

# **KLASIFIKASI KLON DAUN DENGAN MENGGUNAKAN METODE PRINCIPAL COMPONENT ANALYSIS**

**Kristin Lourensi Sitompul<sup>\*1</sup>, Anita Sindar Ros Maryana<sup>2</sup>**

<sup>1</sup>Manajemen Informatika, STMIK Pelita Nusantara

<sup>2</sup>Teknik Informatika, STMIK Pelita Nusantara

Email: <sup>\*1</sup>rajawalilourensi7@gmail.com, <sup>\*2</sup>haito\_ita@yahoo.com

## **ABSTRAK**

*Klasifikasi adalah proses membagi objek atau konsep secara logika kedalam klas-klas hirarki, subklas, dan sub-subklas berdasarkan kesamaan yang mereka miliki secara umum dan yang membedakannya. Klasifikasi secara umum juga diartikan sebagai kegiatan penataan pengetahuan secara universal kedalam beberapa susunan sistematis. Principal Component Analysis (PCA) merupakan suatu algoritma yang mampu mengkonversi sekelompok data yang pada awalnya saling berkorelasi menjadi data yang tidak saling berkorelasi (Principal Component). Jumlah Principal Component yang dihasilkan adalah sama dengan jumlah data aslinya, tetapi dapat direduksi dengan jumlah yang lebih kecil dan tetap mampu merepresentasikan data asli dengan baik. Karet adalah tanaman dengan habitus pohon yang tumbuh tinggi dan memiliki batang cukup besar. Pohon karet melindungi diri dengan cara mengeluarkan getah ketika batangnya disayat. Getah dari batang pohon karet dinamakan lateks. Tumbuhan karet biasanya memiliki percabangan yang tinggi di bagian atas. Karet memiliki daun memiliki warna hijau. Panjang tangkai daun utamanya sekitar 3-20 cm, sedangkan panjang tangkai anak daun sekitar 3-10 cm dan ujungnya bergetah. Dalam satu helai daun, biasanya terdapat 3 anak daun dengan bentuk elips, memanjang, dengan ujung daun meruncing. Daun pohon karet akan berubah warna menjadi kuning atau merah pada saat musim kemarau. Para petani karet di Indonesia mengalami kesulitan dalam pemilihan bibit karet yg terbaik melalui pengklasifikasian daun karet. Metode yang digunakan dalam penelitian ini menggunakan Principal Component Analysis. Tujuan penelitian ini untuk memberikan bobot kualitas terbaik karet dengan melalui daun menggunakan Principal Component Analysis.*

**Kata Kunci :** Klasifikasi, PCA, Klon

## **ABSTRACT**

*Classification is the process of logically dividing objects or concepts into hierarchical classes, subclasses and sub-subclasses based on the similarities they have in general and what differentiates them. Classification is generally also defined as the activity of universally structuring knowledge into several systematic arrangements. Principal Component Analysis (PCA) is an algorithm that is able to convert a group of data that initially collapsed into data that did not destroy each other (Main Component). The resulting number of Principal Components is the same as the original data, but can be reduced to a smaller number and still be able to represent the original data well. Rubber is a plant with a tree habitat that grows tall and has a fairly large trunk. Rubber trees protect themselves by releasing sap when the trunk is cut. The sap from the rubber tree trunk is called latex. Rubber plants usually have high branches at the top. Rubber has green leaves. The length of the main leaf stalk is around 3-20 cm, while the length of the leaf stalk is around 3-10 cm and the tip is gummy. In one leaf, there are usually 3 leaves with an elliptical, elongated shape, with a tapered leaf tip. Rubber tree leaves*

will change color to yellow or red during the dry season. Rubber farmers in Indonesia experience difficulties in selecting the best rubber seeds through classifying rubber leaves. The method used in this research uses Principal Component Analysis. The aim of this research is to provide the best quality rubber weight through the leaves using Principal Component Analysis.

**Keywords:** Classification, PCA, Klon

## 1. PENDAHULUAN

Klasifikasi memiliki suatu fungsi untuk melakukan prediksi kelas dari suatu objek yang kelas-kelasnya belum diketahui. Klasifikasi adalah pola yang dilakukan secara terarah. (Raviya, 2013). Metode klasifikasi yang umum digunakan yaitu *Decision Tree*, *K-Nearest Neighbor*, *Naïve Bayes*, *Neural Network* dan *Support Vector Machine* (Sahu, 2011).

