

Klasifikasi Citra Daun dengan Metode Gabor Co-Occurrence

Mutmainnah Muchtar dan Laili Cahyani

Program Studi Teknik Informatika, Institut Teknologi Sepuluh Nopember, Surabaya, Indonesia
 muchtarmutmainnah@gmail.com, laili.cahyani13@mhs.if.its.ac.id

Diterima 8 September 2015

Disetujui 27 November 2015

Abstract – Plant takes a crucial part in mankind existences. The development of digital image processing technique made the plant classification task become a lot of easier. Leaf is a part of plant that can be used for plant classification where texture of the leaf is a common feature that been used for classification process. Texture offers a unique feature and able to work even when the leaf is damaged or overly big in size which sometimes made the acquisition process become more difficult. This study offers a combination of Gabor filter methods and co-occurrence matrices to produce the most representative features for leaf classification. Classification using SVM with 5-fold cross validation system shows that the proposed Gabor Co-Occurrence methods was able to reach average accuracy up to 89.83%.

Terms: Leaf, Gabor Co-occurrence, Support Vector Machine, Texture

I. PENDAHULUAN

Ilmu sains yang berkaitan dengan pengenalan atau klasifikasi tanaman memegang peranan penting dalam kehidupan manusia, termasuk dalam bidang makanan, pengobatan, industri, pertanian, dan lingkungan. Dengan semakin banyaknya spesies tanaman di dunia, penting untuk melindungi tanaman atau mengumpulkannya dalam bentuk informasi yang menawarkan keanekaragaman tanaman. Klasifikasi berbasis komputer yang mampu mengenali tanaman tentu sangat membantu para peneliti di bidang pertanian dan perkebunan, *botanist*, ahli tanaman herbal, dokter, bahkan dapat juga digunakan sebagai media pembelajaran di sekolah.

Klasifikasi tanaman baik secara manual maupun otomatis dapat dilakukan melalui pengamatan pada ciri-ciri fisik pada tanaman,

yaitu pengamatan pada bagian bunga, daun, buah, akar atau batang [1]. Daun merupakan bagian tanaman yang sering digunakan dalam proses klasifikasi tanaman, baik manual maupun otomatis. Meskipun demikian, ciri fisik berupa warna dianggap tidak begitu signifikan dalam menentukan jenis daun. Hal ini disebabkan karena hampir seluruh jenis daun memiliki warna dominan hijau. Sedangkan untuk memperoleh fitur bentuk, terkadang ditemukan kesulitan dalam pengambilan data daun secara utuh, terutama untuk daun yang memiliki skala besar. Sehingga tekstur daun merupakan fitur yang paling tepat digunakan dalam klasifikasi daun.

Meskipun belum ada definisi yang pasti mengenai tekstur pada citra digital [2], tekstur berkaitan dengan pengukuran sifat-sifat seperti kehalusan (*smoothness*), kekasaran (*coarseness*), dan keteraturan (*regularity*) pada citra. Oleh karena itu, tekstur dari citra digital daun dapat diidentikkan dengan area pada permukaan daun yang menunjukkan keteraturan pola-pola tertentu [1]. Pada penelitian ini, tekstur daun yang akan dianalisis adalah area pada permukaan daun yang bukan merupakan urat daun utama.

Penelitian dalam bidang klasifikasi tanaman telah banyak dilakukan dengan menggunakan daun sebagai dasar untuk membedakan jenis tanaman. Penelitian oleh S.Liao dan A.C.S. Chung [3] berfokus pada penerapan metode ALBP (*Advanced Local Binary Pattern*) untuk mendapatkan karakter struktur lokal pada gambar tekstur. Selanjutnya dilakukan ekstraksi fitur informasi global dengan menggunakan *Aura Matrix measure* berdasarkan informasi distribusi spasial dari pola yang dominan. A. Kadir dkk [4] melakukan klasifikasi berdasarkan fitur bentuk, warna dan tekstur daun menggunakan PNN

(*Probability Neural Network*). S. Agustin dan E. Prasetyo [5] melakukan klasifikasi berdasarkan tekstur daun setelah proses segmentasi dengan *K-means clustering*, mengekstrak fitur, serta *training* dengan menggunakan *K-Nearest Neighbor* dan *Backpropagation*. Tekstur yang dihasilkan dari penelitian tersebut adalah rata-rata intensitas, *smoothness*, dan *entropy* dari pendekatan statistik, 5 dari 7 *moment invariants*, energi, serta kontras dari pendekatan matrik *co-occurrence*.

