

IDENTIFIKASI GEJALA PENYAKIT TANAMAN JERUK MELALUI PENGOLAHAN CITRA

Maura Widyaningsih¹, Agus Harjoko²

¹STMIK Palangkaraya, Jl G. Obos No. 114 Palangka Raya

²Prodi S2/S3 Ilmu Komputer dan Elektronika; Sekip Utara Bulaksumur, (0274)555133

Jurusan Ilmu Komputer dan Elektronika, FMIPA UGM, Yogyakarta

e-mail: ¹maurawidya@gmail.com, ²aharjoko@ugm.ac.id

ABSTRAK

Pengolahan citra adalah trend terkini mendukung suatu pengenalan pola objek citra secara digital, dengan penerapan metode dan konsep dalam menginterpretasikan informasi menjadi pendukung data secara visual. Gejala penyakit pada tanaman dapat terlihat adanya noda pada area objek, sehingga dalam memudahkan pengenalan fitur yang digunakan adalah dengan tekstur, karena tanda penyakit dapat mengenai sekitar atau seluruh area obyek. Usulan yang dibangun diharapkan dapat memberikan solusi untuk melakukan identifikasi gejala suatu penyakit melalui pengolahan citra, dengan melibatkan konsep dan metode. Tahapan yang diterapkan dalam pengelolaan adalah preprocessing, feature extraction, dan identification. Metode preprocessing dilakukan dengan resize, clipping, penajaman tekstur dengan usharp mask filter dan konversi RGB ke gray. Feature extraction dengan metode Fast Fourier Transform (FFT) dan Local Binary Pattern (LBP). FFT merupakan ekstraksi cepat pada transformasi fourier, sedangkan LBP merupakan ekstraksi ciri dengan deskripsi pola pada citra gray. Proses identifikasi dengan metode Probabilistic Neural Network (PNN) dalam melakukan klasifikasi yang mendukung proses identifikasi terhadap penyakit tanaman, jumlah data yang digunakan 233, terbagi dalam 157 data latih dan 76 data uji. Hasil klasifikasi terhadap data latih menunjukkan hasil maksimal untuk semua citra batang, daun, dan buah. Sedang untuk data uji hasilnya tertinggi identifikasi pada penerapan ekstraksi ciri dengan FFT dibandingkan dengan LBP ataupun gabungan kedua ekstraksi ciri tersebut.

Kata kunci: *Penyakit Tanaman Jeruk , Pengolahan Citra, Fast Fourier Transform, Local Binary Pattern, Probabilistic Neural Network*

ABSTRACT

Image processing is the latest trend in supporting a digital image object pattern recognition, by applying methods and concepts in interpreting information to support data visually. Symptoms of disease in plants can be seen with stains on the object area, so that in facilitating the recognition of the features used is the texture, because signs of disease can affect the surrounding or the entire object area. The proposal that was built is expected to provide a solution to identify the symptoms of a disease through image processing, involving concepts and methods. The stages applied in the management are preprocessing, feature extraction, and identification. The preprocessing method is carried out by resizing, clipping, sharpening the texture with a usharp mask filter and converting RGB to gray. Feature extraction using the Fast Fourier Transform (FFT) and Local Binary Pattern (LBP) methods. FFT is a fast extraction in the Fourier transform, while LBP is a feature extraction with a description of the pattern in the gray image. The identification process using the Probabilistic Neural Network (PNN) method in conducting classifications that supports the identification process of plant diseases, the amount of data used is 233, divided into 157 training data and 76 test data. The classification results of the training data show the maximum results for all images of stems, leaves and fruit. As for the test data, the highest results were identified in the application of feature extraction with FFT compared to LBP or a combination of the two feature extractions.

Keywords: *Citrus diseases plant, Image Processing, Fast Fourier Transform, Local Binary Pattern, Probabilistic Neural Network*

Pendahuluan

Identifikasi yang dilakukan terhadap gejala penyakit tanaman rentan terhadap kesalahan saat melakukan diagnosis. Identifikasi terhadap gejala penyakit masih sulit dibedakan secara langsung dengan

pengamatan mata biasa, karena adanya kemiripan penyakit satu dengan yang lain. Terlebih lagi, jika harus mengamati banyak sampel data membutuhkan waktu untuk mengevaluasinya. Oleh karena itu dibutuhkan sistem untuk menangani solusi

identifikasi secara visual melalui pengolahan citra dengan menerapkan metode dan konsep yang berkaitan, disamping itu juga penghematan terhadap waktu hasil evaluasi data citra yang banyak.

Identifikasi dapat dilakukan berdasarkan fitur atau penciri dari suatu obyek berupa warna, bentuk dan tekstur. Pada penelitian ini fitur atau penciri yang digunakan adalah fitur tekstur dengan mempertimbangkan kemiripan pada noda dan spot antara gejala penyakit pada tanaman jeruk. Data yang digunakan akan terbagi dalam 70% sebagai data latih dan 30% sebagai data uji.

Obyek citra diakuisisi dan dilakukan *preprocessing* dengan *clipping*, penajaman citra dengan *unsharp mask filter*, kemudian konversi dari RGB ke citra gray. Citra gray akan diekstraksi ciri dengan metode *Fast Fourier Transform* (FFT) dan *Local Binary Pattern* (LBP) uniform rotation invariant. Hasil ekstrak ciri diklasifikasikan dengan algoritma pelatihan *Probabilistic Neural Network* (PNN) untuk mendapat hasil identifikasi. FFT dan LBP toleran terhadap perubahan rotasi, translasi dan penskalaan. PNN mempunyai kemampuan untuk mengeneralisasi, sehingga jaringan syaraf ini merupakan salah satu pilihan yang dapat digunakan dalam pemecahan masalah klasifikasi dan mengenali pola yang kompleks.