Menurut Nikulin (2008) *classification* diterapkan hanya pada data set training yang lebih kuat dimana telah dijelaskan pada kelas “positif” diwakili pada yang minoritas tanpa menghilangkan atributnya. Sedangkan penelitian yang dilakukan oleh Mladenec (1999) yaitu penelitian yang berkaitan dengan memilih fitur yang berkontribusi untuk klasifikasi menggunakan spesifikasi tertentu serta kemampuan belajar dari *classifier* pada data teks yang distribusi tidak merata.

PCA memberikan hasil yang baik ketika diterapkan pada atribut yang berkorelasi. Dalam penelitian ini, PCA diterapkan dalam pelatihan dan menguji faktor yang sangat mempengaruhi dataset. PCA akan mengidentifikasi pola dalam kumpulan data, menemukan persamaan dan perbedaannya diantara masing-masing faktor. Karena PCA berfungsi sebagai model yang kuat untuk menganalisis data.

Hussainet al. (2015) menggunakan pendekatan *Principal Component Analysis (PCA)* sebagai metode seleksi fitur untuk mereduksi indikator-indikator yang berhubungan dengan prediksi tingkat ketahanan hidup pasien terinfeksi kanker payudara. Data yang digunakan berasal dari *SEER dataset* sebanyak 684.394 rekam medis pasien. Dengan pendekatan yang diusulkan memperoleh akurasi sebesar 92%.

Kelemahan pada metode klasifikasi tersebut dapat mempengaruhi *performance* dalam mengelompokkan data. *Performance* dapat diartikan sebagai tingkat pencapaian hasil. Oleh karena itu menggunakan *Principal Component Analysis (PCA)*, diharapkan hal ini mampu mengatasi peningkatan performa dalam melakukan peng-klasifikasi-an terhadap data yang digunakan sehingga penelitian ini berjudul “**daun Karet**”.

## 2. METODE PENELITIAN

### 2.1 Teknik Pengumpulan Data

Untuk memperoleh data yang tepat dan akurat guna melengkapi sistem yang akan dibuat, maka digunakan beberapa metode pengumpulan data. Adapun beberapa metode pengumpulan data tersebut adalah:

#### 1. Pengumpulan Data Primer

Pengumpulan data primer adalah metode pengumpulan data yang dilakukan dengan melakukan penghimpunan data langsung di instansi terkait.

- Mengambil data – data daun yang akan diidentifikasi
- Mengamati langsung bagaimana tahapan pengolahan data klon, hingga dapat keputusan yang pasti

#### 2. Pengumpulan Data Sekunder

Pengumpulan data sekunder adalah metode pengambilan data melalui literatur atau sumber dari luar tempat riset yang akan dijadikan tempat penelitian. Pengumpulan data sekunder bisa dilakukan dengan mengumpulkan data dengan cara membaca dan mempelajari buku-buku, makalah-makalah, artikel-artikel dan bahan-bahan dari internet yang sesuai dengan topik yang sedang dibahas yang digunakan sebagai referensi dan landasan teori dalam melakukan penelitian.

## 2.2 Metode Penelitian

Metode penelitian yang dilakukan yaitu:

### 1. Menentukan domain persoalan

Pada tahap ini, peneliti mengumpulkan data dan informasi serta mempelajari persoalan yang akan dipecahkan. Teknik pengumpulan data dilakukan sebagai berikut :

#### a. Observasi

Observasi adalah kegiatan melakukan pengamatan terhadap Klon karet di pusat penelitian karet, lalu berkonsultasi dengan staf dan pimpinan instansi tersebut.

#### b. Studi Dokumentasi

Studi dokumentasi adalah pengumpulan data sekunder yang dibutuhkan untuk penelitian yang terdiri dari tahap analisa sampai pada proses pengambilan data dan berakhir pada ketentuan kualitas data.

