

Fitur Tekstur Daun *Aglaonema* dengan Kode *Local Binary Pattern*

Texture Features of Aglaonema Leaves with Local Binary Pattern Code

¹Agung Tjahjo Nugroho*, ²Yuda Nursulistiyono, ³Bowo Eko Cahyono, ⁴Agus Subekti

^{1,2,3,4}Prodi Fisika, FMIPA, Universitas Jember
Jl. Kalimantan no 37, Jember 68121, Indonesia

*e-mail: agungtnugroho@unej.ac.id

(received: 24 May 2024, revised: 9 June 2024, accepted: 10 June 2024)

Abstrak

Aglaonema digemari karena keanekaragaman jenis daunnya. Akan tetapi ragam yang banyak mengakibatkan kesulitan dalam mengidentifikasi jenis, kualitas *Aglaonema*. Untuk itu dalam artikel ini dikembangkan teknik untuk mengklasifikasi jenis *Aglaonema* dari citra daun menggunakan image processing. *Aglaonema* dikenali dari tekstur daun yang diekstrak menggunakan teknik *Local Binary Pattern* (LBP). LBP mengenali objek dalam bentuk pola ketetangaan piksel dalam kode biner. Kode LBP ditentukan oleh radius (R) dan jumlah tetangga (P). Dalam artikel ini akan dipelajari ukuran radius dan jumlah tetangga yang tepat agar kode LBP menjadi atribut tekstur yang akurat. Dalam artikel ini R divariasikan dari 1 sampai dengan 5 sedangkan P divariasikan dari 4 sampai dengan 24 piksel. Secara eksperimen dua jenis *Aglaonema* dengan masing masing jenis diambil dua varietas digunakan untuk menguji akurasi kode LBP. Jenis batik diwakili oleh *Aglaonema* Diana dan *Hot Lady*, sedangkan jenis *lipstick* menggunakan sampel *Aglaonema* Jayanti dan *Lipstik* Putih. Akurasi hasil klasifikasi dilakukan dengan bantuan K-Nearest Neighbours (KNN). Hasil penelitian menunjukkan bahwa semakin banyak jumlah tetangga dalam penentuan kode LBP, semakin akurat hasil klasifikasinya. Tetangga dengan jumlah 18 memiliki akurasi yang sudah stabil mencapai total 79%. Penambahan jumlah tetangga tidak banyak mempengaruhi akurasi. Radius tetangga berpengaruh pada *Aglaonema* jenis batik, semakin luas area tetangga maka akurasi meningkat hingga 84%, akan tetapi untuk jenis *Lipstick*, akurasi terbaik didapat saat R=3. Dengan pemilihan R dan P yang tepat maka jenis *Aglaonema* batik dan *lipstick* dapat dibedakan dengan baik.

Kata kunci: fitur tekstur, *local binary pattern*, jumlah tetangga, klasifikasi *aglaonema*.

Abstract

The *Aglaonema* type and quality is difficult to identify due to leaf pattern variety. For this reason, a technique is developed to classify *Aglaonema* types from leaf images. The *Aglaonema* is identified using the *Local Binary Pattern* (LBP) technique. The LBP recognizes objects in the form of pixel neighbor patterns in binary code, which is sensitive to the radius (R) and the number of neighbors (P) pixels. In this article we will study the appropriate radius and number of neighbors so that the LBP code becomes an accurate object texture attribute. Experimentally, R is varied from 1 to 5 while P is varied from 4 to 24 pixels. Two types of *Aglaonema* with two varieties taken from each type were used to test the accuracy of the LBP code. The accuracy of the classification results is carried out with the help of K-Nearest Neighbors (KNN). The results show that the greater the number of neighbors in determining the LBP code, the more accurate the classification results. Neighbors with a total of 18 have a stable accuracy reaching a total of 79%. Increasing the number of neighbors does not significantly affect accuracy. The neighbor radius affects the batik type of *Aglaonema*, the wider the neighbor area, the accuracy increases up to 84%, but for the *Lipstick* type, the best accuracy is obtained when R=3. By choosing the right R and P, the types of *Aglaonema* batik and *Lipstick* can be differentiated well.

Keywords: texture features, *local binary pattern*, number of neighbors, *aglaonema* classification.

1 Pendahuluan

Tanaman hias khususnya di Indonesia memiliki aneka ragam jenis dan spesies, salah satunya adalah *Aglaonema*. Tanaman *Aglaonema* di Indonesia dikenal dengan sebutan “*Sri Rejeki*” [1]. *Aglaonema* digemari karena ragam bentuk, warna, dan corak daun yang sangat banyak. Ragam daun *Aglaonema* menentukan nilai ekonomis tanaman. Terdapat *Aglaonema* yang bernilai dibawah sepuluh ribu rupiah dan dapat dijumpai jenis *Aglaonema* yang memiliki nilai lebih dari lima puluh juta per tanaman. Perbedaan harga yang sangat tinggi dengan ragam *Aglaonema* sangat banyak, seringkali membuat penggemar tanaman hias salah dalam menentukan nilai ekonomi *Aglaonema* sehingga menimbulkan kerugian. Ragam *Aglaonema* didunia diperkirakan mencapai lebih dari 8000 jenis yang secara umum terbagi menjadi dua kelompok besar yakni *Aglaonema* spesies dan *Aglaonema* hibrida/ Banyaknya jenis *Aglaonema* membuat ahli tanaman atau botanis sering mengalami kesulitan dalam menganalisa dan mengenali jenisnya. Keterbatasan pengetahuan mengenai ciri-ciri setiap jenis *Aglaonema*, sering kali menjadi masalah bagi para pengembang tanaman hias bahkan tak terkecuali bagi masyarakat awam yang ingin menikmati keindahan tanaman *Aglaonema* itu sendiri. Masalah atau kesulitan identifikasi tersebut diakibatkan karena terdapat kemiripan bentuk, warna dan tekstur daun dari beberapa jenis *Aglaonema*.

Botani mengklasifikasi *Aglaonema* berdasar pada karakteristik morfologi. Atibut fisis seperti ukuran daun, panjang dan diameter batang, jumlah rumpun dan helai daun dalam satu rumpun, warna dan corak daun digunakan sebagai parameter pengenalan jenis *Aglaonema*. Parameter yang terkumpul dianalisa secara terstruktur menggunakan metode khusus seperti *Unweighted Pair Group Method Arithmetic Mean (UPGMA)*, untuk menentukan jenis tanaman. Dengan metode UPGMA, 14 varian *Aglaonema* dapat diklasifikasi dengan baik, dengan index perbedaan terkecil sebesar 0.045 dan perbedaan terbesar memiliki indeks 0.455 [2]. Hasil menunjukkan *Aglaonema* ‘Butterfly’ dan *Aglaonema* ‘Esmeralda’ berbeda sedangkan ‘Red Evergreen’ ‘Luilaiwan’, dan ‘Siam Aurora’ memiliki kemiripan. Teknik ini akurat akan tetapi memerlukan keahlian, waktu dan tenaga yang khusus, sehingga mahal dan sukar diaplikasikan secara komersial di lapangan. Alternatif solusi perlu dikembangkan, seperti penggunaan teknologi pengolahan citra.

