

## IDENTIFIKASI KEKURANGAN UNSUR HARA PRIMER PADA PERTUMBUHAN TANAMAN KEDELAI BERDASARKAN TEKSTUR DAUN MENGGUNAKAN SUPPORT VEKTOR MACHINE

<sup>1</sup>M. Syahrul Munir, <sup>2</sup>I Ketut Eddy Purnama

<sup>1</sup>Teknik Informatika, Fakultas Teknologi Industri, UPN “Veteran” Jatim

<sup>2</sup>Teknik Elektro, Fakultas Teknologi Industri, Institut Teknologi Sepuluh Nopember Surabaya

<sup>1</sup>[syahrulmunir\\_spdc@yahoo.com](mailto:syahrulmunir_spdc@yahoo.com), <sup>2</sup>[etutedi@gmail.com](mailto:etutedi@gmail.com)

**Abstrak.** *Pertumbuhan tanaman kedelai dipengaruhi oleh hama, penyakit dan unsur hara. Kekurangan unsur hara tersebut dapat diketahui dari gejala-gejala yang ditimbulkannya, akan tetapi untuk mengetahui secara tepat jenis unsur hara yang menyerang kedelai tersebut, memerlukan seorang pakar/ahli pertanian. Otomatisasi yang dibuat dalam penelitian ini adalah melakukan klasifikasi jenis kekurangan unsur hara primer berdasarkan tekstur daun. Klasifikasi yang digunakan dalam penelitian ini adalah metode SVM (Support Vektor Machine) dan Jaringan Saraf Tiruan (JST) pada fitur tekstur daun yang kekurangan unsur hara primer (antara lain K (kalium), N (Nitrogen) dan P (Pospor). Karena daun kedelai umumnya berwarna hijau, maka fitur warna tekstur yang digunakan adalah fitur warna green dari bagian warna HSV (Hue, Saturation, Value). Fitur tekstur yang digunakan dalam penelitian adalah : contrast, correlation, energy dan homogeneity. Klasifikasi dilakukan pada tiga jenis kekurangan unsur hara primer menggunakan 23 sampel daun yang kekurangan unsur N, 23 sampel daun yang kekurangan unsur P dan 23 sampel daun yang kekurangan unsur K.*

**Kata Kunci:** *Klasifikasi, Support Vektor Machine, Unsur Hara, Kedelai*

Kedelai (*Glycine max L. Merrill*) telah ditanam di Indonesia sejak awal abad ke 18 dan kemungkinan diperkenalkan oleh imigran dari dataran Cina. Areal produksi kedelai yang sebelumnya terbatas di Jawa dan Bali sejak tahun 1950 menyebar ke pulau-pulau lain termasuk Sumatra, Kalimantan, Sulawesi, dan kepulauan Indonesia timur. Sampai 1974 permintaan kedelai dapat dipenuhi oleh produksi dalam negeri. Akan tetapi, sejak tahun 1975 konsumsi produk-produk kedelai mulai meningkat secara nyata. Meningkatnya jumlah penduduk menyebabkan semakin bertambah kebutuhan akan sumber protein murah dalam menu sehari-hari (Adisarwanto, 2007).

Pada Pertumbuhannya tanaman kedelai umumnya tumbuh tegak, berbentuk semak dan merupakan tanaman semusim. Morfologi tanaman kedelai menurut Adisarwanto (2008) didukung oleh komponen utamanya yaitu akar, daun, batang, bunga, dan biji sehingga pertumbuhannya dapat maksimal. Disamping kondisi fisik atau jenis tanah yang berpengaruh terhadap pertumbuhan kacang kedelai, faktor lain yang sangat penting untuk diperhatikan adalah kesuburan tanah. Tingkat kesuburan tanah dipengaruhi oleh kandungan atau kecukupan unsur hara dalam tanah (Hardjowigeno, 1995). Seperti halnya tanaman lain, menurut Adisarwanto (2007) kacang

kedelai pun memerlukan unsur hara makro dan mikro. Unsur hara makro antara lain karbon (C), hidrogen (H), oksigen (O), nitrogen (N), fosfor (P), kalsium (Ca), kalium (K), magnesium (Mg), dan sulfur (S). sementara unsur hara mikro anatara lain besi (Fe), mangan (Mn), tembaga (Cu), seng (Zn), molybdenum (Mo), boron (B), dan klor (Cl). Manfaat pupuk yang paling banyak dirasakan adalah menyediakan unsur hara yang diperlukan bagi tanaman. Selain menyediakan unsur hara, pemupukan juga membantu mencegah kehilangan unsur hara yang cepat hilang seperti N, P, dan K yang mudah hilang oleh penguapan atau oleh air perkolasi. Pemberian pupuk juga membantu penyerapan unsur hara. Hal ini sangat penting, karena unsur hara berperan dalam pertumbuhan tanaman. Tiga unsur hara yang diperlukan dalam jumlah besar adalah nitrogen (N), fosfor (P), dan kalium (K).

Oleh karena itu, penulis berinisiatif untuk melakukan penelitian klasifikasi kekurangan unsur hara primer berdasarkan tekstur daun. Dengan sistem yang dikembangkan ini, diharapkan dapat membantu masyarakat atau petani dalam mengenali jenis kekurangan unsur hara primer pada pertumbuhan tanaman kedelai, sehingga akan lebih cepat untuk mengatasi gejala tersebut dan akan meningkatkan produksinya.

