3 \end{cases} \quad (7)$$

Pada (7) digunakan untuk melakukan *thresholding* dengan $f_0(x, y)$ adalah citra threshold dan T sebagai nilai pemetaan Pixel. Citra di bawah memperlihatkan hasil *thresholding* terhadap komponen B.



Gambar 7 Hasil Thresholding

E. Operasi Morfologi


Hasil segmentasi yang telah dilakukan masih belum sempurna masih terdapat darau yang dapat mengganggu hasil klasifikasi. Sehingga perlu dilakukan penghilangan darau dengan menggunakan operasi morfologi. Dilasi, erosi, *closing*, *filling holes*, dan *area open* akan digunakan dalam operasi morfologi penelitian ini.

1) Erosi

Erosi adalah salah satu dari dua bentuk dasar pencitraan selain pelebaran(dilasi). Operasi erosi, seperti pelebaran, dilakukan dalam biner. Erosi akan menyebabkan objek pada citra menipis atau terkikis[6]. Jika X dan B himpunan dalam Z , erosi X oleh B dinyatakan dengan $X \ominus B$, didefinisikan sebagai:

$$X \ominus B = \{ z \mid \bigvee (B_z) \subseteq X \} \quad (8)$$

Pada persamaan (8) menunjukkan bahwa erosi X oleh B adalah kumpulan semua titik dimana B ditranslasikan oleh Z di dalam isi X .



Gambar 8 Operasi Erosi

2) Closing

Penutupan atau Closing adalah kombinasi di mana citra terkikis setelah menjalani operasi yang diperpanjang. Penutupan juga cenderung memperhalus objek dalam citra, tetapi mereka menggabungkan sekering (putus rapat dan celah tipis) untuk menghilangkan lubang kecil pada objek. operasi closing adalah (X) oleh (B) adalah dilasi (X) oleh (B) , di ikuti erosi hasilnya dengan (B) . Operasi *Closing* tersebut dinyatakan dengan rumus.

$$X \circ B = (X \oplus B) \ominus B \quad (9)$$

Persamaan (9) menunjukkan operasi closing, terlihat bahwa set X terlebih dahulu di dilasi oleh B , kemudian dilanjutkan dengan melakukan erosi ke proses tersebut. *Closing* akan menghapus area yang berlubang kecil pada citra. Perhatikan pada Gambar 9.



Gambar 9 Operasi Closing

3) Filling Holes & Area Open

Filling Holes adalah operasi yang mengisi seluruh region dengan nilai 1. *Area Open* adalah kombinasi proses di mana citra digital mengembang mengikuti operasi erosi. Proses pembukaan citra memiliki efek menghaluskan batas-batas objek, memisahkan objek yang digabungkan sebelumnya, dan menghilangkan objek yang lebih kecil dari ukuran terstruktur. Operasi *Area Open* dinyatakan dengan rumus.

$$X \circ B = (X \ominus B) \oplus B \quad (10)$$

Dari persamaan (10) menunjukkan, operasi opening pada set X mengalami operasi erosi lebih dulu, kemudian dilanjutkan dengan operasi dilasi. Bisa terlihat pada Gambar 10, opening akan menghilangkan objek yang kecil seperti pada Gambar 10.



Gambar 10 Operasi Filling Holes & Area Open

F. Ekstraksi Ciri

Citra yang telah melalui proses segmentasi dan morfologi akan diekstrak fitur warna objek pada citranya. Warna objek yang akan diekstrak adalah komponen warna Red, Green, Blue. Adapun Rumus yang digunakan sebagai berikut:

$$Z = \frac{\sum X}{\sum Y} \quad (11)$$

Rumus untuk mendapatkan nilai warna dapat dilihat pada persamaan (11) Dimana Z diperoleh dari hasil pembagian jumlah nilai *channel* warna(Red/Green/Blue) pada citra asli(X) dan jumlah nilai *channel* warna(Red/Green/Blue) objek pada Gambar yang telah disegmentasi.

