

PENGENALAN TANAMAN HERBAL MENGGUNAKAN ALGORITMA *LEARNING VECTOR QUANTIZATION* DAN *MANHATTAN DISTANCE*

¹Amir Saleh, ²Alexander F K Sibero, ²Immanuel H G Manurung

¹Program Studi Teknik Informatika, ²Program Studi Sistem Informasi

¹Universitas Prima Indonesia, ²Universitas Sari Mutiara Indonesia

Email : amirsalehnst1990@gmail.com

ABSTRAK

Jaringan *learning vector quantization* (LVQ) telah dikenal secara luas untuk melakukan berbagai teknik klasifikasi, seperti pengenalan pola yang menunjukkan perolehan hasil yang baik. Permasalahan yang umum ditemukan pada penerapan jaringan LVQ, yaitu dalam penentuan bobot awal jaringan. Beberapa metode telah diusulkan untuk perbaikan bobot awal pada jaringan LVQ agar memperoleh akurasi yang optimal. Pada penelitian ini, metode *Manhattan distance* akan digunakan untuk pemilihan bobot awal pada jaringan LVQ. Metode ini merupakan metode pengukuran jarak kemiripan data yang dapat menentukan bobot awal berdasarkan kemiripan tertinggi yang berada dalam kelompok yang sama. Perolehan nilai dengan kemiripan tertinggi pada data tersebut digunakan sebagai bobot awal jaringan LVQ. Berdasarkan hasil pengujian yang dilakukan untuk pengenalan tanaman herbal dengan metode LVQ dan *Manhattan* memperoleh akurasi sebesar 81,33%. Sedangkan pada pengujian menggunakan metode LVQ memperoleh akurasi sebesar 78,67%. Peningkatan akurasi pengenalan tanaman herbal dengan menerapkan metode yang diusulkan sebesar 2,66%. Sehingga dapat disimpulkan bahwa metode *Manhattan* di dalam jaringan LVQ memiliki pengaruh yang baik di dalam penentuan bobot awal jaringan LVQ.

Kata Kunci : LVQ, *Manhattan*, Bobot Awal, Tanaman Herbal

I. PENDAHULUAN

Jaringan saraf tiruan merupakan teknik atau cara yang digunakan untuk pemrosesan informasi layaknya seperti jaringan syaraf biologi pada manusia. Jaringan saraf tiruan menyerupai otak manusia dalam dua hal, yaitu: pengetahuan diperoleh jaringan melalui proses dan kekuatan hubungan antara sel syaraf (*neuron*) yang dikenal sebagai bobot-bobot sinaptik untuk menyimpan pengetahuan [1]. Pada jaringan saraf tiruan terdapat *neuron* yang saling berhubungan antara satu dengan lainnya dan bekerja serentak untuk menyelesaikan suatu permasalahan tertentu. Cara kerja jaringan saraf tiruan seperti cara kerja otak manusia, yaitu belajar melalui pelatihan yang telah diberikan sebelumnya. Banyak permasalahan yang bisa diselesaikan dengan metode jaringan saraf tiruan, seperti: pengenalan pola dan klasifikasi data. Terdapat beberapa metode di dalam jaringan saraf tiruan, salah satu metode tersebut adalah *learning vector quantization* (LVQ) yang telah dikenal secara luas untuk pemrosesan informasi seperti pengenalan pola yang menunjukkan perolehan hasil yang baik.

Beberapa peneliti terdahulu telah melakukan berbagai penelitian untuk menguji kinerja jaringan LVQ. Sebagai contoh penelitian yang memaparkan penggunaan model LVQ untuk melakukan pengklasifikasian citra pada daging sapi dan daging babi berbasis GLCM. Pada penelitian tersebut dapat

membedakan citra daging sapi dan daging babi dengan akurasi tertinggi 75% [2]. Penelitian lainnya mengenai jaringan LVQ yaitu penelitian yang memaparkan penggunaan model LVQ dalam pengenalan *finger vein* setelah operasi dan memperoleh hasil pengenalan dengan tingkat akurasi sebesar 90% [3].

