

LEARNING VECTOR QUANTIZATION UNTUK PREDIKSI PRODUKSI KELAPA SAWIT PADA PT. PERKEBUNAN NUSANTARA I PULAU TIGA

Dedy Arisandi¹⁾, Opim Salim Sitompul²⁾, Edgar Audela Batubara³⁾
^{1,2,3}Fakultas Ilmu Komputer dan Teknologi Informasi, Universitas Sumatera Utara
e-mail: edgar.audela.bb@students.usu.ac.id, opim@usu.ac.id, dedyarisandi@usu.ac.id

Abstrak

Kelapa sawit merupakan salah satu komoditas ekspor perkebunan terbesar di Indonesia karena Indonesia mempunyai struktur tanah serta curah hujan yang cocok untuk perkebunan komoditi ini. Sebagai tanaman yang bernilai ekonomi dan sejalan dengan meningkatnya kebutuhan kelapa sawit di pasar dunia, maka pada lingkup perkebunan negara, tiap tahunnya akan diadakan Rencana Kerja dan Anggaran Perusahaan (RKAP). Ini dilakukan untuk merencanakan target produksi dan anggaran yang akan digunakan untuk tahun berikutnya. Pada PT. Perkebunan Nusantara I (PTPN I) pulau tiga, target produksi dilakukan secara manual dengan melihat hasil produksi tahun-tahun sebelumnya. Namun sering sekali rencana hasil produksi yang telah ditargetkan berbeda dengan realisasi hasil produksi. Untuk itu adalah sangat penting untuk dimilikinya sebuah alat prediksi hasil produksi yang lebih akurat. Dalam makalah ini, diajukan algoritma *Learning vector quantization* (LVQ) untuk memprediksi hasil produksi kelapa sawit. Hasil penelitian yang diperoleh menunjukkan bahwa algoritma LVQ mampu memprediksi hasil produksi kelapa sawit dengan lebih akurat dibandingkan hasil prediksi yang dilakukan secara manual. Input yang diberikan kepada algoritma LVQ adalah berupa tahun produksi, tahun tanam, jumlah pokok, luas, umur, bulan, jumlah pupuk, jumlah hari panen dan jumlah produksi. Hasil prediksi terbaik diperoleh dari prediksi produksi kelapa sawit tahun 2014 dengan *epoch* 5000 dan *learning rate* 0.06 yakni pada bulan Januari, Maret, April, Mei, Juni, September, Oktober.

Kata Kunci : Prediksi kelapa sawit, *Learning Vector Quantization*, perkebunan nusantara, Pulau Tiga.

1. PENDAHULUAN

Kelapa sawit (*Elaeis Guineensis*) merupakan salah satu komoditas ekspor perkebunan terbesar di Indonesia. Indonesia mempunyai struktur tanah serta curah hujan yang cocok untuk perkebunan kelapa sawit yang tersebar mulai dari Aceh, Sumatera, Jawa, hingga Sulawesi.

Selain menjadi bahan baku minyak goreng, hasil produksi kelapa sawit juga menjadi bahan baku industri, serta bahan bakar. Kelapa sawit menjadi tanaman yang bernilai ekonomi, sejalan dengan meningkatnya kebutuhan kelapa sawit oleh pasar. Kelapa sawit memberikan kontribusi yang besar terhadap devisa negara. Selain itu, industri kelapa sawit juga membuka banyak lapangan pekerjaan dibandingkan industri lainnya. Seluruh area perkebunan kelapa sawit di Indonesia, dikelola dalam bentuk

perkebunan rakyat dan perkebunan besar. Perkebunan besar terdiri dari perkebunan negara seperti Perseroan Terbatas Perkebunan Nusantara (PTPN) dan perkebunan swasta.

Pada lingkup perkebunan negara, tiap tahunnya akan diadakan Rencana Kerja dan Anggaran Perusahaan (RKAP). Ini dilakukan untuk merencanakan target produksi dan anggaran yang akan digunakan untuk tahun berikutnya. Pada PT. Perkebunan Nusantara I (PTPN I) Pulau Tiga, target produksi dilakukan secara manual dengan melihat hasil produksi tahun-tahun sebelumnya. Namun sering terjadi kendala karena rencana hasil produksi yang telah ditargetkan berbeda dengan realisasi hasil produksi.