Identifikasi tanaman *Aglaonema* dapat dilakukan dengan menganalisis foto daun menggunakan teknologi pengolahan citra. Dalam sepuluh tahun terakhir, teknik ini berkembang dengan pesat. Klasifikasi menggunakan metode *K-Nearest Neighbour (KNN)* dengan fitur *Gray Level Co-occurrence Matrix (GLCM)* dilaporkan oleh Syahidan [3]. Sementara itu, metode *Convolutional Neural Network (CNN)* berdasar pada fitur tekstur berhasil digunakan untuk mengklasifikasi 5 jenis *Aglaonema* dengan baik [4]. Akurasi data training dengan 100 citra training untuk setiap jenis tanaman mencapai 98%, sedangkan akurasi pengujian dengan 50 citra uji mencapai 96%. Eksplorasi CNN untuk mengklasifikasi *Aglaonema* dengan berbagai arsitektur dilaporkan oleh Mulyani [5], Arsitektur *Inception V3* terbukti paling tangguh dengan akurasi pengujian mencapai 93%, sedangkan dalam penelitian yang lain CNN dengan arsitektur yang sama menghasilkan akurasi 83% [6]. Akurasi *machine learning* ditentukan oleh pemilihan parameter ciri yang diekstrak dari fitur objek dalam citra.

Secara umum objek dalam sebuah citra dikenali berdasar tiga fitur utama yaitu bentuk (*shape*), warna dan tekstur. Fitur bentuk dapat digunakan untuk mengidentifikasi buah [7], fitur warna telah digunakan untuk mengklasifikasi penyakit padi dari citra daun [8], dan fitur tekstur dikembangkan untuk mengenali tanaman obat [9]. Fitur dasar dapat dikombinasikan sebagai pengenalan, seperti fitur bentuk dan tekstur digunakan untuk mengenali tanaman dari citra daun [10], fitur warna dan tekstur digunakan untuk mengidentifikasi penyakit tanaman [11], dan ketiga fitur berhasil digunakan bersamaan untuk mengidentifikasi jenis tanaman dari foto daun dalam *Flavia* dan *Folio leaf* datasets dengan akurasi mencapai 98% [12]. Dengan ekstraksi fitur yang tepat maka, buah, penyakit tanaman dan jenis tanaman dapat dikenali dengan bantuan *machine learning*.

Aglaonema dikenal dan digemari karena corak dan pola daun, sehingga fitur tekstur menjadi komponen penciri utama tanaman. Akan tetapi pola tekstur *Aglaonema* belum dinyatakan secara terstruktur. Selama ini identitas dan nama *Aglaonema* dinyatakan secara acak oleh penemu atau pelaku usaha tanaman, sehingga sering kali dijumpai *Aglaonema* dengan nama yang berbeda tetapi memiliki ciri fisiologi yang sukar dibedakan. Dalam artikel ini akan dijabarkan bagaimana fitur tekstur diekstraksi sehingga dapat digunakan sebagai identitas tanaman. Dengan pola yang lebih baku maka

identitas tanaman dapat dikonservasi sehingga dengan mudah dapat tanaman dapat dikenali menggunakan *machine learning*. Artikel ini bertujuan menyusun set fitur tekstur yang diekstrak dari foto daun menggunakan metode LBP. Fitur dengan kode LBP bermanfaat untuk memberi identitas yang unik untuk setiap jenis tanaman sehingga *Aglaonema* dapat dikenali dan dikonservasi dengan baik. Pengembangan fitur tekstur dilakukan dengan teknik ekstraksi citra dalam mode biner menggunakan metode LBP. Variasi jumlah dan radius tetangga pada piksel yang dievaluasi dipelajari dan dianalisis, sehingga didapat fitur tekstur dalam kode LBP yang akurat dan unik.

2 Tinjauan Literatur

Tekstur citra adalah fitur yang dinyatakan berdasar pada informasi fisis di bagian atau partisi dari seluruh area citra. Bagian citra dapat berupa piksel atau sekumpulan piksel yang dinyatakan dalam sebuah kuantitas. Dengan demikian tekstur dapat berupa sebaran spasial dari level intensitas atau warna yang bertetangga. Fitur tekstur dapat diekstraksi dalam berbagai metode seperti metode *Grey Level Co-occurrence Matrix* (GLCM) yang digunakan sebagai fitur tekstur untuk mengenali defisiensi nutrisi pada tanaman cabe [13], dan identifikasi penyakit pada tanaman bawang [14]. Metode *Histogram of Oriented Gradient* (HOG) yang diaplikasikan untuk mengidentifikasi berbagai penyakit tanaman [15], dan klasifikasi buah dan sayuran [16]. dan masih banyak pendekatan statistik yang lainnya.

Fitur tekstur yang diekstrak menggunakan metode *Local Binary Pattern* (LBP) memiliki keistimewaan, karena tidak sensitif terhadap perubahan intensitas dan warna, sehingga potensi untuk diaplikasikan langsung di lapangan sangat besar. Teknik ini bekerja dengan cara mengubah nilai intensitas dalam setiap piksel dengan kode biner. Kode biner didapat dengan membandingkan area atau piksel yang dievaluasi dengan piksel tetangga. Fitur LBP secara luas telah digunakan di berbagai aplikasi beberapa di antaranya adalah : LBP digunakan untuk mengidentifikasi penderita *down syndrome* [17], mengenali wajah [18], [19], mendeteksi kanker [20], mengidentifikasi sidik jari dan citra telapak tangan[21].

Aplikasi LBP dibidang pertanian juga berkembang dengan pesat. Novitasari (2018) menggunakan LBP untuk mengidentifikasi jenis daun tanaman jeruk [22]. Klasifikasi dilakukan dengan membandingkan nilai jarak data menggunakan metode *euclidean distance* histogram. Berdasarkan dari tujuh kelas dan tujuh jenis pengujian, diperoleh akurasi rata-rata sebesar 93,88%, di mana terdapat beberapa pengujian mencapai akurasi 100%. Penelitian ini membuktikan bahwa ekstraksi ciri tekstur metode LBP berhasil mengidentifikasi citra daun jenis tanaman jeruk dengan baik. Sementara itu klasifikasi jenis daun pepaya menggunakan ekstraksi fitur LBP dan metode klasifikasi *Naive Bayes* dilaporkan di [23]. *Dataset* yang digunakan yaitu 150 citra daun pepaya dari lima kelas yang berbeda meliputi, pepaya Sumatera, pepaya Hawaii, pepaya Cibinong, pepaya Bangkok, dan pepaya California. Capaian penelitian berupa tingkat akurasi dari proses evaluasi hasil pelatihan model *Naive Bayes* dalam membaca citra data testing. Berdasarkan 125 data *training* dan 25 data testing, berhasil diperoleh akurasi rata-rata sebesar 96% dengan hanya satu data terbaca salah. Berikutnya variasi data testing yang ditingkatkan menjadi 30 data dengan 125 data *training* akurasi yang diperoleh turun menjadi 93% dengan dua data terbaca salah. Hasil tersebut menunjukkan bahwa metode LBP masih menjadi kekuatan bagi penelitian berbasis daun tanaman, dikarenakan berhasil mengidentifikasi jenis pepaya hanya berdasarkan ekstraksi ciri tekstur daunnya.