G. Klasifikasi K-Nearest Neighbors

Algoritma *K-Nearest Neighbor* (KNN) merupakan metode yang mengklasifikasikan data yang saling berdekatan dengannya berdasarkan data latih[7]. K-Nearest Neighbors (KNN) bekerja dengan cara mengelompokkan data citra uji ke dalam kelas dengan anggota paling banyak. Prinsip operasi dari algoritma ini adalah mencari jarak minimum antara data yang di evaluasi di sekitar K (*neighborhood*). Tujuan dari algoritma ini adalah untuk mengklasifikasikan objek baru berdasarkan atribut dan pola dari data latih. KNN menggunakan *environment classifier* sebagai prediktor nilai versi baru berdasarkan atribut yang dibutuhkan untuk setiap survei. Atribut yang dipilih akan digunakan sebagai parameter untuk mendefinisikan kelas. KNN didasarkan pada interval minimum antara data baru dan data sampel pelatihan. Cari tetangga terdekat dari K. Kemudian dapatkan nilai mayoritas sebagai hasil prediksi Tanggal baru[8].


$$D(a,b) = \sqrt{\sum_{k=1}^d (a_k - b_k)^2} \quad (12)$$

Persamaan (12) metode KNN menggunakan persamaan jarak *Euclidean*. Jarak *Euclidean* juga seharusnya dikategorikan berdasarkan jarak antara dataset dan dataset lainnya. Ada banyak cara untuk mengukur jarak terdekat untuk menghitung jarak, bukan hanya jarak *Euclidean*. Namun, dalam kebanyakan kasus jarak *Euclidean* digunakan.

III. HASIL & PEMBAHASAN

Pada penelitian ini terdapat 2 dataset yang terdiri dari data latih dan data uji. Data latih terdiri dari 40 citra yang terdiri dari 20 citra selada matang dan 20 citra selada belum matang. Kemudian, data uji memiliki 20 citra selada dengan masing-masing 10, selada matang sebanyak 10 citra dan selada belum matang sebesar 10 citra. Citra setiap dataset berupa citra digital berukuran 1920px x 1080px.

Pada Gambar 11 ditampilkan *GUI* Klasifikasi selada dengan menampilkan hasil dari tahap yang dimana diawali dengan memilih citra yang ingin diuji dengan tombol buka citra lalu *GUI* akan menampilkan hasil dari setiap tahap. Tahap yang ditampilkan pada *GUI* yaitu, *input* citra, citra LAB, *thresholding*, *erosi*, *closing*, *filling hole*, *area open*, nilai mean RGB citra, dan hasil klasifikasi.




Gambar 11 Tampilan GUI Klasifikasi Selada

Langkah awal yang dilakukan adalah dengan melakukan penginputan citra daun selada dengan menekan tombol “*Open File*”. Setelah citra diinput maka citra akan ditampilkan seperti pada Gambar 12. Kemudian untuk melakukan proses klasifikasi dilakukan dengan menekan tombol “*Proses Citra*”.



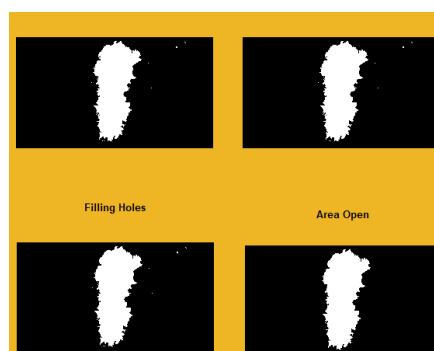
Gambar 12 Tampilan Citra Asli, Nilai RGB & Status citra

Pada Gambar 13 menampilkan hasil proses berupa tampilan citra LAB dari citra asli dan segmentasi Otsu *Thresholding* untuk memisahkan antara objek dengan *background* dalam suatu citra berdasarkan tingkat kecerahannya atau gelap terangnya.



