

Deteksi Defisiensi Unsur Hara Makro pada Tanaman Kopi berdasarkan Karakteristik Gejala Visual Daun menggunakan MTCD dan JST

Ahmad Annas Al Hakim^{*1}, Agus Eko Minarno², Yufis Azhar³

^{1,2,3}Teknik Informatika/Universitas Muhammadiyah Malang

msdjenkgot@gmail.com^{*1}, aguseko@umm.ac.id², yufis@umm.ac.id³

Abstrak

Semua tanaman, termasuk kopi membutuhkan unsur hara yang cukup untuk menunjang pertumbuhan dan perkembangannya secara normal. Apabila kebutuhan hara tidak tercukupi dengan baik, tanaman akan kekurangan suplai makanan dan gejala khas muncul pada tanaman, seperti perubahan ukuran daun, klorosis, nekrosis dan lainnya yang akan terlihat jelas terutama pada organ daun. Gejala – gejala tersebut memberikan ciri khas atau pola pada daun berdasarkan defisiensi hara yang dialami suatu tanaman. Ciri khas tersebut kemudian diekstraksi menggunakan pengolahan citra digital (PCD) dengan menerapkan Multi Texton Cooccurrence Descriptor (MTCD). Metode MTCD akan melakukan penelusuran pada tiap bagian citra, kemudian mengekstrak piksel – piksel yang memiliki kesamaan nilai warna dan tepi. Fitur-fitur hasil ekstraksi digunakan untuk mewakili setiap citra dalam basis data, dan kemudian digunakan untuk klasifikasi dengan menerapkan jaringan saraf tiruan (JST). Hasil akurasi tertinggi yang dihasilkan klasifikasi adalah 0.706.

Kata Kunci: Defisiensi Hara, PCD, MTCD, JST

Abstract

All plants, including coffee, need enough nutrients to support their normal growth and development. If nutrient needs are not fulfilled properly, plants will lack of food supply and typical symptoms appear in plants, such as changes in leaf size, chlorosis, necrosis and others that will be clearly visible, especially in leaf organs. These symptoms give a characteristic or pattern to the leaves based on nutrient deficiencies experienced by a plant. Then these characteristics are extracted using digital image processing (DIP) by applying Multi Texton Cooccurrence Descriptor (MTCD). The MTCD method will search for each part of the image, then extract pixels that have the same color and edge values. Extracted features are used to represent each image in the database, and then used for classification by applying artificial neural networks (ANN). The highest accuracy of the resulting classification is 0.706.

Keywords: Nutrient Deficiency, DIP, MTCD, ANN

1. Pendahuluan

Semua tanaman, termasuk kopi membutuhkan unsur hara yang cukup untuk menunjang pertumbuhan dan perkembangannya secara normal. Apabila kebutuhan hara tidak tercukupi dengan baik, tanaman akan kekurangan suplai makanan dan gejala khas muncul pada tanaman, seperti perubahan ukuran daun, klorosis, nekrosis dan lainnya yang akan terlihat jelas terutama pada organ daun [1]. Gejala–gejala tersebut memberikan ciri khas atau pola pada daun berdasarkan defisiensi hara yang dialami suatu tanaman.

Saat ini, di Pusat Penelitian Kopi dan Kakao, untuk mendiagnosis gejala defisiensi hara bergantung pada keahlian pakar bersebelahan dengan metode konvensional yang menerapkan uji laboratorium, kekurangan metode ini harga yang mahal dan membutuhkan waktu yang tidak singkat. Oleh karena itu untuk mengatasi permasalahan tersebut dibutuhkan suatu metode untuk mendeteksi defisiensi hara pada tanaman kopi secara tepat.

Pengolahan citra digital digunakan sebagai alternatif yang digunakan untuk mendeteksi defisiensi dengan mengekstraksi fitur-fitur citra daun berdasarkan ciri khas atau pola daun yang mengalami defisiensi hara makro. Pengukuran jarak antara beberapa citra serta keberagaman warna dalam citra menjadi masalah tersendiri saat proses pengolahannya [2].