Dalam perkembangan LBP memiliki banyak variasi. Salah satu variasi yang populer dikembangkan adalah menggabungkan teknik penentuan tetangga dan syarat anggota dalam LBP. Pengembangan ini dilakukan untuk meningkatkan kemampuan LBP dalam membedakan objek, walaupun demikian pengembangan yang tidak tepat dapat menimbulkan menurunnya diskriminasi pada sub fitur dan bertambahnya beban komputasi. Tetangga dalam LBP yang didefinisikan berdasar gradien intensitas antar piksel dikembangkan dengan nama *the neighbourhood feature-based local binary pattern* (NF-LBP) [24]. Modifikasi ini diklaim lebih Tangguh terhadap *noise* dibanding dengan tradisional LBP. Metode NF-LBP diaplikasikan untuk mengidentifikasi Parkinson dari data *Vertical Ground Reaction Force* (VGRF). Akurasi klasifikasi mencapai 98.3 % lebih baik dibanding tradisional LBP.[25]. Penentuan tetangga yang tepat dapat meningkatkan akurasi LBP

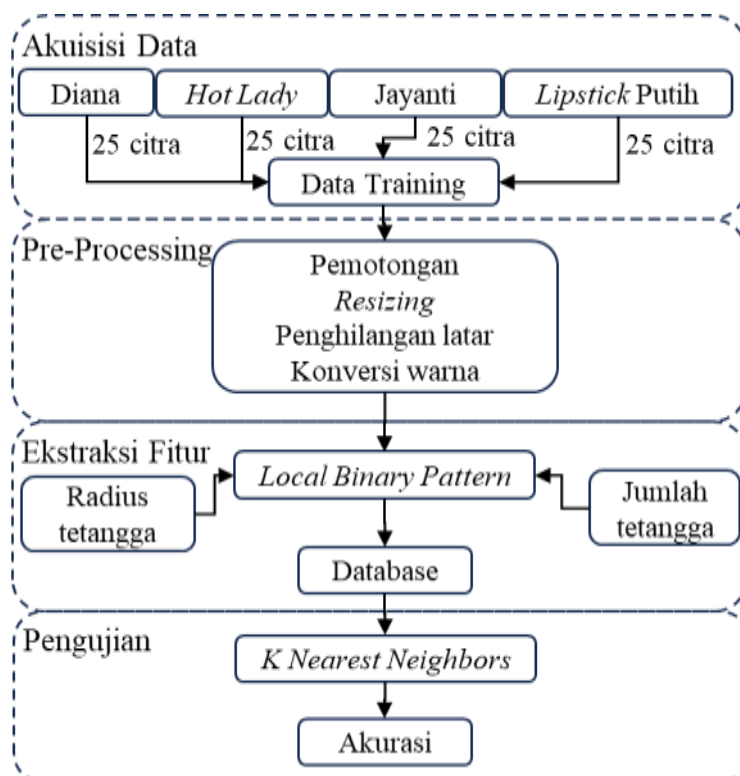
Radius tetangga mempengaruhi akurasi LBP saat diaplikasikan untuk mengenali ekspresi emosi dari foto wajah [26]. Radius piksel yang dikategorikan tetangga yang tepat dapat mengenali ekspresi

tersenyum dalam sebuah foto wajah. Radius tetangga akan menentukan jumlah tetangga, semakin besar radius tetangga semakin banyak tetangga yang harus diperhitungkan, sehingga akan memperpanjang bit kode LBP. Jumlah tetangga yang seragam dan kaku sering kali tidak dapat mendiskriminasi objek. Beberapa usaha dilakukan untuk mengatasi hal ini, seperti penentuan tetangga yang adaptif terhadap variasi intensitas [27], [28] dan perluasan area tetangga yang ditentukan dengan koordinat polar [29]. Fitur tekstur dengan kode LBP dapat digunakan sebagai identitas yang tangguh jika didefinisikan dengan tepat. Radius tetangga dalam sebuah area menjadi komponen yang krusial dalam pembentukan area tetangga.

Berbeda dengan [29] yang menyatakan tetangga dalam model polar dalam artikel ini area tetangga dinyatakan dalam koordinat *Cartesian*. Pemilihan *cartesian* karena lebih mudah direkonstruksi dan lebih mudah diaplikasikan. Area dalam citra diasumsikan tersusun dari piksel yang berbentuk persegi. Area ketetanggaan dinyatakan dengan kedekatan jarak piksel yang dievaluasi dengan piksel tetangga. Pada radius 1 atau R_1 maka jumlah tetangga terdekat maksimal 8, sedangkan untuk area ketetanggaan 2 maka jumlah tetangga maksimal menjadi 16. Jumlah tetangga berimplikasi pada panjang vektor kode LBP dan kemampuan menangkap informasi dalam citra. Radius kecil berorientasi menangkap informasi tekstur lokal dan sebaliknya. Dalam artikel ini akan diaplikasikan beberapa radius tetangga. Kemudian *database* jenis aglaonema dibangun dalam bentuk tabel histogram. Jumlah bin histogram tergantung pada jumlah tetangga dalam sebuah area. Obyek penelitian ini akan memanfaatkan kesamaan karakteristik daun varietas Aglaonema hasil hibrida Greg Hambali [2], [30], yaitu *Hot Lady* dan Diana untuk jenis batik serta kelas Jayanti dan *Lipstick Putih* untuk jenis *lipstick*. Ekstraksi fitur tekstur dikemas dalam histogram dan disimpan dalam *database* yang sesuai dengan radius tetangga yang ditentukan. Akurasi diskriminasi jenis aglaonema dalam *database* dilakukan dengan memanfaatkan klasifikasi dengan metode KNN.

3 Metode Penelitian

Aplikasi LBP untuk menyatakan fitur tekstur daun Aglonema dibagi menjadi empat tahapan seperti terlihat pada Gambar 1.



Gambar 1. Alur penelitian kode LBP untuk fitur tekstur daun aglaonema

3.1 Tahap akuisisi data.

Data berupa foto daun *Aglaonema* diambil menggunakan kamera *smartphone*. Dipilih daun yang utuh dan mekar sempurna. Dikumpulkan data citra sebanyak 25 foto daun untuk setiap jenis *Aglaonema*. Sehingga untuk empat jenis tanaman yaitu *Hot Lady*, *Diana*, *Jayanti*, dan *Lipstik Putih* terkumpul 100 citra data.

3.2 Tahap pre-processing

Citra diolah agar dapat menyeimbangkan ukuran dan intensitas warna serta mengeliminasi background. Pada bagian ini diawali dengan pemotongan (*cropping*). *Cropping* dilakukan untuk memperbaiki dan memfokuskan citra dari gangguan *noise background*. Proses ini dilakukan guna memaksimalkan citra yang hanya fokus pada objek daun saja. Aspek rasio citra yang digunakan pada pengambilan citra berukuran 1:1. Ukuran citra daun disamakan agar sebaran histogram kode LBP setara. Selain itu pengurangan jumlah piksel guna meringankan kerja sistem komputer pada saat proses ekstraksi citra. Ukuran citra akan diseragamkan dari semula berukuran 3000×3000 piksel menjadi 1024×2048 piksel. Eliminasi *background* dilakukan dengan teknik segmentasi warna. Batas eliminasi ditentukan dengan melihat sebaran intensitas warna pada setiap layer pada ruang warna RGB. Dikarenakan pada saat akuisisi data latar daun dipasang kertas dengan warna biru maka warna daun dan warna background dapat dibedakan dengan baik. Setelah objek daun terisolasi dan *background* dihapus, kemudian citra dikonversi ke dalam mode *grayscale*, sehingga setiap piksel hanya memiliki nilai intensitas tunggal.

3.3 Tahap ekstraksi fitur

Fitur tekstur dinyatakan dalam kode biner yang sering juga disebut dengan kode LBP [31]. Kode LBP dinyatakan dalam bentuk nilai biner, dimana jumlah bit sama dengan jumlah tetangga dan nilai bit merupakan perbandingan antara intensitas piksel yang dievaluasi dengan intensitas piksel tetangga. Kode biner LBP dapat ditentukan dengan persamaan (1) dan (2) berikut ini

$$LBP_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p \quad (1)$$

Fungsi biner nilai titik pusat $s(x)$ yaitu,

$$s(x) = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases} \quad (2)$$

Keterangan:

P : Banyaknya piksel tetangga (*sampling point*)

R : Nilai jarak atau radius

g_p : Nilai intensitas piksel tetangga

g_c : Nilai intensitas piksel pusat (x)

Jika jumlah tetangga adalah 8 maka kode biner LBP akan dinyatakan dalam 8 bit, sehingga akan terdapat 256 variasi nilai kode LBP dari 00000000 biner atau 0 desimal sampai dengan 11111111 biner atau 255 desimal. Variasi nilai akan meningkat ketika jumlah tetangga bertambah. Dalam artikel ini dicoba beragam area tetangga dengan radius $R=1$ sampai dengan $R=5$, dengan jumlah tetangga dari $P=4$ sampai dengan $P=24$.