Sistematika dalam paper ini terbagi menjadi 6 bagian : bagian 1 memuat pendahuluan, bagian 2 membahas penelitian sebelumnya yang dilakukan terhadap tanaman lain, bagian 3 membahas teori yang melandasi dalam melakukan penelitian, bagian 4 adalah desain sistem yang digunakan, bagian 5 adalah membahas skenario pengujian, dan analisis hasil pengujian, sedangkan bagian 6 membahas kesimpulan yang didapat dari penelitian.

## I. Metodologi

### Unsur Hara Primer Dan Perlakuan Dataset

Tanaman kedelai dapat tumbuh baik jika drainase dan aerasi tanah baik, untuk dapat tumbuh subur kedelai menghendaki tanah yang subur, gembur, serta kaya akan bahan organik. Pada akar terdapat bintil-bintil akar yang berkoloni dari bakteri *Rhizobium japonicum* yang terbentuk di akar, yang dapat mengikat N, bersimbiosa dengan tanaman. Tanah yang dapat ditanami kedelai memiliki air dan hara tanaman untuk pertumbuhannya cukup. Serapan unsur P oleh tanaman juga dipengaruhi oleh adanya unsur N. Pemberian unsur P yang dikombinasikan dengan N dapat meningkatkan serapan P oleh tanaman. Tanaman kedelai memerlukan unsur P dalam setiap masa pertumbuhannya. Tanaman lebih banyak menyerap  $H_2PO_4$  dibandingkan  $HPO_4$  dan  $PO_4$ . Posfat didalam tanah mudah tersedia pada pH tanah antara 5,5 – 7,0 jika pH tanah berada diatas atau dibawah kisaran tersebut maka serapan P oleh tanaman akan menyusut. Status hara tanaman kedelai dan tanah di dalam bertanam kedelai erat kaitannya dengan tingkat hasil tanaman yang dapat dinilai dan digambarkan. Periode penggunaan P terbesar atau dibutuhkan dalam jumlah yang lebih banyak pada kedelai adalah dimulai pada pembentukan polong sampai kira-kira 10 hari biji berkembang penuh. Hal ini disebabkan karena P banyak terdapat didalam sel-sel tanaman.

Keadaan ini berhubungan dengan fungsi dari P dalam metabolisme sel. Posfat dapat pula dikatakan menstimulir pertumbuhan dan perkembangan perakaran tanaman. Unsur hara yang akan diserap oleh akar ditentukan oleh semua faktor yang mempengaruhi ketersediaan unsur hara sampai unsur hara tersebut berada di permukaan akar sehingga mempengaruhi pertumbuhan dan perkembangan serta hasil tanaman.

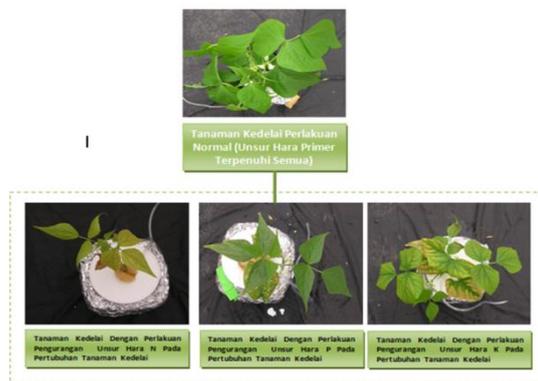
Untuk mendapatkan dataset, dilakukan penanaman tanaman kedelai, dengan kondisi atau perlakuan seperti pada tabel 1.

**Tabel 1.** Perlakuan Data Uji

Data Perlakuan Tanaman	Unsur Hara Makro Primer		
	N (Nitrogen)	K (Potasium)	P (Posfor)
<b>Pot 1</b>	Normal	Normal	Normal
<b>Pot 2</b>	Tanpa	Normal	Normal
<b>Pot 3</b>	Normal	Tanpa	Normal
<b>Pot 4</b>	Normal	Normal	Tanpa
<b>Pot 5</b>	Tanpa	Tanpa	Normal
<b>Pot 6</b>	Tanpa	Normal	Tanpa
<b>Pot 7</b>	Normal	Tanpa	Tanpa

*Keterangan lain : Kondisi Normal (Pasir, Cuaca/iklim, kondisi air) Benih yang ditanam jenis anjasmoro*

Penelitian dilakukan di rumah kaca Fakultas Pertanian UPN “Veteran” Jawa Timur, menggunakan sistem hidroponik, benih kedelai varitas Willis, pupuk Urea, SP 36 dan KCl sebagai pupuk dasar. Rancangan Acak Kelompok non faktorial, 2 (dua) taraf perlakuan yang terdiri : 1. minus one test untuk perlakuan masing-masing pot tanaman dikurangi unsur haranya (N, P atau K) pada pot 2,3 dan 4, 2. Minus two tes, untuk perlakuan masing-masing pot tanaman dikurangi 2 (dua) unsur haranya (Kombinasi : PN, NK dan KP) pada pot 5, 6 dan 7. Setelah kedelai berumur 2 (dua) minggu dipindahkan padapot-pot diberi pupuk dasar dan ditanam benih kedelai. Tanaman dipelihara sampai akhir masa vegetatif. Analisa N-total menggunakan metode Kjeldhal, K-tukar dengan metode  $NH_4OAc$ , P-tersedia dengan metode Bray II. Pengukuran pH tanah dengan metode elektrimetri (pH:H<sub>2</sub>O) dan bobot kering tanaman setelah diovenkan pada suhu 70°C selama 24 jam. Hasil penanaman kedelai selama 2 (bulan) seperti pada gambar 2 dibawah, yang akan digunakan sebagai dataset (data latih dan data uji).