### 2. Mendefinisikan persoalan

Dalam penelitian ini dilakukan pendefinisian persoalan yang terjadi yaitu Bagaimana menganalisa metode PCA dalam menentukan kualitas karet yang terbaik

#### a. Implementasi


Tahap ini merupakan penerapan sistem yang dibangun. Pada tahap ini terdapat beberapa tugas yang harus dilakukan yaitu *testing* sistem, evaluasi sistem serta pengukuran kinerja dari algoritma yang diterapkan

Pemeliharaan dan Pengembangan Sistem merupakan tahapan yang harus dilakukan secara terus menerus untuk mempertahankan keandalan sistem. Serta seiring berjalannya waktu, pengembangan sistem dilakukan untuk menambahkan fasilitas – fasilitas yang dapat digunakan menunjang kebutuhan aplikasi.

## 2.3 Principal Component Analysis

PCA merupakan kombinasi linear dari variabel awal yang secara geometris kombinasi linear ini merupakan sistem koordinat baru yang diperoleh dari rotasi sistem semula. Metoda PCA sangat berguna digunakan jika data yang ada memiliki jumlah variabel yang besar dan memiliki korelasi antar variabelnya. Perhitungan dari principal component analysis didasarkan pada perhitungan nilai *eigen* dan vektor *eigen* yang menyatakan penyebaran data dari suatu dataset. Dengan menggunakan PCA, variabel yang tadinya sebanyak  $n$  variabel akan diseleksi menjadi  $k$  variabel baru yang disebut *principal component*, dengan jumlah  $k$  lebih sedikit dari  $n$ . Dengan hanya menggunakan  $k$  *principal component* akan menghasilkan nilai yang sama dengan menggunakan  $n$  variabel. Variabel hasil dari seleksi disebut *principal component*.

PCA digunakan untuk menjelaskan struktur matriks varians-kovarians dari suatu set variabel melalui kombinasi linier dari variabel-variabel tersebut. Secara umum *principal component* (PC) dapat berguna untuk seleksi fitur dan interpretasi variabel-variabel. Skema konseptual yang diilustrasikan bagaimana PCA dapat membantu untuk menyederhanakan dimensi dari data melalui hipotesa dataset berjumlah  $m$  variabel dapat ditunjukkan pada Gambar 1 berikut :



**Gambar 1.** Model Konseptual PCA untuk Tahap Seleksi Fitur  
(Sumber: Kotu & Deshpande, 2015)

Menurut (Jolliffe, 2002), Prosedur pengerjaan Principal Component Analysis bertujuan untuk menyederhanakan dan menghilangkan faktor atau indikator yang kurang dominan dan kurang relevan tanpa mengurangi maksud dan tujuan dari data asli dari variabel acak  $x$  (matrik berukuran  $n \times n$ , dimana baris-baris yang berisi observasi sebanyak  $n$  dari variabel acak  $x$ ) adalah sebagai berikut:

1. Menghitung Matrik Varians Kovarian dari Data Observasi.

*Varians* ( $\text{Var}(x)$ ) dihitung untuk menemukan penyebaran data dalam set data kanker serviks untuk menentukan penyimpangan data dalam set data sampel. Matrik *Kovarian*  $\text{Cov}(x,y)$  ialah matriks yang nilai-nilai kovariansi pada tiap cell-nya diperoleh dari sampel. Misalkan  $x$  dan  $y$  adalah variabel acak. (Jolliffe, 2002).

$$\text{Var}(x) = \sigma^2 = \frac{1}{n} \sum_{i=1}^n (\tilde{z}_{ij} - \mu_j)^2 \quad (2.1)$$

$$\text{Cov}(x,y) = \frac{1}{n-1} \sum_{i=1}^n (x_{ij} - \mu_{xj})(y_{ij} - \mu_{yj}) \quad (2.2)$$

Dengan  $\mu_x$  dan  $\mu_y$  merupakan rata – rata (*mean*) sampel dari variabel  $x$  dan  $y$ , dimana  $x_i$  dan  $y_i$  merupakan nilai observasi ke- $i$  dari variabel  $x$  dan  $y$ . Dari data nilai yang digunakan, maka diperoleh matrik kovarian berukuran  $n \times n$ .