Berdasarkan paparan dari penelitian sebelumnya dapat diambil kesimpulan bahwa jaringan LVQ berperan baik dalam menangani kasus pengenalan pola atau klasifikasi citra. Permasalahan yang umum ditemukan pada penerapan jaringan LVQ, yaitu dalam penentuan bobot awal jaringan. Beberapa metode yang diusulkan untuk perbaikan bobot pada jaringan LVQ telah banyak dilakukan untuk memperoleh akurasi yang optimal. Penelitian yang meneliti tentang perbaikan bobot pada jaringan LVQ dengan AG (*Algoritma Genetika*). Hasil yang diperoleh menunjukkan akurasi tertinggi sebesar 88% [4]. Penelitian lainnya yang meneliti tentang perbaikan bobot pada jaringan LVQ dengan LDA (*Linear Discriminant Analysis*) pada kasus pengenalan wajah memperoleh akurasi tertinggi sebesar 92,62% [5]. Hal ini menunjukkan bahwa metode yang diusulkan dapat secara efektif menyelesaikan masalah pengenalan wajah.

Berdasarkan penelitian sebelumnya, diperlukan suatu metode tambahan dalam jaringan LVQ untuk mengoptimalkan bobot jaringan tersebut. Hal ini

dilakukan untuk meningkatkan kinerja jaringan agar akurasi yang diperoleh meningkat dibandingkan tanpa perbaikan bobot jaringan.

Pada penelitian ini, penentuan bobot awal yang baik akan diajukan untuk peningkatan akurasi jaringan LVQ. Secara umum, penentuan bobot pada jaringan LVQ diawali dengan penentuan bobot awal secara acak yang diambil dari data pelatihan dan kemudian dilakukan proses perhitungan. Selanjutnya, setiap data *input* akan dibandingkan dengan bobot awal untuk dipilih jarak minimumnya menggunakan persamaan Euclidean *distance*. Perbandingan jarak minimum ini yang akan dijadikan indikator untuk menentukan data-data yang memiliki kesamaan dan akan dijadikan dalam satu kelas. Proses *update* pada bobot akan dilakukan terus-menerus sampai data pengelompokan dalam satu kelas tidak mengalami perubahan dan menghasilkan bobot baru yang akan dipakai dalam pengujian jaringan LVQ. Penentuan bobot awal yang kurang tepat akan berdampak pada penurunan akurasi pembelajaran jaringan LVQ.

Metode yang diusulkan dalam penelitian ini adalah Manhattan *distance*. Manhattan *distance* merupakan metode yang digunakan untuk mengukur jarak kemiripan data. Selain itu, metode ini baik digunakan ketika melakukan klasifikasi data atau pengenalan pola. Penelitian yang melakukan analisis pengenalan wajah menggunakan metode Manhattan *distance* memperoleh hasil yang lebih baik dibandingkan metode Euclidean *distance*. Perbandingan antara metode Manhattan *distance* dengan Euclidean *distance* memperoleh hasil yang tidak jauh beda, yaitu menggunakan Manhattan sebesar 97% dan Euclidean sebesar 96% [6].

Metode Manhattan *distance* yang digunakan dalam penelitian ini akan mencari bobot awal berdasarkan ukuran tingkat kemiripan data. Jarak antara data *input* di dalam satu kelas akan dibandingkan dan dihitung tingkat kemiripannya. Bobot akan dihasilkan dengan membandingkan kemiripan data di dalam satu kelas. Data dengan kemiripan yang lebih tinggi dibandingkan dengan data lainnya di dalam satu kelas akan dipilih menjadi bobot awal di dalam jaringan LVQ. Proses ini dilakukan sebanyak kelas data yang akan digunakan untuk pelatihan jaringan LVQ.


