

Klasifikasi Jenis Kelengkeng Berdasarkan Morfologi Daun Dengan Ekstraksi Ciri RGB, *GLCM*, dan Bentuk Menggunakan Metode BPNN

Mohammad Waail Al Wajieh¹, Bayuda Luqman Alfarisi²

¹ Teknologi Informasi, Fakultas Teknik, Universitas Annuqayah

² Biologi, Fakultas MIPA, Universitas Annuqayah

¹wail.aw@ua.ac.id, ²biobayy@gmail.com

ABSTRAK

Buah Kelengkeng mudah ditemukan di beberapa daerah di Indonesia. Kultivar buah Kelengkeng sangat banyak dan memiliki karakteristik pada morfologinya, termasuk karakteristik daunnya. Banyaknya jenis buah Kelengkeng ini menyulitkan konsumen dalam menentukan jenis buah kelengkeng yang diminati. Selain itu, keberagaman jenis buah Kelengkeng ini juga berpengaruh terhadap petani dalam menentukan harga jual karena terdapat perbedaan yang signifikan pada beberapa jenis Kelengkeng. Penelitian ini bertujuan untuk mengklasifikasi kultivar buah Kelengkeng berdasarkan morfologi daun. Jenis buah Kelengkeng yang digunakan dalam penelitian ini berjumlah 4 jenis, di mana masing-masing jenis menggunakan 20 helai daun. Resolusi citra yang digunakan adalah 433 x 577 piksel. Lokasi pengambilan data dilakukan di Kota Semarang, Jawa Tengah. Metode yang digunakan adalah ekstraksi fitur warna RGB, Grey Level Co-occurrence Matrix (GLCM), dan fitur Bentuk untuk mendapatkan nilai dari setiap kultivar. Selanjutnya, nilai tersebut diolah dengan menggunakan algoritma Back-Propagation Neural Network (BPNN) untuk memperoleh nilai akurasi yang digunakan sebagai penentu klasifikasi gambar daun Kelengkeng. Parameter *metric* dan *eccentricity* digunakan sebagai pendukung algoritma. Hasil pengujian dengan algoritma BPNN memperoleh akurasi sebesar 95%, menunjukkan bahwa algoritma BPNN dapat digunakan untuk mengklasifikasikan jenis daun buah Kelengkeng.

Kata kunci: *Back-Propagation Neural Network; Bentuk; GLCM; Kelengkeng; Pengolahan Citra; RGB*

ABSTRACT

Longan fruit is easily found in several regions in Indonesia. Longan fruit cultivars are numerous and have morphological characteristics, including leaf characteristics. The large number of types of longan fruit makes it difficult for consumers to determine the type of longan fruit that is in demand. In addition, the diversity of longan fruit types also affects farmers in determining selling prices because there are significant differences in several types of longans. This study aims to classify Longan fruit cultivars based on leaf morphology. The types of longan fruit used in this study amounted to 4 types, where each type used 20 leaves. The image resolution used is 433 x 577 pixel. The location of data collection was carried out in Semarang City, Central Java. The methods used are RGB color feature extraction, Grey Level Co-occurrence Matrix (GLCM), and Shape features to obtain values from each cultivar. Furthermore, the value is processed using the Back-Propagation Neural Network (BPNN) algorithm to obtain an accuracy value that is used as a determinant of longan leaf image classification. Metric and eccentricity parameters are used to support the algorithm. The results of testing with the BPNN algorithm obtained an accuracy of 95%, indicating that the BPNN algorithm can be used to classify the type of Longan fruit leaves.

Keywords: *Back-Propagation Neural Network; GLCM; Image Processing; Longan; RGB; Shape*

1. PENDAHULUAN

Heterogen tanaman buah di Nusantara adalah kekayaan alam yang patut disyukuri. Satu jenis buah bisa memiliki beberapa kultivar dengan ciri khas masing-masing. Salah satu buah yang memiliki banyak kultivar adalah buah Kelengkeng atau Kelengkeng. Buah Kelengkeng atau dalam bahasa ilmiah *Dimocarpus longan Lour*, adalah buah yang asalnya dari dataran rendah di barat daya India, dataran Cina dan Burma [1].

Menurut penelitian yang dilakukan oleh T. Prawitasari, Buah Kelengkeng memiliki beberapa jenis ukuran buah, warna kulit buah dan morfologi daun pada beberapa kultivarnya. Buah Kelengkeng, (*Dimocarpus Longan Lour*), adalah pohon buah tropis dari keluarga soapberry (*Sapindaceae*) sejenis buah-buahan gemuk-putih yang lezat seperti leci dan umumnya dijual segar, kering, atau kaleng dalam sirup. Dagingnya yang lezat memiliki rasa manis, sehingga banyak dibudidayakan. Buah Kelengkeng yang dibudidayakan di Nusantara terdapat dua jenis, yaitu buah Kelengkeng lokal dan buah Kelengkeng introduksi. Buah Kelengkeng lokal memiliki beberapa kultivar, diantaranya Kelengkeng jenis batu dan Kelengkeng jenis kopyor [2].

Keberagaman jenis buah Kelengkeng ini menyulitkan konsumen dalam membedakan jenisnya sehingga tidak dapat mengidentifikasi secara langsung jika ada jenis buah Kelengkeng yang disukai, baik sebagai buah konsumsi atau sebagai tanaman koleksi. Selain itu, sulitnya mendeteksi jenis buah kelengkeng juga berpengaruh terhadap penentuan harga jual oleh petani. Hal ini dikarenakan terdapat perbedaan harga yang cukup signifikan antara jenis buah Kelengkeng. Untuk dapat mengklasifikasikan kultivar buah Kelengkeng, dilakukan penelitian yang berfokus pada metode pengolahan citra digital dengan menjadikan daun Kelengkeng sebagai objek utama penelitian.