Multi Texton Histogram (MTH) merupakan metode ekstraksi ciri citra yang menitik beratkan pada fitur bentuk, warna dan tekstur [3]. Metode yang diperkenalkan Liu menggunakan 4 buah *texton* sebagai deteksi tekstur. Matriks yang dihasilkan dari keempat *texton* tersebut kemudian disusun menjadi suatu histogram [4][5]. MTH juga dapat bekerja dengan baik dalam studi temu kembali citra [6][7][8][9]. Akan tetapi MTH masih terdapat kekurangan dari pencocokan citra yang menggunakan fitur lokal saat merepresentasikan citra yang terbatas pada istilah dan hasil ekstraksi *content* yang diperoleh dari setiap citra. Metode MTH kemudian disempurnakan menjadi *Multi Texton Cooccurrence Descriptor* (MTCD) oleh Agus dengan menggabungkan manfaat dari MTH dengan menambah 2 *texton* baru untuk mengatasi kelemahan MTH [10]. Fitur-fitur hasil ekstraksi digunakan untuk mewakili setiap citra dalam basis data, dan kemudian digunakan untuk klasifikasi dengan menerapkan jaringan saraf tiruan (JST). JST andal dalam analisa data seperti akurasi, kecepatan pemrosesan, latensi, skalabilitas dan konvergensi [11]. JST memiliki karakteristik dapat belajar mandiri atau belajar dari pengalaman, adaptifitas, non-linier dan lain sebagainya [12]. JST banyak diadopsi di akademisi dan industri untuk mengatasi tantangan dalam visi komputer [13], pengenalan pola dan bicara [14][15], penyalarsan wajah [16], dan deteksi [17].

2. Metode Penelitian

Metode penelitian menjabarkan tentang metode pengumpulan dan analisa data, lokasi penelitian, metode evaluasi serta penjabaran tentang algoritma atau metode yang digunakan.

2.1 Data

Data yang digunakan dalam penelitian merupakan data primer yang didapatkan dari Pusat Penelitian Kopi dan Kakao Indonesia. Tahapan analisa awal dilakukan proses *preprocessing* citra bertujuan untuk meningkatkan kualitas citra supaya citra yang dihasilkan dapat memberikan informasi yang lebih jelas [18].

2.2 Multi Texton Histogram

2.2.1 Color Feature

Pada *color feature* citra diolah dengan beberapa tahapan, tahapan awal warna pada setiap citra dibagi menjadi tiga warna dasar yang terdiri dari warna Merah (R), Hijau (G), Biru (B) dan di kuantisasi menggunakan 4 *bins* sehingga nilai rentang indeksnya antara 0 sampai 63 pada setiap warna [19].


2.2.2 Edge Feature

Deteksi tepi dari objek yang berada pada citra bertujuan untuk mendeteksi bagian yang menjadi detail pada citra. Deteksi tepi menggunakan operator *sobel* [20], pada setiap citra terdeteksi orientasi horizontal, orientasi vertikal, dan orientasi gabungan. Kemudian nilai *magnitude gradient* perhitungan arah tepi dihitung dengan Persamaan 1.


$$\varphi(x,y) = \tan^{-1} \left(\frac{S_y}{S_x} \right) \quad (1)$$

2.2.3 Deteksi Texton

MTCD meningkatkan MTH dengan menambahkan dua *texton*, jadi ada 6 *texton*. *Texton* baru adalah horizontal bawah dan vertikal kanan. Tujuan dari penambahan ini adalah untuk mencegah hilangnya informasi ketika piksel muncul bersamaan di bagian horizontal bawah dan vertikal kanan, seperti yang ditunjukkan pada Gambar 1 dan Gambar 2.

