

# Prediksi Masa Studi Sarjana dengan *Artificial Neural Network*

Muhamad Hanief Meinanda, Metri Annisa, Narendi Muhandri, dan Kadarsyah Suryadi  
Fakultas Teknologi Industri  
Institut Teknologi Bandung (ITB), Indonesia

**Abstrak**—Prediksi lama masa studi dibutuhkan oleh manajemen perguruan tinggi dalam menentukan kebijakan preventif terkait pencegahan dini kasus *Drop Out (DO)*. Penelitian ini bertujuan untuk menentukan faktor akademis yang berpengaruh terhadap masa studi dan membangun model prediksi terbaik dengan teknik *data mining*. Kriteria pemilihan model yang digunakan adalah minimasi *Sum Square Error (SSE)*. Model terbaik untuk memprediksi lama masa studi adalah model yang dibangun dengan *Artificial Neural Network (ANN)* dengan arsitektur *Multilayer Perceptron (MLP)*. Dari penelitian ini ditemukan bahwa lama masa studi dipengaruhi oleh Indeks Prestasi Kumulatif (IPK), jumlah mata kuliah yang diambil, jumlah mata kuliah mengulang, dan jumlah pengambilan mata kuliah tertentu.

**Kata Kunci**—*Artificial Neural Network, Multilayer Perceptron, Prediksi masa studi.*

## I. PENDAHULUAN

Semakin ketatnya persaingan dalam mendapatkan lapangan pekerjaan menuntut perguruan tinggi menghasilkan sarjana yang berkualitas dan memiliki daya saing. Untuk itu, setiap perguruan tinggi selalu melakukan evaluasi performansi mahasiswa. Hasil evaluasi tersebut disimpan dalam basis data akademik. Data tersebut dapat digunakan untuk sebagai pendukung keputusan oleh manajemen perguruan tinggi. Salah satu variabel indikator efisiensi proses pendidikan adalah informasi mengenai lama masa studi mahasiswa.

Muhamad Hanief Meinanda adalah mahasiswa Program Sarjana Teknik Industri Fakultas Teknologi Industri Institut Teknologi Bandung. Saat ini bertanggung jawab sebagai Koordinator Asisten Laboratorium Perencanaan dan Optimasi Sistem Industri (LPOSI) ITB. Penulis dapat dihubungi melalui e-mail: meinanda@hanief.com. Pandangan dan informasi tentang penulis dapat diakses pada <http://www.hanief.com>.

Metri Annisa Arrum adalah mahasiswi Program Sarjana Teknik Industri Fakultas Teknologi Industri Institut Teknologi Bandung. Saat ini aktif sebagai Asisten Laboratorium Perencanaan dan Optimasi Sistem Industri (LPOSI) ITB. Penulis dapat dihubungi melalui e-mail: m.tirtosiswoyo@yahoo.com.

Narendi Muhandri adalah mahasiswa Program Sarjana Teknik Industri Fakultas Teknologi Industri Institut Teknologi Bandung. Penulis pernah aktif menjadi salah satu asisten mata kuliah dan praktikum Logika Pemrograman dan Komputer Teknik Industri ITB. Penulis dapat dihubungi melalui e-mail: muhandri@yahoo.com.

Kadarsyah Suryadi adalah dosen Program Studi Teknik Industri ITB. Saat ini penulis bertanggung jawab sebagai Ketua Program Studi Magister dan Doktor Teknik & Manajemen Industri. Penulis merupakan dosen dari Laboratorium Sistem Informasi dan Keputusan dengan kelompok keahlian Manajemen Industri. Penulis dapat dihubungi melalui e-mail: kadarsah@bdg.centrin.net.id.

*Artificial Neural Network (ANN)* sejak diperkenalkan pada sekitar tahun 1940 telah banyak diimplementasikan pada berbagai bidang keilmuan. ANN banyak digunakan untuk melakukan prediksi atau peramalan [1]. Williams dan Li (2008) telah meneliti penggunaan ANN dengan algoritma *training back-propagation* untuk melakukan prediksi pacuan kuda di Jamaika. ANN dengan jenis *feed forward network* atau *back-propagation* yang digunakan dalam penelitian ini telah terbukti memberikan hasil yang baik untuk keperluan prediksi [2].