Kode biner LBP tidak invariant terhadap rotasi. Secara umum penentuan kode dimulai dari tetangga terluar atas paling kiri, kemudian memutar searah dengan jarum jam. Walaupun demikian orientasi gambar objek dalam citra akan menentukan kode biner LBP yang terbentuk. Untuk itu diaplikasikan seleksi dan pengelompokan kode yang hanya memiliki pembalikan nilai bit tidak lebih dari dua. Jika kode biner memenuhi syarat pembalikan maka disebut uniform, dan selebihnya merupakan kode tidak uniform. Penentuan kode LBP uniform dapat dilakukan dengan fungsi (3) berikut ini:

$$LBP_{P,R}^{fitur} = \begin{cases} \sum_{p=0}^{p-1} s(g_p - g_c) & \text{if } U(LBP_{P,R}) \leq 2 \\ p + 1 & \text{otherwise} \end{cases} \quad (3)$$

Aplikasi persamaan (3) akan menghasilkan kode LBP yang uniform yang dinyatakan dalam bentuk histogram. Dimana bin 1 berisi kode LBP uniform yang tidak memiliki angka biner 0. Kode LBP uniform yang memiliki 1 buah nilai 1 seperti 01000000 dikelompokkan pada bin 2 dan seterusnya. Untuk kode LBP yang tidak uniform dikelompokkan pada bin P+1, atau bin ke 9 untuk jumlah tetangga P=8 dan bin ke 17 untuk jumlah tetangga P=16. Proses ekstraksi fitur akan menghasilkan database fitur tekstur daun aglonema dalam bentuk matrik kode LBP, yang merupakan gabungan dari histogram kode LBP.

3.4 Tahap pengujian

Pengujian dilakukan untuk melihat akurasi database kode LBP yang dibangun. Untuk setiap database dibuat model matematika kedekatan tetangga menggunakan metode KNN. Jarak antar tetangga ditentukan menggunakan jarak euclidian. Selanjutnya model matematika yang terbangun diuji dengan seluruh database, termasuk database yang digunakan untuk membangun model yang diuji. Hasil jumlah perhitungan kondisi identifikasi dapat dilihat pada data teridentifikasi benar disimbolkan dengan X dan T merupakan simbol jumlah data terbaca salah dalam satu kelas dari *database* uji. Akurasi database ditentukan menggunakan persamaan (4) berikut ini:

$$\text{Akurasi (\%)} = \frac{X}{(X+T)} \times 100\% \quad (4)$$

Diketahui bahwa persamaan (4) merupakan indikator keberhasilan untuk setiap variasi pengujian. Tingkat keberhasilan pada penelitian kali ini akan diukur akurasi seluruh variasi pengujian dengan persamaan (5) sebagai berikut

$$\text{Akurasi}_{\text{total}} = \frac{\sum \text{Akurasi Pengujian}}{\sum \text{Pengujian}} \quad (5)$$

Keterangan:

\sum Akurasi : Jumlah akurasi seluruh pengujian

\sum Akurasi : Jumlah pengujian yang dilakukan

4 Hasil dan Pembahasan


Fitur tekstur dengan kode LBP dikembangkan secara eksperimental. Data yang digunakan diambil langsung dari petani tanaman hias *Aglaonema*. Untuk memudahkan pengolahan citra dan untuk mengurangi gangguan citra latar digunakan bantuan kertas sebagai gambar latar. Kertas dipilih sedemikian rupa sehingga memiliki warna yang kontras. Selanjutnya dilakukan pengolahan awal yang diperuntukkan untuk mengisolasi daun dengan lingkungan dan menyamakan ukuran agar didapat perbandingan kode LBP yang senilai. Ekstraksi fitur dengan beragam jumlah dan radius tetangga dilakukan pada foto yang telah diperbaiki, dan diakhiri dengan pengujian fitur yang terekstrak. Secara berurutan hasil yang didapatkan dipaparkan sebagai berikut

4.1 Akuisisi Data

Dataset terdiri dari 100 citra daun *Aglaonema* yang terdiri 50 foto daun *Aglaonema* Diana dan *Hot Lady* yang merupakan jenis *Aglaonema* batik dan 50 foto daun Jayanti dan *Lipstick* Putih yang merupakan jenis *lipstick*. Contoh foto keempat varietas *Aglaonema* yang merupakan hasil persilangan Greg Hambali dapat dilihat pada Gambar (2). Gambar (2) memperlihatkan contoh citra 4 varietas *Aglaonema* dari jenis batik dan lipstick. Sepintas terdapat perbedaan corak yang mencolok antara jenis batik dan lipstick. Jenis batik memiliki pola yang tidak beraturan dengan dominan warna merah pada tulang daun di tengah. Sedangkan jenis lipstick berwarna kemerahan didaerah tepi daun, seakan dipulas dengan lipstick berwarna merah muda. Untuk varietas *aglaonema* sejenis terlihat hampir mirip. Sedikit

<http://sistemasi.ftik.unisi.ac.id>

perbedaan yang tampak di antaranya adalah corak batik Diana terlihat lebih kecil dan menyebar dibanding corak batik Hot Lady yang cenderung terlihat memiliki warna titik merah yang lebih sedikit, sehingga daun Hot Lady terlihat lebih hijau dibanding daun Diana. Jayanti dan Lipstick putih memiliki corak yang mirip. Ketebalan warna merah Jayanti terlihat lebih dalam dibanding Lipstick putih, sehingga daun Lipstick putih terlihat lebih cerah.



Gambar 2. Citra daun *aglaonema* (a) diana, (b) hot lady, (c) jayanti, dan (d) lipstick putih

Bentuk daun keempat varietas terlihat berbeda. Daun Aglaonema batik secara umum lebih besar dari jenis lipstick. Skala dalam foto tidak banyak mempengaruhi karena jarak pengambilan foto di kisaran 20 cm sampai dengan 30 cm antara kamera dengan objek. Selain itu juga terlihat perbedaan ujung daun dan lebar daun. Diana terlihat lebih ramping dan runcing dibanding dengan Hot Lady sedangkan Jayanti terlihat lebih langsing tetapi memiliki ujung yang lebih tumpul dibanding dengan Lipstick Putih. Karakteristik pada parameter ini sangat potensial untuk dijadikan fitur identitas tanaman seperti yang dilakukan pada artikel [10], [12], [32]. Walaupun demikian parameter tersebut tidak diolah lebih lanjut agar eksplorasi ekstraksi fitur tekstur lebih terarah.