**Gambar 1.** Perlakuan Tanaman Untuk Mendapatkan Data Uji dan Data Latih

### Analisis Tekstur Citra

Analisis tekstur citra terbagi menjadi dua bagian, yang pertama adalah pre-processing menggunakan fitur hsv, yang kedua adalah ekstraksi fitur GLCM adalah matriks co-occurrence.

HSL atau HIS adalah satu pemodelan warna, di mana warna diformulasikan menurut apa yang diterima oleh mata manusia. HIS atau HSV adalah kependekan dari hue(H), saturation(S) dan intensity(I) (atau value V). Hue adalah suatu atribut atau sifat dari cahaya. Sebagai contoh, benda berwarna biru memantulkan hue biru. *Hue* juga menggambarkan persepsi penglihatan manusia terhadap warna.

Suatu *hue* dimana sangat essential untuk persepsi manusia terhadap warna, dapat dibagi menjadi *hue* kuat dan *hue* lemah. Kekuatan dan kelemahan *hue* ini dideskripsikan dengan *saturation*. Sebagai contoh suatu warna dari sumber cahaya *monochromatic*, dimana menghasilkan warna dari satu *hue* saja, maka akan sangat dipengaruhi oleh *saturation*. *Saturation* adalah komponen untuk mendeskripsikan kekuatan warna atau kepuaran suatu warna (kemudaan yang mengarah pada warna putih) dari warna yang diterima oleh mata.

Sedangkan *lightness*(L), atau *intensity*(I) atau *value*(V) digunakan untuk menyatakan kecerahan (*brightness*) dari suatu warna. Attribute ini adalah representasi jumlah, banyak sedikitnya, suatu cahaya dipantulkan atau dipancarkan dari suatu objek. Nilai ini sangat berpengaruh dalam membantu manusia melihat warna, karena suatu objek yang berwarna tidak akan terlihat berwarna pada ruangan yang gelap.

Pada beberapa kasus, ekstraksi orde pertama tidak lagi dapat digunakan untuk mengenali perbedaan antar citra. Pada kasus seperti ini, dibutuhkan pengambilan ciri statistik orde dua dan disebut juga dengan *Gray Level Co-occurrence Matrix (GLCM)*. Salah satu teknik untuk memperoleh ciri statistik orde dua adalah dengan menghitung probabilitas hubungan ketetanggaan antara dua piksel pada jarak dan orientasi sudut tertentu (Haralick et al., 1973). Pendekatan ini bekerja dengan membentuk sebuah matriks kookurensi dari data citra, dilanjutkan dengan menentukan ciri sebagai fungsi dari matriks antara tersebut. Kookurensi berarti kejadian bersama, yaitu jumlah kejadian satu level nilai piksel bertetangga dengan satu level nilai piksel lain dalam jarak ( $d$ ) dan orientasi sudut ( $\theta$ ) tertentu. Jarak dinyatakan dalam piksel dan orientasi dinyatakan dalam derajat. Orientasi dibentuk dalam empat arah sudut dengan interval sudut  $45^\circ$ , yaitu  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ , dan  $135^\circ$ , sedangkan jarak antar piksel biasanya ditetapkan sebesar 1 piksel.

Matriks kookurensi merupakan matriks bujur sangkar dengan jumlah elemen sebanyak kuadrat jumlah level intensitas piksel pada citra. Setiap titik ( $i, j$ ) pada matriks kookurensi berorientasi  $\theta$  berisi peluang kejadian piksel bernilai  $i$  bertetangga dengan piksel bernilai  $j$  pada jarak  $d$  serta orientasi  $\theta$  dan  $(180-\theta)$ .

Ilustrasi pembuatan matriks kookurensi diperlihatkan pada Gambar 2.2.

Setelah memperoleh matriks kookurensi tersebut, dapat dihitung ciri statistik orde dua yang merepresentasikan citra yang diamati. Sebelum tekstur dapat dihitung, perhitungan memerlukan normalisasi matriks yaitu nilai probabilitas setiap piksel terhadap jumlah nilai keseluruhan piksel. Persamaan normalisasi didefinisikan sebagai:

$$p(i, j) = \frac{V(i, j)}{\sum_{i, j=0}^{N-1} V(i, j)} \quad (1)$$

dimana  $i$  adalah nomor baris dan  $j$  adalah nomor kolom pada matriks kookurensi.

Haralick et al (Haralick et al., 1973) mengusulkan berbagai jenis ciri tekstural yang dapat diekstraksi dari matriks kookurensi.

Dalam penelitian ini dipakai 4 ciri statistik orde dua, yaitu *Contrast*, *Correlation*, *Energy*, *Homogeneity*.

*Contrast* menunjukkan ukuran penyebaran (momen inersia) elemen-elemen matriks citra.