Al Cripps (1996) telah melakukan penelitian penggunaan ANN untuk memprediksi performansi akademik berupa presentasi kelulusan, masa studi, dan GPA. Penelitian tersebut menggunakan tidak menggunakan data akademis yang diperoleh selama mahasiswa kuliah. Variabel prediktor yang digunakan pada penelitian tersebut adalah usia, jenis kelamin, skor *American College Testing (ACT)*, ras, dan kemampuan membaca [3]. Bijayananda Naik dan Srinivasan Ragothaman (1998) telah meneliti penggunaan *neural network* untuk memprediksi tingkat kesuksesan mahasiswa MBA, dengan prediktor GPA program sarjana [4].

Dengan acuan kesempatan penelitian yang tersedia berdasarkan penelitian sebelumnya maka pada penelitian ini akan diteliti variabel prediktor dari data akademis yang berpengaruh terhadap masa studi dan pembuatan model ANN untuk prediksi masa studi. Model prediksi tersebut digunakan untuk menentukan kebijakan terhadap mahasiswa yang diprediksi memiliki masa studi melebihi batas. Pada penelitian ini diujicobakan juga model *multiple regression* sebagai model pembandingan dalam melakukan prediksi masa studi.

## II. TINJAUAN PUSTAKA

### A. Struktur Neural Network

*Artificial neural network (ANN)* terinspirasi dari kesadaran atas *complex learning system* pada otak yang terdiri dari set-set neuron yang saling berhubungan secara dekat. Jaringan neuron mampu melakukan tugas yang sangat kompleks seperti klasifikasi dan pemahaman pola. ANN dapat memperkirakan rentang yang cukup luas suatu model statistika dan fleksibel dalam menggambarkan model (linier maupun nonlinier) [5]. ANN dapat digunakan untuk permasalahan yang sama dengan permasalahan statistika multivariat seperti *multiple regression*, analisa diskriminan, dan analisa kluster. Dalam banyak kasus, hasil yang didapat dengan ANN dapat dibandingkan dengan model statistika multivariat [6].

Terdapat tiga jenis utama dari ANN yakni *Multilayer Perceptron*, *Radial Basis Function*, dan *Kohonen Network*. *Multilayer Perceptron* merupakan model yang paling banyak digunakan untuk melakukan prediksi. *Radial Basis Function* merupakan model yang dapat melakukan hal yang dilakukan oleh *Multilayer Perceptron*. *Kohonen Network* baik digunakan pada permasalahan *clustering* [7]. Pada penelitian ini digunakan model *Multilayer Perceptron* karena model ini umum digunakan pada permasalahan prediksi.

*Multilayer Perceptron* merupakan model yang memetakan suatu set *input* data menjadi set *output*, dengan menggunakan fungsi aktivasi nonlinier. Pada *Multilayer Perceptron* variabel independen maupun dependen dapat memiliki tingkat pengukuran metrik maupun nonmetrik. *Multilayer perceptron* merupakan *feedforward neural network* dimana informasi bergerak hanya dalam satu arah, dari simpul *input* melalui simpul tersembunyi dan simpul *output* [8].

### B. Algoritma Pembelajaran

Neural network memperoleh nilai bobot dari suatu algoritma pembelajaran tertentu. Bobot ini digunakan dalam melakukan transformasi nilai dari node *input* ke node *output*. Algoritma pembelajaran merupakan tahap penyesuaian terhadap bobot yang telah terbentuk secara *random*. Pembaharuan nilai bobot secara umum dirumuskan sebagai berikut:

$$w_{ij}(n+1) = w_{ij}(n) + \Delta w_{ij}(n) \quad (1)$$

dimana  $\Delta w_{ij}(n)$  dihitung dengan algoritma pembelajaran dan  $w_{ij}(n)$  merupakan bobot awal yang ditentukan secara acak pada tahap inisialisasi [9].