Sistem yang dibangun dikondisikan 4 jenis untuk identifikasi pada batang yang terkena jamur upas, embun jelaga, blendok dan normal. Pada daun 7 jenis yang terkena jamur upas, kudis, embun jelaga, CVPD, kanker, blendok dan normal. Pada buah 6 jenis yang terkena jamur upas, kudis, embun jelaga, CVPD, kanker dan normal

Banyak metode penelitian yang pernah dilakukan dibidang identifikasi tanaman yaitu penelitian oleh Kebapci dengan menggabungkan ekstraksi ciri warna, bentuk, dan tekstur. Data yang digunakan 380 citra tanaman hias pada daun dan bunga dengan 78 perbedaan. Metode untuk segmentasi menggunakan *Max-Flow Min-Cut* (MFMC), hasilnya akan dihitung dengan *Color Co-Occurrence Matrices* (CCOM). Ekstraksi ciri warna dengan *Content-based image retrieval* (CCOM), ekstraksi ciri bentuk dengan *Scale Invariant Feature Transform* (SIFT), ekstraksi tekstur dengan Gabor wavelets. Nilai akurasi 73% diperoleh dengan retrieval yang dilakukan 15 kali pengujian (Kebapci, 2014). Penelitian Kadir, dkk.

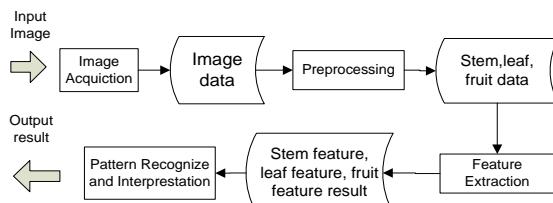
mengenai pengenalan daun-daun tanaman menggunakan ciri kombinasi *Polar Fourier Transform* (PFT), *Color Moment*, dan *Vein Feature*. *Preprocessing* merubah citra RGB ke gray. Hasil gray untuk menentukan threshold dengan menggunakan median. Transformasi citra dengan fungsi PFT, untuk menangkap informasi warna dengan Color Moment. Struktur ciri vena daun ditentukan dengan morfologi opening, dan similarity menggunakan *Eucledian Distance* (ED). Data yang digunakan 50 jenis tanaman dengan variasi warna, hasil pengenalan nilai akurasi 90.80% (Kadir, 2011). Penelitian oleh Arivazhagan, dkk mengenai deteksi bagian tidak sehat pada daun. Klasifikasi menggunakan ekstrak ciri Co-Occurrence. Obyek daun adalah tanaman buah jambu biji, pisang, lemon, kentang, tomat, mangga, nangka dan buncis. Akuisisi citra konversi RGB ke *Hue Saturation Intensity* (HIS). Ekstrak ciri menggunakan metode Color Co-Occurrence (CC) yang dihitung nilai *contrast*, *energy*, local *homogeneity*, *cluster shade* dan *prominence*. Klasifikasi menggunakan Minimum Distance Criterion (MDC) dan *Support Vector Machines* (SVMs). Hasil klasifikasi MDC 86.77%, dengan SVM 94.74% (Arivazhagan, et al, 2013). Penelitian oleh Herdiyeni dan Santoni mengenai kombinasi *Morological*, *Local Binary Pattern Variance* (LBPV) dan *Color Moments Features* (CMF) untuk identifikasi tanaman obat di Indonesia dengan menggunakan fitur ciri tekstur, bentuk dan warna. Ekstraksi ciri bentuk menggunakan Morological, ekstaksi ciri tekstur menggunakan LBPV dan ekstraksi ciri warna menggunakan CMF. Pengujian dengan 2.448 citra, dengan 51 spesies masing-masing 48 sampel dari tanaman obat di Indonesia. Kombinasi ciri dilakukan dengan menggunakan *Product Decision Rule* (PDR) dan klasifikasi menggunakan *Probabilistic Neural Network* (PNN). Nilai akurasi yang dihasilkan identifikasi LBPV 51,76%, Morology 17,84% , CMF 47,45%, dan LBPV+Morology 64,31% , LBPV+CMF 70,78%, Morology+ CMF 51,18% , dan LBPV+ Morology+ CMF 72,16% (Herdiyeni, 2012).

Metode

Dari beberapa sumber seperti menjelaskan gangguan penyakit pada tanaman bisa disebabkan oleh jamur, bakteri, dan virus (Pracaya, 2008). Dalam penelitian

ini gejala penyakit tanaman jeruk yang disebabkan oleh jamur dan bakteri, gejala-gejalanya penyerangan tidak sama antara penyakit satu dengan yang lain. Ada yang menyerang dari daun, dari batang dan dari buah, bahkan ada yang ketiganya (Anonymous, 2010).

Sistem identifikasi penyakit tanaman jeruk dibangun untuk menangani problem dengan pengolahan citra dan pengenalan pola. Citra yang diambil akan diolah secara komputerisasi untuk proses identifikasi, dan hasil evaluasi akhir adalah nilai akurasi terhadap identifikasi ekstraksi ciri yaitu FFT dan $LBP_{P,R}^{riu2}$ terhadap citra batang, daun, dan buah tanaman jeruk. (Widyaningsih dan Harjoko, 2014). Untuk menggambarkan keseluruhan dari pemrosesan sistem ditunjukkan pada Gambar 1.



