



## Identifikasi Penyakit Cabai Berdasarkan Gejala Bercak Daun dan Penampakan Conidia Menggunakan *Probabilistic Neural Network*

Jaka Permadi, Agus Harjoko

*Prodi S2/S3 Ilmu Komputer, JIKE, FMIPA, Universitas Gadjah Mada  
Sekip Utara, Yogyakarta*

*jaka.permadi.ugm@gmail.com*

*Prodi Elektronika dan Instrumentasi, FMIPA, Universitas Gadjah Mada  
Sekip Utara, Yogyakarta*

*aharjoko@ugm.ac.id*

### *Abstract*

Cabai merupakan salah satu komoditas penting di Indonesia yang sangat rentan terserang penyakit, sehingga pengendalian penyakit tanaman sejak dini diperlukan untuk mencegah kerusakan yang lebih lanjut. Sebagian besar gejala penyakit dapat dilihat pada bagian daun, sehingga dengan mengenali gejala awal pada daun diharapkan dapat membantu proses pengendalian penyakit tanaman. Penelitian yang dilakukan adalah identifikasi jenis penyakit tanaman cabai yang dibatasi pada penampakan bercak daun dan *conidia* yang diperoleh dari daun tersebut. Pengenalan dilakukan menggunakan *probabilistic neural network* (PNN) dan data yang dikenali merupakan citra dari daun cabai dan citra mikroskopis yang memperlihatkan *conidia* yang diekstraksi dari permukaan daun. Pengambilan data dilakukan di Yogyakarta dan didapatkan tiga jenis penyakit yang disebabkan oleh bercak daun dan dua jenis *conidia* yang diekstraksi dari setiap daun yang diambil. Ketiga jenis penyakit tersebut adalah bercak daun serkospora, bercak karena bakteri dan bercak kelabu stemfilium. Sementara kedua jenis *conidia* adalah *Cercospora capsici* dan *Leveillula taurica*. GLCM, fitur warna dan *circularity ratio* digunakan sebagai fitur-fitur dalam mengenali jenis bercak daun. Sementara fitur-fitur bentuk digunakan dalam mengenali jenis *conidia*. Akurasi yang didapat dari pengujian PNN untuk mengenali bercak daun sebesar 94,74%, sedangkan akurasi hasil pengujian dalam mengenali *conidia* sebesar 95,31%.

*Keywords*—fitur bentuk, fitur warna, GLCM, *probabilistic neural network*

### I. PENDAHULUAN

Cabai (*Capsicum annuum* L.) merupakan salah satu komoditas pertanian yang cukup penting di Indonesia. Walaupun demikian cabai sangat rentan terkena patogen dengan 33 jenis penyakit yang terdaftar [1]. Pengendalian penyakit tanaman diperlukan untuk mencegah kerusakan pada tanaman cabai jika terserang penyakit.

Gejala penyakit dapat dilihat pada bagian tubuh tanaman, seperti daun, buah, batang dan akar. Sebagian besar gejala penyakit cabai terlihat di daunnya. Sehingga dengan memperhatikan gejala pada daun, beberapa penyakit dan

patogennya dapat diidentifikasi. Agar penyakit tidak terlanjur parah, identifikasi perlu dilakukan pada infeksi awal.

Permasalahannya adalah beberapa jenis penyakit memperlihatkan kemiripan gejala pada infeksi awal tersebut. Hal ini menyebabkan proses identifikasi akan mengalami kesulitan jika hanya mengandalkan penampakan gejala yang tampak dari daun. Oleh karena itu pada penelitian ini identifikasi juga dilakukan menggunakan mikroskop untuk mengetahui patogen apa saja (cendawan) yang diperoleh dari daun yang diteliti. Pada penelitian yang telah dilakukan, terdapat tiga jenis bercak daun yang didapatkan, yaitu

bercak daun serkospora, bercak kelabu stemfilium dan bercak daun yang disebabkan oleh bakteri. Sedangkan jenis patogen yang terdeteksi, yang berupa *conidia* karena merupakan cendawan, ada dua jenis. Kedua jenis patogen tersebut adalah *Cercospora capsici* yang menyebabkan penyakit bercak daun serkospora dan *Leveillula taurica* yang menyebabkan penyakit embun tepung. Penyakit-penyakit yang disebabkan oleh patogen berupa cendawan dapat dibedakan berdasarkan karakteristik bentuk *conidia* yang dapat dilihat dengan menggunakan mikroskop. Bakteri tidak diteliti penampakan mikroskopisnya karena penampakan bakteri tidak dapat diperoleh jika hanya menggunakan mikroskop biasa.