### C. Algoritma Back-Propagation

Masukan dari node *input* diteruskan ke *hidden layer* kemudian dilanjutkan ke node *output*. Setiap hubungan dari unit  $i$  ke unit  $j$  memiliki bobot  $w_{ij}$  yang mengindikasikan kekuatan dari koneksi. Jumlah dari pembobotan,  $a_j$ , untuk suatu input  $x_{ij}$  dan bobot  $w_{ij}$  didefinisikan sebagai berikut:

$$a_j = \sum_{i=1}^n w_{ij} \cdot x_i \quad (2)$$

dimana nilai  $n$  merupakan jumlah *input* pada suatu neuron. Fungsi aktivasi yang digunakan adalah fungsi aktivasi *logistic sigmoid*:

$$g(a) = \frac{1}{1 + e^{-a}} \quad (3)$$

Nilai galat,  $E_j(n)$ , antara output aktual  $y_j(n)$  dan nilai output dari neuron  $d_j(n)$  dihitung dengan rumus:

$$E_j(n) = d_j(n) - y_j(n) \quad (4)$$

Rumus pembelajaran dengan *Back-Propagation* adalah:

$$\Delta w_{ij} = \eta x_i + \alpha \Delta w_{ij} = \eta x_i - \alpha \frac{\delta E_j}{\delta w_{ij}} \quad (5)$$

dimana  $\eta$  adalah laju pembelajaran (*learning rate*) dan  $\alpha$  adalah faktor *moment*. Parameter tersebut menentukan seberapa besar pengaruh parameter lama terhadap arah perubahan parameter yang baru.

## III. METODOLOGI PENELITIAN

Metodologi penelitian diadopsi dari metodologi *Cross-Industry Standard Process for Data Mining (CRISP-DM)* yang dikembangkan pada tahun 1996 oleh analis dari Daimler Chrysler, SPSS, dan NCR. CRISP-DM memiliki enam fase yaitu *Business understanding phase*, *Data understanding phase*, *Data preparation phase*, *Modeling phase*, *Evaluation phase*, dan *Deployment phase* [10].

Tahap awal dari penelitian adalah memahami permasalahan yang akan diselesaikan yaitu melakukan estimasi terhadap masa studi berdasarkan ketersediaan pola antara data masa lalu dengan data aktual. Pada tahap ini, peneliti melakukan pemahaman terhadap data dan mencoba mencari adanya pola serta keterkaitan antara variabel-variabel data dengan masing-masing tujuan penelitian.

Peneliti kemudian melakukan *preprocessing* data di antaranya dengan melakukan pembuatan *cross-tabulation*, koreksi terhadap data yang mengalami *misclassification*, dan menghapus *missing value* dan *outlier*. Setelah itu, dilakukan tahap pembuatan model. Untuk estimasi terhadap masa studi yang memiliki tingkat pengukuran metrik begitu juga dengan prediktornya peneliti menggunakan model *artificial neural network* dan *multiple regression*.

Setelah mengetahui model yang sesuai, peneliti melakukan pembuatan model dengan menggunakan data *training*. Model yang dipilih mempertimbangkan kesesuaian asumsi model dan *error* yang dihasilkan. Kemudian model tersebut diterapkan pada set data *testing* dan dilakukan analisis terhadap penggunaan model dengan hasil yang diperoleh.

## IV. PENGOLAHAN DATA

Data *input* yang digunakan merupakan data hipotetik dalam kontes Data Mining, Pagelaran Mahasiswa Nasional Bidang Teknologi Informasi dan Komunikasi (Gemastik) 2009. Data tersebut berasal dari data akademis aktual di suatu perguruan tinggi. Data tersebut terdiri dari catatan akademis 1289 mahasiswa, dengan variabel yang dapat dilihat pada Tabel I.

