

IDENTIFICATION OF PATCHOULI LEAVES QUALITY USING SELF ORGANIZING MAPS (SOM) ARTIFICIAL NEURAL NETWORK

Kartika Purwandari¹, Candra Dewi², Imam Cholissodin³

^{1,2,3} Teknik Informatika, Fakultas Ilmu Komputer, Universitas Brawijaya, Malang 65145, Indonesia
Email : kartikapurwandari@gmail.com¹, dewi_candra@ub.ac.id², imamcs@ub.ac.id³

ABSTRACT

One of the essential oil export commodities from Indonesia is patchouli oil. However, the price of patchouli today is unstable caused by the low quality of the oils, which has high levels of acid and lower alcohol content. One part of patchouli that is widely used to obtain essential oils is the leaf. The better quality of leaves will produce oil with grade quality. The quality of the leaves can be identified by its physical characteristics. Leaves that have a good quality are small leaves, thick and slightly yellowish red color. This identification process can be done visually, but, it will be easier if it can be done automatically using computer applications. Therefore, this paper performs automatic identification of leaves utilizing image of patchouli leaves and artificial neural network algorithm Self Organizing Maps (SOM). Identification was done to distinguish the leaves with good quality and poor. From the test results using the initial learning rate 0.1, 0.3 deduction learning rate, the minimum rate learning 0.0001, 40 training data and testing the data 60 obtained an average accuracy of 82.82%.

Keywords: *Self Organizing Maps, patchouli leave quality, leave image*

1. PENDAHULUAN

Minyak atsiri dikenal juga dengan dengan minyak terbang atau minyak eteris (*essential oil* atau *volatile*). Minyak ini selain sebagai

komoditas ekspor nonmigas yang banyak dibutuhkan berbagai negara di dunia, juga banyak digunakan di berbagai industri dalam negeri (Kardinan, 2005). Indonesia adalah salah satu negara penghasil minyak atsiri terbesar yang diperdagangkan di dunia dengan kontribusi 90%. Salah satu produk ekspor minyak atsiri dari Indonesia adalah minyak nilam. Indonesia mampu mengekspor minyak nilam sekitar 1200 ton per tahun dengan nilai ekspor $\pm$ US \$ 25 juta. Data dari Badan Pusat Statistik, minyak nilam yang diekspor Indonesia mencapai 60% dari total ekspor minyak atsiri (Halimah, 2010).

Berdasarkan informasi dari Dewan Atsiri Indonesia (DAI) yang ditulis di www.atsiri-indonesia.com pada tanggal 7 September 2012, harga minyak nilam sering melemah. Pada tahun 2011 harga minyak nilam sekitar Rp 450.000/kg namun pada pertengahan tahun 2012 turun sampai di bawah Rp 250.000/kg. Hal ini disebabkan kualitas minyak nilam yang dihasilkan tidak memenuhi standar karena kadar asamnya tinggi dan nilai kandungan alkoholnya rendah, sehingga dihargai lebih rendah (Business News, 2012).

Kualitas minyak nilam dapat diketahui berdasarkan jumlah kandungan minyak terutama komponen *patchouli alcohol* (PA). Kadar PA pada bagian daun jauh lebih besar daripada bagian lainnya dimana bisa mencapai 5-6% (Kardinan, 2005). Daun yang memiliki kualitas yang baik adalah daun yang kecil, tebal dan berwarna merah kekuningan (Rukamana, 2003).

Selama ini cara yang digunakan oleh petani untuk mengetahui kualitas dari daun nilam adalah dengan melihat fisik daun nilam secara langsung dan memperkirakan apakah daun tersebut berkualitas baik atau tidak. Proses ini tentunya memiliki kekurangan terutama bagi petani yang belum berpengalaman. Cara lain adalah dengan membawa daun nilam ke laboratorium untuk diuji. Walaupun hasil yang diperoleh dari laboratorium lebih tepat, namun waktu yang diperlukan cukup lama dan biaya yang dikeluarkan tidak sedikit. Dengan kemampuan teknologi informasi, proses identifikasi daun secara fisik dapat dilakukan secara otomatis dengan memanfaatkan algoritma komputasi dan citra daun.