Perbedaan tersebut disebabkan pertumbuhan dan produktivitas kelapa sawit yang dipengaruhi oleh beberapa faktor. Adapun faktor-faktor tersebut

antara lain faktor lingkungan, bahan tanaman dan tindakan kultur teknis. Faktor lingkungan mencakup iklim, tanah, dan topografi [1]. Oleh karena itu, prediksi produksi kelapa sawit hendaklah didasarkan kepada faktor-faktor yang mempengaruhi tersebut, sehingga hasil prediksi dapat digunakan sebagai acuan target produksi perusahaan.

Dari banyak metode untuk prediksi, salah satu metode yang diakui keunggulannya adalah Jaringan Saraf Tiruan. Jaringan saraf tiruan merupakan rekayasa dari jaringan saraf biologi [2]. Jaringan saraf tiruan dapat menyelesaikan masalah perhitungan yang rumit, seperti prediksi dan pemodelan, klasifikasi, pola pengenalan, pengklasteran serta optimasi. Jaringan saraf tiruan bersifat fleksibel terhadap masukan data serta menghasilkan respon yang konsisten [3].

Dalam makalah ini metode jaringan saraf tiruan yang diterapkan adalah metode *Learning Vector Quantization* (LVQ). LVQ banyak digunakan karena dapat menghasilkan vector acuan yang optimal dengan cara yang sederhana dan cepat [4]. Jaringan LVQ merupakan suatu jaringan pelatihan kompetitif dimana masing-masing outputnya akan dihubungkan dengan sebuah kelas tertentu.

2. PENELITIAN TERDAHULU

Pada tahun 2009, Hermantoro & Purnawan [5] mengusulkan pemodelan dan simulasi produktivitas perkebunan kelapa sawit berdasarkan kualitas lahan dan iklim menggunakan model *Artificial Neural Network*. Data yang dijadikan parameter diambil dari beberapa afdeling PT.Sawit Sumbermas Sarana Kalimantan Tengah. Penelitian ini menggunakan 7 data parameter yaitu curah hujan, ketinggian dari permukaan laut, kelerengan, umur tanaman, batuan, solum, dan keasaman tanah. Pada saat training dicoba berbagai struktur model ANN yaitu model: 7-3-1, model 7-4-1, dan model 7-5-1 dengan koefisien laju pembelajaran 0.9, konstanta momentum 0.9 dan konstanta gain 0.9. Dari hasil penelitian tersebut diperoleh model

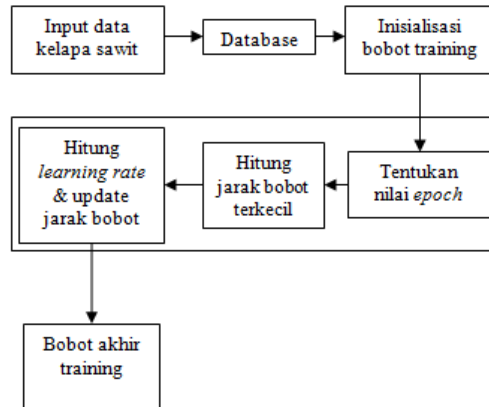
terbaik adalah model 7-3-1, dengan iterasi 30000, laju pembelajaran = 0.9, *momentum* = 0.9 dan konstanta *gain* = 0.9 dengan hasil pelatihan (*training*) $R^2 = 0.9998$ dan $RSME = 0.0709$ dan pengujian (*testing*) $R^2 = 0.8901$ dan $RSME = 2.2196$.

Penelitian yang dilakukan Hidayati & Warsito [6] tentang terjangkitnya penyakit jantung juga menggunakan metode LVQ. Penelitian ini menggunakan 10 data parameter yaitu usia, jenis kelamin, angina (nyeri dada), tekanan darah saat beristirahat, kolesterol, kadar gula darah > 120 mg/dl, denyut nadi maksimal, merokok, keturunan, dan olahraga. Agar dapat dikenali oleh jaringan, data pada variable-variabel yang digunakan diubah ke dalam bentuk numerik, misalnya variabel jenis kelamin diberi nilai 0 untuk jenis kelamin perempuan dan 1 untuk jenis kelamin laki-laki. Sementara itu, target yang diinginkan dituliskan berupa kategori tidak terjangkit penyakit jantung dan terjangkit penyakit jantung, berturut-turut dengan nilai 1 dan 2. Parameter-parameter yang digunakan pada penelitian tersebut saat melakukan training adalah: *learning rate* (α) = 0.25, penurunan *learning rate* (Deca) = 0.1, minimum *learning rate* (Min α) = 0.001, dan maksimum *epoch* (MaxEpoch) = 100. Hasil output menunjukkan bahwa setelah dilakukan training sampai 100 *epoch* tingkat keberhasilan jaringan LVQ untuk dapat mengenali pola dengan benar adalah sebesar 66.79%.