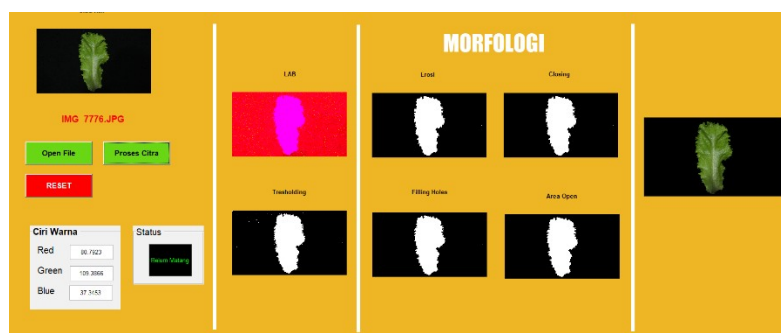
Gambar 13 Tampilan citra LAB dan hasil segmentasi Thresholding

Dengan operasi morfologi erosi, closing, filling hole dan area open menghasilkan area objek dan *background* yang lebih akurat seperti pada Gambar 14. Pada area objek akan ekstrak nilai warna RGB untuk diklasifikasikan.



Gambar 14 Operasi Morfologi Citra

Setelah nilai fitur warna RGB pada objek yang telah melalui proses segmentasi, selanjutnya akan dilakukan proses klasifikasi menggunakan *K-Nearest Neighbor*. Model *K-Nearest Neighbor* yang digunakan dibuat berdasarkan 40 data latih yang terdiri dari 20 citra selada matang dan 20 citra selada belum matang. Hasil klasifikasi terbagi menjadi kelas matang dan kelas belum matang. Hasil klasifikasi pada GUI sebagai berikut.



Gambar 15 Hasil Klasifikasi

Pengujian dilakukan dengan menggunakan 20 data citra yang terdiri dari 10 citra selada matang dan 10 citra selada belum matang. Tabel 1 dan Tabel 2 di bawah menampilkan ekstraksi fitur dan hasil klasifikasi pada kelas matang dan belum matang.

Tabel 1 Hasil Ekstraksi Fitur Matang

Red	Green	Blue	Kelas	Hasil Uji
93.605	112.245	36.523	Matang	Matang
98.406	119.246	37.173	Matang	Matang
98.082	118.391	31.698	Matang	Matang
87.996	112.144	37.012	Matang	Matang
82.983	106.176	32.919	Matang	Matang
88.306	111.017	35.721	Matang	Matang
90.852	113.594	39.187	Matang	Matang
102.411	122.064	44.471	Matang	Matang
90.853	113.781	34.381	Matang	Matang
95.735	120.992	42.343	Matang	Matang

Tabel 2 Hasil Ekstraksi Fitur Belum Matang

Red	Green	Blue	Kelas	Hasil Uji
80.792	109.387	37.345	Belum Matang	Belum Matang
65.403	93.187	27.368	Belum Matang	Belum Matang
56.850	80.760	23.704	Belum Matang	Belum Matang

85.685	114.174	37.768	Belum Matang	Matang
69.588	96.613	30.975	Belum Matang	Belum Matang
69.985	98.449	31.719	Belum Matang	Belum Matang
65.282	95.694	27.703	Belum Matang	Belum Matang
65.331	91.310	28.596	Belum Matang	Belum Matang
77.194	104.517	34.287	Belum Matang	Belum Matang
85.187	113.224	44.227	Belum Matang	Belum Matang

Berdasarkan hasil klasifikasi citra selada yang ditunjukkan pada Tabel 1 dan 2, dapat dihitung tingkat akurasinya dengan menggunakan rumus. Dimana a adalah akurasi, x adalah citra yang kematangannya sesuai dan z adalah jumlah data citra keseluruhan.