Meskipun demikian, penelitian yang berkaitan dengan klasifikasi citra *digital* daun berbasis tekstur dan filter *Gabor* masih jarang ditemukan. Penelitian ini bertujuan untuk melakukan klasifikasi daun pada domain tesktur dengan menggunakan metode filter *Gabor* dan metode matriks *co-occurrence*. Awalnya, citra tekstur dikonversi ke dalam domain frekuensi dengan menerapkan filter *Gabor*, selanjutnya dipilih beberapa citra hasil konvolusi yang memiliki jumlah nilai *response* tertinggi pada tiap skala. Nilai fitur dari tiap citra hasil konvolusi tersebut kemudian dihitung dengan menggunakan metode matriks *co-occurrence*. Terakhir, fitur *Gabor co-occurrence* yang merepresentasikan keunikan tiap daun kemudian digunakan sebagai masukan pada proses klasifikasi dengan menggunakan metode *SVM (Support Vector Machine)*.

II. TINJAUAN PUSTAKA

A. Fitur Tekstur

Tekstur merupakan fitur yang dapat dipertimbangkan dalam sebuah pemrosesan citra dan visi komputer. Tekstur dapat menunjukkan ciri khusus dari sebuah permukaan dan struktur pada objek atau *region*. Pada dasarnya, suatu citra merupakan sebuah kombinasi dari piksel-piksel dan tekstur yang didefinisikan sebagai sekumpulan piksel terkait dalam citra. Kumpulan piksel yang terkait ini disebut tekstur primitif atau elemen tekstur (*texel*). Gambar 1 menunjukkan contoh jenis-jenis tekstur.

Tekstur sulit didefinisikan secara tepat. Namun, terdapat beberapa sifat yang mengasumsikan sebuah tekstur, yaitu:

- Tekstur merupakan sifat suatu area. Tekstur pada sebuah titik tidak dapat didefinisikan.

- Tekstur membentuk distribusi spasial dari tingkat keabuan.
- Tekstur dapat dinyatakan pada skala dan tingkat resolusi yang berbeda.



(a) (b) (c) (d)

Gambar 1. Jenis-jenis tekstur: (a) Tekstur Halus, (b) Tekstur Kasar, (c) Tekstur Teratur, dan (d) Tekstur Tak Teratur

Oleh karena tekstur merupakan suatu pengukuran kuantitatif dari susunan intensitas area, maka metode-metode untuk ekstraksi fitur tekstur dapat dibedakan menjadi 3 kategori : statistika, struktural, dan fraktal. Metode-metode yang termasuk dalam kategori pendekatan secara statistika diantaranya *grey-level histogram*, *grey-level co-occurrence matrix*, fitur *auto-correlation*, dan matriks *run length*. Sedangkan metode-metode yang termasuk dalam kategori pendekatan secara struktural diantaranya : transformasi *wavelet* dan transformasi *gabor*.

B. Filter Gabor

Fungsi *Gabor 2D* merupakan sebuah *local bandpass filter* yang mencapai *optimal localization* pada domain spasial dan frekuensi. Fungsi *Gabor 2D* juga memberikan analisis multi-resolusi dengan membangun multi-kernel dari sebuah fungsi tunggal.

Gabor wavelet dibentuk dengan melakukan proses dilasi dan rotasi pada kernel tunggal dengan sejumlah parameter. Berdasarkan konsep tersebut, digunakan fungsi filter *Gabor* sebagai kernel untuk membentuk sebuah *filter dictionary*. Pada domain spasial, filter *Gabor 2D* merupakan sebuah fungsi kernel *Gaussian* yang dimodulasikan oleh sebuah gelombang sinusoidal yang kompleks. Fungsi tersebut didefinisikan oleh persamaan berikut :

$$G(x, y) = \frac{f^2}{\pi\gamma} \exp\left(-\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}\right) \exp(j2\pi f x' + \phi) \quad (1)$$

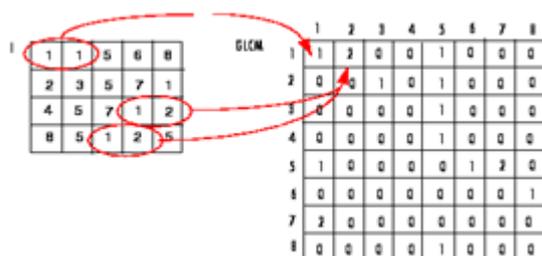
$$x' = x \cos\theta + y \sin\theta,$$

$$y' = -x \sin\theta + y \cos\theta,$$

dimana f merupakan frekuensi faktor sinusoidal, θ merepresentasikan orientasi filter *Gabor*, ϕ merupakan *offset*, σ merupakan standar deviasi *Gaussian*, dan γ merupakan rasio filter [6].

