



Tersedia online di www.journal.unipdu.ac.id

Unipdu

Halaman jurnal di www.journal.unipdu.ac.id/index.php/register



Klasifikasi penyakit noda pada citra daun tebu berdasarkan ciri tekstur dan warna menggunakan *segmentation-based gray level cooccurrence matrix* dan *LAB color moments*

Evy Kamilah Ratnasari ^a, Raden Venantius Hari Ginardi ^b, Chastine Fatichah ^c

^a Teknik Informatika, Universitas Dr. Soetomo, Surabaya, Indonesia

^{b,c} Teknik Informatika, Institut Teknologi Sepuluh Nopember, Surabaya, Indonesia

email: ^aevykamilah@gmail.com, ^bhari.ginardi@gmail.com, ^cchastine.fatichah@gmail.com

INFO ARTIKEL

Sejarah artikel:

Menerima 6 Oktober 2016
Revisi 20 November 2016
Diterima 20 November 2016
Online 13 Februari 2017

Kata kunci:

Citra daun tebu
Color moments
GLCM
Penyakit noda
Segmentasi

Keywords:

Color moments
GLCM
Segmentation
Spot disease
Sugarcane leaf image

Style APA dalam mensitasi artikel ini:

Ratnasari, E. K., Ginardi, R. V., & Fatichah, C. (2017). Klasifikasi penyakit noda pada citra daun tebu berdasarkan ciri tekstur dan warna menggunakan *segmentation-based gray level cooccurrence matrix* dan *lab color moments*. *Register: Jurnal Ilmiah Teknologi Sistem Informasi*, 3(1), 1-10.

ABSTRAK

Penyakit noda pada daun tanaman tebu menampilkan gejala berupa lesi atau bercak. Lesi tersebut menghambat proses fotosintesis daun dan dapat mengakibatkan menurunnya produksi gula. Oleh karena itu, dalam meningkatkan kualitas produksi gula dibutuhkan diagnosa dini untuk mengambil keputusan penanganan penyakit yang cepat dan tepat, sehingga dapat meminimalisir kerusakan daun yang signifikan akibat penyebaran penyakit tersebut. Sayangnya keterbatasan keberadaan ahli penyakit tanaman tebu yang berpotensi dalam mendiagnosa penyakit noda tidak dapat mengatasi hal tersebut. Penelitian ini mengusulkan diagnosa penyakit noda tanaman tebu menggunakan metode pemrosesan citra berdasarkan fitur tekstur *Segmentation-based Gray Level Co-Occurrence Texture* (SGLCM) dan *LAB color moments*. Metode yang diajukan terdiri dari ekstraksi ciri warna pada citra masukan yang akan menghasilkan 12 fitur warna dan ekstraksi ciri tekstur pada citra masukan yang tersegmentasi dan menghasilkan 24 fitur tekstur, kemudian gabungan fitur warna dan tekstur tersebut digunakan sebagai masukan klasifikasi *k-Nearest Neighbor* (kNN) untuk mengenali jenis penyakit noda pada citra daun tanaman tebu. Jenis penyakit noda terdiri dari noda cincin, noda karat, dan noda kuning yang memiliki karakteristik berbeda. Klasifikasi penyakit noda pada tanaman tebu menggunakan metode tersebut dapat menghasilkan akurasi tertinggi 93%.

ABSTRACT

The sugarcane spot disease attack the sugarcane with appear as spots on the leaves, so this spots prevent the vital process of photosynthesis to take place and caused sugar production losses. Early diagnosis of this spot disease can improve the quality of sugar production. The diagnosis result can be used as decision reference to control the disease fast and accurately to minimize attack severe that can caused significant damage. Unfortunately, experts who are able to identify the diseases are often unavailable. This research attempted to identify the three sugarcane spot diseases (ring spot, rust spot, and yellow spot) using Segmentation-based Gray Level Co-Occurrence Texture (SGLCM) and LAB color moments. The SGLCM obtain 24 texture features of segmented image and color moments obtain 12 color features. This method achieved at least 93% accuracy when identifying the diseases using kNN classifier.

© 2017 Register: Jurnal Ilmiah Teknologi Sistem Informasi. Semua hak cipta dilindungi undang-undang.

1. Pendahuluan

Penyakit pada tanaman tebu yang disebabkan oleh jamur akan menyerang daun dengan menimbulkan infeksi berupa lesi atau bercak pada daun yang disebut dengan penyakit noda. Lesi yang ditimbulkan oleh penyakit noda tersebut dapat merusak daun dan menghambat proses fotosintesis yang dibutuhkan oleh daun untuk proses produksi. Menurut penelitian (Sa'diyah & Aeny, 2012), kerusakan area daun

yang merupakan ambang kehilangan hasil yang signifikan yaitu 15%. Diagnosa dini yang dilakukan pada tanaman tebu yang terserang penyakit noda dapat meningkatkan kualitas produksi gula. Hal tersebut karena keputusan penanganan penyakit yang cepat dan tepat berdasarkan diagnosa yang telah dilakukan akan meminimalisir penyebaran penyerangan penyakit. Sayangnya ahli penyakit yang memiliki pengetahuan dalam mengenali penyakit pada tanaman tebu keberadaannya tidak pada semua wilayah persawahan tebu dan pelayanan dari ahli tersebut membutuhkan waktu yang lama (Vibhute & Bodhe, 2012). Hal tersebut dapat diatasi dengan adanya visi komputer yang dapat mengatasi ketergantungan ahli penyakit dalam mengenali penyakit tersebut menggunakan teknik klasifikasi otomatis berdasarkan perubahan fisik daun yang menampakkan lesi dari suatu jenis penyakit. Lesi yang direkam menggunakan kamera digital akan menghasilkan citra yang dapat diproses dan digunakan untuk mengenali jenis penyakit noda secara otomatis, cepat, mudah, murah dan akurat (Vibhute & Bodhe, 2012) (Rathod, Tanawal, & Shah, 2013).