Berdasarkan pada karakteristik penyakit bercak daun yang beragam, diperlukan sebuah sistem yang dapat digunakan untuk mengidentifikasi penyakit-penyakit tersebut. Pengenalan pola adalah suatu disiplin ilmu yang bertujuan untuk mengklasifikasikan sekumpulan objek ke dalam beberapa kategori atau beberapa kelas [2]. Dengan demikian pengenalan pola dapat digunakan untuk memudahkan seseorang dalam mengidentifikasi jenis-jenis penyakit bercak daun pada cabai.

Fitur-fitur yang akan digunakan untuk mengenali jenis penyakit adalah fitur tekstur, warna dan bentuk pada bercak daun dan fitur bentuk dan ukuran pada citra mikroskopis. Metode yang digunakan untuk melakukan ekstraksi fitur pada bercak adalah *Gray Level Co-occurrence Matrix* (GLCM), fitur warna RGB dan *circularity ratio* sebagai fitur bentuk. Sedangkan pada *conidia* ditentukan luasan area, *circularity ratio*, *rectangularity*, *compactness*, dan *eccentricity* sebagai fitur bentuk dan ukuran.

Jaringan Syaraf Tiruan (JST) merupakan suatu usaha untuk memodelkan kemampuan pemrosesan informasi dari sistem syaraf pada makhluk hidup. Salah satu model JST adalah *Probabilistic Neural Networks* (PNN). PNN akan digunakan pada penelitian ini karena menurut [3] tahapan pelatihan pada PNN lebih cepat dan dapat lebih akurat jika dibandingkan dengan jaringan multilayer perceptron. Selain itu PNN juga relatif insensitif terhadap data-data pencilan (*outlier*).

Penelitian ini bertujuan mengembangkan metode identifikasi penyakit cabai (*Capsicum anuum* L.) dengan gejala bercak daun dan penampakan *conidia* menggunakan PNN. Metode tersebut diimplementasikan dalam sebuah prototipe sistem berbasis komputer dengan penggunaannya adalah peneliti yang bergerak dalam bidang penelitian atau pertanian cabai. Identifikasi dilakukan berdasarkan fitur tekstur, warna dan bentuk pada bercak daun serta berdasarkan fitur bentuk dan ukuran dari *conidia* yang dilihat dengan menggunakan mikroskop. *Output* yang diharapkan adalah penyakit tanaman cabai dapat teridentifikasi.

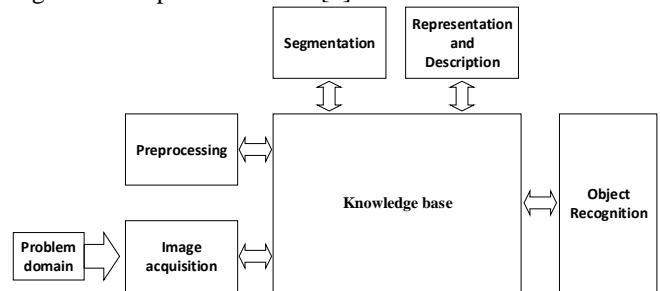
Hasil penelitian ini diharapkan dapat memberikan manfaat bagi peneliti yang bergerak dalam bidang pertanian (khususnya cabai) maupun bidang penelitian mikroba seperti jamur. Pada bidang pertanian, proses identifikasi yang dilakukan berdasarkan citra daun dan mikroskopnya

diharapkan dapat digunakan sebagai referensi dalam penanganan penyakit sedini mungkin. Sementara pada bidang penelitian mikroba proses identifikasi dapat digunakan sebagai referensi dalam perkembangan jamur pada tanaman cabai.

## II. LANDASAN TEORI

### A. Pengolahan Citra

Pengolahan citra digital diperlukan pada suatu sistem dengan citra sebagai masukannya. Pengolahan citra digital mencakup proses-proses di mana masukan dan keluarannya adalah citra, dan juga proses-proses yang dapat mengekstrak fitur dari citra. Langkah-langkah pengolahan citra digital digambarkan pada Gambar 1[4].