3. METODE PENELITIAN

3.1. Arsitektur Umum

Arsitektur umum dari proses training pada penelitian ini dapat dilihat pada Gambar 1. Proses dimulai dari penginputan data berupa tahun produksi, tahun tanam, jumlah pokok, luas, umur, bulan, jumlah pupuk, jumlah hari panen dan jumlah produksi. Data tersebut kemudian disimpan ke database training, untuk kemudian dilanjutkan dengan proses training.



Gambar 1. Proses Training


Proses training dimulai dari penginisialisasian data input. Dua input akan di inisialisasi menjadi bobot training ke-1 dan ke-2, yaitu jumlah produksi kelapa sawit paling kecil dan jumlah produksi kelapa sawit yang paling besar. Sedangkan sisanya akan dijadikan input pembelajaran.

Langkah berikutnya adalah menentukan nilai *epoch*, *learning rate* (α), dan penurunan nilai alpha ($Dec\alpha$). Setelah nilai *epoch* ditentukan, pada *epoch* ke-1 dihitung jarak terpendek dengan bobot training ke-1 dan ke-2. Setelah jarak terpendek pada bobot ke-1 dan ke-2 didapat, kemudian dipilih jarak yang terkecil untuk proses perkalian dengan nilai *learning rate*. Hasil dari perhitungan tersebut akan digunakan sebagai nilai bobot yang baru; proses dilakukan hingga nilai input pembelajaran terakhir didapat pada *epoch* ke-1.

Sebelum masuk ke *epoch* selanjutnya, nilai *learning rate* (α) akan diupdate dengan cara mengalikan $Dec\alpha$ dengan *learning rate* yang lama. Setelah didapat nilai *learning rate* yang baru akan dilakukan proses perhitungan yang sama seperti *epoch* ke-1 hingga mencapai jumlah *epoch* yang ditentukan. Bobot akhir training akan diperoleh setelah tercapainya jumlah *epoch* yang ditentukan untuk digunakan pada proses selanjutnya yakni proses prediksi.

Arsitektur umum dari proses prediksi pada penelitian ini dapat dilihat pada Gambar 2. Proses prediksi dimulai dari penginputan data yang akan diprediksi dan dilanjutkan dengan menghitung jarak

terkecil menggunakan bobot akhir hasil training. Hasil perhitungan jarak terkecil akan digunakan sebagai pengklasifikasian apakah hasil perhitungan masuk kedalam kelas produksi rendah atau kelas produksi tinggi.



Gambar 2. Proses Prediksi

3.2. Pengambilan Data

Dalam perancangan prediksi produksi kelapa sawit, variabel yang akan digunakan sebagai parameter input adalah tahun produksi, tahun tanam, bulan, umur tanaman, luas, jumlah pokok, jumlah hari panen, jumlah pupuk, dan jumlah produksi sebelumnya. Adapun outputnya adalah prediksi produksi kelapa sawit rendah dan prediksi produksi kelapa sawit tinggi.


Data yang diambil untuk training merupakan data produksi kelapa sawit selama empat tahun yaitu tahun 2010, 2011, 2012 dan 2013 dengan tahun tanam sawit 2003. Sedangkan untuk data prediksi, akan digunakan data tahun 2014 dengan tahun tanam sawit 2003. Pada Tabel 1 dapat dilihat data produksi kelapa sawit tahun 2010 sebagai salah satu data produksi kelapa sawit yang akan digunakan untuk proses training.

Tabel 1. Data Produksi kelapa sawit tahun 2010

Tahun produksi	2014											
Tahun tanam	2003											
Umur	7 tahun											
Luas	57 ha											
Jumlah pokok	7766											
Bulan	Jan	Feb	Mar	Apr	Mei	Jun	Jul	Agus	Sep	Oket	Nov	Des
Jumlah hari kerja panen	113	68	54	54	62	88	87	101	76	89	96	99
Pupuk (kg)	0	44.654	34.947	0	0	0	0	0	0	0	31.064	0
Jumlah produksi (kg)	44.410	36.970	26.930	25.160	23.110	49.270	54.590	94.700	72.080	88.430	96.170	75.210

3.3. Pendefinisian Input

Data produksi kelapa sawit yang diambil selanjutnya akan diolah oleh jaringan. Dapat dilihat pada Gambar 3 arsitektur jaringan *learning vector quantization* dengan 9 unit (neuron) pada lapisan input, dan 2 unit (neuron) pada lapisan output.