Jika letaknya jauh dari diagonal utama, maka nilai kekontrasannya besar.

Secara visual, nilai kekontrasan adalah ukuran variasi antar derajat keabuan suatu daerah citra dan didefinisikan dengan :

$$\text{Contrast} = \sum_{i,j=0}^{N-1} (i-j)^2 p(i,j) \quad (2)$$

*Energy* menunjukkan ukuran konsentrasi pasangan intensitas pada matriks kookurensi, dan didefinisikan dengan :

$$\text{Energy} = \sum_{i,j=0}^{N-1} p(i,j)^2 \quad (3)$$

Nilai *energy* makin membesar bila pasangan piksel yang memenuhi syarat matriks intensitas kookurensi terkonsentrasi pada beberapa koordinat dan mengecil bila letaknya menyebar. *Correlation* menunjukkan ukuran ketergantungan linear derajat keabuan citra sehingga dapat memberikan petunjuk adanya struktur linear dalam citra dan didefinisikan sebagai:

$$\begin{aligned} \text{Correlation} &= \frac{\sum_{i,j=0}^{N-1} (i-\mu_i)(j-\mu_j)p(i,j)}{\sigma_i\sigma_j} \\ \mu_i &= \sum_{i,j=0}^{N-1} i(p(i,j)) \\ \mu_j &= \sum_{i,j=0}^{N-1} j(p(i,j)) \\ \sigma_i &= \sqrt{\sum_{i,j=0}^{N-1} p(i,j)(i-\mu_i)^2} \\ \sigma_j &= \sqrt{\sum_{i,j=0}^{N-1} p(i,j)(j-\mu_j)^2} \end{aligned} \quad (4)$$

*Homogeneity* menunjukkan kehomogenan citra yang berderajat keabuan sejenis. Citra homogen akan memiliki nilai *homogeneity* yang besar. Nilai *homogeneity* membesar bila variasi intensitas dalam citra mengecil dan sebaliknya, dan didefinisikan sebagai:

$$\text{Homogeneity} = \sum_{i,j=0}^{N-1} \frac{p(i,j)}{1+(i-j)^2} \quad (5)$$

*Entropy* menunjukkan ukuran ketidakteraturan bentuk. Harga *entropy* besar untuk citra dengan transisi derajat keabuan merata dan bernilai kecil jika struktur citra tidak teratur (bervariasi), dan didefinisikan sebagai:

$$\text{Entropy} = \sum_{i,j=0}^{N-1} p(i,j)(-\ln p(i,j)) \quad (6)$$

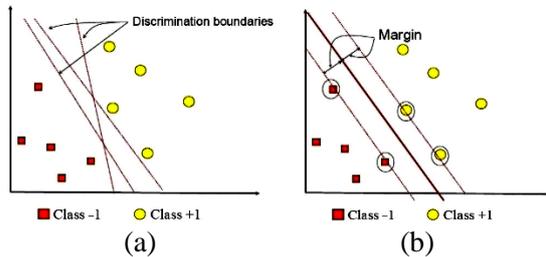
### Metode Klasifikasi *support vector machine* (SVM)

Metode *k-Nearest Neighbour* (k-NN) Setelah fitur diekstraksi dan dipilih maka fitur terpilih akan dimasukkan ke sebuah pengklasifikasi untuk mengkategorikan. Berdasarkan fitur yang dipilih, daerah yang dicurigai akan diklasifikasikan oleh berbagai metoda klasifikasi. Metode klasifikasi yang dipakai pada penelitian ini adalah SVM. SVM adalah metode *machine learning* yang bekerja atas prinsip *Structural Risk Minimization* (SRM) dengan tujuan menemukan *hyperplane* terbaik yang memisahkan dua buah *class* pada *input space*. Metode yang pertama kali dikemukakan pada tahun 1992 oleh seorang ilmuwan dari Rusia bernama Vladimir Vapnik ini telah banyak diaplikasikan dan menunjukkan keberhasilan terutama dalam bidang ilmu bioinformatika (Nugroho et al., 2003).

Konsep umum SVM pada dasarnya merupakan kombinasi harmonis dari teori-teori komputasi yang telah ada puluhan tahun sebelumnya, seperti *margin hyperplane* dalam ruang vektor berdimensi  $d$  adalah *affine subspace* berdimensi  $d-1$  yang membagi ruang vektor tersebut ke dalam dua bagian, yang masing-masing berkorespondensi pada *class* yang berbeda (Boser et al., 1992; Luts et al., 2010), kernel diperkenalkan oleh Aronszajn tahun 1950, dan demikian juga dengan konsep-konsep pendukung yang lain. Akan tetapi hingga tahun 1992, belum pernah ada upaya merangkaikan komponen-komponen tersebut (Vapnik, 1995).

Konsep SVM dapat dijelaskan secara sederhana sebagai usaha mencari *hyperplane* terbaik yang berfungsi sebagai pemisah dua buah *class* pada *input space*. Gambar 2.5 memperlihatkan beberapa pola dari anggota dua buah *class* yaitu: +1 dan -1. Pola yang tergabung pada *class* -1 disimbolkan dengan warna merah (kotak), sedangkan pola pada *class* +1, disimbolkan dengan warna kuning (lingkaran). Problem klasifikasi dapat diterjemahkan dengan usaha menemukan garis (*hyperplane*) yang memisahkan antara kedua kelompok tersebut. Berbagai alternative garis pemisah (*discrimination boundaries*) ditunjukkan pada Gambar 2.5(a). *Hyperplane* pemisah terbaik

antara kedua *class* dapat ditemukan dengan mengukur margin *hyperplane* tersebut dan mencari titik maksimalnya.