Pada penelitian sebelumnya telah dilakukan klasifikasi terhadap citra daun. Penelitian Asanurjaya (2012) melakukan identifikasi tanaman jati menggunakan fitur morfologi yang salah satunya adalah luas daun dan metode *probabilistic neural network*. Penelitian ini menghasilkan akurasi sebesar 77,5% untuk 6 parameter dan 76% untuk 7 parameter. Penelitian lain melakukan identifikasi tumbuhan berdasarkan tulang daun menggunakan ciri jumlah cabang tulang daun dan metode *self organizing map* (SOM). Penelitian ini menghasilkan akurasi untuk jambu biji sebesar 94,386%, terong hijau sebesar 89,469%, cabai local sebesar 85,417, dan ubi jalar sebesar 99,731% (Wahyumianto, 2011). Selanjutnya, penelitian yang dilakukan oleh Wahyuningrum (2012) mengklasifikasi pola senyum citra wajah menggunakan algoritma SOM, dan menghasilkan akurasi sebesar 93%.

SOM adalah *unsupervised learning* yang dapat mengelompokkan data berdasarkan kesamaan pola tertentu (Pratiwi, 2012). Algoritma SOM adalah algoritma yang sederhana dan mudah untuk dipahami. SOM juga memiliki tingkat akurasi yang besar, hal ini dinyatakan dalam proses identifikasi jenis

gas yang dilakukan Frianto menggunakan metode *backpropagation* dan SOM. Dalam penelitian tersebut diperoleh tingkat keberhasilan sebesar 87,5% untuk SOM dan 75% untuk *backpropagation* (Frianto dan Rivai, 2008).

Berdasarkan keunggulan SOM, pada penelitian ini dilakukan identifikasi kualitas daun nilam berdasarkan ciri fisik daun menggunakan citra daun nilam dan algoritma SOM.

2. TANAMAN NILAM

Nilam atau perdu wangi adalah tanaman yang memiliki akar serabut dan daun halus bulat lonjong. Tanaman nilam memiliki batang yang berkayu dengan diameter 10-20 mm dan jumlah cabang sekitar 3-5 cabang per tingkat. Umur tumbuh nilam sekitar 3 tahun. Panen pertama dapat dilakukan pada bulan ke 6-7 dan panen berikutnya bisa dilakukan 2-3 bulan tergantung pola tanam (Mangun, 2006).


Minyak yang dihasilkan oleh tanaman nilam disebut minyak nilam (*patchouli oil*). Minyak ini antara lain digunakan sebagai zat pengikat (fiksatif) dalam industri parfum, sabun, dan tonik rambut. Minyak tersebut diperoleh dari hasil penyulingan daun dan tangkai tanaman nilam. Minyak nilam banyak digunakan dalam pembuatan sabun dan kosmetika karena dapat dicampur dengan jenis minyak atsiri lainnya, seperti minyak cengkih, geranium, dan akar wangi. Aroma minyak nilam sangat kaya dan tahan lama.

Seiring dengan meningkatnya kebutuhan manusia pada kesehatan dan kebugaran, minyak nilam banyak digunakan sebagai bahan baku untuk aromaterapi, karena aromanya yang khas. Minyak nilam dapat mengikat bau wangi dan mencegah penguapan zat pewangi tersebut sehingga bau wanginya lebih tahan lama (Kardinan, 2005). Pada Gambar 1 ditunjukkan contoh tanaman nilam.



Gambar 1 Tanaman Nilam

Minyak nilam ada yang memiliki kualitas baik dan kurang baik. Kualitas tersebut salah satunya dapat dilihat dari bahan pembuatnya yaitu daun nilam. Tanaman nilam dikatakan memiliki kualitas yang baik jika daunnya berwarna kuning kemerahan dan tebal. Sedangkan yang memiliki kualitas kurang baik jika daunnya berwarna hijau pekat dan tipis. Pada Gambar 2 ditunjukkan perbedaan daun nilam yang memiliki kualitas baik dan tidak baik.