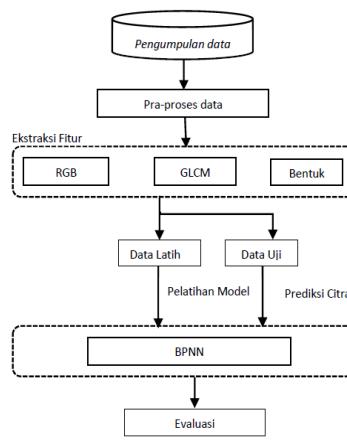
Berdasarkan penelitian yang dilakukan oleh P. K. Groom, ekstraksi fitur pada daun merupakan studi yang tidak mudah. Sehingga, studi dalam bidang ini adalah hal yang menarik untuk dikaji. Dalam pengelompokan tanaman, telah dilakukan beberapa penelitian menurut penggambaran ilmu botani [3]. Pengidentifikasiannya jenis daun akan ideal jika menggunakan faktor bentuk berdimensi tak sederhana dengan analisis citra, menurut penelitian H. Tsukaya [4]. Penelitian oleh S. Sutarno, dkk. [5] menjelaskan bahwa daun merupakan bagian utama dari sebuah tanaman, sehingga pembahasan tentang pengembangan mekanisme kontrol penentuan bentuk daun menjadi penting untuk menentukan jenis dan kondisi tanaman. Penelitian tentang pengolahan citra digital pada sebuah objek merupakan topik yang telah banyak dibahas. Beberapa penelitian tentang pengolahan citra digital menunjukkan bahwa identifikasi dan klasifikasi objek dapat dilakukan dengan satu atau kombinasi beberapa metode. Penelitian ini menggunakan beberapa metode untuk memperoleh nilai pada masing-masing atribut dan menghitung tingkat akurasinya. Salah satunya adalah penelitian yang dilakukan oleh C. Sri Kusuma Aditya, dkk., implementasi fitur *Gray Level Co-occurrence Matrix* (GLCM), dimana fitur ini memiliki performa yang tinggi jika dibandingkan dengan fitur lain [6]. Penelitian selanjutnya oleh C. W. D. de Almeida, dkk. [7] menunjukkan bahwa perpaduan antara GLCM, RGB, dan Neural Network memiliki tingkat akurasi yang sangat baik dibandingkan hanya menggunakan satu fitur saja. Penelitian yang dilakukan oleh A. Minarno dan N. Suciati [8] juga menunjukkan akurasi yang sangat baik dari penggunaan GLCM, yaitu menunjukkan deskripsi tekstur yang lebih efektif dalam mengenali pola pada sebuah objek. Kemudian penelitian oleh H. Syahputra dan A. Harjoko [9] tentang klasifikasi buah Kelengkeng berdasarkan morfologi daun menggunakan metode *Back-Propagation Network* menghasilkan akurasi yang cukup baik, yaitu 46.154. Tingkat akurasi ini disebabkan oleh kurangnya fitur pendekripsi citra, sehingga pada penelitian ini ditambahkan kombinasi fitur untuk meningkatkan tingkat akurasi. Selain itu, penggunaan fitur RGB pada penelitian yang dilakukan oleh I. Jamaliah, dkk. [10] menghasilkan akurasi rata-rata 72% dalam mengidentifikasi jenis daun pada tanaman. Akurasi ini cukup tinggi, meskipun alat yang digunakan pada proses akuisisi data kurang memadai. Penggunaan fitur bentuk pada penelitian yang ditulis oleh F. Y. Manik [11], menghasilkan akurasi 87,5% meskipun beberapa atribut tidak dapat dijadikan sebagai penciri. Hal ini, dikarenakan atribut pada fitur bentuk tidak dapat mengidentifikasi ciri tertentu jika sebarannya merata. Penelitian selanjutnya dilakukan oleh M. Benco, dkk. [12] menunjukkan bahwa penggunaan fitur

GLCM dapat mendeteksi hingga 90% dalam klasifikasi tekstur warna. Pemilihan fitur GLCM pada penelitian yang dilakukan oleh D. P. Patil, dkk. [13] karena fitur ini tidak sulit untuk diterapkan dalam mendeteksi hubungan antar piksel. Penelitian dilakukan oleh J. Jamaludin, dkk. untuk mengklasifikasi jenis buah dengan metode BPNN menggunakan model trainlm dan traingdx menghasilkan akurasi yang sangat baik, dimana pada model trainlm akurasinya mencapai 100%, dan pada model traingdx mencapai 96,05 % [14]. Penelitian yang dilakukan oleh A. H. Tandrian dan A. Kusnadi [15] berkaitan dengan morfologi daun, dimana ukuran daun memegang peranan penting yang mempengaruhi hasil akhir. Hal ini menjadi dasar bahwa identifikasi jenis buah dapat dilakukan berdasarkan morfologi daun. Pada jenis tanaman lain, penggunaan morfologi daun sebagai pengidentifikasi jenis buah juga berhasil dilakukan dengan tingkat akurasi cukup baik, berdasarkan penelitian yang dilakukan oleh K. Syaban dan A. Harjoko [16].