Gambar 1 Diagram blok pemrosesan sistem

Preprocessing adalah proses awal citra untuk meningkatkan kualitasnya melalui peningkatan *contrast*, *sharpness*, warna, dan lainnya. *Preprocessing* yang dilakukan melalui *resize*, *clipping*, *unsharp mask filter*, dan konversi citra ke *grayscale*. *Resize* menentukan perubahan resolusi citra, *clipping* (pemotongan) untuk mengurangi ukuran piksel dan fokus pada area penyakit (Radikar, dkk, 2008). *Unsharp mask filter* dengan kernel Gaussian, untuk mempertajam tekstur citra, dan proses akhir konversi RGB ke gray.

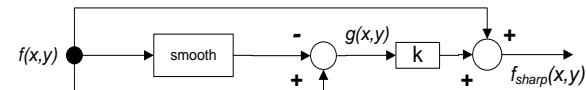
Persamaan (1) merupakan persamaan Gaussian untuk proses low-pass filter yang memerlukan variabel radius untuk pengontrolan tingkat kehalusan citra.

$$G(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{\frac{(x^2+y^2)}{2\sigma^2}}, \text{ dengan } \sigma = \text{deviasi standar}$$

(1)

Gambar 2 menunjukkan proses Unsharp mask filter, sebuah citra asli $f(x,y)$ akan dilakukan penghalusan (*smooth*) dengan fungsi filter lolos rendah, kemudian citra asli $f(x,y)$ dikurangi dengan citra smooth menghasilkan citra mask $g(x,y)$. Dari citra mask $g(x,y)$ akan dilakukan penajaman dengan mengalikan nilai konstanta k , kemudian ditambahkan

lagi hasilnya dengan citra asli $f(x,y)$, sehingga menghasilkan citra $f_{sharp}(x,y)$. Nilai k merupakan skala konstanta untuk meningkatkan kuantitas penajaman citra (Spring, dkk., 2016). Ada 3 parameter yang digunakan pada unsharp mask filter yaitu radius untuk penghalusan citra, nilai amount merupakan nilai konstanta k , dan *threshold* pengontrolan tingkat kecerahan pada citra.



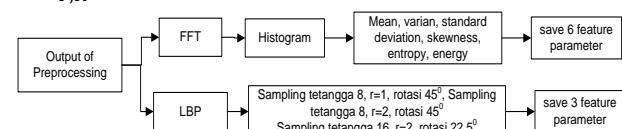
$$f_{sharp}(x,y) = f(x,y) + k * g(x,y)$$

Gambar 2 Pemrosesan *Unsharp Mask Filter*

Persamaan (2) menunjukkan konversi citra RGB ke gray dengan memberi bobot (w) pada RGB, karena mata manusia lebih sensitif pada warna hijau, kemudian merah, terakhir biru [10].

$$Y = 0.29900R + 0.58700G + 0.14400B \quad (2)$$

Gambar 3 menunjukkan proses ekstraksi ciri terhadap citra hasil preprocessing. Proses ekstraksi ciri akan dilakukan untuk semua data, baik data latih dan data uji untuk batang, daun, dan buah. Metode yang digunakan untuk ekstraksi ciri adalah FFT dan $LBP_{P,R}^{riu2}$.



Gambar 3 Diagram blok proses ekstraksi ciri

Fast Fourier Transform (FFT) merupakan metode yang dibuat untuk mempercepat komputasi alih ragam Fourier. FFT digunakan untuk mengurangi kompleksitas dari *Discrete Fourier Transform* (DFT), dimana di DFT sebesar $O(N^2)$ sedangkan FFT sebesar $O(N \log 2N)$ [10].

Hasil perolehan ciri FFT akan diperoleh histogram, yang merupakan suatu fungsi yang menunjukkan jumlah titik dalam suatu citra. Sumbu x (absis) menunjukkan tingkat warna, sumbu y (ordinat) menunjukkan frekuensi kemunculan titik. Definisi dari persamaan FFT, diberikan sinyal waktu dari $f(x)$, yang dapat diuraikan sebagai fungsi integral Fourier pasangan FFT [10] ditunjukkan oleh persamaan (3) :

$$F(u) = \int_{-\infty}^{\infty} f(x) \exp[-j2\pi ux] dx$$

$$\text{dan } f(x) = \int_{-\infty}^{\infty} F(u) \exp[j2\pi ux] du$$

(3)

dengan $j = \sqrt{-1}$

Persamaan (3) merupakan bilangan kompleks yang menentukan sudut fase dan power spektrum fourier. Untuk menentukan proposisional itensitas dari spektrum fourier yang memiliki dinamic range sangat besar, maka persamaan (4) berfungsi menormalisasi kondisi tersebut.

$$D(u, v) = c \log[1 + |F(u, v)|], c = \text{konstanta}$$

(4)

Dari nilai $D(u,v)$ hasil transformasi fourier dapat diperhitungkan histogramnya, yang akan menentukan nilai ciri [10], yang dihitung sebagai berikut :

1. *Mean (μ)*, menunjukkan ukuran dispersi dari suatu citra atau rerata kecerahan obyek. Untuk menghitung mean digunakan persamaan (5).

$$\mu = \sum_{i=0}^{L-1} f_i, \quad (5)$$

dengan f_i sebagai nilai itensitas keabuan dan P_i merupakan probabilitas kemunculan itensitas tersebut pada citra.