4.2 Preprocessing

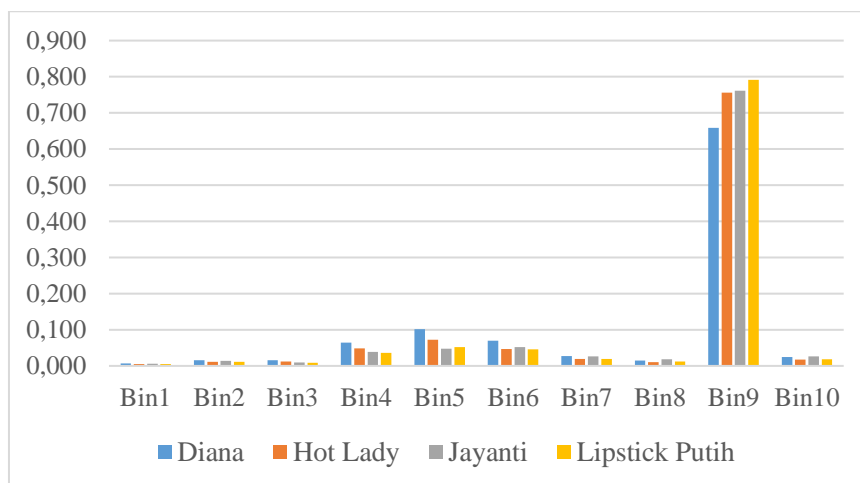
Pengolahan awal citra dengan mengabaikan bentuk dan ukuran. Langkah pertama melakukan penghapusan latar, dengan segmentasi warna [33]. Untuk memudahkan segmentasi, ruang warna diubah dari RGB menjadi YCbCr. Ruang warna YCbCr banyak digunakan untuk mengevaluasi dan mengenali karakteristik tanaman [8], [34]. Dalam konteks foto dalam data maka ruang chromatic blue digunakan untuk mensegmentasi background. Latar yang disengaja berwarna biru dengan mudah dapat dieliminasi. Citra dengan latar yang sudah dihilangkan disamakan ukuran agar histogram LBP yang terbangun menjadi setara. Hasil pengolahan citra awal dapat dilihat di Gambar (3)



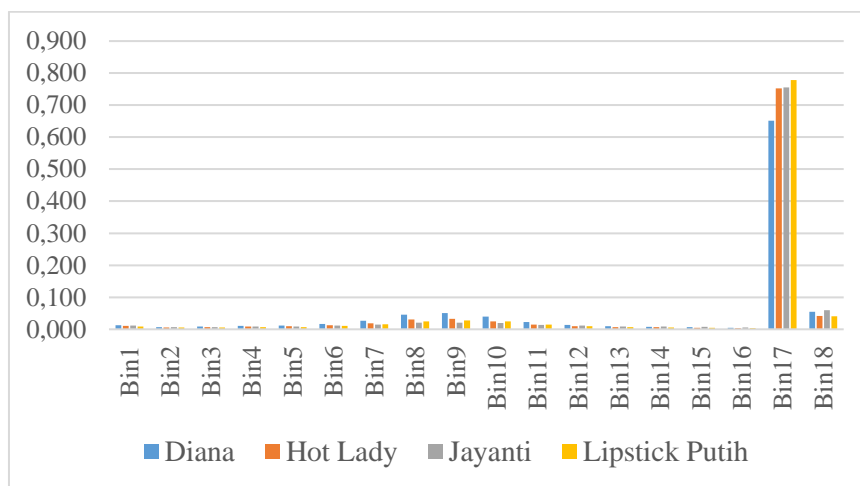
Gambar 3. Hasil citra *pre-processing* pada empat sampel citra daun *aglaonema*

4.3 Ekstraksi fitur tekstur

Fitur tekstur dinyatakan dengan 10 bin histogram ketika jumlah tetangga LBP berjumlah 8. Jumlah bin melebihi jumlah bit dikarenakan dalam proses *uniform*, hanya kode yang memiliki maksimal dua perubahan yang diperhitungkan. Sisa kode dinyatakan sebagai kode *non uniform* dan dimasukkan ke dalam bin P+1, dimana P adalah jumlah tetangga. Hasil ekstraksi kode LBP menggunakan persamaan (1) dan (3) dapat dilihat pada Gambar (4) untuk jumlah tetangga 8 dan Gambar (5) untuk jumlah tetangga 16.



Gambar 4. Histogram kode LBP hasil ekstraksi fitur dengan 8 tetangga



Gambar 5. Histogram kode LBP hasil ekstraksi fitur dengan 16 tetangga

Gambar 4 dan Gambar 5 memperlihatkan rata rata nilai bin untuk semua citra. Terlihat dalam Gambar 4 nilai bin 9 dominan demikian juga bin 17 pada Gambar 5. Hal ini menunjukkan Sebagian besar piksel dalam citra adalah *non uniform*. Secara umum tidak dapat pola histogram untuk semua varietas *Aglaonema* tidak jauh berbeda. Lebih detail untuk model ketetanggan 8, nilai rata rata untuk seluruh bin dan standar deviasi dapat dilihat pada Tabel 1.

Tabel 1. Rata rata dan standar deviasi nilai bin untuk kode LBP dengan 8 tetangga

Rata Rata										
	Bin1	Bin2	Bin3	Bin4	Bin5	Bin6	Bin7	Bin8	Bin9	Bin10
Diana	0.007	0.015	0.016	0.065	0.102	0.069	0.027	0.015	0.659	0.024
Hot Lady	0.005	0.012	0.012	0.049	0.072	0.047	0.019	0.011	0.756	0.017
Jayanti	0.006	0.014	0.010	0.039	0.047	0.052	0.026	0.019	0.761	0.026
Lipstick Putih	0.005	0.011	0.009	0.036	0.052	0.046	0.019	0.012	0.792	0.018
Standart Deviasi										
Diana	0.003	0.005	0.006	0.017	0.030	0.019	0.008	0.004	0.091	0.007
Hot Lady	0.002	0.003	0.003	0.012	0.023	0.013	0.005	0.003	0.061	0.005
Jayanti	0.002	0.005	0.004	0.013	0.018	0.023	0.011	0.009	0.086	0.010
Lipstick Putih	0.004	0.007	0.005	0.018	0.025	0.024	0.011	0.007	0.102	0.011

Tabel 1 memperlihatkan kode LBP pada beberapa bin tidal dapat dipisahkan. Seperti pada bin 1, Diana dan *Hot Lady* tidak sepenuhnya terpisah. Walaupun titik rata rata terlihat berada diposisi yang berbeda, tetapi standar deviasi memperlihatkan terdapat data yang berada di daerah yang berbeda kesekawanan (*adjacency*). Kondisi ini normal terjadi dalam ekstraksi fitur. Akan selalu ditemukan anggota yang berada di tetangga yang berbeda sekawan. Untuk itulah perlu dilakukan pengujian dengan *machine learning*. Dengan jumlah citra 100 dimana masing masing varietas terdapat 25 citra maka terbangun berbagai set database dengan ukuran $(P+2) \times 100$, sehingga didapat 10×100 data untuk ekstraksi fitur dengan 8 tetangga, dimana 10 merepresntasikan jumlah bin dan 100 merupakan jumlah data citra. Sementara untuk jumlah tetangga 16 akan terbangun database dengan ukuran 18×100 . Selain itu database dilengkapi dengan kolom vektor yang berisi label *Aglaonema*. Fitur yang tersimpan dalam matrik dan kolom vektor label merupakan database yang bisa disimpan, yang kemudian dapat dijadikan

model untuk identitas *Aglaonema*. Akurasi dari database diuji dengan *machine learning*. Dalam artikel ini dipilih metode KNN, yang pernah diaplikasikan di [19] untuk mengklasifikasi wajah, dan [35] untuk mengidentifikasi tanaman.

4.4 Hasil Pengujian

KNN merupakan mesin klasifikasi yang banyak diaplikasikan diberbagai bidang. Tabel 2 memperlihatkan variasi akurasi klasifikasi untuk data training pada beberapa nilai k.