Implementasi metode *Back-Propagation Neural Network* (BPNN) pada beberapa penelitian menunjukkan tingkat keberhasilan yang baik. Penelitian yang dilakukan oleh F. A. Hizham, dkk. [17] dengan menggunakan BPNN, diperoleh akurasi sebesar 98,82%. Akurasi tersebut diperoleh pada pola iterasi ke 2000 dan 3000 menggunakan learning rate 0,7 dan 0,9 pada masing-masing iterasi, dan learning rate 0,5, 0,7, dan 0,9 pada iterasi ke 3000. Pola ini juga menghasilkan nilai presisi, *recall*, dan *F-Measure* yang tinggi. Penerapan BPNN pada penelitian yang ditulis oleh A. Herdiansah, dkk. [18] memperoleh akurasi sebesar 88,75%, dimana metode ini berhasil melakukan klasifikasi dengan menggunakan morfologi daun sebagai objek data. Penelitian-penelitian dengan menggunakan fitur RGB, GLCM, dan Bentuk menghasilkan tingkat akurasi yang cukup baik. Penelitian ini bertujuan untuk mengklasifikasikan kultivar buah Kelengkeng berdasarkan morfologi daunnya dengan fitur RGB, GLCM, dan Bentuk menggunakan metode BPNN.

2. METODOLOGI PENELITIAN

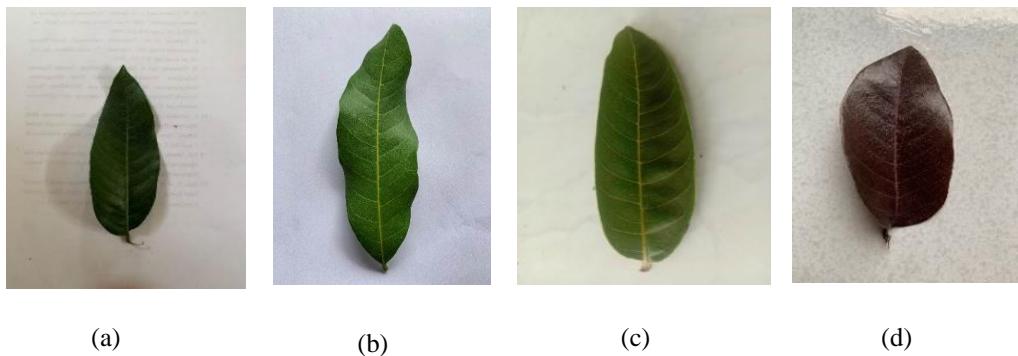
Penelitian ini dilaksanakan dengan beberapa tahapan, yaitu: (1) pengumpulan data berupa daun Kelengkeng dari 4 (empat) jenis Kelengkeng. Jumlah total daun yang digunakan adalah 80 helai daun, yang mana masing-masing jenis buah Kelengkeng menggunakan 20 helai daun. Lokasi pengambilan data dilakukan di Kota Semarang, Jawa Tengah. Langkah berikutnya adalah (2) pra-proses dengan menyamakan ukuran citra, dan menyamakan latar belakang citra. Setelah itu, dilakukan (3) ekstraksi fitur warna RGB, fitur GLCM, dan fitur Bentuk. Hasil ekstraksi fitur (4) dibagi menjadi data latih dan data uji. Citra yang digunakan sebagai data latih sebanyak 60 citra dan 20 citra digunakan sebagai data uji. Selanjutnya dilakukan (5) pengujian menggunakan algoritma klasifikasi BPNN untuk memprediksi nilai kecocokan pada masing-masing citra jenis daun. Selanjutnya hasil prediksi (6) dievaluasi dengan mengukur *accuracy* dan disajikan dalam bentuk *confusion matrix*. Hal ini dilakukan untuk memastikan seberapa baik hasil prediksi pada penelitian ini. Diagram alir penelitian ditunjukkan pada Gambar 1.



Gambar 1. Diagram alir penelitian

2.1 Pengumpulan Data

Proses pengambilan citra dilakukan menggunakan kamera ponsel pintar dengan resolusi kamera 12 mega piksel, kemudian objek diletakkan pada bidang kosong, lalu objek dipotret dari jarak 30 cm. Contoh citra yang digunakan ditunjukkan pada Gambar 2.



Gambar 2. (a) Matalada, (b) Kristal, (c) Itoh, (d) Merah

2.2 Pra-proses Data

Setelah diperoleh citra daun Kelengkeng, selanjutnya dilakukan pra-proses data yang bertujuan untuk menghasilkan pengolahan data yang baik. Pra-proses data dilakukan dengan menyamakan ukuran citra, dan latar belakang citra. Ukuran citra yang digunakan adalah 433 x 577 piksel, sedangkan latar belakang citra yang digunakan adalah warna solid, yaitu putih. Berikut contoh citra yang telah dilakukan pra-proses data, ditunjukkan pada Gambar 3.



Gambar 3. Citra hasil pra-proses ukuran 433x577 piksel

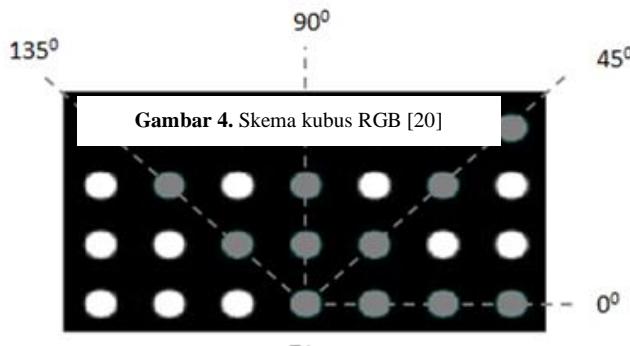
2.3 Ekstraksi Fitur

Setelah dilakukan pra-proses data, masing-masing citra akan diekstraksi menggunakan fitur RGB, GLCM, dan Bentuk. Masing-masing fitur akan menghasilkan nilai yang menjadi input pengujian dan pelatihan, sehingga hasil ekstraksinya dimanfaatkan sebagai data latih dan data uji.