II. TINJAUAN TEORITIS

1. Jaringan Saraf Tiruan

Jaringan saraf tiruan (*artificial neural network*) merupakan salah satu cara yang digunakan untuk pemrosesan informasi layaknya seperti jaringan saraf biologi pada manusia. Menurut Negnevitsky, jaringan saraf tiruan adalah model penalaran yang didasarkan pada otak manusia yang terdiri dari kumpulan sel yang terinterkoneksi penuh atau dasar unit pengolahan informasi yang disebut dengan *neuron* [7]. Secara umum, jaringan syaraf biologi

dan jaringan saraf tiruan memiliki karakteristik yang sama dalam mengolah informasi yang diberikan. Informasi yang diberikan selanjutnya dimasukkan ke dalam struktur jaringan dan diolah sampai diperoleh informasi yang bermanfaat. Semakin banyak jaringan diberikan informasi, maka akan semakin bertambah pengalaman belajarnya dan informasi yang diterima dapat diolah serta menghasilkan *output* yang lebih baik.

Pada jaringan saraf tiruan terdapat banyak *neuron* yang digunakan sebagai *input*-an atau penerima informasi dari dunia luar. *Neuron* yang terdapat pada jaringan saraf tiruan akan dikoneksikan dengan *link* (penghubung) dan setiap link memiliki bobot atau yang lebih dikenal dengan *weight* yang diasosiasikan dengannya [8]. Bobot-bobot antar koneksi pada suatu arsitektur jaringan diberikan nilai awal dan setelah itu jaringan saraf tiruan dapat dijalankan. Bobot-bobot ini nantinya akan digunakan untuk pembelajaran jaringan dan mengingat suatu informasi. Pengaturan bobot dilakukan secara terus-menerus dengan menggunakan kriteria tertentu sampai diperoleh keluaran yang diharapkan [7]. Secara sederhana arsitektur jaringan saraf tiruan dapat diperlihatkan pada Gambar 1 berikut.



Gambar 1. Arsitektur Jaringan Saraf Tiruan [7]

Secara umum lapisan penyusun yang terdapat pada jaringan saraf tiruan dapat dibedakan menjadi tiga, yaitu:

1. Lapisan masukan (*input layer*)
Lapisan ini terletak di bagian terluar yang merupakan tempat unit-unit *input* menerima masukan dari luar. *Input*-an merupakan parameter-parameter yang akan diolah untuk diperoleh *output*. Bagian ini terdiri dari unit-unit *input* yang langsung berhubungan dengan permasalahan yang ingin diselesaikan. Rangkaian *input* pada *neuron* buatan dapat ditulis dengan nama x_1, x_2, \dots, x_n .
2. Lapisan tersembunyi (*hidden layer*)
Lapisan ini terletak di bagian tengah yang merupakan tempat pemrosesan *input* yang akan diselesaikan dengan jaringan saraf tiruan. *Neuron* pada lapisan ini disebut juga dengan *hidden unit*. Pada lapisan ini digunakan fungsi aktivasi yang nantinya akan mengolah *input*-an yang diterima. Terdapat beberapa fungsi aktivasi seperti; fungsi undak biner, fungsi

bipolar, fungsi Gaussian dan lain-lain. Rangkaian *hidden layer* pada *neuron* buatan dapat ditulis dengan nama z_1, z_2, \dots, z_n .


3. Lapisan keluaran (*output layer*)

Lapisan ini merupakan lapisan akhir dari jaringan saraf tiruan yang merupakan *output* dari permasalahan yang telah di-*input*-kan. *Neuron* pada lapisan ini disebut dengan *output unit* yang selanjutnya dikonversi terhadap penyelesaian masalah. Rangkaian *output* pada *neuron* buatan dapat ditulis dengan nama y_1, y_2, \dots, y_n .