**Gambar 2.** SVM menemukan *hyperplane* terbaik yang memisahkan dua *class* (Nugroho et al., 2003)

Margin adalah jarak antara *hyperplane* tersebut dengan pola terdekat dari masing-masing *class*. Pola yang paling dekat ini disebut sebagai *support vector*. Garis solid pada Gambar 2.5.(b) menunjukkan *hyperplane* yang terbaik, yaitu yang terletak pada tengah-tengah kedua *class*, sedangkan titik merah dan kuning yang berada dalam lingkaran hitam adalah *support vector*. Usaha untuk mencari lokasi *hyperplane* ini merupakan inti dari proses pembelajaran pada SVM.

Data yang tersedia dinotasikan sebagai  $\bar{x}_i \in \mathfrak{R}^d$ , sedangkan label masing-masing dinotasikan  $y_i \in \{-1,+1\}$  untuk  $i = 1,2,\dots,l$ , yang mana  $l$  adalah banyaknya data. Diasumsikan kedua *class* -1 dan +1 dapat terpisah secara sempurna oleh *hyperplane* berdimensi  $d$ , yang didefinisikan sebagai:

$$\bar{w} \cdot \bar{x} + b = 0 \tag{7}$$

Pola  $\bar{x}_i$  yang termasuk *class* -1 (sampel negatif) dapat dirumuskan sebagai pola yang memenuhi pertidaksamaan

$$\bar{w} \cdot \bar{x}_i + b \leq -1 \tag{8}$$

Sedangkan pola  $\bar{x}_i$  yang termasuk *class* +1 (sampel positif) dapat dirumuskan sebagai pola yang memenuhi pertidaksamaan

$$\bar{w} \cdot \bar{x}_i + b \geq +1 \tag{9}$$

Margin terbesar dapat ditemukan dengan memaksimalkan nilai jarak antara *hyperplane* dan titik terdekatnya, yaitu  $\frac{1}{\|\bar{w}\|}$ . Hal ini dapat

dirumuskan sebagai *Quadratic Programming (QP) problem*, yaitu mencari titik minimal persamaan (10) dan (11).

$$\min_{\bar{w}} \lambda(w) = \frac{1}{2} \|\bar{w}\|^2 \tag{10}$$

$$y_i (\bar{x}_i \cdot \bar{w} + b) - 1 \geq 0, \quad \forall i \tag{11}$$

Problem ini dapat dipecahkan dengan berbagai teknik komputasi, di antaranya Lagrange Multiplier.

$$A(\bar{w}, b, \delta) = \frac{1}{2} \|\bar{w}\|^2 - \sum_{i=1}^l \delta_i (y_i (\bar{x}_i \cdot \bar{w} + b) - 1) \quad (i = 1, 2, \dots, l) \tag{12}$$

$\delta_i$  adalah Lagrange multiplier yang bernilai 0 atau positif ( $\delta_i \geq 0$ ). Nilai optimal dari persamaan (12) dapat dihitung dengan meminimalkan  $A$  terhadap  $\bar{w}$  dan  $b$  dan memaksimalkan  $A$  terhadap  $\delta_i$ . Dengan memperhatikan sifat bahwa pada titik optimal kemiringan  $A=0$ , persamaan (12) dapat dimodifikasi sebagai maksimalisasi problem yang hanya mengandung  $\delta_i$  saja, yang ditunjukkan oleh persamaan (13).

Maksimalkan:

$$\sum_{i=0}^l \delta_i - \frac{1}{2} \sum_{i,j=1}^l \delta_i \delta_j y_i y_j \bar{x}_i \cdot \bar{x}_j \tag{13}$$

subject to

$$\delta_i \geq 0 \quad (i = 1, 2, \dots, l) \quad \sum \delta_i y_i = 0$$

Dari hasil perhitungan ini diperoleh  $\delta_i$  yang kebanyakan bernilai positif. Data yang berkorelasi dengan  $\delta_i$  yang positif inilah yang disebut sebagai *support vector*.

Pada umumnya masalah dalam domain dunia nyata (*real world problem*) jarang yang bersifat *linear separable*. Kebanyakan bersifat non linear. Untuk menyelesaikan problem non linear, SVM dimodifikasi dengan memasukkan fungsi Kernel. Dalam non linear SVM, pertama-tama data  $\bar{x}$  dipetakan oleh fungsi  $\Phi(\bar{x})$  ke ruang vektor yang berdimensi lebih tinggi. Pada ruang vektor yang baru ini, *hyperplane* yang memisahkan kedua *class* tersebut dapat dikonstruksikan. Hal ini sejalan dengan teori Cover yang menyatakan “*Jika suatu transformasi bersifat non linear dan dimensi dari feature space cukup tinggi, maka data pada input space dapat dipetakan ke*