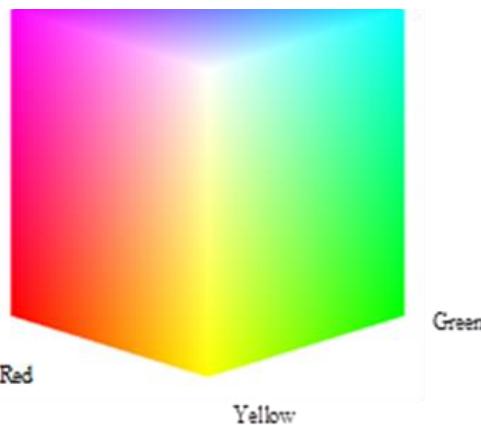
Pada model RGB (Merah, Hijau, Biru), setiap warna memiliki komponen spektral utama merah, hijau, dan biru. Model ini mengacu pada sistem koordinat Cartesian. Sub-ruang warna yang menarik adalah kubus pada Gambar 4, di mana nilai RGB utama terletak pada tiga sudut; Warna cyan, magenta, dan kuning dapat ditemukan di tiga sudut yang tersisa; Hitam adalah asalnya, dan kekosongan ada di sudut terjauh dari asalnya. Skala abu-abu model ini (titik dengan nilai RGB yang sama) memanjang dari hitam ke putih di sepanjang garis yang menghubungkan dua titik. Warna yang berbeda dalam model ini adalah titik-titik pada atau di kubus dan ditentukan oleh vektor yang memanjang dari ujung asal.

Gambar yang menggunakan model warna RGB, direpresentasikan dari tiga gambar komponen, satu untuk setiap warna utama. Saat memasukkan ke monitor RGB, ketiga gambar ini digabungkan di layar untuk menghasilkan gambar berwarna komposit, seperti yang dijelaskan pada pembahasan sebelumnya. Kedalaman piksel diukur dari seberapa banyak jumlah bit yang digunakan di dalamnya. Pertimbangkan gambar RGB di mana masing-masing gambar merah, hijau, dan biru adalah gambar 8-bit. Dalam keadaan ini, setiap piksel warna RGB [yaitu, triplet nilai (R, G, B)] memiliki kerapatan hingga 24 bit (3 bidang gambar dikalikan jumlah bit per bidang).

Istilah gambar penuh warna sering digunakan untuk menunjukkan gambar warna RGB 24-bit. Jumlah total warna yang mungkin dalam gambar RGB resolusi 24-bit adalah $(2^8)^3 = 16,777,216$. Perhatikan juga bahwa untuk gambar digital, rentang nilai dalam kubus diskalakan ke angka yang dapat diwakili oleh jumlah bit dalam gambar. Jika, seperti di atas, gambar utama adalah gambar 8-bit, batas kubus di sepanjang setiap sumbu menjadi [0, 255]. Kemudian, misalnya, putih akan berada di titik [255, 255, 255] pada kubus [19]. Penggunaan fitur *Grey Level Co-occurrence Matrix* (GLCM) dimulai sejak tahun 1973, dimana Haralick



Gambar 5. GLCM dengan sudut 0° , 45° , 90° , dan 135° [20]

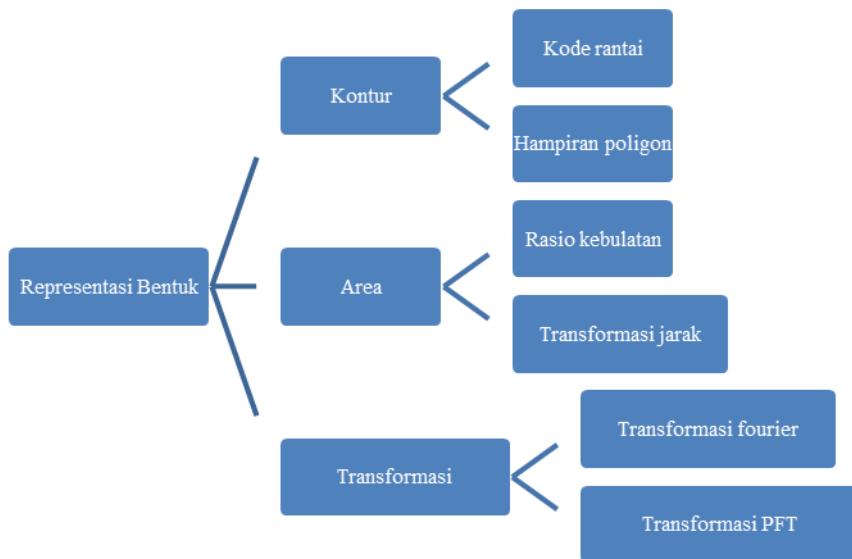


mengusulkan 28 fitur untuk menjelaskan pola ruang dan tempat. Pada orde kedua, GLCM menggunakan tekstur sebagai acuan nilai penghitung. Sedangkan pada orde pertama, perhitungan statistika digunakan untuk pengukuran tekstur yang mengacu pada nilai piksel citra asli, seperti varians, dan hubungan ketetanggaan piksel tidak menjadi perhatian. Hubungan antar-pasangan dua piksel citra asli mulai diperhitungkan pada orde kedua [20].