Jaringan saraf tiruan memiliki dua buah jenis pembelajaran dalam proses pelatihannya, yaitu pembelajaran terawasi (*supervised learning*) dan pembelajaran tidak terawasi (*unsupervised learning*). Pembelajaran terawasi (*supervised learning*) merupakan pembelajaran yang diberikan *input* dan *output* sekaligus dalam proses pelatihannya. Sedangkan pembelajaran tidak terawasi (*unsupervised learning*) yaitu pembelajaran yang hanya diberikan *input* dalam proses pelatihannya dan *output* diperoleh dari hasil pembelajaran untuk dapat dikategorikan sendiri.

2. Jaringan Saraf Tiruan Learning Vector Quantization (LVQ)

Jaringan *learning vector quantization* (LVQ) merupakan suatu metode pelatihan untuk melakukan pembelajaran pada lapisan kompetitif yang terawasi (*supervised Learning*). Jaringan ini sudah banyak digunakan dalam pengenalan pola baik berupa suara, citra dan lain sebagainya. Selain itu, LVQ juga sering dimanfaatkan untuk klasifikasi yang memiliki tingkat akurasi tinggi dan kecepatan dalam hal memproses [9]. Arsitektur jaringan LVQ dapat dilihat pada Gambar 2 berikut.



Gambar 2. Arsitektur Jaringan LVQ [10]

Berdasarkan Gambar 2, prinsip kerja jaringan LVQ yaitu mengurangi *node-node* tetangganya (*neighbor*), sehingga hanya akan ada satu *node output* yang terpilih (*winner node*). Langkah-langkah perhitungan pada jaringan LVQ dapat diuraikan sebagai berikut [9]:

1. Menyiapkan data pelatihan dan target.
2. Menginisialisasi bobot awal (w), maksimum *epoch*, nilai *learning rate* (α), pengurang

learning rate (α) dan minimum α . Nilai *epoch* dan α berfungsi untuk menentukan batas ambang komputasi.

3. Melakukan proses di bawah ini selama *epoch* < *MaxEpoch* atau $\alpha = \alpha$ minimum.

- a. Mengerjakan untuk $i=1$ sampai n
 - 1) Menghitung jarak hingga diperoleh jarak minimum, dimisalkan hasilnya sebagai nilai C_j . Persamaan yang digunakan sebagai berikut:

$$d(x, w) = \sqrt{\sum_{i=1}^j (x_i - w_j)^2}$$

Keterangan :

d = jarak data

x_i = data ke- i

w_j = vektor bobot ke- i

- 2) Memperbarui nilai w_j dengan syarat :
 - a) Jika $T = C_j$, maka : w_j (baru) = w_j (lama) + $\alpha(x - w_j$ (lama))
 - b) Jika $T \neq C_j$, maka : w_j (baru) = w_j (lama) - $\alpha(x - w_j$ (lama))
- b. Mengurangi nilai α selama kondisi berhenti belum terpenuhi dengan persamaan berikut:
$$\alpha(\text{baru}) = \alpha(\text{lama}) \times \text{dec } \alpha$$

dimana,
dec α : pengurangan α

4. Mengulangi langkah ke 3 jika $\alpha \leq \alpha$ minimum belum terpenuhi.

5. Setelah melakukan proses pelatihan, selanjutnya akan didapatkan bobot akhir (w). Bobot tersebut akan digunakan untuk melakukan klasifikasi pada data baru.

3. Pengolahan dan Pengenalan Citra

Pengolahan citra merupakan suatu metode atau teknik yang dapat digunakan untuk memproses citra digital dengan jalan memanipulasinya menjadi suatu data yang bersifat numerik untuk mendapatkan suatu informasi mengenai objek yang sedang diamati. Adapun langkah-langkah umum yang dilakukan dalam pengolahan dan pengenalan citra dapat diuraikan sebagai berikut.

a. Pengambilan Citra (*image acquisition*)

Akuisisi citra merupakan langkah pertama yang dilakukan dalam teknik pengenalan pola (*pattern recognition*) yang dikenal juga sebagai proses *capture* atau menangkap citra dari penglihatan sehingga diperoleh citra digital. Proses ini menggunakan alat yang bisa merekam citra yang ingin diamati dengan kamera, *webcam*, kamera *handphone*, *scanner*, sinar X dan sebagainya.