Gambar 3. Arsitektur Jaringan LVQ

Variabel-variabel yang dinyatakan sebagai input pada jaringan LVQ adalah Tahun Produksi (X_1), Tahun tanam (X_2), Bulan (X_3), Umur tanaman (X_4), Luas (X_5), Jumlah pokok (X_6), Jumlah hari panen (X_7), Jumlah pupuk (X_8), Jumlah produksi sebelumnya (X_9), Produksi rendah (Y_1), dan Produksi tinggi (Y_2).

Lapisan neuron-neuron input tersebut dihubungkan ke vektor W_1 dan W_2 . W_1 dan W_2 merupakan vektor bobot pertama dan kedua. W_1 merupakan vektor bobot yang menghubungkan setiap neuron pada lapisan input ke neuron pertama pada lapisan output, sedangkan W_2 merupakan vektor bobot yang menghubungkan setiap neuron pada lapisan input ke neuron yang kedua pada lapisan output. F_1 dan F_2 merupakan fungsi aktivasi pertama dan kedua. Fungsi aktivasi F_1 akan memetakan y_{in1} ke $y_1 = 1$ apabila $\|X - w_1\| < \|X - w_2\|$, dan $y_1 = 0$ jika sebaliknya. Demikian pula dengan yang terjadi pada fungsi aktivasi F_2 , akan memetakan y_{in2} ke $y_2 = 2$ apabila $\|X - w_2\| < \|X - w_1\|$, dan $y_2 = 0$

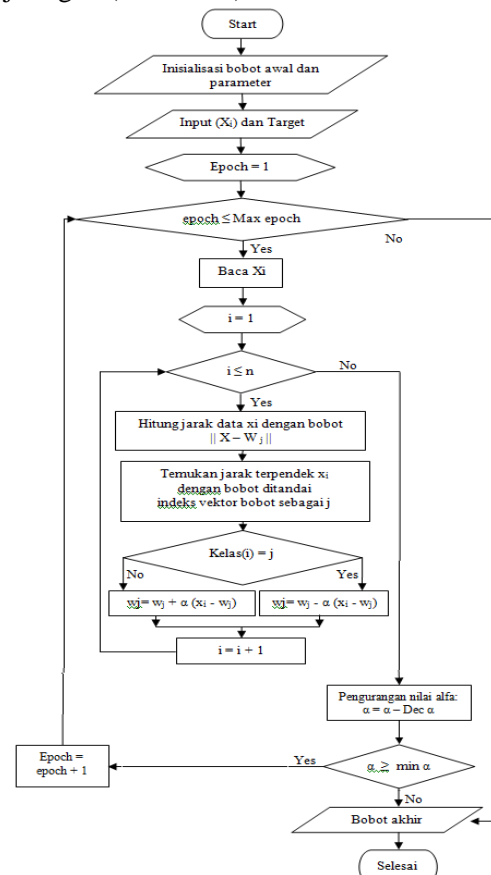
jika sebaliknya. Y_1 dan Y_2 merupakan output pertama dan kedua.

3.4. Penetapan Target Kelas

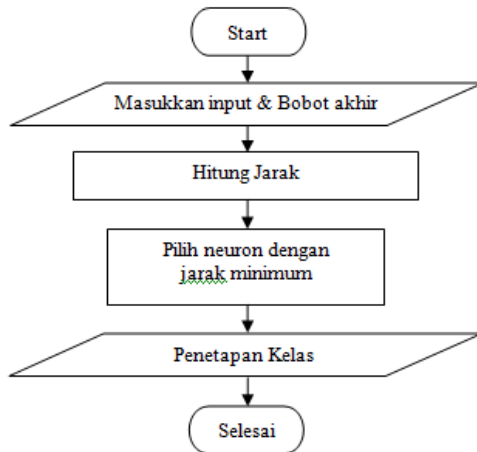
Terdapat 2 kelas yang akan menjadi output dari prediksi, yaitu kelas produksi rendah (kelas 1) dan kelas produksi tinggi (kelas 2). Produksi kelapa sawit tinggi di dapat apabila hasil produksi kelapa sawit lebih tinggi daripada hasil data produksi kelapa sawit yang telah ditetapkan. Sebaliknya jika hasil produksi kelapa sawit lebih rendah daripada data produksi kelapa sawit yang telah ditentukan, maka produksi kelapa sawit tersebut masuk ke kelas 1 yakni produksi kelapa sawit rendah.