C. Matriks Co-occurrence

Matriks intensitas *co-occurrence* adalah suatu matriks yang menggambarkan frekuensi munculnya pasangan dua piksel dengan intensitas tertentu dalam jarak dan arah tertentu dalam citra [7]. Matriks intensitas *co-occurrence* $p(i_1, i_2)$ didefinisikan dengan dua langkah sederhana sebagai berikut: Langkah pertama adalah menentukan lebih dulu jarak antara dua titik dalam arah vertikal dan horizontal (*vektor* $d=(dx, dy)$), di mana besaran dx dan dy dinyatakan dalam piksel sebagai unit terkecil dalam citra digital. Langkah kedua adalah menghitung pasangan piksel-piksel yang mempunyai nilai intensitas i_1 dan i_2 dan berjarak di piksel dalam citra. Kemudian hasil setiap pasangan nilai intensitas diletakkan pada matriks sesuai dengan koordinat-nya, di mana absis untuk nilai intensitas i_1 dan ordinat untuk nilai intensitas i_2 . Gambar 2 merupakan contoh matriks *co-occurrence* dengan nilai intensitas keabuan 1 sampai dengan 8.



Gambar 2. Matriks *co-occurrence* ukuran 8x8

Fitur-fitur tekstur yang bisa didapatkan dari matriks *co-occurrence* diantaranya adalah entropi, energi, kontras, dan homogenitas. Entropi menyatakan ukuran ketidakaturan aras keabuan di dalam citra. Energi adalah ukuran yang

menyatakan distribusi intensitas piksel terhadap jangkauan aras keabuan. Kontras merupakan ukuran keberadaan variasi aras keabuan piksel citra. Sedangkan homogenitas merupakan ukuran kemiripan piksel pada citra [8]. Persamaan (2), (3), (4), dan (5) berturut-turut merupakan rumus untuk memperoleh nilai entropi, energi, kontras, dan homogenitas dari citra, dengan P_{ij} merupakan nilai piksel citra *GLCM* (*Gray Level Co-occurrence Matrix*).

$$-\sum_i \sum_j p(i, j) \log p(i, j) \quad (2)$$

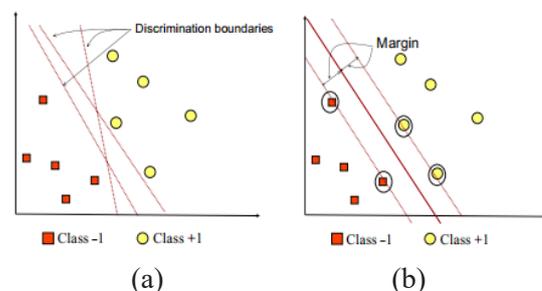
$$\sum_i \sum_j p^2(i, j) \quad (3)$$

$$\sum_i \sum_j (i - j)^2 p(i, j) \quad (4)$$

$$\sum_i \sum_j \frac{p(i, j)}{1 + |i - j|} \quad (5)$$

D. Support Vector Machine

Menurut Nugroho dkk [9], *SVM* (*Support Vector Machine*) merupakan metode *machine learning* yang bekerja atas prinsip *Structural Risk Minimization* (*SRM*) dengan tujuan menemukan *hyperplane* terbaik yang memisahkan dua buah kelas pada *input space*. Gambar 3 menunjukkan beberapa *pattern* yang merupakan anggota dari dua buah kelas : +1 dan -1. *Pattern* yang tergabung pada kelas -1 disimbolkan dengan warna merah (kotak), sedangkan *pattern* pada kelas +1, disimbolkan dengan warna kuning (lingkaran). Proses klasifikasi merupakan usaha untuk menemukan garis (*hyperplane*) yang memisahkan antara kedua kelompok tersebut. Berbagai alternatif garis pemisah (*discrimination boundaries*) ditunjukkan pada Gambar 3 (a).