b. Perbaikan Citra (*image enhancement*)

Proses perbaikan citra bertujuan untuk memperbaiki kualitas citra. Pada proses pengambilan menggunakan kamera, citra yang diperoleh bisa saja mengalami gangguan seperti

terdapatnya noda pada citra, hasil kontras yang terlalu tinggi ataupun rendah, serta gangguan lainnya yang bisa mempengaruhi hasil pengenalan pola. Proses ini bisa tidak dilakukan jika citra yang diperoleh sudah memiliki hasil yang dirasa sudah baik.

c. Segmentasi Citra (*image segmentation*)

Segmentasi citra merupakan proses memisahkan objek yang hendak diamati dengan objek lain yang tidak dikehendaki (*background*). Pada proses pengolahan citra, terkadang tidak semua bagian citra yang kita butuhkan. Proses untuk memisahkan kedua bagian ini secara umum menggunakan metode *thresholding*.

Sebelum melakukan proses *thresholding*, citra diubah terlebih dahulu ke dalam bentuk *grayscale*. Proses ini mengubah citra RGB (*Red, Green, Blue*) menjadi citra keabuan. Pada umumnya citra RGB memiliki nilai kandungan warna piksel yang tinggi sehingga sulit untuk dianalisis. Nilai RGB mengandung 24 bit untuk setiap pikselnya, sedangkan nilai *grayscale* mengandung 8 bit untuk setiap pikselnya. Hal inilah yang menjadi alasan untuk mengubah nilai RGB tersebut menjadi *grayscale* agar lebih mudah untuk dianalisis.

d. Mengekstraksi Ciri Citra (*image feature extraction*)

Proses mengekstraksi ciri citra (*image feature extraction*) adalah langkah akhir sebelum proses pengenalan citra dilakukan. Pada proses ekstraksi ciri akan dihasilkan parameter-parameter yang mencirikan objek yang akan dikenali. Ciri inilah yang akan membedakan antara objek yang satu dengan yang lain. Suatu citra dapat dikenali ciri-cirinya dengan beberapa ciri diantaranya adalah bentuk, tekstur dan warna. Nilai dari ciri inilah yang akan dimasukkan ke dalam jaringan saraf tiruan untuk dipelajari sebagai *input*, sehingga dapat mengenali setiap objek.

Pada penelitian ini, ciri yang digunakan adalah ciri tekstur berbasis GLCM (*Gray Level Co-occurrence Matrix*). Ciri-ciri tersebut antara lain [11].

a) Kontras (*Contrast*), menunjukkan ukuran perbedaan intensitas antara *pixel* terhadap *pixel* tetangganya dalam suatu citra. Perbedaan ini diukur berdasarkan antar derajat keabuan suatu citra. Kontras menunjukkan ukuran penyebaran nilai intensitas suatu citra.

$$Contrast = \sum_i \sum_j (i - j)^2 P(i, j)$$

b) Korelasi (*Correlation*), menunjukkan ukuran korelasi antara *pixel* terhadap *pixel* dalam suatu citra. Selain itu, nilai korelasi memberikan petunjuk adanya struktur *linear* dalam citra.

$$Correlation = \frac{\sum_i \sum_j i \cdot j P(i, j) - \mu_i \mu_j}{\sigma_i \sigma_j}$$

c) Energi (*Energy*), disebut juga *Angular Second Moment* (ASM) yang merupakan ukuran sifat

homogenitas citra. Energi dapat dicari dengan penjumlahan elemen kuadrat di seluruh GLCM.

$$Energy = \sum_i \sum_j P(i, j)^2$$

d) Homogenitas (*Homogeneity*), menunjukkan ukuran kesamaan dalam variasi distribusi di GLCM terhadap diagonal matriks.

$$Homogeneity = \sum_i \sum_j \frac{P(i, j)}{1 + |i - j|}$$

e. Pengenalan Citra (*image recognition*)

Proses pengenalan citra merupakan proses terakhir dalam pengenalan pola (*pattern recognition*). Nilai parameter yang merepresentasikan ciri objek pada masing-masing kelas *sample* dijadikan sebagai data masukan untuk pengenalan pola. Data yang dihasilkan kemudian diolah sehingga diperoleh suatu nilai untuk dapat mengenali objek. Dalam tahapan ini, dilakukan dua proses utama yaitu proses pelatihan dan proses pengujian menggunakan jaringan saraf tiruan.