Gambar 1 Langkah-langkah pengolahan citra digital

1) *Preprocessing*: tahapan yang dilakukan pada penelitian ini memuat *image enhancement*, *grayscale*, dan pemrosesan morfologi. Dalam *image enhancement* metode yang akan digunakan adalah *smoothing* dengan menggunakan *filter box*. Dalam pemrosesan morfologi metode yang digunakan adalah dilasi, erosi, *boundary following* dan *region filling*. Algoritma yang digunakan pada *boundary following* adalah algoritma *Moore boundary tracking*. Sedangkan algoritma yang digunakan pada *region filling* adalah *floodfill reverse* karena pengisian lebih mudah dilakukan pada area *background* [5].

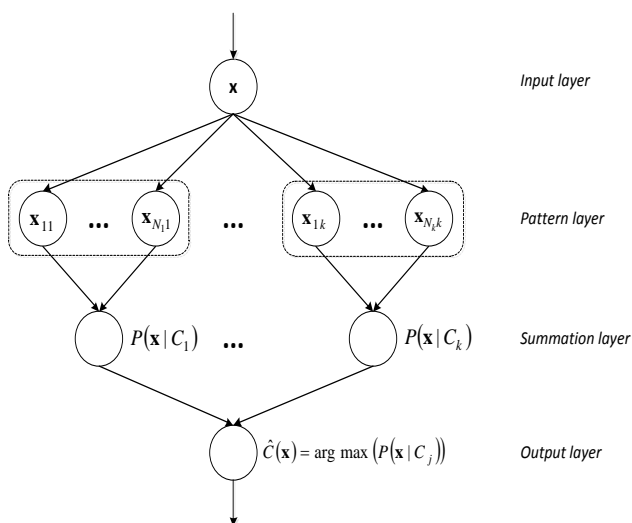
2) *Segmentasi*: Segmentasi membagi suatu citra menjadi bagian-bagian yang terpisah satu dengan yang lain. Segmentasi dibutuhkan ketika terjadi proses yang dilakukan hanya pada suatu bagian atau objek tertentu pada suatu citra. Algoritma segmentasi dibangun berdasarkan diskontinuitas dan similaritas. Diskontinuitas merupakan pendekatan untuk membagi citra berdasarkan pada perbedaan-perbedaan yang tajam pada intensitasnya, misalkan tepian objek pada citra. Jika suatu citra hanya terdiri dari objek-objek berupa garis dalam level grayscale, maka *thresholding* cukup untuk segmentasi tepian objek pada citra tersebut. Similaritas merupakan pendekatan yang berdasarkan pada pembagian citra menjadi area-area (regions) yang similar dengan himpunan kriteria yang telah didefinisikan sebelumnya. Contoh dari algoritma ini adalah segmentasi area pada ruang RGB berdasarkan perbedaan warnanya [4]. *Edge detection* dengan operator Sobel juga digunakan dalam penelitian ini.

3) *Representasi dan Deskripsi*: Representasi adalah suatu bagian dari suatu proses untuk membuat data dapat

berguna bagi komputer. Setelah representasi dilakukan deskripsi data berdasarkan representasi tersebut. Sebagai contoh suatu objek dapat direpresentasikan berdasarkan boundary dan region. Boundary dideskripsikan oleh fiturnya seperti keliling dan circularity, sedangkan region dideskripsikan oleh fiturnya seperti luas area. Representasi eksternal dipilih ketika fokus utama ada pada karakteristik bentuknya. Representasi internal dipilih ketika fokus utama adalah pada fitur area, seperti warna dan tekstur. Panjang suatu boundary dari suatu region merupakan deskriptor yang paling sederhana. Perimeter (keliling) dari suatu region adalah deskriptor yang merupakan panjang dari boundary. Sementara luas area dari region merupakan deskriptor yang didefinisikan sebagai banyaknya piksel dalam region tersebut [4]. Beberapa deskriptor yang memanfaatkan keliling dan luas area suatu region adalah *circularity ratio* dan *compactness*. *Circularity ratio* adalah perbandingan besarnya luasan area  $A_S$  dengan luas area lingkaran  $A_C$  yang memiliki keliling yang sama [6]. Sementara *compactness* merupakan perbandingan antara keliling yang dikuadratkan dengan luas area region. Deskriptor lainnya adalah *Rectangularity* dan *Eccentricity*. GLCM merupakan pendekatan yang paling sederhana untuk mendeskripsikan tekstur pada citra grayscale. Beberapa deskriptor pada matriks GLCM yang dapat digunakan adalah *Angular second moment (ASM)*, *contrast*, *inverse difference moment (IDF)* dan *entropy*. Nilai warna RGB direpresentasikan ke dalam tiga matriks gray-level yang berbeda untuk setiap dimensi R, G, dan B. Deskripsi yang didapatkan dari ketiga matriks tersebut adalah  $R_{mean}$ ,  $G_{mean}$  dan  $B_{mean}$ . GLCM juga dibangun pada dimensi G dan B, dan digunakan untuk mencari selisih nilai entropy pada dimensi G dan B. Nilai *entropy* pada dimensi R tidak perlu dicari karena tekstur pada dimensi tersebut tidak jelas [7].