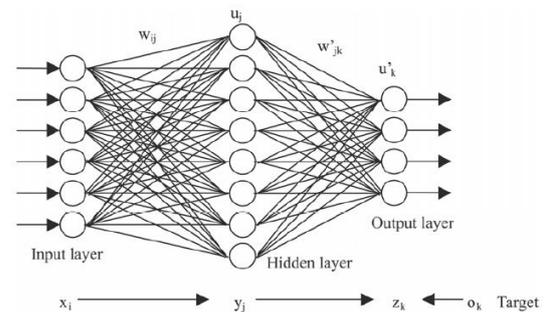
feature space yang baru, dimana pola-pola tersebut pada probabilitas tinggi dapat dipisahkan secara linear”

### Metode Klasifikasi jaringan syaraf tiruan (JST)

Algoritma pelatihan Backpropagation Neural Network (BPNN) pertama kali dirumuskan oleh Werbos dan dipopulerkan oleh Rumelhart & Mc.Clelland. *Backpropagation neural network* merupakan tipe jaringan saraf tiruan yang menggunakan metode pembelajaran terbimbing (*supervised learning*). Pada *supervised learning* terdapat pasangan data *input* dan *output* yang dipakai untuk melatih JST hingga diperoleh bobot penimbang (*weight*) yang diinginkan. Penimbang itu sendiri adalah sambungan antar lapis dalam JST. Algoritma ini memiliki proses pelatihan yang didasarkan pada interkoneksi yang sederhana, yaitu apabila keluaran memberikan hasil yang salah, maka penimbang dikoreksi agar galat dapat diperkecil dan tanggapan JST selanjutnya diharapkan dapat mendekati nilai yang benar. BPNN juga berkemampuan juga berkemampuan untuk memperbaiki penimbang pada lapis tersembunyi (*hidden layer*).

Secara garis besar BPNN terdiri atas tiga lapis (*layer*) yaitu lapis masukan (*input layer*)  $x_i$ , lapis tersembunyi (*hidden layer*)  $y_j$ , dan lapis keluaran (*output layer*)  $z_k$ . Lapis masukan dan lapis tersembunyi dihubungkan dengan penimbang  $w_{ij}$  dan antara lapis tersembunyi dan lapis keluaran dihubungkan oleh penimbang  $w'_{jk}$ . Pada pelatihan BPNN, ketika JST diberi pola masukan sebagai pola pelatihan maka pola tersebut akan menuju ke unit pada lapis tersembunyi untuk diteruskan pada unit yang berada pada lapis keluaran. Keluaran sementara pada lapis tersembunyi  $u_j$  akan diteruskan pada lapis keluaran dan lapis keluaran akan memberikan tanggapan yang disebut sebagai keluaran sementara  $u'_k$ . Ketika  $u'_k \neq o_k$  dimana  $o_k$  adalah keluaran yang diharapkan, maka selisih (*error*) keluaran sementara  $u'_k$  akan disebarkan mundur (*backward*) pada lapis tersembunyi dan diteruskan ke unit pada lapis masukan. Oleh karena itu proses tersebut disebut propagasi balik (*backpropagation*) dimana tahap pelatihan dilakukan dengan merubah penimbang yang menghubungkan unit dalam lapis JST ketika diberi umpan maju dan umpan balik. Untuk mempercepat proses pelatihan digunakan

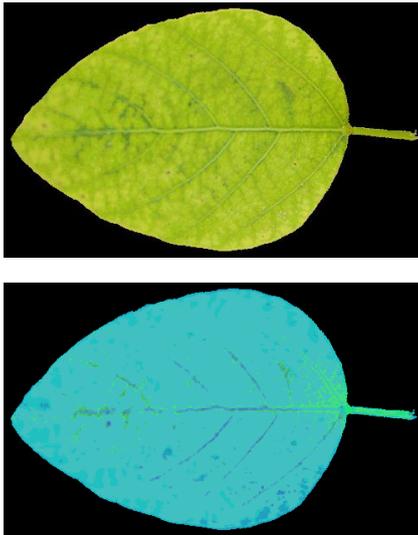
parameter laju pelatihan (*learning rate*) yang nilainya berada pada kisaran 0-1. Selain parameter laju pelatihan, untuk mempercepat proses pelatihan dapat digunakan parameter tambahan berupa momentum yang nilainya dijaga antara 0.5-0.9. Ketika proses pelatihan selesai dan JST dapat digunakan untuk menyelesaikan masalah, tahap tersebut disebut sebagai tahap penggunaan yang disebut *mapping* atau pemetaan.