2. *Variance (σ^2)*, untuk menghitung varian yang berfungsi memberikan ukuran kekontrasan digunakan persamaan (6).

$$\sigma^2 = \sum_{i=0}^{L-1} (f_i - \mu)^2 P_i, \mu: \text{nilai mean} \quad (6)$$

3. *Standard Deviation (σ)*, menunjukkan tebing-tebing tajam (*strong edges*) ada citra. Untuk menghitung Standar Deviasi digunakan persamaan (7).

$$\sigma = \sqrt{\sum_{i=0}^{L-1} (f_i - \mu)^2 P_i} \quad (7)$$

4. *Skewness (α_3)*, menunjukkan tingkat kemencengen relatif kurva histogram dari suatu citra. Untuk menghitung Skewness digunakan persamaan (8).

$$\alpha_3 = \frac{1}{\sigma^3} \sum_{i=0}^{L-1} (f_i - \mu)^3 P_i \quad (8)$$

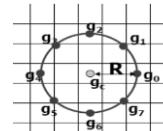
5. *Entropy (H)*, menunjukkan ukuran ketidakteraturan (kompleksitas) bentuk dari suatu citra. Untuk menghitung entropy digunakan persamaan (9).

$$H = - \sum_{i=0}^{L-1} P_i \cdot \log_2 P_i \quad (9)$$

6. *Energy (E)*, ukuran yang menyatakan distribusi intensitas piksel terhadap jangkauan aras keabuan. Untuk menghitung *energy* digunakan persamaan (10).

$$E = \sum_{i=0}^{L-1} P_i^2 \quad (10)$$

Metode dalam mendeskripsikan pola-pola tekstur secara lokal pada citra dengan mode warna *grayscale* (Sahu dan Bhanodia, 2013) *Local Binary Pattern* (LBP) menggunakan delapan ketetanggaan yang tersebar secara melingkar (*circular neighborhoods*) dengan pusat piksel berada di tengah seperti ditunjukkan pada Gambar 4, notasi g merupakan nilai gray level piksel ketetanggaan. Rataan seluruh level piksel ketetanggaan. Rataan seluruh piksel (piksel ketetanggaan dan piksel pusat) digunakan sebagai nilai ambang batas (threshold) untuk memotong setiap nilai ketetanggaan (Pietikainen dkk.,2011).

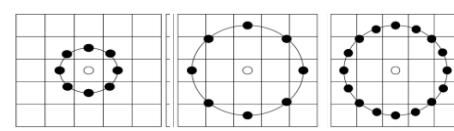


Gambar 4 *Circular neighborhood* delapan sampling points

Tanpa menghilangkan informasi, pola transisi yang dapat dibentuk untuk proses perhitungan ke bentuk bit dengan memperhatikan bin-bin ketetanggaan , misalkan menggunakan 8 titik ketetanggaan :

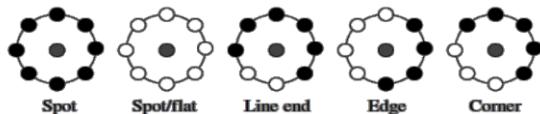
$$T \approx p(s(g1-g0), s(g2-g0), s(g3-g0), s(g4-g0), \dots, s(g8-g0)).$$

Operator LBP mengalami perkembangan dengan dimodelkannya operator menggunakan berbagai ukuran *sampling points* dan radius. Gambar 5 memperlihatkan contoh *circular neighborhood* tiga operator yaitu ketetanggaan 8 jari-jari 1(8,1), ketetanggaan 16 jari-jari 2(16,2), dan ketetanggaan 8 jari-jari 2 (8,2).



Gambar 5 Beberapa ukuran *Circular Neighborhood*

Uniform pattern berfungsi untuk mengidentifikasi noda (spot), flat area atau dark spot, sudut dan tepi (Pietikainen dkk.,2011). Hampir semua 90 persen dari tekstur merupakan *uniform pattern*, seperti ditunjukkan pada Gambar 6.



Gambar 6 Tekstur uniform pattern

Untuk mengidentifikasi uniform pattern digunakan formulasi dengan persamaan (11)

$$U(LBP_{P,R}) = | s(g_{p-1} - g_c) - s(g_0 - g_c) | + \sum_{p=1}^{P-1} | s(g_p - g_c) - s(g_{p-1} - g_c) | \quad (11)$$

$U(LBP_{P,R})$ merupakan uniform pattern dari P banyaknya sampling points dan radius R, p adalah circular sampling points, gp adalah nilai keabuan dari p, dan gc adalah nilai keabuan rata-rata seluruh piksel neighborhood (Pietikainen dkk.,2011).

Jumlah pola yang dihasilkan uniform patterns adalah $P(P-1) + 2$ bins. Ketika uniform pattern di rotasi sampai ke nilai minimum yang dimilikinya, jumlah pola yang dihasilkan menjadi $P+1$ bins. Rotation invariant uniform patterns diformulasikan dengan persamaan (12).

$$LBP_{P,R}^{riu2} = \begin{cases} \sum_{p=1}^{P-1} s(g_p - g_c), & \text{if } U(LBP_{P,R}) \leq 2 \\ p + 1 & \text{, selainnya} \end{cases} \quad (12)$$

Jika pola yang diidentifikasi termasuk uniform patterns, akan dihitung banyaknya bit satu pada pola tersebut yang menentukan letak bin uniform patterns berada. Jika bukan uniform patterns, akan masuk dalam bin terakhir yang telah dilabelkan (Pietikainen dkk.,2011).