### B. Probabilistic Neural Network (PNN)

PNN terdiri atas 4 layer, yaitu *input layer*, *pattern layer*, *summation layer* dan *output layer*. Arsitektur PNN tersebut digambarkan pada Gambar 2.



Gambar 2 Arsitektur PNN [8]

1) *Input layer dan pattern layer:* Input layer mendistribusikan data-data yang ada di dalamnya ke dalam pattern layer. Vektor  $x$  merupakan vektor input yang dapat dijabarkan menjadi  $[x_1 \ x_2 \ \dots \ x_l]^T$  dengan  $l$  adalah jumlah atribut dari vektor  $x$  tersebut. Pattern layer berisi data-data yang telah dibagi ke dalam kelas-kelas  $C_j$  yang dinotasikan dengan  $x_{ij}$ , dengan  $j = 1, 2, \dots, k$  merupakan banyaknya kelas dan  $i = 1, 2, \dots, N_j$  ( $N_j$  adalah banyaknya data pada kelas  $j$ ).

2) *Summation layer:* Setiap atribut pada  $x$  diukur kedekatannya dengan setiap atribut dari setiap data  $x_{ij}$  pada setiap kelas  $j$ . Diberikan fungsi likelihood yang merupakan output dari tiap neuron pada pattern layer seperti ditunjukkan pada persamaan berikut [8]:

$$\phi_{ij}(x) = \frac{1}{(2\pi)^{\frac{p}{2}} \cdot \sigma^p} \cdot \frac{1}{N_j} \cdot e^{-\left(\frac{(x-x_{ij})^T(x-x_{ij})}{2\sigma_j^2}\right)}$$

Pada persamaan di atas,  $p$  menyatakan besarnya dimensi dari vektor  $x$  dan  $\sigma_j$  adalah parameter penghalus pada kelas  $C_j$ . Probabilitas  $x$  terhadap kelas  $C_j$ , yang selanjutnya disebut sebagai *probability density function (pdf)* merupakan suatu nilai yang terisi pada *summation layer*. Nilai pdf tersebut didapatkan dengan menambahkan semua *output* pada setiap unit di *pattern layer* pada kelas yang sama seperti digambarkan pada persamaan berikut:

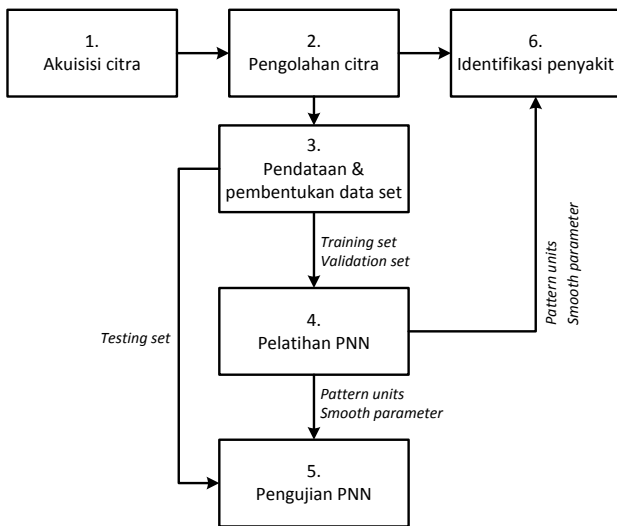
$$P(x|C_j) = \sum_{i=1}^{N_j} \phi_{ij}(x)$$