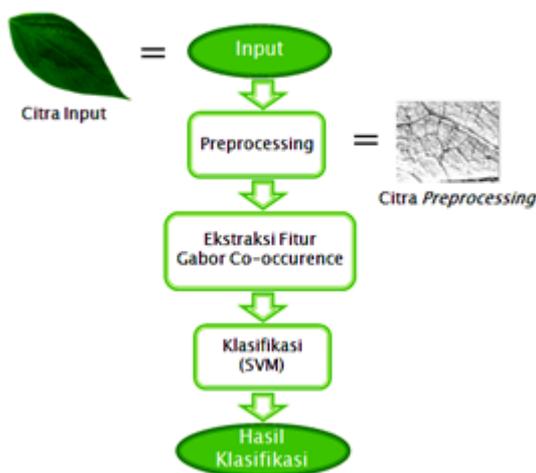


Gambar 3. Penentuan *discrimination boundary* (a) dan letak margin (b).

Hyperplane pemisah terbaik antara kedua kelas dapat ditemukan dengan mengukur *margin hyperplane* tersebut dan mencari titik maksimalnya. *Margin* adalah jarak antara *hyperplane* tersebut dengan *pattern* terdekat dari masing-masing kelas. *Pattern* yang paling dekat ini disebut sebagai *support vector*. Garis tebal pada Gambar 3(b) menunjukkan *hyperplane* yang terbaik, yaitu yang terletak tepat pada tengah-tengah kedua kelas, sedangkan titik merah dan kuning yang berada dalam lingkaran hitam adalah *support vector*.

III. METODE

Alur proses klasifikasi tanaman berdasarkan tekstur daun menggunakan fitur *Gabor Co-occurrence* secara garis besar dapat dilihat pada Gambar 4.



Gambar 4. Keseluruhan alur proses klasifikasi tanaman berdasarkan tekstur daun menggunakan *Gabor Co-occurrence*

Citra yang menjadi inputan merupakan citra daun dari *flavia* yang dapat diunduh secara bebas. Akuisis citra *flavia* dilakukan dengan menggunakan sebuah *scanner*, dengan latar belakang putih. Adapun ukuran citra daun yang dihasilkan adalah sebesar 1600x1200 piksel. Tahap *preprocessing* dilakukan untuk memperbaiki kualitas citra agar tekstur tampak lebih jelas. Keluaran dari tahapan *preprocessing* dijadikan masukan pada proses ekstraksi fitur.

Selanjutnya, dilakukan ekstraksi fitur pada citra dengan nilai respon maksimum sehingga menghasilkan 20 fitur, yaitu Entropi, Energi, Kontras, dan Homogenitas dari kombinasi *Gabor Co-occurrence*. Fitur-fitur tersebut yang dijadikan ukuran pada tahap klasifikasi dengan menggunakan metode *Support Vector Machine* sehingga didapatkan kelas untuk tiap daun.

A. Preprocessing

Pada tahap *preprocessing* ini, citra diproses untuk mendapatkan hasil yang lebih baik agar mempermudah dalam ekstraksi fitur tekstur. Langkah pertama yang dilakukan yaitu konversi nilai RGB citra menjadi nilai *grayscale* dengan menggunakan persamaan berikut [10] :

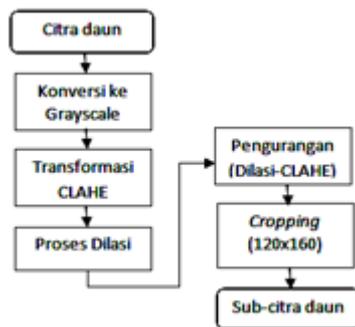
$$\text{gray} = (0.2989 \times R) + (0.5870 \times G) + (0.1140 \times B) \quad (6)$$

dimana R, G, B berturut-turut merupakan piksel warna merah, hijau dan biru pada sebuah citra.

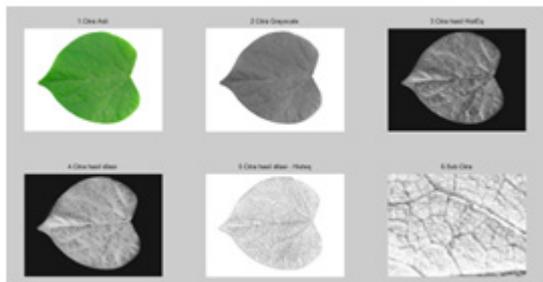
Langkah kedua adalah melakukan transformasi citra *grayscale* dengan CLAHE (*Contrast Limited Adaptive Histogram Equalization*). Hal tersebut bertujuan untuk memperbaiki citra dengan menerapkan batasan *contrast* secara adaptif pada *histogram equalization* agar *noise* yang dihasilkan tidak berlebihan. Langkah ketiga adalah melakukan proses dilasi. Proses ini bertujuan untuk menebalkan struktur tekstur agar tampak lebih jelas. Langkah berikutnya adalah melakukan operasi pengurangan antara citra hasil proses dilasi dan transformasi CLAHE. Tujuannya adalah menipiskan *noise* atau garis-garis yang dianggap tidak signifikan sebagai tekstur sehingga didapatkan tekstur citra daun yang tampak lebih jelas.