Rotation invariance adalah sesuatu cara yang dibuat agar pola-pola LBP tidak sensitif terhadap perubahan rotasi. *Rotation invariance* didefinisikan sebagai nilai minimum dari rotasi (ROR). P-bit biner yang dilakukan sebanyak i kali, persamaan (13) merupakan proses untuk *rotation invariance*

$$LBP_{P,R}^{riu2} = \min\{ROR(LBP_{P,R}^i) \mid i = 0, 1, \dots, P-1\} \quad (13)$$

dengan ri menunjukkan rotation invariance. Fungsi $ROR(x, i)$ merupakan pergeseran circular P-bit nilai biner xi sewaktu ke kanan ($|i| < P$). Untuk nilai biner x ditunjukkan pada persamaan (14).

$$x = \sum_{k=0}^{P-1} 2^k a_k, \quad a_k \in \{0,1\} \quad (14)$$

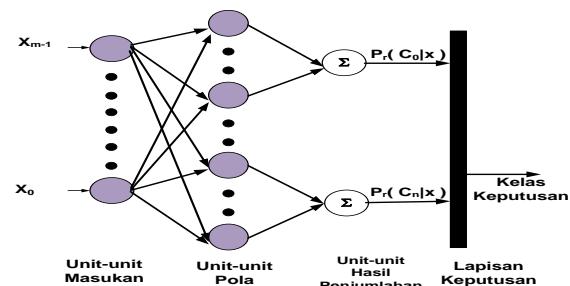
Pattern recognize merupakan proses temu kembali terhadap objek yang akan dikenali dengan proses pelatihan dan pengujian data hasil ekstraksi ciri. Image Interpretation memberikan arti pada objek yang sudah berhasil dikenali dari hasil pelatihan dan pengujian data, keberhasilan pengujian ditentukan oleh parameter nilai akurasi.

Probabilistic Neural Network (PNN) merupakan salah satu model pembelajaran *supervised* (terbimbing) untuk klasifikasi pola dengan aturan pengambilan keputusan yang meminimalkan suatu resiko (Suyanto dalam Widyaningsih dan Harjoko, 2014). PNN merupakan teorema probabilitas klasik (pengklasifikasian Bayes), model yang dibentuk berdasarkan penaksir fungsi padat peluang. *Training* data PNN mudah dan cepat, karena dilakukan hanya dalam satu tahap pelatihan. Persamaan (15) merupakan persamaan nilai penaksir fungsi peluang dengan metode *Gaussian*, dimana tiap kelas dapat memiliki parameter penghalus (σ_k) seperti ditunjukkan pada persamaan (16).

$$p(x|C_k) \approx \frac{1}{(2\pi)^{m/2} \sigma_k^m |C_k|} \sum_{\rho_i \in C_k} \exp \left[\frac{-||x - w_i||^2}{2\sigma_k^2} \right] \quad (15)$$

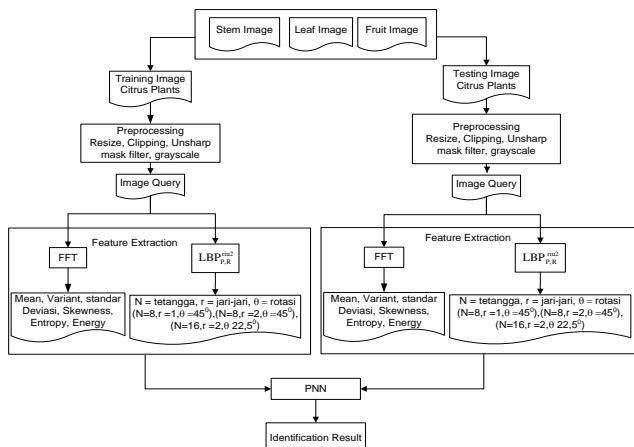
$$\sigma_k = g \cdot d_{avg}[k], \text{ dimana } d_{avg}[k] = \frac{1}{|C_k|} \sum_{\rho_i \in C_k} d_i \quad (16)$$

di mana $|C_k|$: jumlah pola latih pada kelas C_k , dan m merupakan dimensi vektor pola masukan, w_i adalah vektor bobot pada pola latih ke- i , $d_{avg}[k]$ merupakan rata-rata jarak minimum antar vektor pada kelas C_k , dan g adalah nilai konstanta. Nilai penghalus σ_k menyebabkan jaringan bekerja otomatis membentuk parameter setiap kelas pada proses tahap kedua. Penentuan pemilihan peluang $Pr(C_k|x)$ paling besar yang akan terpilih sebagai hasil akhir pengambilan keputusan.



Gambar 7 Arsitektur JST Probabilistik (PNN)

Gambar 8 menunjukkan skema pemrosesan citra yang diawali dengan pengumpulan kebutuhan data yang dibutuhkan seperti citra daun, batang dan buah hingga proses akhir dari pengujian.



Gambar 8 Skema identifikasi pemrosesan penyakit tanaman jeruk

Hasil Dan Pembahasan

Citra yang digunakan dalam penelitian berjumlah 233 citra, 70% akan digunakan untuk data latih, dan 30% untuk data uji. Citra penyakit yang akan diteliti adalah Jamur Upas, Kudis, Embun Jelaga, CVPD, Kanker, Blendok dan normal. Batang diklasifikasi menjadi 4 kelas, daun 7 kelas, dan buah 5 kelas. Jumlah data latih batang 38 buah dan data uji 17 buah, jumlah data latih daun 70 buah dan data uji 35 buah, jumlah data latih buah 49 buah dan data uji 24 buah.

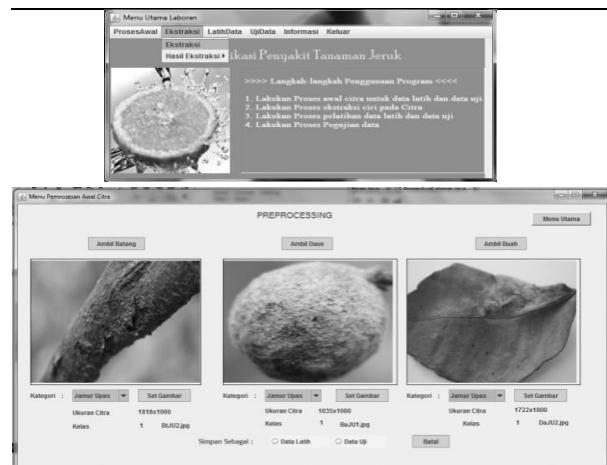
Sistem dibangun dengan melalui tahapan proses awal terlebih dahulu terhadap semua citra sebelum dilakukan ekstraksi ciri, manajemen awal dilakukan agar semua citra tersimpan dengan baik, sehingga memudahkan proses selanjutnya. Gambar 9 merupakan sebagian gambaran sistem yang dibangun dalam penelitian ini, dalam menu utama tersedia tahapan pemrosesan citra dari *preprocessing*, *feature extraction*, dan *identification*.