Gambar 2 Daun Nilam (a) Berkualitas Baik
(b) Berkualitas Kurang Baik

3. METODE

Secara keseluruhan proses identifikasi yang dilakukan ditunjukkan pada Gambar 3. Masukan dari proses berupa citra daun nilam dalam keadaan bersih tanpa *noise* dengan ukuran 200x250 piksel. Proses *cropping*, *resize* dan *denoise* dari daun dilakukan secara manual dengan bantuan aplikasi *Adobe Photoshop CS3*. Proses selanjutnya adalah preproses citra yang meliputi kegiatan mengubah citra RGB menjadi *grayscale*, mengubah citra *grayscale*

menjadi biner dengan nilai *threshold* $d(T)$. Setelah dilakukan beberapa kali percobaan pada nilai *threshold* 100, 130, 150, 165, 180 dan 190, diperoleh nilai terbaik 190 dimana mampu menghasilkan citra biner yang sempurna. Setelah itu dilakukan proses ekstraksi fitur yang meliputi ekstraksi fitur warna dan fitur luas. Fitur warna yang digunakan adalah nilai rata-rata *red*, rata-rata *green*, dan rata-rata *blue*. Untuk mendapatkan nilai luas, diambil total dari warna putih dibagi dengan nilai 255 pada citra biner.

Fitur yang telah diperoleh kemudian digunakan untuk proses pelatihan (*training*) dan pengujian (*testing*) dengan menggunakan algoritma SOM. *Output* berupa label kualitas dari daun nilam dan nilai akurasi yang dihasilkan.



Gambar 3 Diagram alir proses secara umum

3.1 Citra Hitam Putih atau *Grayscale*

Citra *grayscale* mempunyai warna gradasi mulai dari putih sampai hitam pada setiap pikselnya. Salah satu bentuk fungsinya digunakan dalam kedokteran yaitu citra X-ray [7]. Nilai dari citra *grayscale* diperoleh dari

rata-rata citra berwarna menggunakan persamaan (1):

$$I_{BW}(x, y) = \frac{I_R(x, y) + I_G(x, y) + I_B(x, y)}{3} \quad (1)$$

imana:

$I_{BW}(x, y)$ = nilai piksel *Black and White* titik (x,y)

$I_R(x, y)$ = nilai piksel *Red* titik (x,y)

$I_G(x, y)$ = nilai piksel *Green* titik (x,y)

$I_B(x, y)$ = nilai piksel *Blue* titik (x,y)

3.2 Citra Biner

Pada citra biner, setiap piksel hanya terdiri dari warna hitam atau putih, dengan nilai 1 bit per piksel (0 atau 1). Gambar yang direpresentasikan dengan biner sangat cocok untuk teks (dicetak atau tulisan tangan), sidik jari (*finger print*) atau gambar arsitektur [7]. Citra biner diperoleh dari citra *grayscale* menggunakan persamaan 2.

$$I_{Bin}(x, y) = \begin{cases} 0 & I_{BW}(x, y) < T \\ 1 & I_{BW}(x, y) \geq T \end{cases} \quad (2)$$

Dimana:

$I_{BW}(x, y)$ = nilai piksel *grayscale* titik (x,y)

$I_{Bin}(x, y)$ = nilai piksel biner titik (x,y)

T = nilai *threshold*

3.3 Ekstraksi Fitur Luas

Salah satu ciri dasar yang digunakan dalam menentukan kualitas dari daun nilam adalah luas area. Luas area pada daun dapat dihitung dari banyaknya piksel bernilai 1 di dalam tepi daun.