Pada penelitian (Sungkur, Baichoo, & Poligadu, 2013) melakukan pengenalan penyakit noda coklat, kuning, cincin dan karat pada tanaman tebu telah dilakukan berdasarkan ciri bentuk dari lesi penyakit noda dan menghasilkan akurasi rata-rata 95,3%. Lesi dari suatu penyakit noda secara kasat mata dapat dibedakan dari warna, tekstur, dan bentuk. Tetapi beberapa kasus lesi suatu penyakit noda yang ditemui dalam penelitian ini yang memiliki warna dan tekstur berbeda, menampakkan bentuk lesi yang berulang sehingga membentuk pola yang tidak beraturan. Pengenalan penyakit pada padi yang dilakukan pada penelitian (Asfarian, Herdiyeni, Rauf, & Mutaqin, 2013) menggunakan informasi ciri warna dan tekstur. Penelitian tersebut mengidentifikasi penyakit berdasarkan ciri warna berupa komponen "S" dari ruang warna HSV dan ciri tekstur menggunakan *fractal descriptor* berdasarkan *fourier spectrum* menghasilkan akurasi 83%. Penggunaan kombinasi fitur warna dan tekstur juga dilakukan pada beberapa penelitian dalam mengenali jenis penyakit noda. Penelitian (Huang, 2007) menggunakan fitur tekstur yang didapatkan dari *Gray Level Co-Occurrence Matrix* (GLCM) dan fitur warna *mean* dari masing-masing komponen RGB untuk mendeteksi penyakit *Phalaenopsis* dengan akurasi 89.6%. Penelitian tersebut menggunakan *Back-Propagation Neural Network* (BPNN) sebagai klasifikasi pada citra yang tersegmentasi menggunakan *exponential transform* dengan parameter tertentu dan teknik pemrosesan citra seperti operasi *hole-filling*, erosi, dilasi, *opening* dan *closing*. Selain itu, penelitian (Bashish, Braik, & Ahmad, 2010) menggunakan fitur tekstur *color co-occurrence matrix* dan fitur warna H dan S dari komponen warna HIS untuk mendiagnosa dan mengklasifikasi penyakit pada daun dan batang tanaman yang menghasilkan presisi klasifikasi *Neural Network* sebesar 93% pada citra yang tersegmentasi menggunakan klastering *k-Means*. Sedangkan penggunaan *co-occurrence matrix* pada warna *Hue* dari komponen HIS untuk mendeteksi penyakit daun anggur dilakukan oleh penelitian (Meunkaewjinda, Kumsawat, Attakitmongcol, & Srikaew, 2008). Penelitian tersebut mengekstraksi tekstur area berlesi menggunakan klastering *k-means* pada komponen "AB" dari ruang warna LAB yang digunakan dalam klasifikasi BPNN. Penelitian lain yang melakukan perbandingan segmentasi area lesi yaitu (Chaudhary, Chaudhari, Cheeran, & Godara, 2012) menggunakan *thresholding* komponen "A" dari ruang warna LAB dapat menghasilkan segmentasi lesi yang akurat. Hal tersebut dikarenakan komponen "A" lebih baik dalam menampakkan gejala penyakit dibandingkan dengan menggunakan ruang warna HIS dan YCbCr.

Oleh karena itu, penelitian ini mengusulkan metode pengenalan penyakit noda pada daun tebu berupa melalui citra yang telah tersegmentasi bagian lesi daun, kemudian dari citra lesi yang tersegmentasi tersebut diekstraksi untuk mendapatkan ciri tekstur dan warna sebelum dilakukan pengenalan jenis lesi menggunakan teknik klasifikasi. Untuk mendapatkan bagian lesi dari suatu citra daun, segmentasi dilakukan menggunakan *thresholding* komponen "A" dari ruang warna LAB. Sedangkan lesi yang telah didapatkan kemudian diekstraksi untuk mendapatkan ciri tekstur GLCM atau dalam penelitian ini disebut dengan *Segmentation-based Gray Level Co-Occurrence Texture* (SGLCM) dan ciri warna *color moments* pada ruang warna LAB. Kedua ciri tekstur dan warna tersebut kemudian digunakan dalam pengenalan penyakit noda cincin, noda karat, dan noda kuning pada citra daun tanaman tebu menggunakan teknik klasifikasi. Kombinasi ciri tersebut digunakan karena ruang warna LAB merupakan ruang warna yang representatif dalam menginterpretasikan permukaan citra buah atau sayuran (Mendoza, Dejmek, & Aguilera, 2006), sedangkan analisis *color moment* merepresentasikan

ciri warna yang diekstraksi dari informasi citra menggunakan perhitungan statistik (Kadir, Nugroho, Susanto, & Santosa, 2013). Sedangkan metode klasifikasi yang digunakan yaitu *k-Nearest Neighbor* (kNN) dan evaluasi berupa akurasi untuk mengetahui performa dari pengenalan jenis penyakit tersebut.