2. Mencari Eigenvalues dan Eigenvector dari Matrik Kovarian

Nilai eigen dan vektor eigen untuk matriks kovarians dihitung. Nilai eigen yang dikomputasi kemudian ditransformasikan (rotasi orthogonal varimax) menggunakan persamaan berikut (Jhonson & Wichern 2007):

$$\text{Det}(A - \lambda I) = 0 \quad (2.3)$$

dimana :

$A$  = matrik  $n \times n$

$\lambda$  = nilai *eigenvalue*

$I$  = matriks identitas (matriks persegi dengan elemen diagonal utama bernilai 1 sedangkan elemen lain bernilai 0)

3. Menentukan Nilai Proporsi Principal Component (Proporsi Principal Component (%))

$$\text{PC}(\%) = \frac{\text{Nilai Eigen}}{\text{Varians Kovarian}} \times 100\% \quad (2.4)$$

4. Menghitung Bobot Factor (Factor Loading) Berdasarkan Eigenvector dengan Persamaan(Jhonson & Wichern, 2007) :

$$A_x = \lambda_x \quad (2.5)$$

Sehingga diperoleh kombinasi linear yaitu:

$\lambda_1, \lambda_2, \lambda_3 \dots \lambda_n$  adalah *eigenvalue* matrik A

$x_1, x_2, x_3 \dots x_n$  adalah *eigenvector* sesuai *eigenvalue*-nya ( $\lambda_n$ )

Persamaan *eigenvalue* & *eigenvector* merupakan **Eigen Value Decomposition (EVD)**, dengan persamaan sebagai berikut:

$$\begin{aligned} AX &= XD \\ A &= X D X^{-1} \end{aligned} \quad (2.6)$$

dimana :

A = matrik  $n \times n$  yang memiliki *eigenvalue* ( $\lambda_n$ )

D = *eigenvalue* dari *eigenvector*-nya

X = *eigenvector* dari matrik A

$X^{-1}$  = *invers* dari *eigenvector* X

## 3. HASIL DAN PEMBAHASAN

### 3.1 Analisis Data Alternatif

Tujuan dari analisis data penelitian adalah untuk memastikan bahwa hasil penelitian tidak duragukan dengan mengidentifikasi data yang valid tersedia digunakan selama penelitian. Kebutuhan data pada penelitan ini diperoleh dengan teknik observasi dan wawancara. Data yang dikumpulkan adalah data yang akan menjadi alternatif penelitian berupa jumlah klon karet sebanyak 30 lembar.

**Tabel 1. Data Alternatif**

| No | Panjang 1 (cm) | Panjang 2(cm) | Lebar (cm) | Tebal | Panjang Irisan |
|----|----------------|---------------|------------|-------|----------------|
| 1  | 2              | 4             | 8          | 2.6   | 0.1            |
| 2  | 3              | 4.5           | 19.2       | 3.1   | 0.14           |
| 3  | 3              | 4.4           | 16         | 2.9   | 0.12           |
| 4  | 4              | 4.1           | 4.793      | 1.32  | 0.18           |
| 5  | 4              | 4.2           | 8          | 2.5   | 0.11           |
| 6  | 5              | 4.1           | 8          | 2.6   | 0.1            |
| 7  | 5              | 4             | 8          | 3     | 0.21           |
| 8  | 6              | 4.4           | 32         | 2.1   | 0.12           |

$$z = \frac{x - \mu}{\sigma}; z = \frac{2 - 53.23}{56.39} = -0.90$$

**Tabel 2. Normalisasi**

| No | Panjang daun - tulang daun (cm) | Panjang keseluruhan(cm) | Lebar (cm) | Tebal | Panjang Irisan |
|----|---------------------------------|-------------------------|------------|-------|----------------|
| 1  | -0.90                           | -0.45                   | -0.44      | -0.35 | -0.42          |
| 2  | -0.89                           | -0.08                   | -0.20      | -0.31 | -0.24          |
| 3  | -0.89                           | -0.16                   | -0.27      | -0.33 | -0.33          |
| 4  | -0.87                           | -0.38                   | -0.51      | -0.43 | -0.06          |
| 5  | -0.87                           | -0.31                   | -0.44      | -0.35 | -0.37          |
| 6  | -0.85                           | -0.38                   | -0.44      | -0.35 | -0.42          |
| 7  | -0.85                           | -0.45                   | -0.44      | -0.32 | 0.07           |
| 8  | -0.83                           | -0.16                   | 0.07       | -0.38 | -0.33          |