3) *Output layer:* Jika estimasi kelas dari suatu data  $x$  dinotasikan dengan  $\hat{C}(x)$ , maka persamaan yang menentukan estimasi kelas berdasarkan nilai pdf terbesar dituliskan dalam persamaan berikut [8]:

$$\hat{C}(x) = \arg \max_{1 \leq j \leq k} (P(x|C_j))$$

### III. METODE PENELITIAN

Penelitian yang dilakukan adalah mengembangkan metode identifikasi penyakit cabai dengan gejala bercak daun berdasarkan citra daun dan mikroskopisnya menggunakan PNN (*Probabilistic Neural Network*). Pengolahan citra digital diterapkan pada penelitian ini. Citra daun dan mikroskopisnya diolah untuk mendapatkan fitur atau fitur yang dibutuhkan untuk mengenali kelas penyakit pada tanaman tersebut. Pada citra daun dilakukan proses ekstraksi fitur warna dan tekstur pada bagian yang dicurigai sebagai bercak daun. Sedangkan citra yang diperoleh dengan mengadakan pengamatan melalui mikroskop dilakukan proses ekstraksi fitur bentuk. Gambaran umum tentang sistem identifikasi tanaman penyakit cabai dapat dilihat pada Gambar 3.



Gambar 3 Gambaran umum sistem identifikasi penyakit tanaman cabai

Jumlah data bercak daun yang diperoleh setelah pendataan adalah sebanyak 1522 data yang terbagi ke dalam empat kelas: bercak karena bakteri sebanyak 161 data, bercak daun serkospora sebanyak 216 data, bercak kelabu stemfilium sebanyak 96 data dan bukan bercak penyakit sebanyak 1049 data. Jumlah data conidia yang diperoleh setelah pendataan sebanyak 639 data yang terbagi ke dalam 3 kelas: *Cercospora capsici* sebanyak 100 data, *Leveillula taurica* sebanyak 57 data dan bukan conidia sebanyak 482 data. Untuk kepentingan pelatihan dan pengujian, data set tersebut dibagi menjadi tiga jenis data, yaitu *training set*, *validation set*, dan *testing set* dengan perbandingan 7:2:1.

Pada proses pelatihan, *input units* dari pelatihan tersebut berupa *training set* dan *validation set*. Sedangkan bagian *pattern layer* diisi oleh *training set*. Pelatihan dilakukan berulang-ulang dengan nilai  $\sigma$  yang berbeda-beda. Hasil dari pelatihan adalah nilai parameter penghalus  $\sigma$  dimana memiliki akurasi yang tertinggi. Setelah didapatkan nilai  $\sigma$  dari pelatihan, kemudian dilakukan pengujian untuk mengukur kemampuan PNN (menghitung akurasi) dengan  $\sigma$  yang didapatkan dari pelatihan dengan *input units* berupa *testing set*. Karena ada dua jenis data (data bercak daun dan data conidia), maka pelatihan keduanya pun dipisah. pelatihan yang menggunakan data bercak daun dapat saja berbeda dengan hasil pelatihan yang menggunakan *conidia*. Selain proses pelatihan dan pengujiannya yang berbeda, proses akuisisi citra dan pengolahannya juga berbeda. Untuk mendapatkan objek berupa bercak daun dari citra daun yang diolah, dibutuhkan metode berupa: segmentasi daun (RGB), *grayscale*, *edge detection*, *smoothing*, *thresholding*, *boundary following*, *region filling*, dilasi, segmentasi objek (RGB) dan kemudian ekstraksi fitur tekstur, warna dan bentuk dari bercak daun yang didapatkan. Untuk mendapatkan objek berupa conidia dari citra mikroskopis yang diolah, dibutuhkan metode berupa *grayscale*, *smoothing*, *cropping*, *thresholding*, dilasi, erosi, *boundary following*, *region filling*, dan terakhir ekstraksi fitur bentuk.

#### IV. HASILDAN PEMBAHASAN

##### A. Pelatihan dan Pengujian Menggunakan Data Bercak Daun

Pelatihan dilakukan dengan memasukkan nilai penghalus dalam range [0.001, 0.03] dengan step sebesar 0.001. Hasil pelatihan yang dilakukan dengan menggunakan data bercak daun adalah nilai parameter penghalus sebesar 0.025 dengan akurasi dari *training set* sebesar 100% dan *validation set* sebesar 85.809%. Eksplorasi yang dilakukan ini dapat dilihat pada Tabel 1.