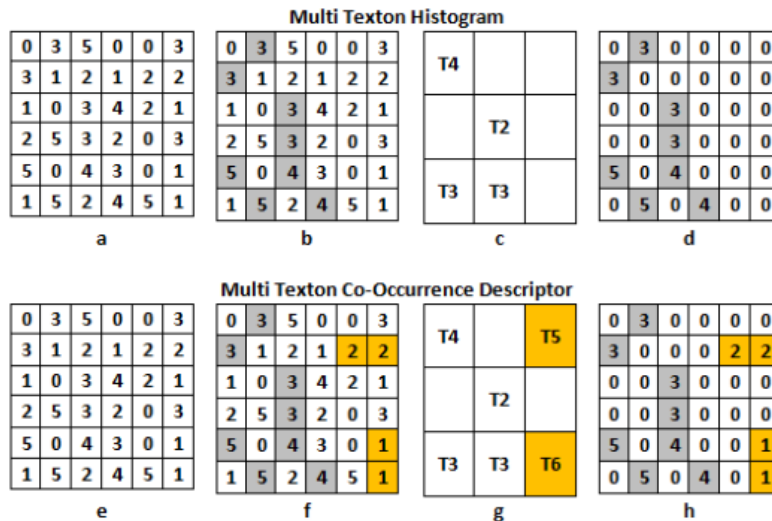


Gambar 1. Grid dan MTH Texton. Grid (Kiri); (T1-T4) MTH Texton



Gambar 2. MTC D Texton

Pada Gambar 3, langkah konvolusi dilakukan dari kiri ke kanan dan dari atas ke bawah dengan dua piksel. Dimensi *grid* yang digunakan adalah 2x2 piksel, ditandai sebagai v1, v2, v3 dan v4. Jika ada dua piksel yang sama, maka grid terdeteksi sebagai *texton*.



Gambar 3. Perbedaan Deteksi Texton pada MTH dan MTC D. (a-d) Deteksi Texton MTH; (e-h) Deteksi Texton MTC D

2.3 Gray Level Co-occurrence Matrix

Proses perhitungan GLCM dilakukan untuk memperoleh informasi derajat keabuan dari setiap dua piksel yang dipisahkan dengan jarak. 0°, 45°, 90°, dan 135° adalah derajat yang dicari [21][22]. Jika GLCM memiliki matriks ukuran LxL di mana (L) adalah nilai keabuan citra asli dan probabilitas (P) dari piksel (i) dan piksel ketetanggaan (j) dalam jarak (d) dan orientasi sudut (θ). Maka, Angular Second Moment atau Energy, Entropy, Contrast dan Correlation dapat dihitung dengan persamaan (2), (3), (4) dan (5) berdasarkan [23]. *Angular Second Moment* atau Energy digunakan untuk mengukur keseragaman/homogen tekstur pada citra. Semakin tinggi nilai *Energy* maka semakin homogen citra tersebut. Perhitungan *energy* menggunakan Persamaan 2.

$$ASM = \sum_{i,j=0}^{L-1} P^2(i, j, d, \theta) \tag{2}$$

Entropy adalah kebalikan dari *energy*. Fitur ini mewakili keacakan dari suatu citra. *Entropy* dihitung dengan Persamaan 3.

$$Ent = \sum_{i,j=0}^{L-1} P(i, j, d, \theta) \cdot \log P(i, j, d, \theta) \tag{3}$$

Contrast mewakili tingkat keabuan citra. Citra dengan tekstur halus menunjukkan nilai kontras rendah. Sebaliknya, citra dengan tekstur kasar menunjukkan nilai kontras tinggi. *Contrast* dihitung dengan Persamaan 4.

$$Cont = \sum_{i,j=0}^{L-1} (i - j)^2 \cdot P(i, j, d, \theta) \tag{4}$$

Correlation digunakan untuk mengukur hubungan linier antar piksel. *Correlation* dihitung dengan Persamaan 5.

$$Corr = \sum_{i,j=0}^{L-1} \frac{(i - \mu_x)(j - \mu_y)P(i, j, d, \theta)}{\sigma_x \sigma_y} \quad (5)$$

Di mana :

$$\begin{aligned} \mu_x &= \sum_{i,j=0}^{L-1} i \cdot P(i, j, d, \theta) & \sigma_x &= \sum_{i,j=0}^{L-1} (i - \mu_x)^2 \cdot P(i, j, d, \theta) \\ \mu_y &= \sum_{i,j=0}^{L-1} j \cdot P(i, j, d, \theta) & \sigma_y &= \sum_{i,j=0}^{L-1} (j - \mu_y)^2 \cdot P(i, j, d, \theta) \end{aligned}$$


2.4 Representasi Fitur MTCD

Semua fitur MTCD berasal dari hasil kuantisasi warna Merah (R), Hijau (G), Biru (B), hasil kuantisasi tepi dan fitur GLCM. Nilai warna Merah (R), Hijau (G), Biru (B) yang terkuantisasi terdeteksi oleh *texton* mewakili warna struktur spasial citra. Kemudian, nilai yang terkuantisasi dihitung menggunakan operator *Sobel* dan terdeteksi oleh *texton* mewakili tekstur dan bentuk. Jika warna Merah (R), Hijau (G), Biru (B) di kuantisasi menjadi 4 *bins*, maka jumlah total fitur warna adalah 64. Dan jika fitur tepi di kuantisasi menjadi 18 *bins*, maka ada 18 fitur tepi. Ketika 4 fitur GLCM diukur dari 4 arah (0° , 45° , 90° dan 135°), maka dihasilkan 16 fitur global. Jadi, total ada $64 + 18 + 16 = 98$ fitur di MTCD. Fitur-fitur ini digunakan untuk mewakili setiap citra dalam *database*, dan kemudian digunakan untuk klasifikasi.