Tabel 2. Akurasi Hasil Klasifikasi *Aglaonema* dengan KNN pada Variasi Nilai k

Nilai k	Akurasi				
	Diana	Hot Lady	Jayanti	Lipstick Putih	Total
2	100	76	100	68	86
3	88	80	100	68	84
4	92	76	92	68	82
5	80	80	64	68	73
6	80	76	68	72	74
7	76	68	68	72	71
8	72	64	68	72	69
9	72	68	68	72	70
10	72	68	68	56	66
11	72	72	64	68	69
12	72	72	84	48	69
13	72	72	76	44	66
14	72	76	72	44	66
15	72	76	74	40	68

KNN bekerja dengan mengkuantisasi kedekatan data yang dievaluasi dengan model *fitting* yang dibangun dengan data training. Sebuah data dikelompokkan pada jenis tertentu tergantung pada jumlah jarak terpendek data tersebut terhadap data training yang sering disebut dengan nilai k pada KNN. Nilai k menentukan akurasi hasil klasifikasi, sehingga banyak usaha dilakukan agar dicapai klasifikasi terbaik dengan k yang dinamis ataupun dengan mengaplikasikan optimasi [36]. Nilai k dari KNN berkaitan erat dengan *error model*, nilai k yang terlalu kecil akan menghasilkan model *overfitting*, yang bermakna model akan bagus untuk mengevaluasi data training, akan tetapi berdampak pada unjuk kerja yang kurang bagus saat data testing dihadirkan [37]. Sebaliknya nilai k yang terlalu besar akan mengasilkan model yang *underfitting*.

Terlihat dari Tabel 2, akurasi hasil klasifikasi data training menurun dengan bertambahnya nilai k. Hal ini memperlihatkan model fitting mengalami *underfitting* dengan bertambahnya nilai k. Secara umum akurasi terbaik diperlihatkan saat nilai k sama dengan 3. Akurasi total untuk keseluruhan data dengan 4 varietas tanaman mencapai 84%, dimana akurasi untuk seluruh varietas diatas 80% kecuali untuk *Lipstick Putih*. Walaupun demikian k dengan nilai 3 dikhawatirkan memiliki sifat *underfitting* yang kuat sehingga k dengan nilai 3 tidak menjadi pilihan. Acuan penggunaan nilai k sebesar akar dari jumlah data training untuk setiap jenis [38] memungkinkan efek *underfitting* bisa dihindari.

Tabel 3. Akurasi hasil klasifikasi *aglaonema* dengan KNN pada berbagai radius dan jumlah tetangga

k=5		Akurasi				
R	P	Diana	Hot Lady	Jayanti	Lipstick Putih	Total
1	4	80	76	68	72	74
1	5	88	68	64	64	71

1	6	88	72	72	60	73
1	7	88	76	68	64	74
1	8	80	80	64	68	73
2	9	92	76	84	64	79
2	10	84	76	80	64	76
2	11	92	80	76	68	79
2	12	84	80	84	68	79
2	13	92	80	76	68	79
2	14	84	80	72	68	76
2	15	84	80	68	68	75
2	16	84	80	76	68	77
3	17	84	80	76	76	79
3	18	84	80	76	76	79
3	19	84	80	76	76	79
3	20	84	80	76	76	79
3	21	84	80	76	76	79
3	22	84	80	76	76	79
3	23	84	80	76	76	79
3	24	84	84	76	76	80

Dengan jumlah data training sebesar 25 maka nilai yang memenuhi adalah 5. Walaupun akurasi total pada saat k bernilai 5 bukan yang terbaik akan tetapi dengan akurasi 73% dianggap sudah memenuhi nilai yang cukup untuk ditelaah lebih lanjut. Nilai k sama dengan 5 dijadikan parameter yang digunakan untuk evaluasi jumlah tetangga ketika melakukan ekstraksi fitur tekstur dengan LBP. Tabel 3 memperlihatkan akurasi hasil klasifikasi *Aglaonema* ketika radius tetangga dan jumlah tetangga yang diperhitungkan dalam LBP. Terlihat dalam tabel 3 jumlah tetangga erat kaitannya dengan radius tetangga. Untuk radius sebesar 1 jumlah tetangga maksimal yang bisa digunakan adalah 8, sedangkan untuk radius 2 jumlah tetangga maksimal adalah 16. Hal ini berkaitan dengan jumlah piksel yang berdekatan dengan piksel yang dievaluasi. Dengan demikian secara umum jika diinginkan jumlah tetangga banyak maka radius yang didefinisikan juga harus mencukupi. Untuk LBP dengan asumsi piksel berbentuk persegi maka radius terkecil adalah 1 dan radius 5 dianggap radius yang luas [29], [39]. Ekstraksi fitur LBP dengan jumlah tetangga sedikit mengeksplorasi detail tekstur sedangkan jumlah tetangga yang besar lebih menggambarkan pola global [40]. Tabel 3 memperlihatkan hubungan akurasi dengan variasi jumlah tetangga dalam proses ekstraksi LBP. Terlihat semakin besar jumlah tetangga semakin besar akurasi hasil klasifikasi data training. Hal ini memperlihatkan jika data training terkelompok dalam segmen yang berkesesuaian. Walaupun demikian dengan jumlah tetangga yang terlalu besar akan menyulitkan klasifikasi ketika data baru diperkenalkan dalam model fitting KNN. Jika perbedaan kelas objek terletak pada detail tekstur maka kemungkinan tidak akan terdeteksi dengan baik.

Variasi radius mempengaruhi akurasi klasifikasi [41], [42], [43], untuk itu pengaruh radius tetangga juga dipelajari. Terlihat dalam tabel 4, variasi akurasi terhadap perubahan radius tetangga ketika jumlah tetangga dibuat konstan. Semakin besar radius semakin tinggi akurasi hasil klasifikasi pada data training. Hal ini berkesesuaian dengan variasi jumlah tetangga. Dengan demikian klasifikasi pada pola tekstur global meningkatkan akurasi klasifikasi data training. Walaupun demikian jumlah anggota dan radius tetangga harus diperhitungkan dengan bijaksana agar tidak terjadi *overdetermined* sehingga ketika data baru yang tidak termasuk dalam kelompok training dimunculkan menjadi sukar dikenali karena lemahnya detail tekstur yang dipromosikan.

Tabel 4 Akurasi hasil klasifikasi *aglaonema* dengan KNN pada berbagai radius tetangga

k=5		Akurasi				
R	P	Diana	Hot Lady	Jayanti	Lipstick Putih	Total
2	22	84	80	76	68	77
3	22	84	80	76	76	79
4	22	92	88	72	72	81
5	22	92	92	72	72	82

Tabel 4 memperlihatkan variasi radius tetangga LBP terhadap akurasi hasil klasifikasi. Secara umum semakin besar radius tetangga semakin besar akurasinya. Terlihat *Aglaonema* Diana dan *Hot Lady* pada jenis batik terpisahkan sampai dengan 92%. Akan tetapi akurasi Jayanti menurun dengan bertambahnya radius sedangkan Lipstick Putih terpisahkan maksimal pada radius 3 dan kemudian menurun dengan bertambahnya radius hingga tersisa 72% pada setting radius sejauh 5. Dapat disimpulkan untuk jenis batik maka radius 5 bekerja dengan baik sedangkan jenis lipstick memerlukan parameter tekstur yang lebih detail.

Aglaonema jenis batik dan lipstick memiliki karakteristi yang berbeda. Melihat karakteristik yang jauh berbeda maka dicobakan dipisahkan antara *Aglaonema* jenis batik dan jenis lipstick. Hasil pemisahan terlihat bahwa jenis batik dapat dikenali 100%, sedangkan hanya sekitar 78% dari jenis lipstick dikenali sebagai lipstick. Dimana hanya 72% Jayanti dikenali sebagai jenis lipstick, sedangkan 84% Lipstick Putih dikenali sebagai jenis lipstick. Untuk varietas *Aglaonema* pada jenis yang sama bisa dibedakan dengan baik. Pada jenis batik, dengan 50 sampel, total 89% Diana dapat dibedakan dengan *Hot Lady*. Dimana 96% *Hot Lady* dapat diklasifikasikan dengan baik, sementara 14% Diana terklasifikasi sebagai *Hot Lady*. Sementara itu, untuk Jayanti dan Lipstick Putih juga dapat dibedakan dengan baik. Keseluruhan sampel foto Jayanti dapat dikenali sebagai Jayanti, sedangkan 84% dari Lipstick Putih dari 25 sampel dikenali dengan benar.