2. Penyakit Noda pada Daun Tanaman Tebu

Penyakit pada tanaman tebu dapat disebabkan oleh bakteri, jamur maupun virus. Penyakit pada tanaman tebu yang disebabkan oleh jamur dinamakan penyakit noda. Penyakit tersebut terdiri dari noda karat, noda cincin, noda kuning dan *leaf scorch* yang memiliki ciri unik yang dapat dibedakan secara visual oleh mata manusia. Sedangkan dalam penelitian ini penyakit yang diidentifikasi merupakan penyakit-penyakit penting yang terdapat pada bagian daun yaitu noda karat, noda kuning dan noda cincin (Rott, 2000).

2.1. Penyakit noda cincin

Penyakit noda cincin menampilkan lesi berbentuk lonjong memanjang dengan lingkaran berwarna kuning dengan gejala awal terbentuk dari hijau tua menjadi kecoklatan, kemudian lesi melebar dan bagian tengah lesi menjadi kekuning-kuningan dengan tepi yang terlihat jelas berwarna merah kecoklatan. Lesi tersebut terutama terjadi pada helai daun tetapi dapat terjadi pada pelepah daun dan memiliki ukuran yang bervariasi yaitu dari $(1 - 5) \times (4 - 18)$ mm. Penyakit noda cincin yang disebabkan oleh tiga cendawan yaitu *Heptosphaeria sacchari*, *Helminthosporium sacchari* dan *Phyllsticta Saghina* pada umumnya tidak hanya terjadi pada daun yang berumur tua, tetapi juga daun yang berumur lebih muda (Rott, 2000). Gejala yang ditampakan oleh penyakit noda cincin pada daun seperti ditunjukkan pada Gambar 1(a).

2.2. Penyakit noda karat

Orange rust dan *common rust* merupakan dua jenis penyakit karat yang terjadi pada daun tebu. Penyakit ini menampilkan gejala berupa bercak noda pada bagian permukaan bawah daun dengan panjang $2\text{ mm} - 20\text{ mm}$ dan lebar $1\text{ mm} - 3\text{ mm}$. Penyakit *common rust* dengan *orange rust* memiliki lesi yang cukup mirip. Kedua penyakit karat tersebut dapat menyebabkan kesalahan pada saat diidentifikasi, tetapi *common rust* berupa bercak kecil berwarna kuning memanjang dan semakin besar menjadi berwarna coklat kemerah-merahan hingga coklat, tampak pada kedua permukaan daun dan tidak pernah berwarna *orange*. Indonesia merupakan salah satu penyebaran penyakit karat tebu jenis *common rust* yang disebabkan oleh jamur *Puccinia Melanocephala* (Rott, 2000). Gambar 1(b) merupakan contoh gejala visual yang ditampakan oleh penyakit noda karat.

2.3. Penyakit noda kuning



(a)

(b)

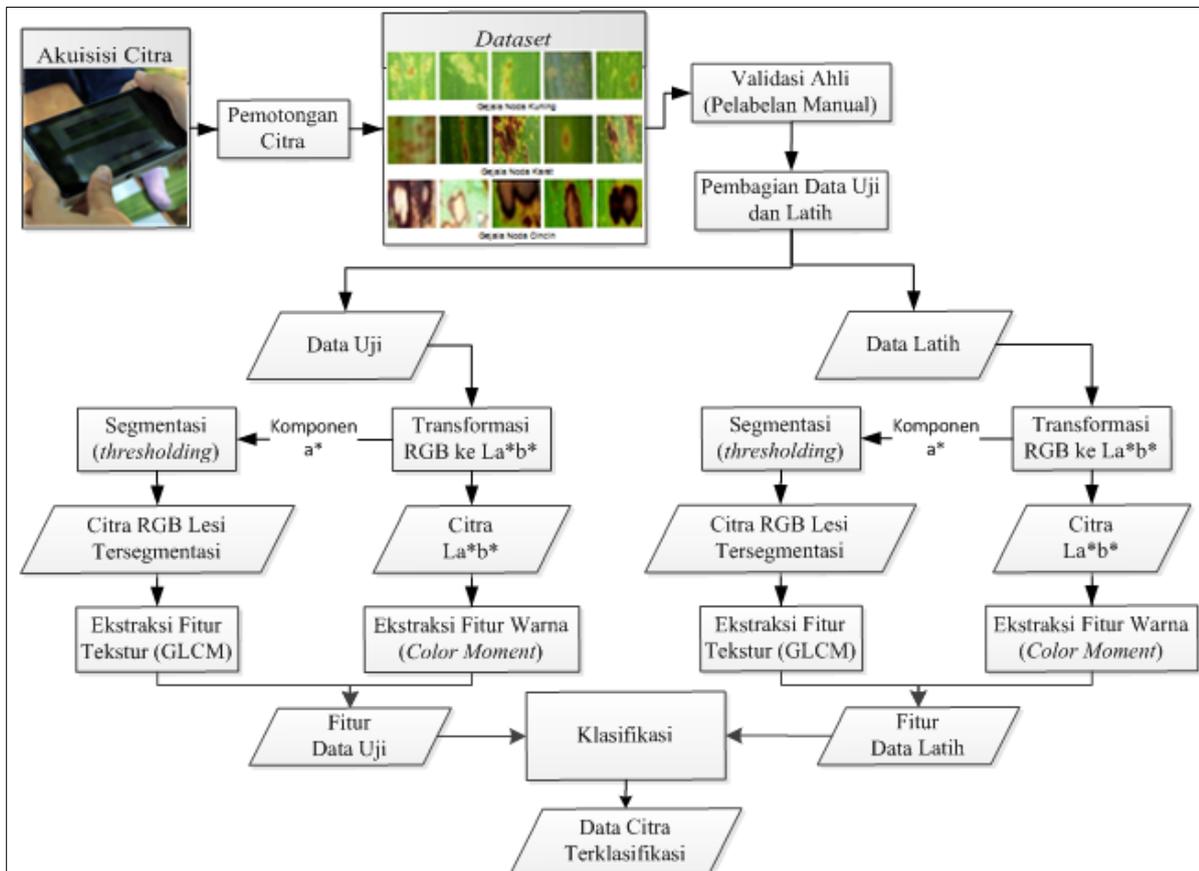
(c)