2.5 Jaringan Saraf Tiruan

Jaringan saraf tiruan melakukan simulasi proses pembelajaran pada sistem komputer melalui input dan output yang dimodelkan berdasarkan sistem saraf manusia. Model JST pada dasarnya merujuk pada interkoneksi dari beberapa neuron yang ditempatkan pada lapisan yang berbeda, yang mendefinisikan fungsi model matematika $f : X \rightarrow Y$.

Secara umum, ada tiga lapisan pada JST. Lapisan pertama, merupakan lapisan masukan (input layer) yang terdiri dari neuron yang menerima data masukan dari variabel X. Neuron pada lapisan ini dapat terhubung dengan neuron yang ada pada lapisan tersembunyi atau langsung pada lapisan luaran jika pada arsitekturnya tidak menggunakan lapisan tersembunyi. Lapisan kedua, merupakan lapisan tersembunyi (hidden layer) terdiri dari neuron yang menerima data dari lapisan pertama atau lapisan masukan. Lapisan ketiga, merupakan lapisan luaran (output layer) terdiri dari neuron yang menerima data dari lapisan kedua atau langsung dari lapisan pertama yang melambungkan hasil nilai kalkulasi dari X menjadi Y.



Gambar 4 Arsitektur Multi Layer Perceptron (MLP)

Arsitektur pada Gambar 4 biasa disebut sebagai *Multi Layer Perceptron* (MLP) atau *Fully-Connected Layer* [24]. Pada setiap data *input layer* dilakukan operasi linear dengan nilai bobot yang ada, kemudian hasil komputasi akan ditransformasi menggunakan operasi non-linear yang disebut sebagai fungsi aktivasi. Fungsi aktivasi memungkinkan JST untuk dapat mentransformasi data *input* menjadi dimensi yang lebih tinggi sehingga dapat dilakukan pemotongan *hyperlane* sederhana yang memungkinkan dilakukannya klasifikasi [25].

Pada tahap pelatihan setiap bobot dan bias dari setiap neuron akan diperbarui terus menerus hingga *output* yang dihasilkan sesuai dengan harapan. Secara garis besar ada dua tahapan dalam proses latihan. *Forward pass* adalah proses di mana kita membawa data pada *input* melewati tiap neuron pada *hidden layer* sampai kepada *output layer* yang nanti akan dihitung galatnya. *Backward Pass* atau bisa juga *backpropagation* disebut galat yang kita dapat pada *forward pass* akan digunakan untuk memperbarui setiap bobot dan bias dengan *learning rate* tertentu.

2.5.1 Algoritma Optimasi

Algoritma optimasi digunakan untuk mencari nilai optimal, dengan cara memaksimalkan atau meminimalkan fungsi objektif.

1. Adam

Algoritma yang menggabungkan sifat-sifat terbaik yang dimiliki oleh algoritma optimasi *RMSProp* dan *AdaGrad*.

2. Stochastic Gradient Descent (SGD)

Algoritma yang mengimplementasikan *batching* dengan cara membagi data latihan menjadi beberapa *batch*. Bobot akan diperbarui dalam setiap selesai proses. SGD memperbarui nilai bobot tanpa menunggu 1 *epoch* selesai.

2.5.2 Epoch


Siklus di mana machine learning belajar keseluruhan set data latihan. Proses pembelajaran yang terus berulang bertujuan untuk mencapai konvergensi nilai bobot dalam jaringan saraf tiruan.

3. Hasil Penelitian dan Pembahasan

Pada bab hasil dan penelitian dijelaskan hasil dari penelitian dan pembahasan yang lengkap. Hasil dapat direpresentasikan dalam gambar, grafik, tabel dan lainnya yang dapat mempermudah pembaca dalam memahami makalah. Penjelasan dapat dibuat dalam bentuk sub bab.