5 Kesimpulan

Kode LBP yang diekstrak dari foto daun dapat digunakan sebagai atribut terkstur *Aglaonema*. Akurasi kode LBP tergantung pada seting metode pengklasifikasi dan seting parameter LBP. Dalam artikel ini klasifikasi dilakukan menggunakan KNN. Penelitian menunjukkan nilai k pada parameter KNN sangat menentukan akurasi hasil klasifikasi pada data training. Semakin kecil nilai k maka akurasi semakin besar. Hal ini sesuai dengan model *fitting* menggunakan KNN, ketika nilai k kecil maka akan terjadi *underfitting* dimana akurasi hasil klasifikasi data training akan bagus akan tetapi jika data baru dihadirkan pada model fitting maka kemungkinan data tidak terklasifikasi dengan baik cukup besar. Untuk itu walaupun saat k bernilai 3 menghasilkan akurasi yang bagus akan tetapi dalam aplikasi untuk membangun kode LBP dipilih k bernilai 5. Saat k bernilai 5 dengan jumlah tetangga 8 dihasilkan akurasi total sebesar 73% dimana Diana dan *Hot Lady* dapat dikenali dengan baik dengan akurasi mencapai 80%. Radius dan jumlah tetangga menjadi parameter yang menentukan akurasi kode LBP sebagai atribut tekstur *Aglaonema*. Secara umum semakin banyak jumlah anggota tetangga yang dilibatkan untuk menentukan kode LBP semakin besar akurasi nya. Total akurasi dapat mencapai 80%, ketika seluruh 24 tetangga piksel yang dievaluasi digunakan untuk menentukan atribut tekstur. Akan tetapi semakin besar jumlah tetangga semakin panjang pula vektor kode LBP. Jumlah anggota 16 dan 22 menjadi jumlah yang cukup bagus untuk menjadi pilihan parameter kode LBP. Sementara itu radius tetangga meningkatkan akurasi klasifikasi data training. Radius sebesar 5 memberikan akurasi yang paling bagus diantara radius yang lainnya untuk jenis *Aglaonema* batik, tetapi sebaliknya untuk *Aglaonema* jenis lipstick akurasi terbaik berada pada radius 3.

Ucapan Terima Kasih

Penulis mengucapkan terima kasih kepada Lembaga Penelitian dan Pengabdian Universitas Jember yang telah mendukung pendanaan dalam pebelitian ini. Penulis juga memberikan apresiasi yang sebesar besarnya kepada FMIPA Universitas Jember yang telah memberi fasilitas, sarana dan prasarana sehingga penelitian dan penulisan artikel ini dapat berjalan dengan lancar

Referensi

- [1] Leman, Aglonema, Tanaman Pembawa Keberuntungan. Jakarta: Penebar Swadya, 2006.
- [2] F. R. Alifia, S. Sukarsa, and W. Herawati, "Keanekaragaman Aglaonema di Kecamatan Temanggung, Kabupaten Temanggung, Jawa Tengah," *BioEksakta : Jurnal Ilmiah Biologi Unsoed*, vol. 5, no. 1, 2023, doi: 10.20884/1.bioe.2023.5.1.4734.
- [3] N. Syahidan, S. Rati, S. Lubis, and N. Fadillah, "Klasifikasi Tanaman Aglaonema Menggunakan Fitur Ekstraksi *Gray Level Co-Occurrence Matrix* dan *K-Nearest Neighbor*," *J-ICOM - Jurnal Informatika dan Teknologi Komputer*, vol. 1, no. 2, pp. 58–63, Nov. 2020, doi: 10.33059/j-icom.v1i2.2770.
- [4] Y. Purna Irawan and Indah Susilawati, "Klasifikasi Jenis Aglaonema Berdasarkan Citra Daun Menggunakan *Convolutional Neural Network (CNN)*," *Journal of Information System and Artificial Intelligence*, vol. 2, no. 2, 2022, doi: 10.26486/jisai.v2i2.57.
- [5] Y. Mulyani, D. Septiangraini, M. A. Muhammad, and G. F. Nama, "Comparison Study of *Convolutional Neural Network Architecture* in *Aglaonema Classification*," *International Journal of Electronics and Communications Systems*, vol. 2, no. 2, 2022, doi: 10.24042/ijecs.v2i2.13694.
- [6] A. Pratondo and A. Novianty, "Classification of *Aglaonema* Using *Machine Learning*," in *Proceedings - 2022 14th IEEE International Conference on Computational Intelligence and Communication Networks, CICN 2022*, 2022. doi: 10.1109/CICN56167.2022.10008261.
- [7] I. M. Hassoon, "Shape feature extraction techniques for fruits: A review," *Iraqi Journal of Science*, vol. 62, no. 7. *University of Baghdad-College of Science*, pp. 2425–2430, Jul. 31, 2021. doi: 10.24996/ij.s.2021.62.7.31.
- [8] V. K. Shrivastava and M. K. Pradhan, "Rice Plant Disease Classification using Color Features: a machine learning paradigm," *Journal of Plant Pathology*, vol. 103, no. 1, pp. 17–26, Feb. 2021, doi: 10.1007/s42161-020-00683-3.
- [9] D. Puri, A. Kumar, J. Virmani, and Kriti, "Classification of Leaves of Medicinal Plants Using *Laws' Texture Features*," *International Journal of Information Technology (Singapore)*, vol. 14, no. 2, pp. 931–942, Mar. 2022, doi: 10.1007/s41870-019-00353-3.
- [10] C. Yang, "Plant Leaf Recognition by Integrating Shape and Texture Features," *Pattern Recognit*, vol. 112, Apr. 2021, doi: 10.1016/j.patcog.2020.107809.
- [11] N. Ahmad, H. M. S. Asif, G. Saleem, M. U. Younus, S. Anwar, and M. R. Anjum, "Leaf Image-Based Plant Disease Identification using Color and Texture Features," *Wirel Pers Commun*, vol. 121, no. 2, pp. 1139–1168, Nov. 2021, doi: 10.1007/s11277-021-09054-2.
- [12] M. Keivani, J. Mazloum, E. Sedaghatfar, and M. B. Tavakoli, "Automated Analysis of Leaf Shape, Texture, and Color Features for Plant Classification," *Traitement du Signal*, vol. 37, no. 1, pp. 17–28, 2020, doi: 10.18280/ts.370103.
- [13] D. Rahadiyan, S. Hartati, Wahyono, and A. P. Nugroho, "Feature Aggregation for Nutrient Deficiency Identification in Chili Based On Machine Learning," *Artificial Intelligence in Agriculture*, vol. 8, 2023, doi: 10.1016/j.aiaa.2023.04.001.
- [14] A. Zalvadila, "Klasifikasi Penyakit Tanaman Bawang Merah menggunakan Metode SVM dan CNN," *Jurnal Informatika: Jurnal Pengembangan IT*, vol. 8, no. 3, 2023, doi: 10.30591/jpit.v8i3.5341.
- [15] R. Cristin, B. S. Kumar, C. Priya, and K. Karthick, "Deep Neural Network Based Rider-Cuckoo Search Algorithm for Plant Disease Detection," *Artif Intell Rev*, vol. 53, no. 7, 2020, doi: 10.1007/s10462-020-09813-w.
- [16] Y. Yohannes, M. R. Pribadi, and L. Chandra, "Klasifikasi Jenis Buah dan Sayuran Menggunakan SVM Dengan Fitur Saliency-HOG dan Color Moments," *ELKHA*, vol. 12, no. 2, 2020, doi: 10.26418/elkha.v12i2.42160.
- [17] Nugroho Agung Tjahjo, Wulandari Yustisi, and Cahyono Bowo Eko, "Klasifikasi *Down Syndrome* Menggunakan Tekstur Lbp Dengan Tiga Variasi *Distance Classifiers*," *STRING (Satuan Tulisan Riset dan Inovasi Teknologi)*, vol. 7, no. 1, 2022.
- [18] L. Shi, X. Wang, and Y. Shen, "Research on 3d Face Recognition Method Based on LBP and SVM," *Optik (Stuttg)*, vol. 220, 2020, doi: 10.1016/j.ijleo.2020.165157.