Pada langkah awal semua citra baik batang, daun dan buah akan dilakukan manajemen awal *preprocessing*, hasilnya akan tersimpan sebagai citra queri untuk tahapan proses *feature extraction*. Hasil *feature extraction* akan tersimpan sebagai data ciri berupa nilai diskrit, yang akan digunakan untuk tahapan proses pelatihan.

Tabel 1 menunjukkan parameter nilai yang digunakan pada proses *clipping* dan *unsharp mask filter* pada data citra.

Tabel 1 Rincian parameter nilai pemrosesan awal citra

Data	Ukuran clipping	Unsharp Mask Filter
Batang	Lebar = 350, Tinggi = 460, X = 90, Y = 80	Amount = 150 ,Radius = 150, Treshold = 40
Daun	Lebar = 320, Tinggi = 250, X = 70, Y = 110	Amount = 150, Radius = 150, Treshold = 40
Buah	Lebar = 325, Tinggi = 300, X = 100, Y = 90	Amount = 140, Radius = 3, Treshold = 5

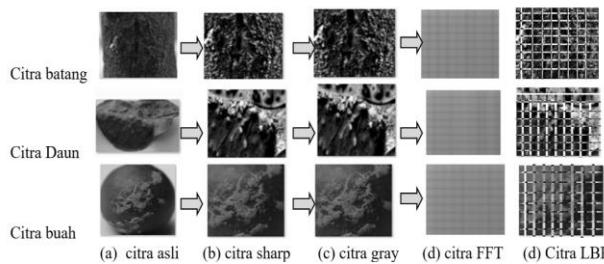


Gambar 9 Sistem identifikasi gejala penyakit tanaman jeruk

Proses akuisisi citra merupakan proses pengambilan objek dari kamera digital, dan disimpan dalam format ".jpg". Citra hasil akuisisi yang telah tersimpan dalam database akan dilakukan proses awal meliputi *resize*, *clipping*, penajaman tekstur citra dengan *unsharp mask filter*, dan konversi RGB ke *grayscale*. Hasil *preprocessing* adalah citra *gray* dengan dengan tekstur tajam berukuran 500x500 piksel, kemudian dilakukan ekstraksi ciri dengan FFT dan LBP terhadap data latih dan data uji. Untuk batang, daun, dan buah.

Nilai probabilitas frekuensi yang diperoleh dari hasil histogram FFT, untuk menentukan penciri *mean*, *variance*, *standard deviation*, *skewness*, *entropy*, dan *energy*. Ekstraksi $LBP_{P,R}^{iu^2}$, di-sampling dalam ukuran 3x3 untuk (8, r=1, ror = 450), dan 5x5 untuk (8, r= 2, ror = 450), dan 5x5 untuk (16, r=2, ror= 22,50). Setiap blok *sampling* akan diproses ke dalam bentuk biner berdasarkan batas *treshold* piksel tengah. Pola setiap blok yang *uniform* diproses lanjut dan dihitung bobot

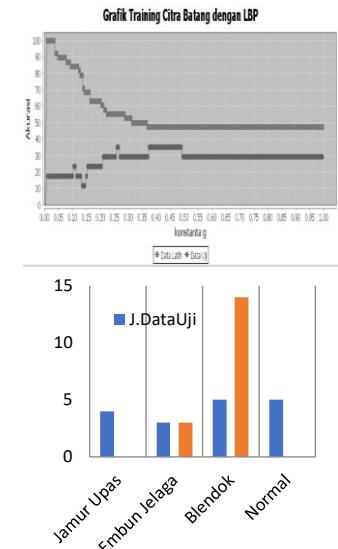
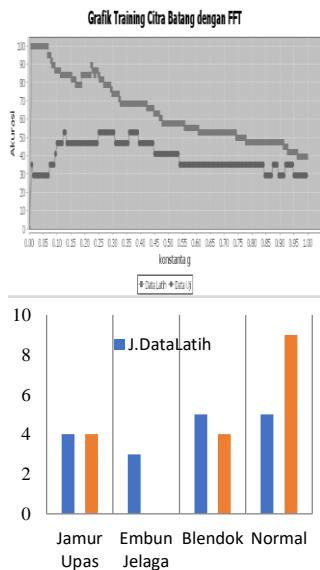
biner pada setiap rotasi , nilai minimal bobot biner setiap rotasi menentukan nilai blok tersebut. Rata-rata seluruh nilai minimal blok merupakan penciri dari citra. Hasil ekstraksi ciri akan disimpan dalam *database* untuk dilakukan proses pelatihan dan pengujian. Untuk contoh *preprocessing* hingga ekstraksi ciri citra dapat dilihat pada Gambar 10.