3.1 Dataset

Pada Gambar 6, data merupakan citra daun yang mengalami defisiensi hara makro yang terdiri dari unsur N, P, K, Ca, Mg, S. Jumlah data yang digunakan dalam penelitian sebanyak 630 data citra, yang dibagi menjadi 6 kategori defisiensi hara makro dan 1 kategori normal dengan 90 data pada masing-masing kategori.



Gambar 5. Contoh Citra Daun Kopi

3.2 Hasil Ekstraksi Fitur MTCD

3.2.1 Color Feature

Setelah dilakukan proses ekstraksi citra menggunakan color feature maka didapatkan hasil yang dapat dilihat pada Tabel 1.

Tabel 1. Potongan Hasil Ekstraksi Color Feature

Citra	I	II	III	IV	...	LXIV
L.IMG.001.jpg	7444.83	0	0	0	...	3787.66
L.IMG.002.jpg	6650.83	0	0	0	...	6276.16
L.IMG.003.jpg	4764.66	0	0	0	...	4771
L.IMG.004.jpg	6841.16	0	0	0	...	1954
L.IMG.005.jpg	6927	0	0	0	...	4496.166

Pada ekstraksi ini menghasilkan sebanyak 64 fitur yang sesuai dengan penelitian acuan sebelumnya. Kolom I merupakan hasil nilai ekstraksi pertama, kolom II merupakan hasil ekstraksi kedua dan seterusnya sampai dengan kolom LXIV yang merupakan nilai ekstraksi ke 64 atau terakhir pada ekstraksi color feature ini. Nilai 0 pada ekstraksi color feature menandakan tidak adanya warna pada nilai kuantisasi tertentu. Semakin tinggi nilai ekstraksi pada color feature menandakan semakin banyak pula warna yang terdapat pada nilai kuantisasi di suatu citra.

3.2.2 Edge Feature

Setelah dilakukan proses ekstraksi citra menggunakan edge feature maka didapatkan hasil yang dapat dilihat pada Tabel 2.

Tabel 2. Potongan Hasil Ekstraksi Edge Feature

Citra	LXV	LXVI	LXVII	LXVIII	...	LXXXIII
L.IMG.001.jpg	202242.33	8793.83	4836.5	2703	...	0.0538
L.IMG.002.jpg	199087.66	9042.66	5190.16	3008	...	0.0610
L.IMG.003.jpg	195263.166	9666.16	6196	3633.83	...	0.0647
L.IMG.004.jpg	202939.83	9008.83	4987	2770.5	...	0.0556
L.IMG.005.jpg	200843.66	8784.66	4912.5	2801.83	...	0.0626

Pada ekstraksi ini menghasilkan sebanyak 18 fitur yang sesuai dengan penelitian acuan sebelumnya. Kolom LXV merupakan hasil nilai ekstraksi pertama, kolom LXVI merupakan hasil ekstraksi kedua dan seterusnya sampai dengan kolom LXXXIII yang merupakan nilai ekstraksi ke 18 atau terakhir pada ekstraksi edge feature ini. Nilai 0 pada ekstraksi edge feature menandakan ketidak acakan tepi objek pada nilai kuantisasi tertentu. Semakin tinggi nilai pada edge feature menandakan semakin acak tepi yang terdapat pada nilai kuantisasi tertentu di suatu citra.

3.2.3 GLCM

Setelah dilakukan proses ekstraksi citra menggunakan GLCM maka didapatkan hasil yang dapat dilihat pada Tabel 3.

Tabel 3. Potongan Hasil Ekstraksi GLCM

Citra	LXXXIV	LXXXV	LXXXVI	LXXXVII	...	XCVIII
L.IMG.001.jpg	0.0465	0.0553	0.0472	21.48	...	9.868
L.IMG.002.jpg	0.0528	0.0630	0.0536	16.59	...	9.504
L.IMG.003.jpg	0.0555	0.0652	0.0561	11.72	...	9.436
L.IMG.004.jpg	0.0481	0.0572	0.0486	18.52	...	9.829
L.IMG.005.jpg	0.0544	0.0649	0.0552	14.29	...	9.415