$$A = \frac{x}{z} \times 100 \quad (13)$$

Tabel 3 Hasil Klasifikasi

Klasifikasi	Hasil Klasifikasi Jumlah			Akurasi (A)
	Citra	Sesuai (x)	Error (z)	
Matang	10	10	0	
Belum Matang	10	9	1	
Total	20	19	1	95%

Dari Tabel 3 di atas dapat dilihat bahwa terdapat 1 citra pada data uji yang tidak sesuai dengan data aslinya. Citra tersebut adalah data citra belum matang yang ketika citra tersebut dilakukan proses klasifikasi terdeteksi sebagai daun selada matang. Hal ini dapat terjadi karena nilai atribut pada data citra tersebut mendekati nilai atribut data citra matang. Sehingga pada proses klasifikasi data citra tersebut dimasukkan ke dalam kelompok matang.

IV. KESIMPULAN

Berdasarkan penelitian dengan judul Klasifikasi Kematangan Daun Selada Berdasarkan Fitur Warna Menggunakan *K-Nearest Neighbors*, dapat ditarik beberapa kesimpulan sebagai berikut:

1. *K-Nearest Neighbor* memanfaatkan data training untuk menghasilkan probabilitas setiap kriteria untuk class yang berbeda, sehingga nilai-nilai probabilitas dari kriteria tersebut dapat dioptimalkan untuk memprediksi penggunaan listrik berdasarkan proses klasifikasi yang dilakukan oleh metode *K-Nearest Neighbor* itu sendiri.
2. Dalam penelitian ini kami menggunakan 60 dataset citra yang dibagi menjadi 40 data latih dan 20 data uji. Berdasarkan hasil uji dengan menggunakan metode *K-Nearest Neighbor* didapatkan akurasi pengujian sebesar 98%.

DAFTAR PUSTAKA

- [1] K. D. Septiaji dan K. Firdausy, "Deteksi Kematangan Daun Selada (*Lactuca Sativa* L) Berbasis Android Menggunakan Nilai RGB Citra," *Jurnal Ilmiah Teknik Elektro Komputer dan Informatika*, vol. 4, no. 1, hlm. 20, Jun 2018, doi: 10.26555/jiteki.v4i1.8994.
- [2] F. R. Megantara dan D. Y. Purwanto, "DETEKSI KONDISI TANAMAN SELADA BERDASARKAN CITRA MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK (CNN)," hlm. 9.
- [3] D. Winarso dan E. Edo Arribé, "Seleksi Pegawai dan Dosen UMRI Berbasis E-Recruitment Menggunakan Metode *K-Nearest Neighbor*," *Digitalzone*, vol. 8, no. 2, hlm. 71–80, Nov 2017, doi: 10.31849/digitalzone.v8i2.631.
- [4] Universitas Hamzanwadi, Y. Yahya, W. Puspita Hidayanti, dan Universitas Hamzanwadi, "Penerapan Algoritma *K-Nearest Neighbor* Untuk Klasifikasi Efektivitas Penjualan Vape (Rokok Elektrik) pada 'Lombok Vape On,'" *JIT*, vol. 3, no. 2, hlm. 104–114, Agu 2020, doi: 10.29408/jit.v3i2.2279.

- [5] I. Setiawan, W. Dewanta, H. A. Nugroho, dan H. Supriyono, "Pengolah Citra Dengan Metode Thresholding Dengan Matlab R2014A," *J. n.a Infotama*, vol. 15, no. 2, Okt 2019, doi: 10.37676/jmi.v15i2.868.
- [6] M. R. Nugroho, "OPERASI MORFOLOGI CITRA DENGAN MATLAB," hlm. 6.
- [7] W. Yustanti, "Algoritma K-Nearest Neighbour untuk Memprediksi Harga Jual Tanah," hlm. 12.
- [8] R. Rahmadiano, E. Mulyanto, dan T. Sutojo, "Implementasi Pengolahan Citra dan Klasifikasi *K-Nearest Neighbor* untuk Mendeteksi Kualitas Telur Ayam," hlm. 10.