3.4 Ekstraksi Fitur Warna

Untuk melakukan ekstraksi fitur warna digunakan nilai rata-rata dari warna merah, hijau, dan biru [10] dengan persamaan (3).

$$\bar{X} = \frac{\sum_{i=1}^n X_{ij}}{n} \quad (3)$$

Dimana:

$\bar{X}$ = rata-rata (*Mean*)

X_{ij} = nilai RGB dari baris ke-i dan kolom ke-j

n = banyaknya jumlah data RGB

3.5 Pelatihan dan Pengujian dengan SOM

Jaringan SOM menggunakan metode pembelajaran *unsupervised* yang secara otomatis mengelompokkan data berdasarkan kedekatan informasi yang dimiliki. Jika kondisi yang ditetapkan sudah terpenuhi, maka proses pembelajaran akan berhenti. Proses *training* pada SOM dapat dijelaskan sebagai berikut:

- Inisialisasi bobot masukan secara acak, dan set beberapa parameter seperti *learning rate* (α) awal, pengali *learning rate*, *minimum learning*, dan iterasi = 0.
- Lakukan langkah a-d jika *learning rate* < *minimum learning rate*.
 - a. Cari jarak antara data ke-j dengan tiap bobot input ke-i (D_j) dengan persamaan 4:

$$D(j) = \sum_{i=0}^m (w_{ij} - X_i)^2 \quad (4)$$

- b. Cari bobot yang terkecil.

- c. *Update* bobot terkecil dengan persamaan 5

$$w_{ij}(\text{baru}) = w_{ij}(\text{lama}) + \alpha [X_i - w_{ij}(\text{lama})] \quad (5)$$

- Perbarui *learning rate* (α).

Pada proses pengujian hanya menghitung jarak antara bobot dengan data tanpa melakukan *update* bobot. Adapun bobot yang digunakan adalah bobot terbaik yang diperoleh dari proses pelatihan.

3.6 Normalisasi Data

Sebelum digunakan sebagai masukan dari SOM, fitur yang diperoleh perlu dinormalisasi data memiliki range yang sama yaitu antara 0 – 1 (Budhi dan Liliana, 2008). Proses ini sangat diperlukan karena nilai pada fitur warna dan fitur luas memiliki perbedaan yang cukup besar. Pada paper ini digunakan metode min-max normalisasi dengan persamaan 6.

$$X_{norm} = \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad (6)$$

Dimana:

X_{norm} = Data baru hasil normalisasi

X_i = nilai data lama

X_{min} = nilai *minimum* dari X_i

X_{max} = nilai *maximum* dari X_i

3.7 Evaluasi

Evaluasi yang dilakukan bertujuan untuk mengetahui tingkat akurasi dari penggunaan algoritma SOM. Akurasi dihitung dari perbandingan jumlah data yang sesuai dengan jumlah seluruh data yang ada dan direpresentasikan dalam bentuk persentase [10]. Untuk menghitung akurasi menggunakan persamaan 7.

$$\text{akurasi} = \frac{\text{jumlah data yang benar}}{\text{jumlah seluruh data yang ada}} \times 100\% \quad (7)$$

4. HASIL DAN PEMBAHASAN

Data yang digunakan sebagai masukan berupa citra hasil pemindaian daun nilam tampak depan pada resolusi 600 dpi dengan *background* putih dengan format JPG dan berukuran 200x250 piksel. Daun nilam diambil dari Balai Penelitian Tanaman Nilam, Kesamben, Kabupaten Blitar dengan jenis tanaman nilam Aceh diploid. Daun yang diambil berumur 6 bulan masing-masing sebanyak 50 daun dengan kualitas baik dan 50 daun dengan kualitas kurang baik. Daun nilam masing-masing diambil 3 pasang daun termuda dari setiap tanaman.


Proses pelatihan dilakukan untuk mendapatkan kombinasi parameter yang menghasilkan bobot terbaik. Parameter yang dilatih meliputi *learning rate* awal, pengurang *learning rate*, *learning rate minimum*, iterasi *maksimum*, rasio jumlah data latih dan data uji.