Output daun yang telah diproses kemudian dipotong dengan ukuran 120x160 piksel. Hal ini dilakukan karena berbagai alasan. Alasan pertama karena resolusi citra input yang akan diproses terlalu besar. Kedua untuk meyakinkan bahwa sembarang area yang diambil sebagai input pada suatu daun akan menghasilkan tekstur yang sama.

Ketiga, adalah untuk mengatasi kesulitan dalam pengambilan dataset daun secara utuh. Hasil *cropping* tersebut akan digunakan sebagai masukan pada tahap ekstraksi fitur. Alur *preprocessing* dapat dilihat pada Gambar 5. Sedangkan citra hasil tahapan *preprocessing* dapat dilihat pada Gambar 6.



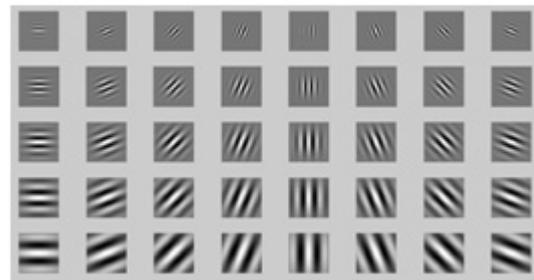
Gambar 5. Alur Preprocessing pada sistem klasifikasi tanaman berdasarkan tekstur daun menggunakan Gabor Co-occurrence



Gambar 6. Hasil citra pada tahapan *preprocessing*

B. Pembentukan Filter Gabor

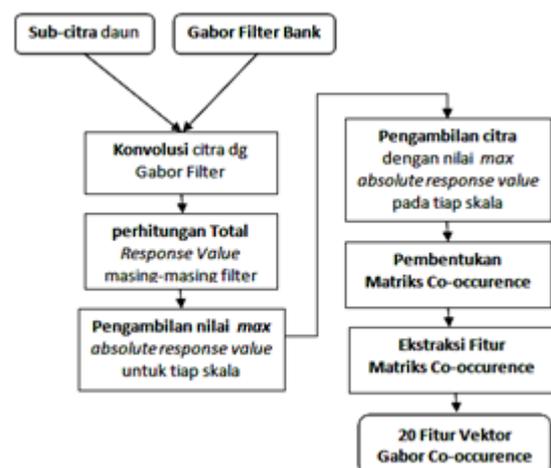
Sebuah *Bank* filter *Gabor* yang terdiri dari 40 filter *Gabor* dibentuk menggunakan fungsi *Gabor 2D*. Skala yang digunakan adalah sebanyak 5 skala dan orientasi sebanyak 8 arah. Ukuran filter ditentukan yaitu 39×39 . Ukuran filter dapat ditentukan atau diganti secara manual dengan syarat ukuran harus bernilai ganjil. Gambar 7 merupakan contoh *bank* filter *Gabor* yang dibentuk.



Gambar 7. *Gabor* filter bank (5x8)

C. Ekstraksi Fitur Maximum Response Gabor Co-occurrence

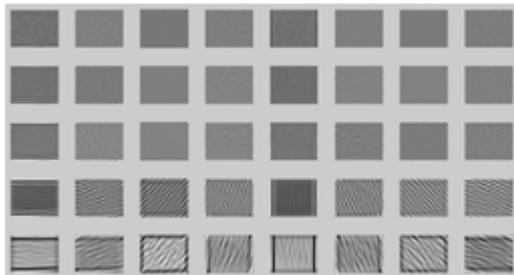
Untuk mendapatkan fitur tekstur menggunakan metode *Gabor Co-occurrence*, dilakukan beberapa tahapan, di antaranya yaitu: konvolusi citra hasil *preprocessing* dengan *gabor filter bank*, perhitungan total *response value* pada masing-masing filter yang dihasilkan dari hasil konvolusi, pengambilan nilai maksimum *absolute response value* untuk tiap skala, pengambilan citra dengan nilai maksimum *absolute response value* pada tiap skala, pembentukan matriks cooccurrence, dan ekstraksi fitur. Tahapan-tahapan tersebut ditunjukkan oleh Gambar 8.