Gambar 10 Contoh pemrosesan awal citra dan ekstraksi ciri dengan FFT dan LBP

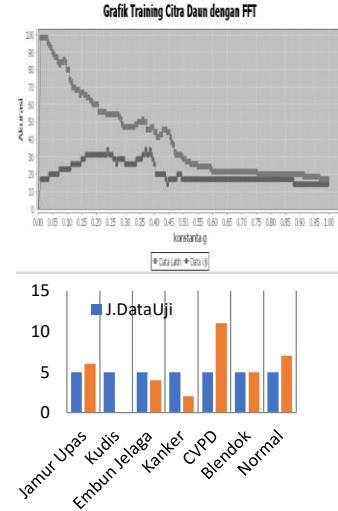
Pelatihan dilakukan dengan memberi batasan konstanta g, batas bawah 0.01 dan batas atas 1 dengan interval step 0.005 pada setiap pengujian terhadap batang, daun dan buah dengan FFT dan LBP baik untuk data latih maupun data uji.

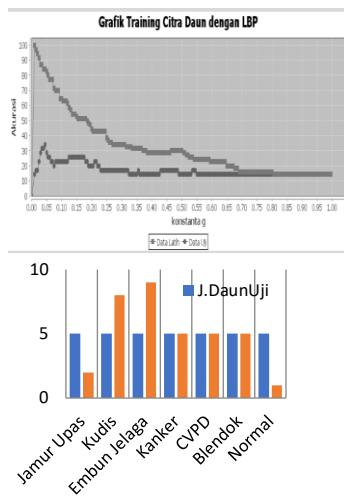
Gambar 10 menunjukkan pengujian PNN hasil ekstrasi FFT pada batang, yang dapat dilihat hasilnya yang digambarkan dalam bentuk grafik batang dan plot pengujian data latih dan data uji, konstanta g pada plot data latih digunakan dalam pengujian data.



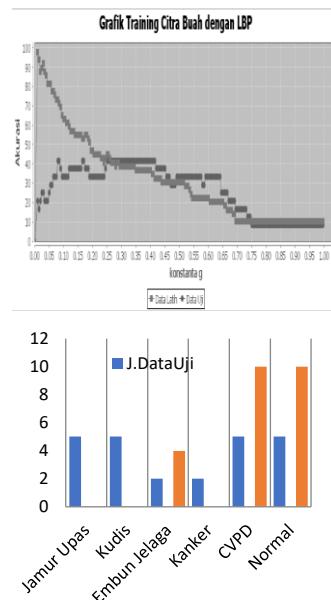
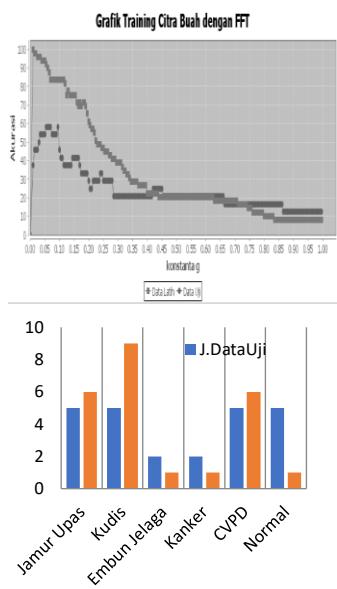
Gambar 10 Pelatihan data batang

Gambar 11 menunjukkan pengujian PNN hasil ekstrasi FFT pada daun, seperti halnya pada pengujian batang, untuk plot training konstanta g digunakan untuk pengujian data daun. Gambar 12 menunjukkan pengujian PNN hasil ekstrasi FFT pada buah.





Gambar 11 Pelatihan data daun



Gambar 12 Pelatihan data buah

Hasil pengujian pada batang menunjukkan dengan ekstraksi FFT bahwa embun jelaga sulit diidentifikasi, pada LBP jamur upas mengalami hal yang sama sulit diidentifikasi dan kecenderungan dikenali sebagai kelas lain. Kelas normal mendominasi identifikasi ekstraksi dengan FFT, sedangkan kelas blendok mendominasi pada proses identifikasi $LBP_{P,R}^{riu^2}$.

Hasil pengujian pada daun menunjukkan dengan ekstraksi FFT pada kelas kudis sulit diidentifikasi, sementara dengan $LBP_{P,R}^{riu^2}$ ada sebagian kelas dikenali sebagai kelas lain. Kelas CVPD dan normal mendominasi identifikasi ekstraksi dengan FFT, kelas kudis dan embun jelaga mendominasi proses $LBP_{P,R}^{riu^2}$.

Hasil pengujian pada buah menunjukkan dengan ekstraksi FFT ada sebagian kelas dikenali sebagai kelas lain, sementara dengan LBP kelas jamur upas, kudis dan kanker sulit diidentifikasi dan dikenali sebagai kelas lain. Kelas jamur upas, kudis, dan CVPD mendominasi identifikasi ekstraksi dengan FFT, kelas embun jelaga, CVPD dan normal mendominasi proses $LBP_{P,R}^{riu^2}$.

Kompleksitas pengenalan kelas masih terjadi saat pengujian data uji, sehingga masih sulit dibedakan, hal ini karena adanya kemiripan nilai ciri tiap kelas dengan kelas yang lain.

Akurasi yang rendah pada data uji dapat menyebabkan hasil identifikasi kurang optimal, dengan melihat hasil yang ditunjukkan pada grafik bahwa ada beberapa kelas kurang dikenali, cenderung dikenali sebagai kelas lain. Hasil nilai ciri citra yang dekat dengan kelas lain, menyebabkan sulit untuk membedakan dan mengenali kelasnya sendiri, pada akhirnya akan mempengaruhi hasil identifikasi. Penanganan akuisisi dan proses awal citra input berpengaruh terhadap hasil nilai ciri yang diperoleh, dan menentukan hasil identifikasi yang sesuai atau tidak.