TABEL 1  
HASIL EKSPLORASI PARAMETER PEGHALUS TERHADAP AKURASI PELATIHAN BERCAK DAUN

HasilTrainingDaun			
No	Smooth Parameter	Akurasi TrainingSet	Akurasi ValidationSet
1	0.001	100	6.271
2	0.002	100	10.231
3	0.003	100	27.393
4	0.004	100	44.224
5	0.005	100	58.086
6	0.006	100	66.667
7	0.007	100	74.587
8	0.008	100	79.538
9	0.009	100	81.518
10	0.01	100	82.508
11	0.011	100	82.508
12	0.012	100	82.838
13	0.013	100	83.828
14	0.014	100	84.818
15	0.015	100	84.818
16	0.016	100	84.818
17	0.017	100	84.818
18	0.018	100	85.149
19	0.019	100	85.149
20	0.02	100	85.149
21	0.021	100	85.479
22	0.022	100	85.479
23	0.023	100	85.479
24	0.024	100	85.479
25	0.025	100	85.809
26	0.026	100	85.809
27	0.027	100	85.809
28	0.028	99.906	85.809
29	0.029	99.906	85.809
30	0.03	99.906	85.479

Pengujian yang dilakukan dengan menggunakan *testing set* dari data bercak daun dengan nilai  $\sigma = 0.025$  menghasilkan akurasi sebesar 94.737%.

##### B. Pelatihan dan Pengujian Menggunakan Data Conidia

Pelatihan dilakukan dengan memasukkan nilai penghalus dalam range [0.001, 0.03] dengan step sebesar 0.001. Hasil pelatihan yang dilakukan dengan menggunakan data conidia adalah nilai parameter penghalus sebesar 0.012 dengan akurasi dari *training set* sebesar 98.661% dan *validation set*

sebesar 86.614%. Eksplorasi yang dilakukan ini dapat dilihat pada Tabel 2

TABEL 2  
HASIL EKSPLORASI PARAMETER PEGHALUS TERHADAP AKURASI  
PELATIHAN CONIDIA

Hasil Training Mikro			
No	Smooth Parameter	Akurasi TrainingSet	Akurasi ValidationSet
1	0.001	100	39.37
2	0.002	100	68.504
3	0.003	100	77.165
4	0.004	100	79.528
5	0.005	99.777	81.102
6	0.006	99.777	82.677
7	0.007	99.554	82.677
8	0.008	99.554	84.252
9	0.009	99.33	84.252
10	0.01	99.33	84.252
11	0.011	99.107	85.827
12	0.012	98.661	86.614
13	0.013	98.214	86.614
14	0.014	97.098	87.402
15	0.015	96.429	87.402
16	0.016	96.205	87.402
17	0.017	94.643	88.976
18	0.018	93.75	89.764
19	0.019	93.75	89.764
20	0.02	92.857	89.764
21	0.021	92.411	89.764
22	0.022	91.295	89.764
23	0.023	89.509	89.764
24	0.024	89.286	89.764
25	0.025	88.393	89.764
26	0.026	87.5	90.551
27	0.027	87.054	91.339
28	0.028	86.607	91.339
29	0.029	86.384	91.339
30	0.03	85.714	91.339

Pengujian yang dilakukan dengan menggunakan *testing set* dari data conidia dengan nilai  $\sigma = 0.012$  menghasilkan akurasi sebesar 95.313%.

#### DAFTAR PUSTAKA

- [1] A. S. Duriat, N. Gunaeni & A. W. Wulandari, *Penyakit Penting Tanaman Cabai dan Pengendaliannya*, Bandung, Indonesia : Balitsa, 2007.
- [2] S. Theodoridis & K. Koutroumbas, *Pattern Recognition*, fourth ed, California : Academic Press, 2009.
- [3] S. N. Ghaiwat & P. Arora, "Detection and classification of plant leaf diseases using image processing techniques: a review", *International Journal of Recent Advances in Engineering & Technology (IJRAET)*, Vol. 2, Issue 3, 2014.
- [4] R. C. Gonzalez & R. E. Woods, *Digital Image Processing*, 3<sup>rd</sup> ed, New Jersey : Prentice Hall, 2008.
- [5] P. Andre, "Intelligent Flood Fill or: The Use of Edge Detection in Image Object Extraction", University of Southampton, Southampton, 2005.
- [6] Y. Mingqiang, K. Kidiyo & R. Joseph, "A Survey of Shape Feature Extraction Techniques", P. Yin, Ed. Rijeka : InTech, 2008.
- [7] K. Huang, "Application of Artificial Neural Network for Detecting Phalaenopsis Seedling Diseases Using Color and Texture Features", *Computers and Electronics in Agriculture*, Vol. 57, pp. 3-11, 2007.
- [8] K. Z. Mao, K.C. Tan & W. Ser, "Probabilistic Neural-Network Structure Determination for Pattern Classification", *IEEE transactions on neural networks*, Vol. 11, Issue. 4, pp. 1009-1016.