4.1 Hasil Pelatihan *Learning Rate* Awal

Proses ini dilakukan dengan menaikkan nilai parameter *learning rate* awal dari 0.1 sampai 0.9. Parameter lain yang digunakan adalah pengurang *learning rate* = 0.8, *learning rate minimum* = 0.000001, jumlah data latih = 60, dan jumlah data uji = 40.


Hasil pelatihan nilai *learning rate* awal terhadap akurasi dan iterasi ditunjukkan pada Gambar 4 dan Gambar 5.

Dari Gambar 4 diketahui bahwa penggunaan semua nilai *learning rate* awal menghasilkan akurasi yang sama yaitu sebesar 85%. Hal ini dikarenakan bobot akhir yang dihasilkan dengan menggunakan pengurang *learning rate* mulai dari 0.1 sampai 0.8 dengan *learning rate minimum* 0.000001 selalu mencapai konvergen.



Gambar 4 Grafik hasil pelatihan *learning rate* awal terhadap akurasi

Pada Gambar 5 diketahui semakin besar nilai *learning rate* awal yang digunakan, maka akan semakin besar juga jumlah iterasi yang dihasilkan. Perbandingan nilai *learning rate* awal yang digunakan dengan jumlah iterasi yang dilakukan berbanding lurus. Hal ini dikarenakan untuk mencapai nilai *learning rate minimum* sebesar 0.000001 dengan menggunakan pengurang *learning rate* 0.8 membutuhkan pengulangan yang semakin lama.



Gambar 5 Grafik hasil pelatihan *learning rate* awal terhadap iterasi


Berdasarkan hasil diperoleh *learning rate* awal yang optimal adalah 0.1 dan digunakan untuk poses pelatihan selanjutnya.

4.2 Hasil Pelatihan Pengurang *Learning Rate*

Pelatihan ini dilakukan dengan menaikkan nilai pengurang *learning rate* dari 0.1 sampai 0.9. Parameter lain yang digunakan dalam proses ini adalah *learning rate* awal = 0.1, *learning rate* minimum = 0.000001, jumlah data latih = 60, dan jumlah data uji = 40.


Hasil pelatihan nilai pengurang *learning rate* terhadap akurasi dan iterasi ditunjukkan pada Gambar 6 dan Gambar 7.

Pada Gambar 6 diperoleh nilai pengurang *learning rate* terbaik adalah 0.8 dan 0.9, dimana dihasilkan akurasi tertinggi 85%. Hal ini dikarenakan dengan pengurang *learning rate* tersebut hasil *update learning rate* cukup optimal sehingga *update* bobot yang dihasilkan sudah mendekati konvergen.



Gambar 6 Grafik Pengaruh Parameter Pengurang *Learning Rate* Pada Akurasi

Pada Gambar 7 ditunjukkan nilai pengurang *learning rate* sebesar 0.1 memiliki iterasi yang paling sedikit. Namun hasil akurasi maksimal pada pengurang *learning rate* 0.8 dan 0.9. Pada pengurang *learning rate* 0.8 memiliki iterasi yang lebih sedikit dibandingkan 0.9 dengan kenaikan yang cukup signifikan.




Gambar 7 Grafik Pengaruh Parameter Pengurang *Learning Rate* Pada Jumlah Iterasi

Berdasarkan hasil pengujian tersebut, dengan demikian pengurang *learning rate* 0.8 akan digunakan untuk pengujian selanjutnya.

4.3 Hasil Pelatihan *Learning Rate* Minimum

Pelatihan ini dilakukan dengan menurunkan nilai *learning rate* minimum dari 10^{-3} sampai 10^{-7} . Parameter lain yang digunakan dalam pengujian ini adalah *learning rate* awal = 0.1, pengurang *learning rate* = 0.8, jumlah data latih = 60, dan jumlah data uji = 40.


Hasil pelatihan nilai *learning rate* minimum terhadap akurasi dan iterasi ditunjukkan pada Gambar 8 dan Gambar 9.