**Tabel 3. Perhitungan Covariance**

| No | X <sub>1</sub> | X <sub>2</sub> | X <sub>1</sub> -X <sub>avg</sub> | X <sub>2</sub> -X <sub>avg</sub> | Product |
|----|----------------|----------------|----------------------------------|----------------------------------|---------|
| 1  | -0.90          | -0.45          | -0.90                            | -0.45                            | 0.41    |
| 2  | -0.89          | -0.08          | -0.89                            | -0.08                            | 0.07    |
| 3  | -0.89          | -0.16          | -0.89                            | -0.16                            | 0.14    |
| 4  | -0.87          | -0.38          | -0.87                            | -0.38                            | 0.33    |
| 5  | -0.87          | -0.31          | -0.87                            | -0.31                            | 0.27    |

$$\text{Cov}(X_1, X_2) = \frac{\sum(-0.9-0)(-0.45-0)+(-0.89-0)(-0.08-0)}{7-1} = -0.011$$

Selanjutnya adalah memasukkan hasil perhitungan nilai *covariance* pada setiap pasangan atribut kedalam bentuk matrik kovarian (*Covariance Matrix*) yang berukuran  $8 \times 8$  dimana nilai  $\text{Cov}(X_1, X_2)$  sama dengan  $\text{Cov}(X_2, X_1)$ , nilai  $\text{Cov}(X_1, X_3)$  sama dengan nilai  $\text{Cov}(X_3, X_1)$  dan seterusnya dengan cara yang sama juga berlaku untuk setiap pasangan atribut.

### Hasil Dekomposisi nilai dari matrik kovarian

Matrik kovarian yang dibentuk memiliki *square matrix* berukuran  $m \times m$ , maka untuk nilai eigen ( $\lambda$ ) yang sesuai dengan matrik kovarian tersebut memiliki skalar ( $\lambda_1, \lambda_2, \dots, \lambda_m$ ) yang digunakan untuk menghitung bobot atribut menggunakan *eigenvector*.

$$\begin{aligned} \text{Varians kovarians} &= \text{Cov}(X_1, X_1) + \text{Cov}(X_2, X_2) + \text{Cov}(X_3, X_3) + \dots + \text{Cov}(X_8, X_8) \\ &= 1+1+1+1+1+1+1+1 \\ &= 8 \end{aligned}$$

Kemudian dilanjutkan dengan menghitung persentase nilai proporsi varians kovarian untuk dataset seperti berikut:

1. Nilai Proporsi PC1 (%) =  $\frac{\text{Nilai Eigen PC 1}}{\text{Varians kovarians}} \times 100\% = \frac{216.80}{8} \times 100\% = 27.10\%$
2. Nilai Proporsi PC 2 (%) =  $\frac{\text{Nilai Eigen PC 2}}{\text{Varians kovarians}} \times 100\% = \frac{191.20}{8} \times 100\% = 23.90\%$
3. Nilai Proporsi PC 3(%) =  $\frac{\text{Nilai Eigen PC 3}}{\text{Varians kovarians}} \times 100\% = \frac{116.80}{8} \times 100\% = 14.60\%$
4. Nilai Proporsi PC 4 (%) =  $\frac{\text{Nilai Eigen PC 4}}{\text{Varians kovarians}} \times 100\% = \frac{94.40}{8} \times 100\% = 11.80\%$
5. Nilai Proporsi PC 5 (%) =  $\frac{\text{Nilai Eigen PC 5}}{\text{Varians kovarians}} \times 100\% = \frac{80.80}{8} \times 100\% = 10.10\%$
6. Nilai Proporsi PC 6 (%) =  $\frac{\text{Nilai Eigen PC 6}}{\text{Varians kovarians}} \times 100\% = \frac{62.40}{8} \times 100\% = 7.80\%$
7. Nilai Proporsi PC 7 (%) =  $\frac{\text{Nilai Eigen PC 7}}{\text{Varians kovarians}} \times 100\% = \frac{28}{8} \times 100\% = 3.50\%$
8. Nilai Proporsi PC 8 (%) =  $\frac{\text{Nilai Eigen PC 8}}{\text{Varians kovarians}} \times 100\% = \frac{10.40}{8} \times 100\% = 1.30\%$

*Principal Component* (PC) yang terbentuk merupakan kombinasi linear dari atribut ke- $m$  yang memiliki nilai eigen dan proporsi varians maksimum dari total keseluruhan data varians (*total variability*).