Normalisasi nilai-nilai pada elemen GLCM dilakukan untuk menghilangkan ketergantungan pada ukuran citra sehingga menjadi bernilai 1. Dengan demikian, maka akan terjadi pola sebagai berikut:

$$\begin{bmatrix} \frac{4}{24} & \frac{2}{24} & \frac{1}{24} & \frac{0}{24} \\ \frac{2}{24} & \frac{4}{24} & \frac{0}{24} & \frac{0}{24} \\ \frac{1}{24} & \frac{0}{24} & \frac{6}{24} & \frac{1}{24} \\ \frac{0}{24} & \frac{1}{24} & \frac{2}{24} & \frac{2}{24} \end{bmatrix}$$

Sebuah objek memiliki karakteristik yang terkait dengannya. Fitur bentuk adalah salah satu fitur yang didapatkan berdasarkan pada bentuk objek dan dapat direpresentasikan dengan kontur, wilayah, dan transformasi, seperti yang terlihat pada Gambar 6. Fitur bentuk biasanya direpresentasikan oleh kontur, wilayah, dan transformasi objek [19].



Gambar 6. Representasi fitur bentuk

Penghitungan pada fitur bentuk didasarkan pada variabel *metric* dan *eccentricity*. Penghitungan antara luas dan keliling suatu objek yang dapat menghasilkan variabel *metric*. Sedangkan nilai penghitungan jarak fokus *elips mayor* dan fokus *elips minor* menghasilkan variabel *eccentricity*. Rumus yang digunakan untuk menghitung nilai *metric* (2) dan *eccentricity* (3) adalah:

(2)

$$e = \sqrt{1 - \frac{b^2}{a^2}} \quad (3)$$

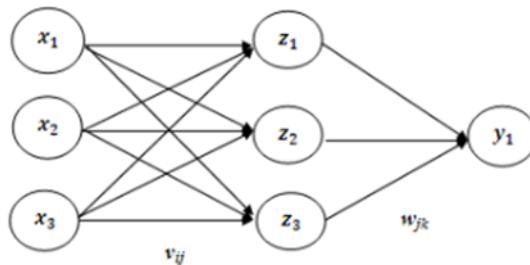
$$M = \frac{4\pi \times A}{C}$$

Sumbu minor ditunjukkan dengan notasi a dan sumbu mayor ditunjukkan dengan notasi b. Simbol A menunjukkan luas dan C menunjukkan keliling [18].

2.4 Prediksi Citra

Pada penelitian ini, setiap citra yang diekstraksi menggunakan fitur RGB, GLCM, dan Bentuk akan digunakan sebagai input untuk pemodelan menggunakan metode BPNN. Maka, data dipecah menjadi data *training* dan data *testing* yang masing-masing memiliki 4 target *output*, yaitu Itoh, Kristal, Matalada, dan Merah.

BPNN merupakan algoritma pembelajaran terawasi yang terdiri dari beberapa bagian, yaitu *input layer*, *hidden layer*, dan *output layer* yang selanjutnya terjadi perubahan bobot yang menghubungkan masing-masing layer [21]. BPNN mengevaluasi pendekatan kontribusi error dari setiap neuron dalam sebuah *data series*. Hal ini bertujuan untuk memodifikasi bobot, sehingga pemetaan keluaran dan pelatihan jaringan saraf dapat berlangsung dengan benar [22]. Gambar 7 menunjukkan contoh arsitektur BPNN.



Gambar 7. Arsitektur BPNN [18]

Input layer dinotasikan menggunakan x_1 , x_2 , dan x_3 . Sedangkan z_1 , z_2 , dan z_3 merupakan *hidden layer*, dan y_1 adalah *output layer*. *Layer-layer* jaringan tersebut dihubungkan oleh bobot masing-masing *layer*. Persamaan BPNN (4) dapat dijabarkan sebagai berikut.

(4)

$$y_k = f_k \left(\sum_{j=1}^p w_{jk} f_j (v_{0j} + \sum_{i=1}^n x_i v_{ij}) + w_{0k} \right)$$

2.5 Evaluasi

Langkah ini dilakukan untuk mengetahui efisiensi model yang dikembangkan. Hasil klasifikasi akan diperiksa keakuratannya untuk menentukan seberapa dekat hasil pengujian dengan nilai sebenarnya [23]. Pengujian dilakukan dengan persamaan (5).

(5)

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN}$$

TP (*True Positif*) = Data positif yang diprediksi benar

TN (*True Negatif*) = Data negatif yang diprediksi salah

FP (*False Positif*) = Data positif yang diprediksi salah

FN (*False Negatif*) = Data negatif yang diprediksi salah

3. HASIL DAN PEMBAHASAN

3.1 Pengumpulan data

Data berupa citra daun Kelengkeng diperoleh secara mandiri dari kebun pribadi dan kebun milik pengembang swasta di daerah Kota Semarang. Data berasal dari 4 pohon dan karakteristik buah yang berbeda. Total data yang diperoleh dari masing-masing pohon berjumlah 200 helai daun, sehingga total keseluruhan dari 4 pohon adalah 50 helai daun. Daun yang diperoleh dari masing-masing pohon kemudian dipilah untuk memperoleh daun dengan warna dan bentuk terbaik. Setelah dilakukan proses pemilahan, diperoleh 20 helai daun terbaik dari masing-masing

jenis, sehingga total data menjadi 80 helai daun, yang selanjutnya akan didokumentasikan. Proses dokumentasi daun dilakukan menggunakan kamera ponsel pintar dengan resolusi 12 mega piksel. Teknik dokumentasi citra dilakukan dengan menempatkan objek pada sebuah bidang kosong, yaitu kertas, kemudian dipotret dari jarak 30 cm.