3.5. Flowchart Training dan Prediksi

Flowchart training memperlihatkan proses pembelajaran data input oleh jaringan dengan algoritma LVQ (seperti terlihat pada gambar 4). Adapun flowchart prediksi memperlihatkan proses penetapan kelas hasil produksi kelapa sawit yang didapat dari data input ke jaringan (Gambar 5).



Gambar 4. Flowchart Training

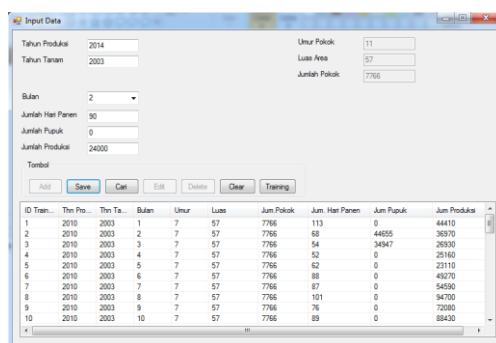


Gambar 5. Flowchart prediksi

4. HASIL DAN PEMBAHASAN

Pada bagian ini diperlihatkan hasil yang diperoleh berupa prediksi produksi kelapa sawit di PT. Perkebunan Nusantara I Pulau Tiga yang diimplementasikan dalam bentuk program aplikasi. Pada aplikasi sistem prediksi produksi kelapa sawit yang dibangun, terdapat dua sub menu yaitu: sub menu input data yang berfungsi untuk masuk ke menu input data dan sub menu training dan prediksi yang berfungsi untuk langsung masuk ke menu training dan prediksi tanpa memasukkan data.

Pada sub menu input data, data produksi yang diinput selanjutnya disimpan ke dalam database. Data tersebut berupa data tahun produksi, tahun tanam, luas area, jumlah pokok, bulan, jumlah hari panen, jumlah pupuk dan yang terakhir jumlah produksi kelapa sawit. Adapun data umur akan otomatis didapat setelah melalui proses pengurangan tahun produksi dengan tahun tanam (lihat Gambar 6).



Gambar 6. Interface Input Data

Pada sub menu training dan prediksi tombol training berfungsi untuk melanjutkan ke tahap selanjutnya yakni tahap training. Halaman proses training dan prediksi ditampilkan pada halaman yang sama. Pada tampilan prediksi user di minta untuk memasukkan data yang akan di prediksi. Mulai dari data tahun produksi, tahun tanam, bulan, perkiraan jumlah hari panen, perkiraan jumlah pupuk. Sedangkan untuk kolom umur pokok, luas kebun, jumlah pokok akan otomatis ditampilkan sesuai dengan data yang terdapat di database. Setelah semua kolom terisi dengan benar maka user dapat melakukan prediksi. Tahap selanjutnya adalah tahap pengujian sistem prediksi. Pada pengujian, produksi yang akan diprediksi adalah produksi kelapa sawit tahun 2014, yang dalam hal ini data produksi kelapa sawit tahun 2014 tersebut telah diketahui hasilnya.

Tabel 2. Tabel Hasil Prediksi kelapa sawit Tahun 2014

Bulan	Jumlah Hari panen	Jumlah Pupuk(kg)	Jumlah Produksi Kelapa Sawit (kg)
Jan	99	0	27.490
Feb	52	0	41.500
Mar	79	0	55.090
Apr	103	0	80.480
Mei	114	0	97.910
Jun	98	14.550	86.910
Jul	93	0	87.200
Agu	112	9.100	182.940
Sep	101	0	121.150
Okt	116	21.750	110.010
Nov	105	0	87.170
Des	112	0	72.340

Pada Tabel 2 terlihat bahwa jumlah produksi sawit yang telah berumur 11 tahun dapat menghasilkan 21.000 kg/ha/tahun. Jika dihitung maka akan terlihat seperti berikut.

$$\begin{aligned} \text{Produksi/tahun} &= 57 \text{ ha} \times 21.000 \text{ kg/ha} \\ &= 1.197.000 \text{ kg/tahun} \\ \text{Produksi/bulan} &= 1.197.000 / 12 \\ &= 99.750 \text{ kg/bln} \end{aligned}$$

Hasil yang didapat dari perhitungan ini memperlihatkan bahwa normalnya sawit akan menghasilkan 99.750 kg tiap

bulannya. Jika produksi kelapa sawit kurang dari jumlah tersebut maka sawit dikategorikan kelas produksi rendah. Sebaliknya jika jumlah produksi sawit lebih dari jumlah normal maka sawit dikategorikan kelas produksi tinggi. Dapat dilihat pada Tabel 3 hasil produksi kelapa sawit menurut kelas dan epoch.