4. Manhattan Distance

Manhattan *distance* digunakan untuk menghitung perbedaan absolut (mutlak) antara koordinat sepasang objek [12]. Persamaan yang digunakan adalah sebagai berikut.

$$d(x, y) = \sum_{i=1}^n |x_i - y_i|$$

dimana,

d = jarak antara x dan y

x = data *input*

y = bobot

n = jumlah data

x_i = data ke-i

y_i = bobot ke-i

Jika hasil dari persamaan tersebut besar, maka tingkat kemiripan antara kedua objek akan semakin kecil. Sebaliknya, jika hasil persamaan tersebut kecil, maka tingkat kemiripan antara kedua objek akan semakin besar.

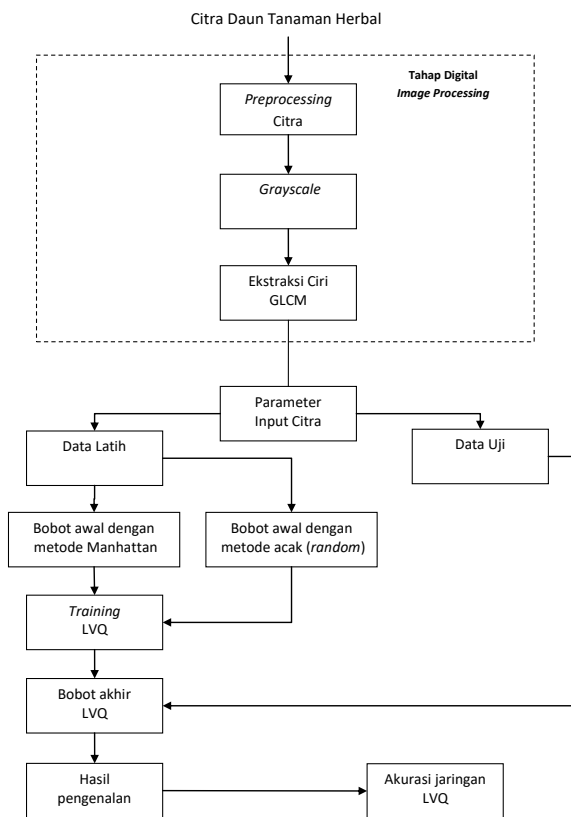
III. METODE PENELITIAN

Metode pada penelitian ini dimulai dengan mengidentifikasi masalah, yaitu melakukan pengenalan tanaman herbal dan perbaikan bobot pada jaringan LVQ. Setelah masalah teridentifikasi, langkah selanjutnya adalah mengumpulkan riset-riset penelitian terdahulu yang kemudian dilanjutkan dengan menentukan tujuan dari penelitian tersebut. Proses selanjutnya yaitu mengumpulkan *dataset* yang nantinya dibutuhkan saat proses pengujian dengan metode yang diusulkan. *Dataset* yang digunakan merupakan citra tanaman herbal yang terdapat pada lingkungan sekitar dengan jumlah sebanyak 450 citra. Adapun nama setiap tanaman herbal yang digunakan dapat dilihat pada Tabel 1 berikut.