Gambar 8. Alur proses ekstraksi fitur tekstur menggunakan *Gabor Co-occurrence*

Konvolusi dilakukan terhadap citra hasil *preprocessing* dengan *Gabor Filter Bank* berukuran 5×8 yang telah dibentuk sebelumnya. Proses ini menghasilkan suatu nilai yang disebut nilai *response*. Nilai *response* memiliki nilai awal berupa nilai imajiner. Sehingga, diperlukan

konversi ke bentuk nilai *real* dan absolut untuk memudahkan proses berikutnya. Jumlah citra hasil konvolusi adalah sebesar banyaknya jumlah piksel citra dikalikan dengan jumlah banyaknya filter. Citra hasil konvolusi ditunjukkan oleh Gambar 9.



Gambar 9. Hasil konvolusi citra tekstur dengan *Gabor Filter Bank* (5x8)

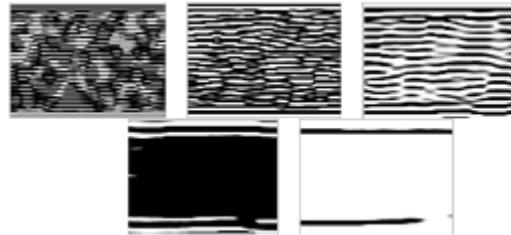
Matriks *co-occurrence* dibentuk dari citra hasil konvolusi yang memiliki jumlah nilai *response* tertinggi pada tiap skala. Pemilihan ini dilakukan dengan alasan bahwa orientasi dari citra dengan nilai *response* tertinggi dapat mewakili orientasi-orientasi lainnya. Hal ini membuktikan bahwa metode yang diajukan *invariant* terhadap rotasi. Pembentukan matriks *co-occurrence* dapat dijelaskan dengan persamaan berikut:

$$C_{ki}(i,j) = \sum_x \sum_y \begin{cases} 1 \\ 0 \end{cases} \quad (7)$$

Nilai matriks *co-occurrence* bertambah 1 jika $g_k(x,y) = i$ dan $g_l(x,y) = j$. Sedangkan jika syarat tidak terpenuhi maka nilai piksel matriks *co-occurrence* tidak bertambah.

$$g_m(x,y) = \max_{n=0..15} (G_{mn}(x,y) * I(x,y)) \quad (8)$$

Persamaan (8) merupakan nilai *response* maksimum dari hasil konvolusi filter pada skala m dengan citra I . Gambar 10 menunjukkan contoh citra yang memiliki nilai *response* tertinggi pada tiap skala yang sudah ditentukan.



Gambar 10. Citra dengan nilai *maximum absolute response* pada tiap skala

D. Klasifikasi Menggunakan SVM

Pada tahap klasifikasi, *dataset* akan dibagi ke dalam 5 partisi dan klasifikasi dilakukan dengan menggunakan pengklasifikasi *Support Vector Machine (SVM)*. Pada penelitian ini, digunakan *Multi-Class Support Vector Machine* karena data memiliki lebih dari 2 kelas. *Multi-Class SVM* dapat melakukan klasifikasi terhadap banyak kelas dengan melakukan kombinasi pada setiap 2 kelas atau membandingkan satu kelas dengan gabungan kelas-kelas yang tersisa.

Salah satu metode implementasi *Multi-Class SVM* adalah metode *one against all*. Pada metode ini, dibangun k buah model SVM biner (k adalah jumlah kelas). Setiap model klasifikasi ke- i dilatih dengan label positif, dengan menggunakan keseluruhan data yang diberi label negatif. Adapun tipe kernel yang digunakan adalah tipe kernel linear dengan nilai parameter *penalty C* adalah 0.5. Alasan pemilihan pengklasifikasi ini adalah karena kemampuannya dalam generalisasi, implementasinya yang relatif mudah, serta kemampuannya dalam menangani data berdimensi tinggi [9]. Berikutnya, klasifikasi dilakukan terhadap 20 fitur yang dihasilkan dari matriks *co-occurrence* pada masing-masing skala.

IV. HASIL DAN PEMBAHASAN

Data yang digunakan dalam penelitian ini merupakan citra daun *flavia* yang dapat diunduh melalui situs <http://flavia.sourceforge.net/>. Jumlah keseluruhan citra yang digunakan adalah sebanyak 108 citra yang terdiri atas 4 kelas daun dengan jumlah yang sama pada tiap kelas. Gambar 11 menunjukkan contoh daun dari

masing-masing kelas yang akan diklasifikasi.