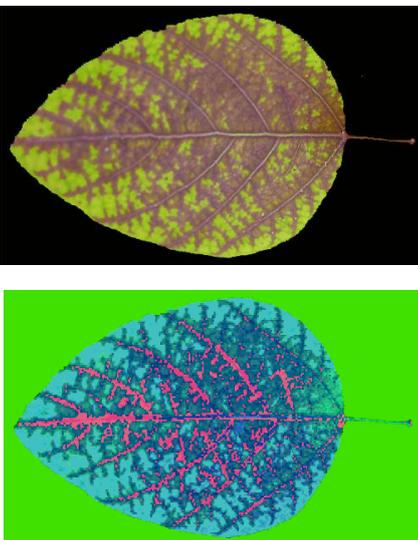
Gambar 3. Lapisan dan aliran sinyal

## II. Hasil dan Pembahasan

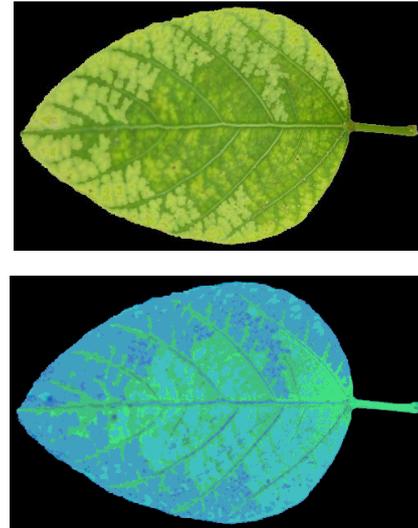
preprocessing dihasilkannya citra HSV dimana model warna HSV mendefinisikan warna dalam terminologi Hue, Saturation dan Value. Hue menyatakan warna sebenarnya, seperti merah, violet, dan kuning. Hue digunakan untuk membedakan warna-warna dan menentukan kemerahan (redness), kehijauan (greenness), dsb, dari cahaya. Hue berasosiasi dengan panjang gelombang cahaya. Saturation menyatakan tingkat kemurnian suatu warna, yaitu mengindikasikan seberapa banyak warna putih diberikan pada warna. Value adalah atribut yang menyatakan banyaknya cahaya yang diterima oleh mata tanpa memperdulikan warna. Dibawah ini hasil dari konversi gambar daun hara kedelai (*rgb*) yang telah dilakukan konversi menjadi *HSV*



Gambar 4. Unsur hara N (rgb to hsv)



Gambar 5. Unsur hara P (rgb to hsv)



Gambar 6. Unsur hara K (rgb to hsv)

Hasil dari konversi citra gambar daun hara kedelai menggunakan hsv dapat dianalisa menggunakan *gray level co-ocurance matriks (GLCM)* sehingga matriks analisa glcm dapat dilihat pada tabel 2.

Tabel 2. Nilai Hue

<u>citra</u>	<u>contrast</u>	<u>correlation</u>	<u>energy</u>	<u>homogeneity</u>	<u>klaster</u>
T_N1	0.0039	0.9922	0.5020	0.9981	1
T_N2	0.0484	0.9638	0.3259	0.9758	1
T_N3	0.0114	0.9798	0.4786	0.9943	1
T_P1	1.5703	0.7005	0.2992	0.9383	2
T_P2	0.0468	0.8644	0.6776	0.9812	2
T_P3	1.3549	0.5453	0.5308	0.9440	2
T_K1	0.0325	0.9803	0.3553	0.9839	3
T_K2	0.0329	0.9800	0.3558	0.9837	3
T_K3	0.0353	0.8791	0.6736	0.9823	3

Tabel 3. Nilai Saturation

<u>citra</u>	<u>contrast</u>	<u>correlation</u>	<u>energy</u>	<u>homogeneity</u>	<u>klaster</u>
T_N1	0.2060	0.9890	0.3662	0.9525	1
T_N2	0.1619	0.9907	0.3746	0.9658	1
T_N3	0.1590	0.9906	0.3702	0.9659	1
T_P1	0.2405	0.9704	0.2473	0.9145	2
T_P2	0.1857	0.9379	0.2813	0.9341	2
T_P3	0.2059	0.9671	0.2708	0.9236	2
T_K1	0.1698	0.9894	0.2983	0.9472	3
T_K2	0.1656	0.9886	0.2853	0.9479	3
T_K3	0.1963	0.9074	0.2704	0.9365	3

Tabel 4. Nilai Value

<u>citra</u>	<u>contrast</u>	<u>correlation</u>	<u>energy</u>	<u>homogeneity</u>	<u>klaster</u>
T_N1	0.1693	0.9834	0.3110	0.9563	1
T_N2	0.1431	0.9878	0.3802	0.9664	1
T_N3	0.1468	0.9870	0.3510	0.9641	1
T_P1	0.1440	0.9839	0.3111	0.9515	2
T_P2	0.1228	0.9877	0.3255	0.9568	2
T_P3	0.1508	0.9859	0.3050	0.9474	2
T_K1	0.1742	0.9847	0.2795	0.9565	3
T_K2	0.1795	0.9832	0.3006	0.9577	3
T_K3	0.1670	0.9847	0.2872	0.9542	3

Hasil dari konversi citra rgb menjadi hsv sesuai dengan tabel 2, 3 dan 4. Ketiga tabel tersebut mewakili nilai *hsv* dari data sampling yang berjumlah 183 daun kedelai yang telah diekstraksi fitur dan didapatkan hasil *contrast*, *correlation*, *energy* dan *homogeneity*.