Tabel 1. *Dataset* yang Digunakan

No.	Nama Tanaman Herbal	Jumlah Data
1.	<i>Acalypha australis L</i>	50
2.	<i>Murraya paniculata</i>	50
3.	<i>Murraya koenigii syn. Chalcas koenigi</i>	50
4.	<i>Sauropus androgynus</i>	50
5.	<i>Dimocarpus logan L</i>	50
6.	<i>Vernonia amygdalina</i>	50
7.	<i>Polyscias scutellaria</i>	50
8.	<i>Artocarpus heterophyllus</i>	50
9.	<i>Syzygium polyanthum</i>	50
Total		450

Adapun langkah-langkah penelitian yang diajukan dapat dilihat pada Gambar 3 sebagai berikut.



Gambar 3. Diagram Blok Jaringan LVQ dan Manhattan *Distance*

Pengujian terhadap *dataset* tersebut menggunakan algoritma jaringan LVQ dan Manhattan *distance* sebagai metode yang diusulkan untuk pengenalan tanaman herbal. Manhattan *distance* digunakan untuk pemilihan bobot awal jaringan LVQ. Metode ini merupakan metode pengukuran jarak kemiripan data, sehingga dapat ditentukan data pada *input*-an jaringan LVQ dengan kemiripan tertinggi yang berada dalam satu kelas. Perolehan dengan kemiripan tertinggi pada data tersebut digunakan sebagai bobot awal pada jaringan LVQ. Hasil

akurasi dengan metode tersebut akan dibandingkan dengan metode tanpa perbaikan bobot awal jaringan LVQ dan dilihat metode mana yang lebih baik dan meningkatkan akurasi pengenalan menggunakan jaringan LVQ. Langkah terakhir yaitu menarik kesimpulan yang bertujuan untuk memberikan informasi.

IV. HASIL DAN PEMBAHASAN

Pada penelitian ini menggunakan data berupa citra daun tanaman herbal berjumlah 9 jenis dan pengambilan setiap jenis daun dilakukan sebanyak 50 kali. Sehingga, total citra yang dijadikan objek penelitian berjumlah 450 citra. Adapun proses pengenalan tanaman herbal menggunakan metode yang diusulkan dapat dilihat pada Gambar 4 sebagai berikut.



Gambar 4. Proses Pengenalan Tanaman Herbal dengan Metode yang Diusulkan

Akurasi pengenalan tanaman herbal menggunakan metode yang diusulkan secara keseluruhan dapat dilihat pada Tabel 2 berikut.

No.	Metode	Jumlah Benar	Akurasi
1.	LVQ	354	78,67%
2.	LVQ-Manhattan	366	81,33%

Berdasarkan hasil pengujian yang telah dilakukan dapat diketahui akurasi jaringan LVQ dan Manhattan *distance* memperoleh hasil pengenalan sebesar 81,33% dengan jumlah data yang terklasifikasi benar sebanyak 366. Sedangkan akurasi jaringan LVQ tanpa perbaikan bobot memperoleh hasil pengenalan sebesar 78,67% dengan jumlah data yang terklasifikasi benar sebanyak 354. Peningkatan akurasi dengan menggunakan metode yang diusulkan mengalami peningkatan sebesar 2,66%.

Proses awal pada jaringan LVQ dilakukan dengan penentuan bobot awal secara acak untuk proses pelatihan. Pemilihan bobot yang tidak tepat dilakukan akan berdampak pada penurunan akurasi. Penggunaan Manhattan *distance* dalam jaringan

LVQ dapat melakukan penentuan bobot awal dengan pendekatan kemiripan data. Penentuan ini dilakukan dengan proses mencari nilai kemiripan tertinggi antara satu ciri citra dengan ciri lainnya di dalam satu kelas data. Hasil yang diperoleh akan menampilkan ciri dengan kemiripan tertinggi dan akan dijadikan sebagai bobot awal pada jaringan LVQ. Proses ini dilakukan untuk setiap kelas data yang terdapat pada *dataset* sebelumnya.

Hasil yang diperoleh pada penelitian ini menunjukkan bahwa penggunaan metode Manhattan *distance* dalam penentuan bobot awal pada jaringan LVQ memperoleh hasil yang lebih baik dibandingkan dengan LVQ tanpa perbaikan bobot.