Pada ekstraksi ini menghasilkan sebanyak 16 fitur yang dihasilkan dari nilai derajat 0° , 45° , 90° , dan 135° yang masing-masing derajat mempunyai ciri *Angular Second Moment* atau *Energy*, *Entropy*, *Contrast* dan *Correlation* sesuai dengan penelitian acuan sebelumnya. Kolom LXXXIV merupakan hasil nilai ekstraksi pertama, kolom LXXXV merupakan hasil ekstraksi kedua dan seterusnya sampai dengan kolom XCVIII yang merupakan nilai ekstraksi ke 16 atau terakhir pada ekstraksi GLCM ini. *Energy* digunakan untuk mengukur keseragaman/homogen tekstur pada citra, semakin homogen suatu citra maka semakin tinggi nilai energi pada hasil ekstraksinya. *Entropy* adalah kebalikan dari *energy*. Fitur ini mewakili keacakan dari suatu citra, semakin acak distribusi keabuan suatu citra, maka tinggi nilai *entropy* pada hasil ekstraksinya. *Contrast*

mewakili tingkat keabuan citra. Citra dengan tekstur halus menunjukkan nilai kontras rendah. Sebaliknya, citra dengan tekstur kasar menunjukkan nilai kontras tinggi. *Correlation* digunakan untuk mengukur hubungan linier antar piksel dalam suatu citra.

3.3 Hasil Pengujian Klasifikasi

Skenario pengujian yang dilakukan menggunakan metode multi holdout di mana dataset yang terdiri dari data latih dan data uji dibagi dalam beberapa persentase; 80:20 sebagai skenario 1, 70:30 sebagai skenario 2 dan 60:40 sebagai skenario 3. Metode ini digunakan untuk membandingkan nilai akurasi dan dari setiap skenario. Sedangkan pengujian dalam jaringan saraf tiruan menerapkan *tuning parameter* dengan mengubah algoritma pada fungsi aktivasi, algoritma optimasi, atau banyak *epoch*.

Tuning parameter yang digunakan antara lain ReLU dan TanH untuk fungsi aktivasi, Adam dan SGD untuk algoritma optimasi. Selain itu, beberapa nilai *epoch* yang diujikan adalah kelipatan 50, dengan nilai terkecil adalah 50 dan nilai terbesar adalah 500. Jadi, pada *dataset* dilakukan proses klasifikasi sebanyak 30 kali (3 skenario dengan masing-masing 10 *epoch*).

Tabel 4 Rangkuman Nilai Akurasi Tertinggi dengan Tuning Parameter

Skenario	Tuning Parameter			Akurasi Tertinggi
	Fungsi Aktiva	Algoritma Optimasi	Epoch Terkecil	
1	ReLU	Adam	400	0.706
	ReLU	SGD	400	0.627
	TanH	Adam	350	0.651
	TanH	SGD	300	0.627
2	ReLU	Adam	250	0.672
	ReLU	SGD	450	0.577
	TanH	Adam	450	0.635
	TanH	SGD	500	0.582
3	ReLU	Adam	500	0.623
	ReLU	SGD	500	0.579
	TanH	Adam	500	0.583
	TanH	SGD	500	0.552

Terdapat metode yang selalu menghasilkan nilai akurasi tertinggi pada setiap skenario, yaitu ReLU dan Adam. Nilai akurasi tertinggi dari metode tersebut sebesar 0.706 dengan nilai *epoch* 400 pada skenario 1. Berdasarkan Tabel 4, fungsi aktivasi yang selalu memberikan hasil akurasi terbaik adalah ReLU. Sedangkan algoritma optimasi yang selalu memberikan hasil akurasi terbaik adalah Adam. Berdasarkan nilai akurasi tertinggi yang dihasilkan oleh kombinasi fungsi aktivasi dan algoritma optimasi pada setiap skenario, tidak ada perbedaan performa antara metode terbaik dengan metode lainnya. Perbedaan terbesar terdapat pada skenario 2, yaitu antara metode ReLU dan Adam dengan metode TanH dan SGD dengan perbedaan tingkat akurasi sebesar 0.095. Rata-rata metode terbaik yang menghasilkan nilai akurasi tertinggi dengan nilai *epoch* 400 ke atas, kecuali pada skenario 2 yang dapat menghasilkan nilai akurasi tertinggi dengan *epoch* sebesar 250.