3.2 Pra-proses data

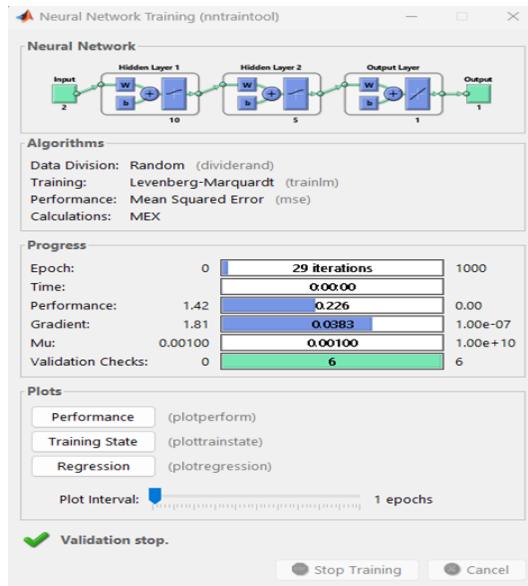
Setelah citra daun Kelengkeng terkumpul, selanjutnya dilakukan pra-proses data. Tujuannya adalah agar data yang akan diolah menghasilkan nilai yang baik sehingga hasil prediksinya mendekati data nyata. Pra-proses data dilakukan dengan beberapa tahapan, yaitu: (a) mengekstrak komponen pada RGB; (b) *Thresholding*; (c) *Complement*; dan (d) Morfologi.

Pra-proses data dimulai dengan mengekstrak komponen red dari citra RGB. Komponen R (Red) dipilih karena antara objek dan latar belakang lebih kontras dibandingkan dengan komponen G (Green) dan B (Blue). Selanjutnya dilakukan thresholding pada citra RGB untuk mengkonversi citra RGB menjadi citra biner. Nilai threshold yang digunakan adalah 0,6 untuk membedakan objek dari latar belakang. Setelah berhasil melakukan threshold, dilakukan operasi complement agar latar belakang bernilai 0, dan objek bernilai 1, sehingga pengolahan citra lebih baik. Setelah melakukan complement, selanjutnya dilakukan operasi morfologi untuk menyempurnakan hasil segmentasi. Langkah morfologi pertama yang dilakukan adalah operasi closing, yaitu untuk menggabungkan piksel yang ada di sekeliling objek untuk mengurangi noise pada objek. Pada operasi ini ditambahkan structuring element berbentuk bulat dengan radius 5. Selanjutnya dilakukan operasi *filling holes*, yaitu menutup lubang yang terdapat pada objek sehingga tidak terdapat lubang pada objek yang akan mempengaruhi hasil ekstraksi. Kemudian, setelah dilakukan penggabungan piksel, untuk memastikan tidak ada *noise* yang tersisa, maka dilakukan operasi *area opening* untuk menghilangkan *noise* tersebut. Batas nilai yang digunakan adalah 5000, sehingga jika terdapat objek dengan luas di bawah 5000, maka objek tersebut akan dihilangkan atau dihapus.

3.3 Ekstraksi fitur

Setelah melakukan pra-proses data, langkah selanjutnya adalah melakukan ekstraksi ciri untuk membedakan satu kelas dengan kelas lainnya untuk mendapatkan nilai yang akan digunakan sebagai input pemodelan. Sebelum dilakukan ekstraksi ciri, data dipecah menjadi dua bagian yaitu 60 citra data latih (*training*) dan 20 citra data uji (*testing*). Kelas yang digunakan adalah kelas itoh, kelas kristal, kelas matalada dan kelas merah. Variabel yang digunakan adalah *metric* dan *eccentricity*, dimana variabel ini digunakan untuk mengidentifikasi bentuk dari suatu objek. Untuk memperoleh variabel *metric*, digunakan variabel *area* dan *perimeter*. Variabel *area* digunakan untuk menghitung luas dari objek. Variabel *perimeter* digunakan untuk menghitung keliling dari objek. Setelah variabel *metric* dan *eccentricity* diperoleh, maka selanjutnya adalah melakukan klasifikasi citra menggunakan algoritma BPNN. Tahapan klasifikasi dilakukan dengan menyusun variabel input antara *metric* dan *eccentricity*. Selanjutnya menyusun variabel target untuk memisahkan antara satu kelas dengan kelas yang lainnya. Pemisahan target dilakukan dengan memberikan urutan sesuai dengan jumlah citra dari masing-masing jenis Kelengkeng. Selanjutnya, adalah membangun arsitektur BPNN dengan komponen berupa input dan target, dengan menggunakan lapisan tersembunyi sebanyak 10 dan 5. Setelah arsitektur jaringan