**Tabel 4. Hasil Nilai Eigen**

| PC | Nilai Eigen | Proporsi Varian (%) | Cumulative |
|----|-------------|---------------------|------------|
| 1  | 216.80      | 27.10               | 27.10      |
| 2  | 191.20      | 23.90               | 50.90      |
| 3  | 116.80      | 14.60               | 65.50      |
| 4  | 94.40       | 11.80               | 77.30      |
| 5  | 80.80       | 10.10               | 87.40      |

|   |       |      |        |
|---|-------|------|--------|
| 6 | 62.40 | 7.80 | 95.30  |
| 7 | 28.00 | 3.50 | 98.70  |
| 8 | 10.40 | 1.30 | 100.00 |

**Tabel 5. hasil Principal Component**

| PC                                 | Nilai Eigen | Proporsi Varian (%) | Cumulative |
|------------------------------------|-------------|---------------------|------------|
| 1                                  | 216.80      | 27.10               | 27.10      |
| 2                                  | 191.20      | 23.90               | 50.90      |
| <b>Variance Threshold = 50.90%</b> |             |                     |            |

Menjelaskan persentase proporsi varians PC 1 hanya dapat memenuhi 27.10% dari total varians kovarians data asli, apabila ditambah dengan proporsi varians PC 2 maka telah dapat memenuhi 50.90% dari total varians kovarians data asli sehingga sudah dapat mewakili proporsi varians kovarians maksimum dari data asli sebesar 50% dari data asli keseluruhan.

## 4. KESIMPULAN

Adapun Kesimpulan dalam penelitian ini adalah, Klasifikasi untuk menentukan daun yang terbaik menggunakan metode PCA sangatlah membantu dalam mencetak kualitas daun dengan penilaian yang objektif tanpa ada faktor subjektif yang selama ini terjadi.

## UCAPAN TERIMA KASIH

Penulis ingin mengucapkan terima kasih yang sebesar-besarnya kepada semua pihak yang telah memberikan dukungan dan kontribusi dalam penelitian ini. Tanpa kerjasamadan bantuan mereka, penulisan jurnal ini tidak akan terwujud. Serta terimakasih TIM Jurnal Ilmiah Multidisiplin Ilmu Komputer

## DAFTAR PUSTAKA

- [1] Acharya, J., Gadhiya, S., and Raviya, K. 2013. Segmentation techniques for image analysis: A review. *Journal of Computer Science and Management Research*, 2(1): pp. 1218-1221.
- [2] Alpaydin, E. 2010. *Introduction to Machine Learning*. 2<sup>nd</sup> Edition. MIT Press: Massachusetts.
- [3] Arif Jurmawanto., Rudy Hartono., Dhidik Prastiyanti. 2013. *Aplikasi Jaringan Syaraf Tiruan Backpropagation untuk Memprediksi Penyakit THT di Rumah Sakit Mardi Rahayu Kudus*. Kudus..
- [4] Brian Thomas. 2016. *Analisis Learning Rates Pada Algoritma Backpropagation Untuk Klasifikasi Penyakit Diabetes*. Universitas Trunojoyo Madura Bangkalan, Indonesia.
- [5] B. Sahu, C. R. Taylor, R. O. Riddle, and K. K. Leang. 2011. Design and fabrication of an automatic nanoscale tool-tip exchanger for scanning probe microscopy. *Proc. International Manufacturing Science and Engineering Conf.*, Corvallis, OR, 2011, pp. 493-506.
- [6] Dang, T., Pham, T., Tran, H. & Van, Q. 2016. Using Dimension Reduction with Feature Selection to Enhance Accuracy of Tumor Classification. *International Conference on Biomedical Engineering*, pp.14-17.