Gambar 1. Gejala visual penyakit noda: (a) Noda cincin; (b) Noda karat; dan (c) Noda kuning

Penyakit noda kuning banyak ditemukan di daerah dataran tinggi yang lembab disebabkan oleh cendawan *Cercospora Kopkei*. Penyakit noda kuning menampilkan gejala timbul noda-noda kuning pucat pada daun muda dan berubah menjadi kuning terang yang bertahan sampai daun menjadi tua. Pada bercak tersebut kemudian timbul noda berupa titik atau garis berwarna darah kotor yang tidak teratur. Pada bagian bawah daun tertutup lapisan putih kotor pada saat cuaca lembab. Sedangkan bercak berwarna agak kehitaman pada helaian daun yang mati. Contoh daun yang mengalami penyakit noda kuning ditunjukkan pada Gambar 1(c).

3. Metode Penelitian

Penelitian ini menggunakan informasi ciri tekstur dan warna sebagai informasi klasifikasi dalam mengenali jenis penyakit noda pada citra daun tebu yang terdiri dari noda cincin, noda karat dan noda kuning. Metode yang diusulkan penelitian secara umum terdiri dari pengumpulan *dataset*, ekstraksi ciri dan klasifikasi seperti yang terlihat pada Gambar 2. Langkah awal yang telah dilakukan yaitu pengumpulan *dataset* yang digunakan sebagai data uji dan data latih. Ekstraksi ciri warna dan tekstur dilakukan pada masing-masing data citra latih dan uji menggunakan SGLCM dan *color moments* pada ruang warna LAB. Kemudian pengenalan penyakit pada citra berdasarkan informasi ciri tersebut menggunakan klasifikasi kNN.



Gambar 2. Diagram blok metode yang diusulkan

Penjelasan langkah-langkah metode yang ditunjukkan diagram blok pada Gambar 2 yaitu sebagai berikut:

3.1. Pengumpulan dataset



Gambar 3. Contoh *dataset* citra pada kelas: (a) Cincin; (b) Karat; (c) Kuning; dan (d) Non-Noda

Dataset berupa potongan citra berdimensi (50×50) piksel merupakan data yang didapatkan dari perekaman menggunakan kamera digital, kemudian dipotong dengan memperhatikan lesi yang ditampakkkan untuk dijadikan *point of interest*. *Dataset* tersebut terdiri dari data citra dengan kelas Cincin untuk citra daun yang berlesi noda cincin, Karat untuk citra daun yang berlesi noda karat, Kuning

untuk citra daun yang berlesi noda kuning dan Non-Noda untuk citra yang merupakan area daun tidak berlesi.

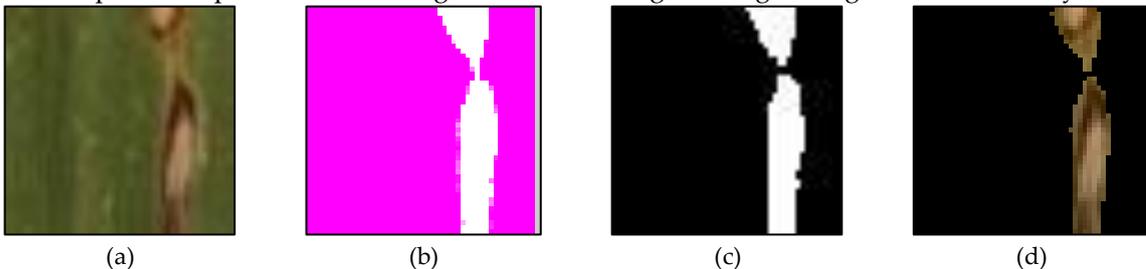
Gambar 3 merupakan contoh masing-masing potongan citra daun dengan jenis penyakit noda tertentu yang digunakan pada penelitian ini. Pelabelan citra menurut kelasnya dilakukan secara manual yang divalidasi oleh ahli penyakit tanaman tebu dari Pusat Penelitian Perkebunan Gula Indonesia (P3GI) sebagai *ground truth*. *Dataset* yang telah dikumpulkan kemudian dibagi menjadi data citra latih dan data citra uji dengan rincian yang ditunjukkan pada Tabel 1.