Gambar 11. Contoh citra dari masing-masing kelas

Percobaan I bertujuan untuk melakukan klasifikasi daun dengan menggunakan fitur *gabor co-occurrence*. Pada percobaan ini, dataset dibagi ke dalam 84 citra latih dan 24 citra uji. Untuk melakukan validasi terhadap keakuratan hasil klasifikasi, digunakan metode *k-fold cross validation* [11]. Tabel 1 menunjukkan hasil perbandingan akurasi klasifikasi berdasarkan jumlah *fold* yang telah ditentukan. Dengan menggunakan *3-fold* dan *7-fold* diperoleh akurasi klasifikasi yang tidak jauh berbeda, yaitu sebesar 85.18% dan 85.97%. Akurasi terbaik sebesar 89.83% pada percobaan ini diperoleh ketika menggunakan *5-fold*.

Tabel 1. Perbandingan jumlah *fold*

| Fold ke- | Akurasi (%) | | |
|-----------|-------------|--------|--------|
| | 3 Fold | 5 Fold | 7 Fold |
| 1 | 88.89 | 95.833 | 93.75 |
| 2 | 86.11 | 83.33 | 87.5 |
| 3 | 80.556 | 95 | 81.25 |
| 4 | - | 90 | 93.75 |
| 5 | - | 85 | 78.57 |
| 6 | - | - | 85.71 |
| 7 | - | - | 81.25 |
| Rata-rata | 85.18 | 89.83 | 85.97 |

Percobaan II bertujuan untuk membandingkan metode ekstraksi fitur *gabor co-occurrence* yang diajukan dengan metode matriks *co-occurrence* yang telah ada sebelumnya. Selain itu, pada percobaan ini dilakukan pula perbandingan antara dua metode klasifikasi, yaitu *SVM* dan *FKNN* (*Fuzzy K-Nearest Neighbor*). Tabel 2 menunjukkan perbandingan metode *gabor co-occurrence* terhadap metode matriks *co-occurrence*.

Tabel 2. Perbandingan metode

| Metode | SVM | FKNN |
|----------------------|----------|---------|
| Gabor Cooccurrence | 94,44 % | 86,11 % |
| Matriks Cooccurrence | 61,111 % | 55,56 % |

Tabel 3. Hasil klasifikasi daun yang tidak utuh

| Citra Asli | Hasil Klasifikasi | Citra Tidak Utuh | Hasil Klasifikasi |
|------------|-------------------|------------------|-------------------|
| | Kelas 1 | | Kelas 1 |
| | Kelas 1 | | Kelas 1 |
| | Kelas 2 | | Kelas 2 |
| | Kelas 2 | | Kelas 2 |
| | Kelas 3 | | Kelas 3 |
| | Kelas 3 | | Kelas 3 |
| | Kelas 4 | | Kelas 4 |
| | Kelas 4 | | Kelas 4 |
| Akurasi | 100% | Akurasi | 100% |

Perbandingan dengan metode matriks *co-occurrence* menunjukkan bahwa metode gabungan *gabor co-occurrence* yang diajukan mampu menghasilkan akurasi klasifikasi yang lebih baik, yaitu 94,44 %. Selain itu, perbandingan metode yang juga diuji dengan metode klasifikasi berbeda yaitu *SVM* dan *FKNN* menunjukkan bahwa hasil klasifikasi menggunakan metode *SVM* lebih unggul daripada *FKNN*.

Untuk menguji keandalan metode klasifikasi daun berdasarkan tekstur ini, maka dilakukan pula Percobaan III, dengan menggunakan citra daun yang sudah tidak utuh. Awalnya, 8 citra uji diklasifikasi dengan menggunakan 84 citra lainnya sebagai data latih. Selanjutnya, citra daun

yang sama dipotong sedemikian rupa hingga tidak menyerupai bentuk aslinya, untuk kemudian diberikan perlakuan yang sama dalam proses klasifikasi. Tabel 3 menunjukkan perbandingan hasil akurasi klasifikasi antara 8 citra daun yang utuh dan yang sudah tidak utuh lagi.

Berdasarkan Tabel 3, hasil klasifikasi dengan menggunakan 8 citra daun dalam kondisi utuh, menunjukkan akurasi sebesar 100%. Ketika daun yang sama dipotong atau kehilangan bagiannya antara 1/6 hingga 1/2 bagian, akurasi yang diperoleh masih sama, yaitu 100%. Hal ini menunjukkan bahwa dengan menggunakan fitur tekstur daun, metode *gabor co-occurrence* yang diajukan memiliki keunggulan bahkan ketika citra daun sudah tidak utuh lagi.