- [7] Danades, A., Pratama, D., Anggraini, D., Anggriani, D. 2016. Comparison of Accuracy Level K-Nearest Neighbor Algorithm and Support Vector Machine Algorithm in Classification Water Quality Status. *International Conference on System Engineering and Technology*, pp. 137-141.
- [8] Dewi S.& M. Muslikh. 2013. Perbandingan akurasi backpropagation neural network dan ANFIS untuk memprediksi cuaca. *Journal of Scientific Modeling & Computation*, Volume 1 No.1, pp. 7 - 13.
- [9] Dimililer Kamil. 2013. *Backpropagation Neural Network Implementasi For Medical Image Compression*. Electrical and electronic engineering department. Turkey.
- [10] Ganatra Amit., Kosta Y P., Panchal Gaurang., Gajjar Chintan. 2011. Initial Classification Through Backpropagation in A Neural Network Following Optimization Through GA to Evaluate The Fitness of an Algorithm. *Charotar university of science and technology. India*, pp. 100 – 155.
- [11] Gorunescu, F, 2011. *Data Mining Concepts, Model and Techniques*. Berlin: Springer.
- [12] Halim, S. A., Ahmad, A., Noh. N. M., Safudin, M. S., & Ahmad, R. 2011. A Comparative Study between Standard Back Propagation and Resilient Propagation. *IT in Medicine and ducation (ITME), 2011 International Sympoium on. 2*, pp. 242-246.
- [13] Han, J., Kamber, M.& Pei, J. 2012. *Data Mining: Concepts and Techniques*. 3<sup>rd</sup> Edition. Morgan Kaufmann Publishers: San Francisco.
- [14] Hamid., A. N., Nawi M.N., Ghazali., R. and Salleh M N.M. 2011. *Accelerating Learning Performance of Back Propagation Algorithm by Using Adaptive Gain Together with Adaptive Momentum and Adaptive Learning Rate on Classification Problems*. Malaysia: Springer-Verlag Berlin Heidelberg.
- [15] Hussain, H., Quazilbash. N.Z., Bai. S. &Khoja, S. 2015. Reduction of Variables for Predicting Breast Cancer Survivability Using Principal Component Analysis. *International Conference on Computer-Based Medical Systems*, pp. 131-134.
- [16] Izhari F, Dhany H W, Zarlis M, et al. 2017. *Analysis Backpropagation Methods With Neural Network For Prediction Of Children's Ability In Psychomotoric*. 2nd International Conference on Computing and Applied Informatics, pp. 2-6
- [17] Kotu, V., & Desphande, B. 2015. *Predictive Analytics and Data Mining*. Waltham, USA : Morgan Kaufmann Publishers.
- [18] Loochach, R. & Garg, K. July 2012. *Effect of Distance Functions on K-Means Clustering Algorithm*. *International Journal of Computer Applications*. Volume. 49, pp. 7-9.
- [19] Omaima N.A., AL-Allaf. 2010. Improving the Performance of Backpropagation Neural Network Algorithm for Image Compression/Decompression System. *AL-Zaytoonah Private University of Jordan. Ipp*, pp. 1348 – 1354.
- [20] Pratap Singh Kirar Vishnu. 2015. Improving the Performance of Back-Propagation Training Algorithm by Using ANN. *International Journal of Computer and Information Engineering*, pp. 188 – 191.
- [21] Raviya. Kaushik H & Gajjar, Biren. 2013. *Performance Evaluation of Different Data Mining Classification Algoritma Using WEKA*. *Indian Journal of Research*. Volume. 2, pp. 2-5.
- [22] Siregar B., U Andayani., N fatihah, L Hakim., F Fahmi. 2016. Tropical Timber Identification using Backpropagation Neural Network. *Journal of Physics Conference Series 801(1):012051*. pp.2 – 7.
- [23] Sahu, Mridu., Nagwani. N.K., Verma Shrish., Shirke. Saransh. 2015. *Performance Evaluation of Different Classifier for Eye State Prediction Using EEG Signal*. *International Journal of Knowledge Engineering*, Volume.1, No.2. pp. 141 – 145.