Tabel 1. Jumlah *dataset* per-kelas

Kelas	Data Latih	Data Uji
Cincin	95 Citra	22 Citra
Karat	58 Citra	15 Citra
Kuning	80 Citra	20 Citra
Non-Noda	53 Citra	24 Citra
Jumlah total	286 citra	81 Citra

3.2. Segmentasi citra

Segmentasi citra merupakan penentuan *point of interest* berupa lesi dari tanda penyakit noda pada citra daun sebelum dilakukan ekstraksi. Segmentasi tersebut menggunakan teknik *thresholding* yang dilakukan pada komponen A dari ruang warna LAB. Langkah-langkah segmentasi tersebut yaitu:



Gambar 4. Contoh segmentasi lesi menggunakan metode Otsu: (a) Citra asli; (b) Citra LAB; (c) Citra segmentasi menggunakan teknik *thresholding* komponen "A"; dan (d) Citra RGB hasil segmentasi

1. Citra masukan RGB ditransformasi menjadi LAB (Busin, Vandenbroucke, & Macaire, 2008) dengan langkah-langkah sebagai berikut dengan Persamaan 1, Persamaan 2 dan Persamaan 3,

$$L = 116f\left(\frac{Y}{Y_n}\right) - 16 \quad (1)$$

$$A = 500 \left[f\left(\frac{X}{X_n}\right) - f\left(\frac{Y}{Y_n}\right) \right] \quad (2)$$

$$B = 200 \left[f\left(\frac{Y}{Y_n}\right) - f\left(\frac{Z}{Z_n}\right) \right] \quad (3)$$
 Di mana X_n , Y_n dan Z_n , merepresentasikan koordinat stimulus *white point*, sedangkan XYZ didapatkan dari perhitungan dengan Persamaan 4, Persamaan 5 dan Persamaan 6,

$$X = 0,412453R + 0,357580G + 0,180423B \quad (4)$$

$$Y = 0,212671R + 0,715160G + 0,072169B \quad (5)$$

$$Z = 0,019334R + 0,119193G + 0,950227B \quad (6)$$
 dan $f(q)$ didefinisikan pada Persamaan 7,

$$f(q) = \begin{cases} q^{\frac{1}{3}}, & \text{jika } q > 0,008856 \\ 7,787q + 16/116, & \text{untuk yang lain} \end{cases} \quad (7)$$
2. Segmentasi komponen "A" dari ruang warna LAB menggunakan Otsu *thresholding* (Otsu, 1979), sehingga menghasilkan citra lesi tersegmentasi.
3. Mengembalikan warna RGB dari citra asli berdasarkan mask pada langkah 2, sehingga didapatkan citra lesi tersegmentasi RGB (Kusuma & Darmanto, 2016).

Gambar 4 merupakan gambar beberapa citra dalam proses segmentasi menggunakan teknik *thresholding* pada komponen "A" ruang warna LAB.

3.3. Ekstraksi ciri

Fitur yang digunakan dalam penelitian ini yaitu ciri warna dan ciri tekstur citra. Masing-masing *dataset* citra latih dan uji diekstraksi menggunakan metode SGLCM untuk ciri tekstur dan LAB *color moments*

untuk ciri warna. Metode ekstraksi ciri tekstur SGLCM merupakan fitur Haralick yang terdiri dari 6 fitur *Angular Second Moment (ASM)*, kontras, *Inverse Different Moment (IDM)*, entropi, dan korelasi yang diekstraksi dari area lesi tersegmentasi menggunakan *Otsu thresholding* pada komponen "A" dari ruang warna LAB. Langkah-langkah ekstraksi fitur menggunakan SGLCM dan *color moment* yaitu sebagai berikut:

1. Transformasi citra RGB tersegmentasi yang didapatkan dari proses segmentasi ke level keabuan untuk ekstraksi ciri tekstur.
2. Ekstraksi ciri tekstur menggunakan fitur Haralick (Haralick, Shanmugam, & Dinstein, 1973) sehingga mendapatkan 6 fitur tekstur menggunakan rumus seperti berikut:
 - a. *Angular Second Moment (ASM)* merupakan ukuran homogenitas citra ditunjukkan pada Persamaan 8 Semakin tinggi nilai ASM maka citra tersebut semakin homogen,

$$ASM = \sum_i \sum_j \{P(i, j)\}^2 \quad (8)$$

di mana P_{ij} menyatakan nilai pada baris i dan kolom j pada matrik kookurensi.