Gambar 8 Grafik Pengaruh Parameter *Learning Rate* Minimum Pada Akurasi

Dari Gambar 8 didapatkan akurasi tertinggi sebesar 85% dengan nilai *learning*

rate minimum sebesar 0.001 sampai 0.0000001 dan nilai terendah sebesar 83% dengan nilai *learning rate minimum* antara 0.01. Hasil ini menunjukkan penggunaan *learning rate* awal 0.1 dan pengurang *learning rate* 0.8, pada *learning rate minimum* 0.001 menghasilkan bobot yang sudah konvergen, sehingga tidak akan berpengaruh pada nilai *learning rate minimum* yang lebih kecil.



Gambar 9 Grafik Pengaruh Parameter *Learning Rate Minimum* Pada Jumlah Iterasi


Berdasarkan Gambar 9 diketahui semakin kecil nilai *learning rate minimum* maka jumlah iterasi semakin besar atau dapat dikatakan bahwa perbandingan nilai *learning rate minimum* yang digunakan dengan jumlah iterasi yang dilakukan berbanding terbalik. Hal ini dikarenakan untuk mencapai nilai *learning rate minimum* yang semakin kecil, semakin lama sistem akan melakukan perhitungan sampai mendekati nilai *minimum* tersebut.

Dari hasil pengujian tersebut, dengan demikian *minimum learning rate* dengan nilai 0.001 akan digunakan untuk pengujian selanjutnya.

4.4 Pengujian Jumlah Iterasi Maksimum

Pengujian ini adalah untuk mendapatkan jumlah iterasi terhadap tingkat akurasi yang dihasilkan dari sepuluh kali percobaan pada masing-masing nilai iterasi maksimum. Pengujian ini dilakukan dengan menaikkan nilai iterasi *maksimum* dari 2 sampai 14. Parameter lain yang digunakan dalam pengujian ini adalah menggunakan *learning*

rate awal = 0.1, pengurang *learning rate* = 0.8, jumlah data latih = 60, dan jumlah data uji = 40.




Gambar 10 Grafik Pengaruh Jumlah Iterasi *Maksimum* Pada Akurasi

Pada Gambar 10 ditunjukkan hasil pengujian pengaruh jumlah iterasi *maksimum* terhadap akurasi. Hasil pengujian menunjukkan akurasi terbaik yaitu pada iterasi ke 4 sampai 10 dengan nilai 82.5 %. Hal ini menunjukkan bahwa pada iterasi ke 4 hasil bobot yang dihasilkan sudah konvergen, sehingga tidak berpengaruh pada iterasi selanjutnya.

4.5 Pengujian Terhadap Perbandingan Jumlah Data Latih dan Data Uji

Pengujian dilakukan dengan menggunakan *learning rate* awal = 0.1, pengurang *learning rate* = 0.8, *learning rate minimum* = 0.001 dan iterasi *maksimum* = 4. Perbandingan data latih dan uji yang digunakan adalah 10:90 sampai dengan 90:10 dengan kenaikan data latih 10 dan penurunan data uji 10.



Gambar 11 Grafik Pengaruh Perbandingan Jumlah Data Latih Dan Data Uji Pada Akurasi

Dari Gambar 11 diketahui akurasi tertinggi sebesar 85% pada rasio data latih dan uji adalah 60:40. Hal ini dapat disebabkan variasi data yang terdapat pada data *training* dengan rasio 60:40 tidak terlalu banyak perbedaan pada fitur ukuran daun antar masing-masing kelas sehingga perubahan bobot yang dihasilkan tidak terlalu jauh. Namun pada rasio lainnya yang mendapatkan akurasi terendah yaitu misalnya pada rasio 10:90, hal ini dikarenakan terdapat daun dengan perbedaan ukuran yang sangat jauh antar masing-masing kelas. Apabila ditemukan daun dengan hasil ekstraksi fitur yang terlalu jauh, maka akan menyebabkan hasil *update* bobot yang terlalu jauh dan mempengaruhi bobot akhir yang dihasilkan pada proses pelatihan.