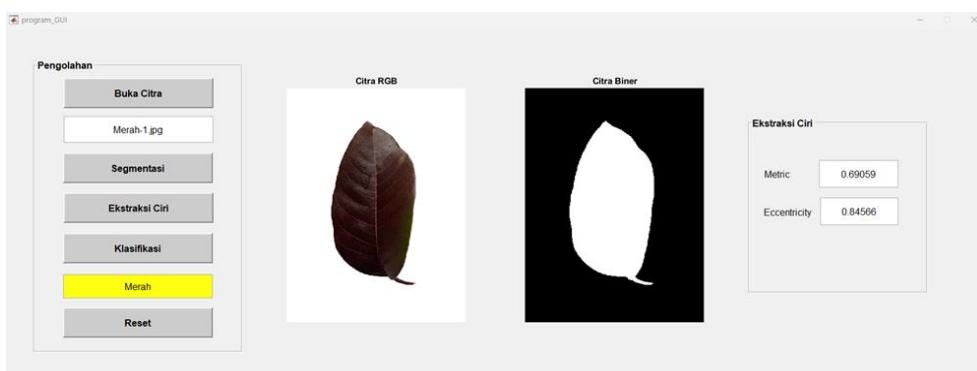
dibangun, maka dilakukan pelatihan jaringan untuk mencocokkan nilai *input* dengan target kelas dan kemudian disimulasikan pada *output*. Hasil pelatihan arsitektur jaringan dilakukan berhenti pada iterasi ke-29 hingga 1000 epoch, dengan 2 input, 10 neuron pada *hidden layer* pertama, 5 neuron pada *hidden layer* kedua dan 1 neuron pada *output layer*. Tampilan arsitektur Jaringan Hasil Pembelajaran ditunjukkan pada Gambar 9. Tingkat akurasi dari hasil pelatihan arsitektur jaringan adalah sebesar 73,33 %. Hasil pelatihan arsitektur jaringan kemudian disimpan untuk digunakan sebagai pengujian prediksi citra.



Gambar 8. Arsitektur pelatihan BPNN

3.4 Prediksi Citra dan Evaluasi

Tahapan prediksi citra dilakukan dengan pengujian pada data uji sebanyak 20 citra, dengan jumlah citra dari masing-masing jenis adalah 5 citra. Pengujian dilakukan dengan memanggil kembali arsitektur jaringan hasil pelatihan. Input data pengujian berupa citra daun sejumlah 20 citra. Akurasi yang dihasilkan dari pengujian input sebesar 95% dari target. Hasil prediksi citra disajikan dalam confusion matrix. Untuk memudahkan pengujian model, dibuatkan tampilan antar muka dalam bentuk GUI pada Matlab seperti yang terlihat pada Gambar 9. Tombol “Buka Citra” digunakan untuk mengambil citra dari folder, sehingga nama dokumen citra yang dipilih tampil dibawahnya. Tombol “Segmentasi” digunakan untuk melakukan Segmentasi Citra, yaitu memisahkan objek (*foreground*) dengan latar (*background*) citra, hasilnya ditampilkan pada frame “Citra RGB” dan “Citra Biner”. Tombol “Ekstraksi Ciri” digunakan untuk melakukan deteksi objek berupa daun. Ekstraksi ciri yang digunakan adalah ciri bentuk, hasilnya ditampilkan pada *field* “Metric” dan “Eccentricity”. Tombol “Klasifikasi” digunakan untuk melakukan proses klasifikasi dengan metode BPNN, *field* berwarna kuning menunjukkan hasil prediksi citra. Tombol “Reset” digunakan untuk mereset data untuk proses berikutnya.



Gambar 9. GUI Sistem Klasifikasi Jenis Daun Buah Kelengkeng

4. KESIMPULAN

Penelitian ini telah melakukan klasifikasi jenis buah Kelengkeng berdasarkan morfologi daun menggunakan ekstraksi fitur *Red*, *Green*, *Blue* (RGB), *Grey Level Co-occurrence Matrix* (GLCM), dan Bentuk dengan algoritma Back-propagation Neural Network (BPNN). Penggunaan algoritma BPNN mampu mendeteksi perbedaan yang terdapat pada morfologi daun. BPNN digunakan untuk mengklasifikasi jenis daun buah Kelengkeng dengan menggunakan parameter *metric* dan *eccentricity* untuk mendukung kinerjanya. Hasil pelatihan model memperoleh akurasi sebesar 73,33%, sedangkan hasil pengujian model memperoleh akurasi sebesar 95%. Hasil pengujian model ini menunjukkan bahwa klasifikasi daun Kelengkeng dapat dilakukan menggunakan model ini. Saran untuk penelitian berikutnya, agar menggunakan dataset dengan kualitas yang lebih baik, salah satunya dengan proses dokumentasi citra yang lebih profesional sehingga diperoleh citra dengan kualitas warna dan bentuk yang baik. Selain itu, pengembangan terhadap model yang digunakan akan sangat bermanfaat terhadap peta jalan penelitian pada bidang yang serupa.

Ucapan Terima Kasih

Ucapan terima kasih disampaikan kepada Kementerian Pendidikan, Kebudayaan, Riset, dan Teknologi yang telah mengadakan Program Hibah Penelitian Dosen Pemula (PDP) tahun 2022.