- b. Kontras yang dihitung dengan Persamaan 9 merupakan ukuran keberadaan variasi tingkat keabuan piksel satu dengan piksel yang berdekatan di seluruh citra,

$$Contrast = \sum_{n=1} n^2 \{ \sum_i \sum_j P(i, j) \} \quad (9)$$

di mana $|i - j| = n$

- c. *Inverse Different Moment (IDM)* IDM pada Persamaan 10 mengukur homogenitas citra yang berderajat keabuan sama,

$$IDM = \sum_i \sum_j \frac{P(i, j)}{1+(i-j)^2} \quad (10)$$

- d. Entropi

Entropi yang ditunjukkan pada Persamaan 11 merupakan ukuran ketidakaturan tingkat keabuan citra,

$$Entropi = - \sum_i \sum_j P(i, j) \lim_{P(i, j)} P(i, j) \quad (11)$$

- e. Korelasi

Korelasi merupakan ukuran ketergantungan linear antar nilai level keabuan citra. Korelasi dapat memberikan petunjuk adanya struktur linear yang dihitung menggunakan Persamaan 12,

$$Korelasi = \frac{\sum_i \sum_j (ij)(P(i, j)) - (\mu_i' \mu_j')}{\sigma_i' \sigma_j'} \quad (12)$$

di mana $\mu_i' \mu_j'$ merupakan rata-rata dari $p_i' p_j'$ dan $\sigma_i' \sigma_j'$ adalah deviasi standar dari $p_i' p_j'$.

3. Citra pada ruang warna LAB yang didapatkan pada langkah 2 proses segmentasi, selain digunakan sebagai *mask* untuk ekstraksi ciri tekstur juga digunakan ekstraksi ciri warna menggunakan *color moment* yang terdiri dai *mean*, deviasi standar, *skewness* dan kurtosis, sehingga menghasilkan 4 fitur untuk masing-masing komponen L, A, dan B. Ekstraksi *color moment* (Kadir, Nugroho, Susanto, & Santosa, 2013) menggunakan rumus-rumus berikut,

- a. *Mean*

Mean digunakan untuk merepresikan nilai rata-rata pada masing-masing *channel* warna. *Mean* merupakan rata-rata nilai piksel (P_{ij}) pada masing-masing *channel* R, G dan B, seperti pada Persamaan 13,

$$\mu = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N P_{ij} \quad (13)$$

- b. Deviasi standar

Deviasi standar merupakan akar dari *variance* yang dihitung dengan Persamaan 14,

$$\sigma = \sqrt{\frac{1}{N} \sum_{j=1}^N ((P_{ij} - \mu)^2)} \quad (14)$$

c. *Skewness*

Skewness merupakan pengukuran untuk simetri yang dihitung dengan Persamaan 15,

$$\theta = \frac{\sum_{i=1}^M \sum_{j=1}^N (P_{ij} - \mu)^3}{MN\sigma^3} \quad (15)$$

d. *Kurtosis*

Kurtosis yaitu pengukuran suatu distribusi, apakah datar bila dibandingkan dengan distribusi normal, seperti pada Persamaan 16,

$$\theta = \frac{\sum_{i=1}^M \sum_{j=1}^N (P_{ij} - \mu)^4}{MN\sigma^4} \quad (16)$$

di mana N merupakan dimensi lebar citra, M merupakan dimensi tinggi dari citra, dan P_{ij} merupakan nilai intensitas warna baris i dan kolom j .

3.4. Pengenalan penyakit noda

Pengenalan penyakit noda pada citra daun tebu pada penelitian ini menggunakan klasifikasi kNN (Cover & Hart, 1967). Untuk mengetahui performa metode yang diajukan dalam penelitian ini dievaluasi menggunakan akurasi. Akurasi tersebut didapatkan dari perbandingan jumlah data uji yang terklasifikasi dengan benar terhadap jumlah total data uji.

4. Hasil dan Pembahasan

Pengujian pengenalan jenis penyakit noda dilakukan dengan menggunakan variasi variasi nilai k pada 5, 7, 9, 11 dan 15 dengan jarak kNN *euclidean*, *cosine*, *correlation* dan *cityblock*. Sedangkan untuk mengetahui apakah metode yang diajukan pada penelitian ini dapat mempunyai performa yang baik maka dilakukan percobaan variasi kombinasi fitur sebagai berikut:

- Kombinasi fitur tekstur GLCM dengan LAB *color moment* (LAB+GLCM)
- Kombinasi fitur tekstur GLCM dengan RGB *color moment* (RGB+GLCM)
- Kombinasi fitur tekstur SGLCM dengan LAB *color moment* (LAB+SGLCM)
- Kombinasi fitur tekstur SGLCM dengan RGB *color moment* (RGB+SGLCM)

Hasil yang didapatkan dari percobaan tersebut ditunjukkan pada Tabel 2.

Berdasarkan Tabel 2, dapat diketahui bahwa pengenalan penyakit noda melalui citra daun tebu menggunakan fitur tekstur GLCM dan LAB *color moments* menghasilkan akurasi tertinggi 83% pada $k = 5$ dengan jarak *euclidean* dan terendah akurasi sebesar 77% pada $k = 7$ dengan jarak *cosine* dan $k = 15$ dengan jarak *cityblock*. Sedangkan percobaan yang mengkombinasikan tekstur GLCM dan RGB *color moments* menghasilkan akurasi tertinggi sebesar 85% pada $k = 11$ dengan jarak *euclidean* dan terendah 75% pada $k = 15$ dengan jarak *correlation*. Hal tersebut menunjukkan bahwa kombinasi ekstraksi fitur GLCM dan RGB *color moments* dapat mengenali lebih baik dibandingkan kombinasi fitur GLCM dan LAB *color moments*.