Dari Tabel 4 menunjukkan bahwa semakin banyak data latih yang digunakan proses belajar mesin semakin cepat begitu pula sebaliknya, yang ditunjukkan berdasarkan nilai *epoch* pada setiap skenario. Skenario 1 memiliki nilai rata-rata *epoch* sebesar 350, skenario 2 memiliki nilai rata-rata *epoch* sebesar 400 dan skenario 3 memiliki nilai rata-rata *epoch* sebesar 500. Tidak hanya kecepatan proses belajar, nilai akurasi pun dipengaruhi dengan jumlah data latih yang digunakan.

4. Kesimpulan

Dataset citra daun dilakukan proses ekstraksi fitur guna memperoleh nilai dari setiap fitur warna, tepi dan sudut menggunakan metode MTCD. Metode tersebut menghasilkan 98 fitur yang mewakili sebuah citra daun. Dataset yang telah dilakukan ekstraksi fitur dibagi menjadi data latih dan data uji dengan pembagian data 80:20 sebagai skenario 1, 70:30 sebagai skenario 2 dan 60:40 sebagai skenario 3 kemudian dilakukan proses klasifikasi menggunakan jaringan saraf tiruan.

Proses klasifikasi jaringan saraf tiruan menerapkan *tuning parameter* yang mengkombinasikan fungsi aktivasi dan fungsi optimasi. Fungsi yang memberikan nilai akurasi tertinggi adalah fungsi aktivasi ReLu dan algoritma optimasi Adam dengan nilai akurasi sebesar 0.706 pada skenario 1, 0.672 pada skenario 2 dan 0.623 pada skenario 3. Jumlah data latih yang digunakan dapat mempengaruhi nilai akurasi, semakin besar jumlah data latih yang digunakan maka nilai akurasi semakin tinggi begitu pula sebaliknya. Jumlah data latih yang digunakan juga mempengaruhi kecepatan belajar mesin, semakin besar jumlah data latih yang digunakan maka jumlah *epoch* terkecil lebih sedikit untuk mencapai nilai akurasi tertinggi begitu juga sebaliknya.

Untuk meningkatkan nilai akurasi yang dihasilkan bisa dengan menambahkan jumlah lapisan tersembunyi beserta jumlah neuron pada setiap lapisannya, menentukan nilai learning rate, mengubah fungsi aktivasi dan algoritma optimasi pada tuning parameter. Pada penelitian selanjutnya bisa mengubah model pembelajaran mesin dengan model pembelajaran selain jaringan saraf tiruan untuk membandingkan apakah nilai akurasi bisa lebih baik dari model jaringan saraf tiruan.

Daftar Notasi

- d : jarak.
 θ : sudut.
 $P_{i,j}$: probabilitas nilai *cell* i,j .
 i,j : i nomor baris dan j nomor kolom.
 L : nomor baris atau kolom.