DAFTAR PUSTAKA

- [1] J. Janick, *Horticultural reviews. Volume 16*. J. Wiley & Sons, 1994.
- [2] T. Prawitasari, "Fisiologi Pembuangan Tanaman Lengkeng (*Euphorbia longana* Lam.) pada Beberapa Ketinggian Tempat," 2001.
- [3] P. K. Groom, B. B. Lamont, and A. S. Markey, "Influence of leaf type and plant age on leaf structure and sclerophyll in *Hakea* (Proteaceae)," *Aust J Bot*, vol. 45, no. 5, pp. 827–838, 1997.
- [4] H. Tsukaya, "Mechanism of leaf-shape determination," *Annu. Rev. Plant Biol.*, vol. 57, pp. 477–496, 2006.
- [5] S. Sutarno, R. F. Abdullah, and R. Passarella, "Identifikasi Tanaman Buah Berdasarkan Fitur Bentuk, Warna dan Tekstur Daun Berbasis Pengolahan Citra dan Learning Vector Quantization (LVQ)," in *Annual Research Seminar (ARS)*, 2017, pp. 65–70.
- [6] C. Sri Kusuma Aditya, M. Hani'ah, R. R. Bintana, and N. Suciati, "Batik classification using neural network with gray level co-occurrence matrix and statistical color feature extraction," in *2015 International Conference on Information & Communication Technology and Systems (ICTS)*, 2015, pp. 163–168. doi: 10.1109/ICTS.2015.7379892.
- [7] C. W. D. de Almeida, R. M. C. R. de Souza, and A. L. B. Candeias, "Texture classification based on co-occurrence matrix and self-organizing map," in *2010 IEEE International Conference on Systems, Man and Cybernetics*, 2010, pp. 2487–2491. doi: 10.1109/ICSMC.2010.5641934.
- [8] A. Minarno and N. Suciati, "Batik Image Retrieval Based on Color Difference Histogram and Gray Level Co-Occurrence Matrix," *TELKOMNIKA (Telecommunication Computing Electronics and Control)*, vol. 12, p. 597, Nov. 2014, doi: 10.12928/v12i3.80.
- [9] H. Syahputra and A. Harjoko, "Klasifikasi Varietas Tanaman Kelengkeng Berdasarkan Morfologi Daun Menggunakan Backpropagation Neural Network dan Probabilistic Neural Network," *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*, vol. 5, no. 3, pp. 11–16, 2011.
- [10] I. Jamaliah, R. N. Whidhiasih, and M. Maimunah, "Identifikasi Jenis Daun Tanaman Obat Hipertensi Berdasarkan Citra Rgb Menggunakan Jaringan Syaraf Tiruan," *PIKSEL: Penelitian Ilmu Komputer Sistem Embedded and Logic*, vol. 5, no. 1, pp. 1–11, 2017.
- [11] F. Y. Manik, "Identifikasi Penyakit Daun Jabon Berdasarkan Ciri Morfologi Menggunakan Support Vector Machine (Svm)," Bogor Agricultural University (IPB), 2015.

-
- [12] M. Benco, R. Hudec, P. Kamencay, M. Zachariasova, and S. Matuska, “An Advanced Approach to Extraction of Colour Texture Features Based on GLCM,” *Int J Adv Robot Syst*, vol. 11, no. 7, p. 104, Jan. 2014, doi: 10.5772/58692.
 - [13] D. P. Patil, S. R. Kurkute, P. S. Sonar, and S. I. Antonov, “An advanced method for chilli plant disease detection using image processing,” in *52nd International Scientific Conference On Information, Communication and Energy Systems and Technologies, Niš, Serbia*, 2017, pp. 309–313.
 - [14] J. Jamaludin, C. Rozikin, and A. S. Y. Irawan, “Klasifikasi Jenis Buah Mangga dengan Metode Backpropagation,” *Techné: Jurnal Ilmiah Elektroteknika*, vol. 20, no. 1, pp. 1–12, 2021.
 - [15] A. H. Tandrian and A. Kusnadi, “Pengenalan pola tulang daun dengan jaringan syaraf tiruan backpropagation,” *Ultima Computing: Jurnal Sistem Komputer*, vol. 10, no. 2, pp. 53–58, 2018.
 - [16] K. Syaban and A. Harjoko, “Klasifikasi varietas cabai berdasarkan morfologi daun menggunakan backpropagation neural network,” *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*, vol. 10, no. 2, pp. 161–172, 2016.
 - [17] F. A. Hizham, Y. Nurdiansyah, and others, “Implementasi metode backpropagation neural network (bnn) dalam sistem klasifikasi ketepatan waktu kelulusan mahasiswa (studi kasus: Program studi sistem informasi universitas jember),” *Berkala Sainstek*, vol. 6, no. 2, pp. 97–105, 2018.
 - [18] A. Herdiansah, R. I. Borman, D. Nurnaningsih, A. A. J. Sinlae, and R. R. Al Hakim, “Klasifikasi Citra Daun Herbal Dengan Menggunakan Backpropagation Neural Networks Berdasarkan Ekstraksi Ciri Bentuk,” *JURIKOM (Jurnal Riset Komputer)*, vol. 9, no. 2, pp. 388–395, 2022.
 - [19] R. C. Gonzalez and R. E. (Richard E. Woods, *Digital image processing*, Fourth Edition. Ney York: Pearson, 2018.
 - [20] A. Kadir, “Teori dan Aplikasi Pengolahan Citra,” 2013. [Online]. Available: <https://www.researchgate.net/publication/236673073>
 - [21] P. Prasetyawan, I. Ahmad, R. I. Borman, Y. A. Pahlevi, D. E. Kurniawan, and others, “Classification of the Period Undergraduate Study Using Back-propagation Neural Network,” in *2018 International Conference on Applied Engineering (ICAE)*, 2018, pp. 1–5.
 - [22] S. Setti and A. Wanto, “Analysis of Backpropagation Algorithm in Predicting the Most Number of Internet Users in the World,” *Jurnal Online Informatika*, vol. 3, no. 2, pp. 110–115, 2019
 - [23] R. I. Borman and B. Priyopradono, “Implementasi Penerjemah Bahasa Isyarat Pada Bahasa Isyarat Indonesia (BISINDO) Dengan Metode Principal Component Analysis (PCA),” *Jurnal Informatika: Jurnal Pengembangan IT*, vol. 3, no. 1, pp. 103–108, 2018.