Sedangkan ketika LAB *color moments* dikombinasikan dengan fitur tekstur SGLCM dapat menghasilkan akurasi tertinggi lebih baik dibandingkan dengan kombinasi SGLCM dan RGB *color moments*. Kombinasi tekstur SGLCM dan RGB *color moments* menghasilkan akurasi tertinggi sebesar 91% pada $k = 9$ dan $k = 11$ dengan jarak *euclidean* dan terendah 85% pada $k = 15$ dengan jarak *correlation*. Akurasi tertinggi dari semua kombinasi yang telah dilakukan dalam percobaan ini dihasilkan dari klasifikasi kNN menggunakan $k=5, 7$, dan 9 dengan jarak *euclidean*, $k=5$ dan 7 dengan jarak *correlation*, serta $k = 5$ dengan jarak *cityblock* mencapai 93%. Akurasi klasifikasi tersebut berdasarkan kombinasi informasi ciri tekstur SGLCM dan LAB *color moments*. Kombinasi ciri tersebut memperoleh akurasi terendah sebesar 88% pada $k = 9, 11$ dan 15 dengan jarak *cosine* dibandingkan dengan metode lain yang telah diuji coba yaitu dibawah 88%. Perbedaan perolehan akurasi tiap metode terlihat jelas ketika citra yang diklasifikasi hanya menggunakan citra lesi tersegmentasi lebih unggul yaitu metode ekstraksi ciri RGB + SGLCM dan LAB + SGLCM dibandingkan dengan citra tanpa segmentasi lesi terlebih dahulu yaitu metode ekstraksi ciri RGB + GLCM dan LAB + GLCM. Akurasi dengan nilai tertinggi dari semua

percobaan yang telah dilakukan mengalami konsistensi pada nilai $k=5$ untuk setiap penggunaan jarak yang berbeda terjadi pada percobaan metode yang diusulkan, yaitu ekstraksi menggunakan metode SGLCM dan LAB *color moments*. Akurasi pengenalan setiap kelas oleh metode yang diusulkan pada nilai $k=5$ dengan jarak *euclidean* ditunjukkan pada Tabel 3.

Tabel 2. Hasil akurasi Percobaan

No	Jarak	k	LAB + GLCM	RGB + GLCM	LAB + SGLCM	RGB + SGLCM
1.	<i>Euclidean</i>	5	0.83	0.84	0.93	0.88
2.		7	0.81	0.80	0.93	0.88
3.		9	0.80	0.84	0.93	0.91
4.		11	0.79	0.85	0.90	0.91
5.		15	0.79	0.80	0.89	0.88
6.	<i>Cosine</i>	5	0.79	0.84	0.91	0.86
7.		7	0.77	0.79	0.90	0.90
8.		9	0.80	0.83	0.88	0.89
9.		11	0.78	0.80	0.88	0.89
10.		15	0.80	0.77	0.88	0.86
11.	<i>Correlation</i>	5	0.78	0.80	0.93	0.86
12.		7	0.78	0.78	0.93	0.89
13.		9	0.78	0.84	0.90	0.90
14.		11	0.80	0.84	0.90	0.88
15.		15	0.78	0.75	0.89	0.85
16.	<i>Cityblock</i>	5	0.79	0.83	0.93	0.88
17.		7	0.78	0.80	0.90	0.89
18.		9	0.78	0.83	0.91	0.88
19.		11	0.78	0.79	0.90	0.89
20.		15	0.77	0.78	0.89	0.88

Berdasarkan Tabel 3 pengenalan yang dihasilkan dari metode tersebut yaitu dapat mengenali dengan baik dengan menghasilkan akurasi 100% pada citra Non-Noda. Sedangkan kesalahan klasifikasi terjadi pada beberapa citra berjenis penyakit cincin yang menghasilkan akurasi 96%. Akurasi tersebut disebabkan karena sebanyak 1 dari 22 data citra yang tidak terklasifikasikan sebagai penyakit noda cincin tetapi sebagai noda karat. Citra yang mengalami kesalahan klasifikasi tersebut dapat dilihat pada Tabel 3. Secara visual citra tersebut menampilkan lesi yang hampir mirip dengan noda karat, yaitu tepi cincin berwarna coklat dan bergaris seperti gejala penyakit noda karat. Sedangkan pada noda penyakit karat didapatkan akurasi pengenalan sebesar 70% dengan kesalahan klasifikasi citra sebanyak 4 data yang dapat dilihat pada Tabel 3. Hal tersebut berseberangan dengan pernyataan sebelumnya, di mana karat yang memiliki ciri lesi berbentuk garis berwarna coklat terdeteksi sebagai noda cincin. Kesalahan pengenalan pada lesi karat tersebut dapat disebabkan karena noda karat memiliki lesi yang sama dengan lesi gejala awal noda cincin yaitu berwarna coklat memanjang (Ratnasari, Ginardi, & Fatichah, 2014). Sedangkan citra berpenyakit noda karat lainnya dideteksi sebagai noda kuning yaitu penyakit noda karat yang menampilkan lesi berwarna kuning pada area non lesi yang merupakan gejala awal penyakit noda karat. Kesalahan klasifikasi juga dialami oleh citra berpenyakit kuning sebanyak 1 citra yang dideteksi sebagai penyakit noda cincin. Secara visual lesi dari penyakit noda kuning pada citra tersebut membentuk pola seperti yang ditampilkan pada penyakit noda cincin sehingga citra tersebut dideteksi sebagai noda penyakit cincin.