Simpulan dan Saran

Simpulan

1. Pengujian terhadap data uji pada batang dengan ekstraksi FFT dan LBP terhadap data latih dikenali untuk semua data, namun saat pengujian data mengalami pergeseran kelas dikenali sebagai kelas lain pada kasus embun jelaga dengan FFT sehingga masih dianggap kelas normal, sedangkan Jamur upas dengan LBP cenderung dikenali kelas blendok.
2. Pengujian terhadap data uji pada daun dengan ekstraksi FFT dengan LBP dikenali semua kelas, sementara FFT pada kelas kudis sulit diidentifikasi namun CVPD dan normal mendominasi identifikasi, sementara dengan LBP kelas kudis dan embun jelaga mendominasi identifikasi.
3. Masih ada beberapa kelas sulit teridentifikasi, kelas jamur upas, kudis, dan CVPD mendominasi identifikasi ekstraksi dengan FFT. Kelas embun jelaga, CVPD dan normal mendominasi proses LBP, namun kelas jamur upas, kudis dan kanker sulit diidentifikasi
4. Nilai konstanta g pelatihan terhadap pengujian batang latih diperoleh pada interval kurang lebih pada 0.01 sampai 0.06. Nilai konstanta pelatihan terhadap pengujian batang uji dari hasil akurasi maksimal adalah $g = 0.39$ dengan menggunakan ekstraksi ciri FFT. Pengujian pada daun hasil akurasi sama antara FFT dan LBP, dengan FFT diperoleh $g = 0.39$, LBP diperoleh $g = 0.04$. Pengujian terhadap buah hasil akurasi maksimal diperoleh nilai $g = 0.10$ dengan ekstraksi ciri FFT.
5. Identifikasi masih belum menunjukkan akurasi yang baik, secara keseluruhan belum optimal untuk proses identifikasi data uji, masih ada

sebagian data tidak mengenali kelasnya, karena adanya kemiripan dengan kelas lain

Saran

1. Pengembangan pada *preprocessing* khususnya di *enhancement* pada pemrosesan latar belakang dengan area spot, sehingga dominasi warna dapat direduksi sehingga dapat membantu perbedaan kelas.
2. Pengembangan metode untuk *feature extraction* tekstur lain, misalnya dengan domain spasial ataupun frekuensi lain, dan LBP dengan metode lain sehingga memberikan informasi yang baik pada hasil identifikasi.
3. Perlu dikembangkan metode pelatihan lain dari *Neural Network* misalnya secara *unsupervised learning* atau *supervised learning*, sehingga identifikasi lebih memberikan nilai akurasi yang baik.

Pustaka Acuan

- Arivazhagan, S., Shebiah, R.N., Ananthi, S., dan Varthini S.V. (2013) Maret. Detection of Unhealthy Region of Plant Leaves and Classification of plant Leaf Diseases using Texture Feature. Department of Electronics and Communication Engineering.
- Anonymous. (2010). Penyakit Penting Pada Tanaman Jeruk - Agricultur Product, www.agriculturproduct.blogspot.com/2010/11/penyakit-penting-pada-tanaman-jeruk, diakses 18 Februari 2014
- Spring, KR., Russ, JC., Parry-Hill, MJ., Fellers, TJ., Davidson, MW. (2016). *Unsharp Mask Filtering*, <https://micro.magnet.fsu.edu/primer/java/digitalimaging/processing/unsharpmask/index.html>.
- Gonzales, R., Woods, R.E. (2008). Digital Image Processing. Third Edition. Pearson Education. Prentice-Hall. Inc.
- Herdiyeni, Y., Santoni, M.M. (2012). Combination of Morphological, Local Binary Pattern Variance and Color Moments Features for Indonesian Medicinal Plants Identification, dalam jurnal ICACSIS. ISBN : 978-979-1421-15-7. Jurusan Ilmu Komputer. Fakultas MIPA. Universitas Pertanian. Bogor.
- Kadir, A., Nugroho, L.E, Susanto, A., dan Santosa, P.I. (2011). 3 September 2011. Folliage Plant

- Retrieval Using Polar Fourier Transform. Color Moments And Vein Features. dalam jurnal Signal dan Image Processing An International (SIPIJ), Vol.2, Jurusan Teknik Elektro . Universitas Gadjah Mada, Yogyakarta.
- Kadir, A., dan Susanto, A. (2012). Teori dan Aplikasi Pengolahan Citra, penerbit Andi Offset. Yogyakarta.
- Kebapci, H., Yanikoglu B., dan Unal G. (2010) 9 April. Plant Image Retrieval Using Color, Shape, and Texture Features. Faculty of Engineering and Natural Sciences Sanbaci University. Istanbul.Turkey.
- Pracaya (2008). Hama dan Penyakit Tanaman, Penebar Swadaya. ISBN 979-489-098-7, Jakarta. www.books.google.com, diakses 11 September 2013.
- Sahu, H. dan Bhanodia, P., (2013), An Analysis of texture classification : Local Binary Pattern, *Journal of Global Research in Computer Science (JGRCS)*, Volume 4, No. 5, May 2013, www.jgrcs.info.
- Pietikainen, M., Zhao G., Hadid A., dan Ahonen T., (2011). Computer Vision Using Local Binary Patterns. Springer London Dordrecht Heidelberg. New York.
- Radikar, S., dan Sil,J. (2008). Rice Disease Identification using Pattern Recognition Techniques, Internastional Conference on Computer and Information Technology 2. West Bengal University of Technology. India.
- Widyaningsih, M. dan Harjoko, A. (2014). Identifikasi Gejala Penyakit Tanaman Jeruk Menggunakan Fast Fourier Transform dan Local Binary Pattern dengan Probabilistic Neural Network. Tesis. http://etd.repository.ugm.ac.id/index.php/home/detail_pencarian/73454