5. KESIMPULAN

Dari hasil pengujian yang dilakukan dapat diambil kesimpulan bahwa akurasi terbaik yang diperoleh adalah 85% menggunakan data latih sebanyak 60, data uji sebanyak 40, *learning rate* awal 0.1, pengurang *learning rate* 0.8, *learning rate minimum* 0.001, dan jumlah iterasi maksimum 12. Hasil ini menunjukkan bahwa SOM dapat digunakan untuk mendeteksi kualitas daun nilam berdasarkan ciri fisik daun yang terlihat melalui citra daun nilam.

Namun demikian masih perlu dilakukan pengujian lebih lanjut apabila citra masukan berupa citra daun yang diambil langsung dari kamera dengan kondisi pencahayaan dan posisi daun yang berbeda.

DAFTAR PUSTAKA

- ANDREW, ALASDAIR. 2004. An Introduction to Digital Image Processing with Matlab. Victoria University of Technology: School of Computer Science and Mathematics.
- ASANURJAYA, BANGUN. 2012. Identifikasi Tanaman Jati Menggunakan Probabilistic Neural Network Dengan Ekstraksi Fitur Ciri Morfologi Daun. Skripsi. Bogor: Institut Pertanian Bogor.
- BUDHI, G.S., LILIANA, HARRYANTO, S., 2008. *Cluster Analysis* untuk Memprediksi Talenta Pemain Basket Menggunakan Jaringan Saraf Tiruan *Self Organizing Maps (SOM)*. Research. Surabaya: Universitas Kristen Petra.
- BUSINESS NEWS. 2012. Selama Semester I Tahun 2012 Harga Minyak Nilam Melemah. Jakarta.
- FRIANTO, HERRI TRISNA, RIVAI, MUHAMMAD. 2008. Implementasi Jaringan Syaraf Tiruan *Backpropagation* dan *Self Organizing Map* Menggunakan Sensor Gas Semikonduktor Sebagai Identifikasi Jenis Gas. Seminar Nasional Informatika. Yogyakarta: UPN.
- HALIMAH, DIANA P.P. 2010. Minyak Atsiri dari Tanaman Nilam (*Pogostemon cablin* Benth.) Melalui Metode Fermentasi dan Hidrodistilasi Serta Uji Bioaktivitasnya. Prosiding. Surabaya: Institut Teknologi Sepuluh Nopember.
- KARDINAN, AGUS. 2005. Tanaman Penghasil Minyak Atsiri Komoditas Wangi Penuh Potensi. PT Agromedia Pustaka, Tangerang.
- MANGUN, H.M.S. 2006. Nilam. Penebar Swadaya, Jakarta.
- MUNAWAROH, SITI. 2010. Pengolah Citra Digital untuk Identifikasi Uang Kertas. Jurnal Teknologi Informasi DINAMIK Volume XV, No.1.
- PRATIWI, DIAN. 2012. *The Use of Self Organizing Map Method and Feature Selection in Image Database*

Classification Image. Research. Jakarta:
Universitas Trisakti.

RUKAMANA, H. RAHMAT. 2003. Nilam,
Prospek Agribisnis dan Teknik Budi
Daya. Kanisius, Yogyakarta.

WAHYUMINIANTO, ARGA., PURNAMA,
K. E., CHRISTYOWIDIASMORO. 2011.
Identifikasi Tumbuhan Berdasarkan
Minutiae Tulang Daun Menggunakan
SOM Kohonen. Skripsi. Surabaya: Institut
Teknologi Sepuluh Nopember.

WAHYUNINGRUM, R.T., ROSYID, B.,
PERMANA, K. E., 2012. Pengenalan
Pola Senyum Menggunakan *Self
Organizing Maps* (SOM) Berbasis
Ekstraksi Fitur Two Dimensional
Principal Componen Analysis
(2DPCA). Seminar Nasional Aplikasi
Teknologi Informasi (SNATI).