Tabel 3. Hasil Pengujian menurut kelas dan epoch

Bln	Jml Hri panen	Jml Pupuk (kg)	Jumlah Produksi Kelapa Sawit (kg)	Kelas			epoch
				epoch 5000	epoch 5500	epoch 5200	
Jan	99	0	27.490	Rendah	Rendah	Sukses	Sukses
Feb	52	0	41.500	Rendah	Rendah	Gagal	Gagal
Mar	79	0	55.090	Rendah	Rendah	Gagal	Sukses
Apr	103	0	80.480	Rendah	Rendah	Sukses	Sukses
Mei	114	0	97.910	Rendah	Rendah	Sukses	Sukses
Jun	98	14.550	86.910	Rendah	Tinggi	Gagal	Gagal
Jul	93	0	87.200	Rendah	Tinggi	Gagal	Gagal
Agus	112	9.100	182.940	Tinggi	Tinggi	Sukses	Sukses
Sep	101	0	121.150	Tinggi	Tinggi	Sukses	Sukses
Okt	116	21.750	110.010	Tinggi	Tinggi	Sukses	Sukses
Nov	105	0	87.170	Rendah	Tinggi	Gagal	Gagal
Des	112	0	72.340	Rendah	Tinggi	Gagal	Gagal

Selanjutnya dilakukan pengujian dengan menggunakan aplikasi prediksi produksi kelapa sawit yang telah dirancang. Hasil prediksi produksi kelapa sawit kemudian dibandingkan dengan hasil produksi kelapa sawit yang sebenarnya. Prediksi akan dilakukan dengan mengubah nilai *epoch*, yakni mulai 5000, 5200, dan 5500.

Dapat dilihat Tabel 3 tabel hasil pengujian dengan *epoch* 5000, *learning rate* 0.06 dengan penurunan *alfa* tiap epochnya sebesar 0.01. Adapun jumlah neuron yang digunakan adalah 9 neuron.

5. KESIMPULAN

Setelah merancang serta mengaplikasikan algoritma *Learning Vector Quantization* pada Prediksi produksi kelapa sawit di Perkebunan Kelapa Sawit Pulau Tiga, maka diperoleh kesimpulan yaitu: aplikasi dapat

melakukan prediksi produksi kelapa sawit dengan inputan berupa tahun produksi, tahun tanam, jumlah pokok, luas, umur, bulan, jumlah pupuk, jumlah hari panen dan jumlah produksi; hasil prediksi terbaik tahun 2014 diperoleh dari pengujian dengan *epoch* 5000 yakni pada bulan Januari, Maret, April, Mei, Juni, September, Oktober. Hasil prediksi terbaik juga diperoleh dari pengujian dengan *learning rate* 0.06. Dapat dilihat bahwa nilai *learning rate* sangat berpengaruh terhadap hasil prediksi kelapa sawit daripada nilai *epoch*.

6. REFERENSI

- [1] Risza, S. 1994. Upaya Peningkatan Produktivitas Kelapa Sawit. Yogyakarta. Kanisius.
- [2] Yadav, S. J., Yadav, M. & Jain, A. 2013. Artificial Neural Network. *Int. J. Of Scientific Research And Education* 1(6):108-118.
- [3] Pham, D. T. 1994. Neural Network for Chemical Engineers. Amsterdam. Elsevier Press.
- [4] Kohonen, T. 1989. *Self-organization and associative Memory*. 3rd Edition. Springer : Berlin
- [5] Hermantoro & Purnawan, W. R. 2009. Prediksi Produksi Kelapa Sawit Berdasarkan Kualitas Lahan Menggunakan Model Artificial Neural Network. *Agroteknose*, 4(2). pp. 1-6.
- [6] Hidayati, N. & Warsito, B. 2010. *Prediksi Terjangkitnya Penyakit Jantung Dengan Metode Learning Vector Quantization*. *Media Statistika*, 3 (1). pp. 21-30. ISSN 1979-3693.