- [19] B. ZHAI and Z. LI, "Face Recognition Based on Fusion Feature of LBP and PCA with KNN," *DEStech Transactions on Computer Science and Engineering*, no. cmsam, 2018, doi: 10.12783/dtce/cmsam2018/26592.
- [20] D. Q. Zeebaree, A. M. Abdulazeez, D. A. Zebari, H. Haron, and H. N. A. Hamed, "Multi-Level Fusion in Ultrasound for Cancer Detection Based on Uniform LBP Features," *Computers, Materials and Continua*, vol. 66, no. 3, 2020, doi: 10.32604/cmc.2021.013314.
- [21] B. Tüü-Szabó, G. Kovács, P. Földesi, S. Nagy, and L. T. Kóczy, "Local Binary Pattern-Based Fingerprint Matching," 2022. doi: 10.1007/978-3-030-74970-5_21.
- [22] A. Novitasari, E. P. Purwandari, and F. F. Coastera, "Identifikasi Citra Daun Tanaman Jeruk Dengan Local Binary Pattern Dan Moment Invariant," *Jurnal Informatika dan Komputer*, vol. 3, no. 2, 2018.
- [23] C. A. Sari and E. H. Rachmawanto, "Fitur Esktraksi LBP dan Naive Bayes dalam Klasifikasi Jenis Pepaya Berdasarkan Citra Daun," *Jurnal Masyarakat Informatika*, vol. 12, no. 2, 2021, doi: 10.14710/jmasif.12.2.42222.
- [24] S. Lan, J. Li, S. Hu, H. Fan, and Z. Pan, "A Neighbourhood Feature-Based Local Binary Pattern for Texture Classification," *Visual Computer*, May 2023, doi: 10.1007/s00371-023-03041-3.
- [25] O. C. Yurdakul, M. S. P. Subathra, and S. T. George, "Detection of Parkinson's Disease From Gait using Neighborhood Representation Local Binary Patterns," *Biomed Signal Process Control*, vol. 62, Sep. 2020, doi: 10.1016/j.bspc.2020.102070.
- [26] B. Smolka and K. Nurzynska, "Power Lbp: A Novel Texture Operator for Smiling and Neutral Facial Display Classification," *In Procedia Computer Science*, Elsevier B.V., 2015, pp. 1555–1564. doi: 10.1016/j.procs.2015.05.350.
- [27] S. Hu, J. Li, H. Fan, S. Lan, and Z. Pan, "Scale and Pattern Adaptive Local Binary Pattern for Texture Classification[Formula Presented]," *Expert Syst Appl*, vol. 240, Apr. 2024, doi: 10.1016/j.eswa.2023.122403.
- [28] D. Liu, S. Wang, D. Huang, G. Deng, F. Zeng, and H. Chen, "Medical Image Classification using Spatial Adjacent Histogram Based on Adaptive Local Binary Patterns," *Comput Biol Med*, vol. 72, pp. 185–200, May 2016, doi: 10.1016/j.compbiomed.2016.03.010.
- [29] I. Al Saidi, M. Rziza, and J. Debayle, "A Novel Texture Descriptor: Circular Parts Local Binary Pattern," *Image Analysis and Stereology*, vol. 40, no. 2, pp. 105–114, 2021, doi: 10.5566/ias.2580.
- [30] Y. Mulyani, D. Septiangraini, M. A. Muhammad, and G. F. Nama, "Comparison Study of Convolutional Neural Network Architecture in Aglaonema Classification," *International Journal of Electronics and Communications Systems*, vol. 2, no. 2, pp. 75–83, Dec. 2022, doi: 10.24042/ijecs.v2i2.13694.
- [31] T. Ojala, M. Pietikäinen, S. Member, IEEE, and T. Mäenpää, "Multiresolution Gray-Scale and Rotation Invariant Texture Classification with Local Binary Patterns," *IEEE Trans Pattern Anal Mach Intell*, vol. 24, no. 7, pp. 971–987, 2002.
- [32] G. Saleem, M. Akhtar, N. Ahmed, and W. S. Qureshi, "Automated analysis of visual leaf shape features for plant classification," *Comput Electron Agric*, vol. 157, 2019, doi: 10.1016/j.compag.2018.12.038.
- [33] J. Khan, A. S. Malik, N. Kamel, S. C. Das, and A. M. Affandi, "Effect of color feature normalization on segmentation of color images," in *International Conference on Intelligent and Advanced Systems, ICIAS 2016, 2017*. doi: 10.1109/ICIAS.2016.7824099.
- [34] B. S. Anami, N. M. Naveen, and P. Surendra, "Automated Paddy Variety Recognition from Color-Related Plant Agro-Morphological Characteristics," *International Journal of Image, Graphics and Signal Processing*, vol. 11, no. 1, 2019, doi: 10.5815/ijigsp.2019.01.02.
- [35] J. Su, M. Wang, Z. Wu, and Q. Chen, "Fast Plant Leaf Recognition Using Improved Multiscale Triangle Representation and KNN for Optimization," *IEEE Access*, vol. 8, pp. 208753–208766, 2020, doi: 10.1109/ACCESS.2020.3037649.
- [36] A. Çelik, "Improving Iris Dataset Classification Prediction Achievement by Using Optimum k Value of kNN Algorithm," *Eskişehir Türk Dünyası Uygulama ve Araştırma Merkezi Bilişim Dergisi*, vol. 3, no. 2, pp. 23–30, May 2022, doi: 10.53608/estudambilisim.1071335.

- [37] J. Li, J. Zhang, J. Zhang, and S. Zhang, "Quantum KNN Classification With K Value Selection and Neighbor Selection," *IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems*, May 2023, doi: 10.1109/TCAD.2023.3345251.
- [38] S. Zhang and J. Li, "KNN Classification With One-Step Computation," *IEEE Trans Knowl Data Eng*, vol. 35, no. 3, 2023, doi: 10.1109/TKDE.2021.3119140.
- [39] I. Al Saidi, M. Rziza, and J. Debayle, "A Novel Texture Descriptor: Circular Parts Local Binary Pattern," *Image Analysis and Stereology*, vol. 40, no. 2, 2021, doi: 10.5566/ias.2580.
- [40] R. Tekin, Ö. F. Ertuğrul, and Y. Kaya, "New Local Binary Pattern Approaches Based on Color Channels in Texture Classification," *Multimed Tools Appl*, vol. 79, no. 43–44, pp. 32541–32561, Nov. 2020, doi: 10.1007/s11042-020-09698-5.
- [41] M. Heikkilä, M. Pietikäinen, and C. Schmid, "Description of Interest Regions with Center-Symmetric Local Binary Patterns," 2006. doi: 10.1007/11949619_6.
- [42] Y. Yang, F. Duan, J. Jiang, L. Ma, and H. Zheng, "Robust Method for Interest Region Description Based on Local Intensity Binary Pattern," *J Electron Imaging*, vol. 26, no. 04, 2017, doi: 10.1117/1.jei.26.4.043025.
- [43] R. Tekin, Ö. F. Ertuğrul, and Y. Kaya, "New Local Binary Pattern Approaches Based on Color Channels in Texture Classification," *Multimed Tools Appl*, vol. 79, no. 43–44, 2020, doi: 10.1007/s11042-020-09698-5.