5. Kesimpulan

Berdasarkan evaluasi uji coba yang telah dilakukan, dapat disimpulkan bahwa metode yang diajukan dalam mengidentifikasi tiga penyakit noda pada citra daun tebu dapat menunjukkan performa paling baik dengan akurasi tertinggi sebesar 93% dibandingkan dengan kombinasi fitur lainnya yang telah dilakukan pada percobaan. Informasi warna dan tekstur berpengaruh terhadap pengenalan jenis penyakit noda pada citra daun tebu, di mana terdapat kesalahan klasifikasi yang memiliki tekstur maupun warna yang mirip. Selain itu segmentasi yang baik diperlukan untuk mendapat informasi yang akurat dari lesi suatu penyakit noda. Segmentasi tersebut berpengaruh pada pengenalan citra, di mana

terkadang terdapat bercak yang bukan merupakan lesi penyakit noda sehingga dapat menimbulkan kesalahan klasifikasi yang tidak sesuai dengan label *ground truth*.

Tabel 3. Data citra yang mengalami kesalahan klasifikasi pada $k=5$ Jarak *Euclidean*

No	Kelas	Citra	Kelas Hasil Klasifikasi
1	Cincin		Karat
2	Karat		Cincin
			Kuning
3	Kuning		Cincin

6. Ucapan Terima Kasih

Terima kasih disampaikan kepada Ibu Ari Kristin selaku ahli penyakit tanaman tebu dari P3GI yang bersedia menjadi validator *dataset* yang digunakan dalam penelitian ini sehingga data yang digunakan sesuai dengan keadaan lapangan.

7. Referensi

- Asfarian, A., Herdiyeni, Y., Rauf, A., & Mutaqin, K. H. (2013). Paddy diseases identification with texture analysis using fractal descriptors based on fourier spectrum. *Computer, Control, Informatics and Its Applications (IC3INA), 2013 International Conference on* (hal. 77-81). Jakarta: IEEE.
- Bashish, D. A., Braik, M., & Ahmad, S. B. (2010). A framework for detection and classification of plant leaf and stem diseases. *Signal and Image Processing (ICSIP), 2010 International Conference on* (hal. 113-118). Chennai: IEEE.
- Busin, L., Vandenbroucke, N., & Macaire, L. (2008). Color spaces and image segmentation. *Advances in Imaging and Electron Physics, 151*, 65-168.
- Chaudhary, P., Chaudhari, A. K., Cheeran, A. N., & Godara, S. (2012). Color transform based approach for disease spot detection on plant leaf. *International Journal of Computer Science and Telecommunications, 3*(6), 65-70.
- Cover, T., & Hart, P. (1967). Nearest neighbor pattern classification. *IEEE Transactions on Information Theory, 13*(1), 21-27.
- Haralick, R. M., Shanmugam, K., & Dinstein, I. (1973). Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics, 3*(6), 610-621.

- Huang, K.-Y. (2007). Application of artificial neural network for detecting Phalaenopsis seedling diseases using color and texture features. *Computers and Electronics in Agriculture*, 57(1), 3–11.
- Kadir, A., Nugroho, L. E., Susanto, A., & Santosa, P. I. (2013). Leaf classification using shape, color, and texture features. *International Journal of Computer Trends and Technology*, 225-230.
- Kusuma, A. P., & Darmanto, D. (2016). Pengenalan angka pada sistem operasi android dengan menggunakan metode template matching. *Register: Jurnal Ilmiah Teknologi Sistem Informasi*, 2(2), 68-78.
- Mendoza, F., Dejmek, P., & Aguilera, J. M. (2006). Calibrated color measurements of agricultural foods using image analysis. *Postharvest Biology and Technology*, 41(3), 285–295.
- Meunkaewjinda, A., Kumsawat, P., Attakitmongcol, K., & Srikaew, A. (2008). Grape leaf disease detection from color imagery using hybrid intelligent system. *Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology, 2008. ECTI-CON 2008. 5th International Conference on* (hal. 513-516). Krabi: IEEE.
- Otsu, N. (1979). A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, 9(1), 62-66.
- Rathod, A. N., Tanawal, B., & Shah, V. (2013). Image processing techniques for detection of leaf disease. *International Journal of Advanced Research in Computer Science and Software Engineering*, 3(11), 397-399.
- Ratnasari, E. K., Ginardi, R. V., & Fatichah, C. (2014). Pengenalan penyakit noda pada citra daun tebu berdasarkan ciri tekstur fractal dimension co-occurrence matrix dan $L^*a^*b^*$ color moments. *JUTI*, 12(2), 27–36.
- Rott, P. (2000). *A guide to sugarcane diseases*. Paris: Quae.
- Sa'diyah, N., & Aeny, T. N. (2012). Keragaman dan heritabilitas ketahanan tebu populasi F1 terhadap penyakit bercak kuning di PT. Gunung Madu Plantations Lampung. *Jurnal Hama dan Penyakit Tumbuhan Tropika*, 12(1), 71-77.
- Sungkur, R. K., Baichoo, S., & Poligadu, A. (2013). An automated system to recognise fungi-caused diseases on sugarcane leaves. *Proceedings of Global Engineering, Science and Technology Conference*. Bencoolen, Singapura: Global Institute of Science & Technology.
- Vibhute, A., & Bodhe, S. K. (2012). Applications of image processing in agriculture: A survey. *International Journal of Computer Applications*, 52(2), 34-40.