Hasil nilai tersebut telah di klasterkan sesuai dengan keadaan kurang hara daun kedelai. Sehingga hasil dari matriks yang didapat saat ekstraksi fitur dapat dilakukan klastering menggunakan *support vektor machine* dan *jaringan saraf tiruan*.

```

Time taken to build model: 0.17 seconds

=== Cross-validation ===
=== Summary ===

Correlation coefficient          0.0916
Mean absolute error             0.6484
Root mean squared error        0.7932
Relative absolute error        96.5788 %
Root relative squared error    99.5142 %
Total Number of Instances      183
    
```

Gambar 7. Hasil klasifikasi SVM



Gambar 8. Grafik hasil klasifikasi SVM

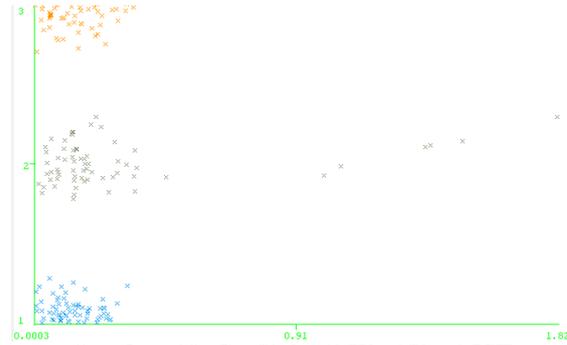
```

Time taken to build model: 0.06 seconds

=== Cross-validation ===
=== Summary ===

Correlation coefficient          0.1847
Mean absolute error             0.6875
Root mean squared error        0.8449
Relative absolute error       102.2269 %
Root relative squared error    106.0624 %
Total Number of Instances      183
    
```

Gambar 9. Hasil Klasifikasi JST



Gambar 10. Grafik hasil Klasifikasi JST

### III. Simpulan

1. Identifikasi kekurangan unsur hara pada pertumbuhan tanaman kedelai berdasarkan tekstur daun memungkinkan dilakukan untuk membantu masyarakat atau pihak-pihak terkait untuk mengenali jenis kekurangan unsur hara pada pertumbuhan daun kedelai berdasarkan tekstur daun.
2. Karena akurasi yang didapatkan masih jauh dari target yang diinginkan yaitu diatas 90%, maka sistem ini belum sepenuhnya berhasil dalam pekerjaan identifikasi berdasarkan tekstur daun.
3. Komponen warna daun yang digunakan dalam penelitian ini adalah hijau, artinya tidak memandang daun yang didominasi warna kuning atau merah, sehingga mungkin saja hal inilah yang menjadi salah satu faktor penyebab kurang berhasilnya proses klasifikasi.

### IV. Daftar Pustaka

- [1] Atınç Yılmaz, Kürsat Ayan, Enes Adak, 2011, Risk Analysis In Cancer Disease By Using Fuzzy Logic, IEEE, 78-1-61284-968-3/11
- [2] A.Meunkaewjinda, P.Kumsawat, K.Attakitmongcol, A. Srikaew, 2008, Grape Leaf Disease Detection From Color Imagery Using Hybrid Intelligent System, IEEE, 978-1-4244-2101-5/08
- [3] Chih-Lyang Hwang, Li-Jui Chang, 2008, Internet-Based Smart-Space Navigation of a Car-Like Wheeled Robot Using Fuzzy-Neural Adaptive Control, IEEE, 1063-6706
- [4] Hong-ning Li, Jie Feng, Wei-ping Yang, dkk, 2011, Spectrum-based method for quantitatively detecting diseases on cucumber leaf, 4th International Congress on Image and Signal Processing

- [5] Jun Pang, Zhong-ying Bai, 2011, Automatic Segmentation of Crop Leaf Spot Disease Images by Integrating Local threshold and Seeded Region Growing, *IEEE*, 978-1-61284-881-5/11
- [6] Libo Liu, Guomin Zhou, 2009, *Extraction of the Rice Leaf Disease Image Based on BP Neural Network*, *IEEE*, 978-1-4244-4507-3/09
- [7] Liqun Han, 2008, Recognition of the Part of Growth of Flue-Cured Tobacco Leaves Based on Support Vector Machine, *IEEE*, 978-1-4244-2114-5/08
- [8] Mauridhi Hery P; Agus Kurniawan, *Supervised Neural Networks dan Aplikasinya*, Graha Ilmu, Yogyakarta, 2006.
- [9] Qing Yao, Zexin Guan, Yingfeng Zhou, Jian Tang, Yang Hu, Baojun Yang, 2009, Application of support vector machine for detecting rice diseases using shape and color texture features, *IEEE*, 978-0-7695-3655-2/09
- [10] Santanu Phadik ar, Jaya Sil, 2008, Rice Disease Identification using Pattern Recognition Techniques, *IEEE*, 1-4244-2136-7/08
- [11] Shen Weizheng, Wu Yachun, Chen zhanliang, Wei Hongda, 2008, Grading Method of Leaf Spot Disease Based on Image Processing, *IEEE*, 978-0-7695-3336-0/08
- [12] Wikipedia Indonesia – ensiklopedia bebas, 2012, JST, [online] (Updated 13 Juli 2011) Available at: [http://id.wikipedia.org/wiki/Jaringan\\_saraf\\_tiruan](http://id.wikipedia.org/wiki/Jaringan_saraf_tiruan) [Accessed 11 April 2012]
- [13] Xiguang Yang, Wenyi Fan, Ying Yu, 2009, Leaf and Canopy Chlorophyll Content Retrieval from Hyperspectral Remote Sensing Imagery, *IEEE*, 978-1-4244-2787-1/09
- [14] Zhang Jian, Zhang Wei., 2010, Support Vector Machine For Recognition Of Cucumber Leaf Diseases, *IEEE*, 978-1-4244-5848-6/10

*Halaman ini sengaja dikosongkan.*