V. KESIMPULAN

Berdasarkan dari hasil pengujian yang dilakukan untuk pengenalan tanaman herbal dengan menggunakan jaringan LVQ dan Manhattan *distance* memperoleh akurasi sebesar 81,33%. Sedangkan pada pengujian menggunakan metode LVQ memperoleh akurasi sebesar 78,67%. Kenaikan akurasi pengenalan tanaman herbal dengan menerapkan metode yang diusulkan sebesar 2,66%. Sehingga dapat disimpulkan bahwa metode Manhattan *distance* di dalam jaringan LVQ memiliki pengaruh yang baik di dalam penentuan bobot awal pada jaringan LVQ.

DAFTAR PUSTAKA

- [1] S. Haykin, "Neural Networks: A Comprehensive Foundation." Prentice Hall, 1999.
- [2] D. P. Kusumaningrum, U. Sudibyo, E. H. Rachmawanto, and C. A. Sari, "(Lvq) Dalam Klasifikasi Citra Warna Pada Daging Sapi Dan Babi," no. 1, pp. 978–979, 2018.
- [3] J. Y. Sari and R. A. Saputra, "Pengenalan Finger Vein Menggunakan Local Line Binary Pattern dan Learning Vector Quantization," *J. Ultim. Comput.*, vol. 9, no. 2, pp. 52–57, 2018, doi: 10.31937/sk.v9i2.790.
- [4] K. Widyawati, B. D. Setiawan, and P. P. Adikara, "Optimasi Vektor Bobot Learning Vector Quantization Menggunakan Algoritme Genetika untuk Penentuan Kualitas Susu Sapi," *J. Pengemb. Teknol. Inf. dan Ilmu Komput. Univ. Brawijaya*, vol. 2, no. 1, pp. 217–225, 2017.
- [5] A. Ouyang, K. Li, X. Zhou, Y. Xu, G. Yue, and L. Tan, "Improved LDA and LVQ for face recognition," *Appl. Math. Inf. Sci.*, 2014, doi: 10.12785/amis/081L38.
- [6] K. M. Ponnoli and S. Selvamuthukumar, "Analysis of Face Recognition using Manhattan Distance Algorithm with Image Segmentation," *Ijcsmc*, vol. 3, no. 7, pp. 18–27, 2014.
- [7] M. Negnevitsky, *Artificial Intelligence: A Guide to Intelligent Systems*, 2nd ed. Harlow, England: Addison-Wesley, 2005.
- [8] M. Agustin and T. Prahasto, "Penggunaan Jaringan Syaraf Tiruan Backpropagation Untuk Seleksi Penerimaan Mahasiswa Baru Pada Jurusan Teknik Komputer Di Politeknik Negeri Sriwijaya," *J. Sist. Inf. Bisnis*, vol. 2, no. 2, pp. 89–97, 2012, doi: 10.21456/vol2iss2pp089-097.
- [9] F. R. Hariri, E. Utami, and A. Amborowati, "Learning Vector Quantization untuk Klasifikasi Abstrak Tesis," *Creat. Inf. Technol. J.*, 2015, doi: 10.24076/citec.2015v2i2.43.
- [10] R. Langari, S. Member, and J. Won, "Intelligent Energy Management Agent for a Parallel Hybrid Vehicle — Part I: System Architecture and Design of the Driving Situation Identification Process," no. June, 2005, doi: 10.1109/TVT.2005.844685.
- [11] G. A. B, M. C. Chandrashekhar, and M. Z. Kurian, "Texture Feature Extraction of Video Frames Using GLCM," *Int. J. Eng. Trends Technol.*, vol. 4, no. 6, pp. 2718–2721, 2013.
- [12] M. D. Malkauthekar, "Analysis of Euclidean distance and Manhattan distance measure in face recognition," *IET Conf. Publ.*, vol. 2013, no. CP646, pp. 503–507, 2013, doi: 10.1049/cp.2013.2636.