V. SIMPULAN

Pada penelitian ini, telah dilakukan penerapan metode ekstraksi fitur *gabor co-occurrence* untuk klasifikasi daun. Gabor filter menghasilkan sebuah *filter bank* yang terdiri atas berbagai skala dan arah/orientasi. Filter ini kemudian dikonvolusikan ke citra tekstur daun yang menghasilkan sekumpulan citra dengan berbagai nilai *response* untuk tiap skala dan arah. Orientasi dari citra dengan nilai *response* tertinggi dapat mewakili orientasi-orientasi lainnya, sehingga nilai matriks *co-occurrence* untuk citra yang memiliki nilai *response* tertinggi pada tiap skala kemudian dihitung. Sebuah fitur vektor kemudian dihasilkan dan menjadi masukan pada proses klasifikasi.

Percobaan dilakukan dengan menggunakan 108 citra daun dari *flavia*. Hasil menunjukkan bahwa metode yang diajukan lebih unggul daripada metode matriks *co-occurrence* ketika hanya bekerja sendiri. Selain itu, dengan menggunakan metode validasi *5-Fold cross validation* dan metode klasifikasi SVM, diperoleh akurasi klasifikasi sebesar 89.83%. Percobaan pada daun yang sudah tidak utuh lagi juga menunjukkan bahwa metode yang diajukan masih bisa mengklasifikasikan daun dengan tepat meskipun bentuk daun sudah tidak seperti bentuk aslinya lagi. Hal ini menunjukkan bahwa metode yang diajukan cukup andal karena tidak terpengaruh oleh kondisi daun.

Tulang daun pada klasifikasi daun berbasis tekstur dianggap sebagai *noise* dan seringkali mempengaruhi akurasi klasifikasi. Oleh karena itu, ke depannya perlu untuk dikembangkan metode *cropping* otomatis yang mampu mendapatkan area daun yang tidak bercampur dengan tulang daun.

DAFTAR PUSTAKA

- [1]. A.R. Backes, D. Casanova, dan O. Bruno, "Plant leaf identification based on volumetric fractal dimension", *International Journal of Pattern Recognition and Artificial Intelligence*, 23(06), hal. 1145-1160, 2009.
- [2]. R.C. Gonzalez dan R.E. Woods. "Digital Image Processing". Upper Saddle River, New Jersey: Prentice Hall. 2002.
- [3]. S. Liao dan A.C.S. Chung, "Texture classification by using advanced local binary patterns and spatial distribution of dominant patterns", di dalam *Acoustics, Speech and Signal Processing, 2007. ICASSP 2007. IEEE International Conference on*, vol. 1, hal. I-1221. IEEE, 2007.
- [4]. A. Kadir, L.E. Nugroho, A. Susanto, dan P. I. Santosa, "Leaf classification using shape, color, and texture features", *International Journal of Computer Trends and Technology*, issue 201, July - Aug 2011, hal. 225-230.
- [5]. S. Agustin dan E. Prasetyo, "Klasifikasi jenis pohon mangga gadung dan curut berdasarkan tesktur daun", *SESINDO 2011-Jurusan Sistem Informasi ITS*, hal. 58-64, 2011.
- [6]. M. Haghghat, S. Zonous, and M.A. Mottaleb, "Identification Using Encrypted Biometrics" di dalam *15th International Conference CAIP*, York, UK, Proceedings Part II, August 27-29, 2013, hal . 440-448.
- [7]. R.M. Haralick, I.Dinstein, dan K. Shanmugam, "Textural features for image classification". *IEEE Transactions on Systems, Man, and Cybernetics SMC-3*, hal. 610-621, 1973.
- [8]. A. Kadir dan A. Susanto, "Ekstraksi Fitur Tekstur", di dalam *Pengolahan Citra Teori dan Aplikasi*. Yogyakarta : ANDI, 2013, bab 13, hal 672-676.
- [9]. A.S. Nugroho, A.B. Witarto, dan D. Handoko, "Support vector machine teori dan aplikasinya dalam bioinformatika". *Kuliah Umum IlmuKomputer. Com*. 2003.

- [10]. S.G. Wu, F.S. Bao, E.Y. Xu, Y.X. Wang, Y.F. Chang, dan Q.L. Xiang, "A leaf recognition algorithm for plant classification using probabilistic neural network", di dalam *Signal Processing and Information Technology, 2007 IEEE International Symposium on*, hal. 11-16. IEEE, 2007.
- [11]. R. Kohavi, "A study of cross-validation and bootstrap for accuracy estimation and model selection", *IJCAI* Vol. 14, No. 2, hal. 1137-1145, 1995.