Referensi

- [1] P. dan M. Teguh Wahyudi, Ed., "Pengelolaan Hara Tanaman," in *Kopi: Sejarah, Botani, Proses Produksi, Pengolahan, Produksi Hilir, dan Sistem Kemitraan*, Pertama., Gadjah Mada University Press, 2016, pp. 235–252.
- [2] K. N. Setiawan and I. M. S. Putra, "Klasifikasi Citra Mammogram Menggunakan Metode K-Means, GLCM, dan Support Vector Machine (SVM)," vol. 6, no. 1, pp. 13–24, 2018.
- [3] N. Ulinnuha and H. Sa'dyah, "Sistem temu kembali citra untuk e-commerce," vol. 1, no. 1, pp. 35–41, 2015.
- [4] G. H. Liu and J. Y. Yang, "Image retrieval based on the texton co-occurrence matrix," *Pattern Recognit.*, vol. 41, no. 12, pp. 3521–3527, 2008.
- [5] G. Liu, L. Zhang, Y. Hou, Z. Li, and J. Yang, "Image retrieval based on multi-texton histogram," *Pattern Recognit.*, vol. 43, no. 7, pp. 2380–2389, 2010.
- [6] A. E. Minarno, Y. Munarko, A. Kurniawardhani, and F. Bimantoro, "Classification of Texture Using Multi Texton Histogram and Probabilistic Neural Network," *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 105, no. 1, 2016.
- [7] M. Y. Qazi and M. S. Farid, "Content based image retrieval using localized multi-texton histogram," *Proc. - 11th Int. Conf. Front. Inf. Technol. FIT 2013*, pp. 107–112, 2013.
- [8] X. Wang and Z. Wang, "A novel method for image retrieval based on structure elements' descriptor," *J. Vis. Commun. Image Represent.*, vol. 24, no. 1, pp. 63–74, 2013.
- [9] S. Mohan and S. Suresh Kumar, "A New Shape Feature Extraction Method for Leaf Image Retrieval," *Lect. Notes Electr. Eng.*, vol. 221 LNEE, no. VOL. 1, 2013.
- [10] A. E. Minarno and N. Suciati, "Image Retrieval Using Multi Texton Co-," vol. 67, no. 1, pp. 103–110, 2014.
- [11] A. Mozaffari, M. Emami, and A. Fathi, *A comprehensive investigation into the performance, robustness, scalability and convergence of chaos-enhanced evolutionary algorithms with boundary constraints*, vol. 52, no. 4. Springer Netherlands, 2019.
- [12] D. Wang, H. He, and D. Liu, "Intelligent Optimal Control with Critic Learning for a Nonlinear Overhead Crane System," *IEEE Trans. Ind. Informatics*, vol. 14, no. 7, pp. 2932–2940, 2018.
- [13] D. Cho, Y. W. Tai, and I. S. Kweon, "Deep Convolutional Neural Network for Natural Image Matting Using Initial Alpha Mattes," *IEEE Trans. Image Process.*, vol. 28, no. 3, pp. 1054–1067, 2019.
- [14] A. Samsudin and R. Budiarto, "Lightweight and Cost-Effective," pp. 525–526.
- [15] Y. Lecun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436–444, 2015.
- [16] R. Toufiq and M. R. Islam, "Face recognition system using PCA-ANN technique with feature fusion method," *1st Int. Conf. Electr. Eng. Inf. Commun. Technol. ICEEICT 2014*, 2014.

- [17] W. Yue, Z. Wang, H. Chen, A. Payne, and X. Liu, "Machine Learning with Applications in Breast Cancer Diagnosis and Prognosis," *Designs*, vol. 2, no. 2, p. 13, 2018.
- [18] N. G. A. . H. Saptarini and R. Y. Dillak, "Content Based Image Retrieval Menggunakan Moment Invariant , Tekstur Dan Backpropagation," vol. 2012, no. semnasIF, pp. 86–91, 2012.
- [19] A. E. Minarno, A. S. Maulani, A. Kurniawardhani, and F. Bimantoro, "Comparison of Methods for Batik Classification Using Multi Texton Histogram," vol. 16, no. 3, pp. 1358–1366, 2018.
- [20] S. E. Indraani, I. D. Jumaddina, S. Ridha, and S. Sinaga, "Implementasi Edge Detection Pada Citra Grayscale dengan Metode Operator Prewitt dan Operator Sobel," pp. 1–5, 2014.
- [21] A. E. Minarno and N. Suciati, "Batik image retrieval based on color difference histogram and gray level co-occurrence matrix," *Telkomnika (Telecommunication Comput. Electron. Control.*, vol. 12, no. 3, pp. 597–604, 2014.
- [22] R. Widodo, A. W. Widodo, and A. Supriyanto, "Pemanfaatan Ciri Gray Level Co-Occurrence Matrix (GLCM) Citra Buah Jeruk Keprok (Citrus reticulata Blanco) untuk Klasifikasi Mutu," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 2, no. 11, pp. 5769–5776, 2018.
- [23] A. A. Kasim and A. Harjoko, "Klasifikasi Citra Batik Menggunakan Jaringan Syaraf Tiruan Berdasarkan Gray Level Co- Occurrence Matrices (GLCM)," *Semin. Nas. Apl. Teknol. Inf. Yogyakarta, 21 Juni 2014*, pp. 7–13, 2014.
- [24] O. I. Abiodun, A. Jantan, A. E. Omolara, K. V. Dada, N. A. E. Mohamed, and H. Arshad, "State-of-the-art in artificial neural network applications: A survey," *Heliyon*, vol. 4, no. 11, p. e00938, 2018.
- [25] W. S. Eka Putra, "Klasifikasi Citra Menggunakan Convolutional Neural Network (CNN) pada Caltech 101," *J. Tek. ITS*, vol. 5, no. 1, 2016.