TABEL I  
KETERANGAN VARIABEL PADA DATA INPUT

Field	Deskripsi Data	Tipe Data
ID	Identitas mahasiswa ( <i>primary key</i> )	String
Masa Studi	Rentang waktu Mahasiswa menjalani masa kuliah	Integer
Kode Mata Kuliah	Kode unik untuk tiap mata kuliah	String
Nama Mata Kuliah	Nama mata kuliah	String
Ambil Ke	Jumlah pengambilan suatu mata kuliah oleh mahasiswa bersangkutan	Integer
Nilai	Nilai untuk tiap mata kuliah yang diambil mahasiswa bersangkutan	String

TABEL II  
KETERANGAN VARIABEL PADA *CROSS-TABULATION*

Nama Data	Deskripsi Data	Pengolahan Data	Tingkat Pengukuran
Bobot	Nilai mahasiswa yang di-transformasikan ke dalam angka	Melakukan kodifikasi nilai A=4; B=3; C=2; D=1; E=0	Ordinal
SKS	Jumlah satuan kredit semester yang diambil oleh mahasiswa	Menjumlahkan seluruh satuan kredit semester dari tiap mata kuliah yang diambil oleh mahasiswa.	Metrik
IPK	Indeks prestasi kumulatif mahasiswa	Hasil pembagian kolom bobot dengan kolom SKS	Metrik
Jumlah Mata Kuliah	Jumlah mata kuliah yang diambil mahasiswa	Penjumlahan total mata kuliah yang diambil mahasiswa	Metrik
Jumlah Mengulang	Jumlah pengulangan mata kuliah	Penjumlahan total pengulangan mata kuliah yang diambil mahasiswa	Metrik

Dari data *input* tersebut kemudian dilakukan tahap *preprocessing* yang terdiri dari transformasi dan pembersihan data. Transformasi data dilakukan dengan membuat *cross-tabulation* sehingga data memiliki *unique key* dan memiliki kolom sesuai dengan hipotesa variabel prediktor (Tabel II). Selanjutnya dilakukan koreksi terhadap entri data yang memiliki *misclassification*. *Misclassification* terjadi karena ada perbedaan kurikulum sehingga nama mata kuliah yang sama tertulis berbeda. Selanjutnya dilakukan penghapusan terhadap *missing value* dan data yang memiliki nilai tidak wajar (*outlier*).

Eksperimen dilakukan pada komputer berbasis *Intel Atom N280* menggunakan algoritma ANN *Multilayer Perceptron*, *Linear Regression*, dan *Spearman Correlation* dengan perangkat lunak *SPSS 16 (Windows XP x32)*. *Preprocessing* data dan pembuatan *Cross-Tabulation* dilakukan pada platform yang sama dengan menggunakan *Microsoft Excel 2007 SP0*.

## V. EKSPERIMEN DAN ANALISIS

### A. Penentuan Variabel Prediktor

Variabel masa studi yang terdapat pada data *training* terdiri dari 47 nilai berbeda dengan interval antara 41 sampai 88 bulan, sehingga variabel masa studi merupakan variabel dengan skala pengukuran metrik. Variabel prediktor untuk data masa studi memiliki skala pengukuran metrik. Dalam melakukan prediksi nilai masa studi, peneliti akan menggunakan model dependensi dengan variabel dependen metrik.

Langkah selanjutnya adalah penentuan prediktor yang dapat mempengaruhi variabel masa studi. Data yang disediakan adalah catatan akademis setiap mahasiswa, sehingga prediktor yang akan dimasukkan ke dalam model prediksi merupakan data yang berkaitan dengan performansi akademik mahasiswa. Peneliti mengajukan hipotesa *a priori* dalam menentukan

variabel independen sebagai prediktor masa studi. Hipotesa tersebut adalah adanya hubungan antara Indeks Prestasi Kumulatif, jumlah mata kuliah yang diambil, dan jumlah mata kuliah mengulang terhadap masa studi.

Variabel prediktor IPK dihitung dengan menghitung bobot nilai dibagi dengan total SKS yang diambil. Peneliti tidak memasukan variabel IPK ke dalam model, karena variabel IPK merupakan variabel turunan dari variabel bobot dan SKS. Variabel IPK tidak digunakan dalam membangun model dan digantikan oleh variabel bobot dan variabel SKS.

### B. Preprocessing

*Preprocessing* data dilakukan agar pada tahap pembuatan model mampu menghasilkan model yang efektif. Beberapa hal yang dilakukan pada tahap data *preprocessing* adalah transformasi ke dalam bentuk yang lebih informatif dengan menggunakan *cross-tabulation*. Tahap data *preprocessing* selanjutnya adalah melakukan penghapusan terhadap *missing-value* dan *outlier* pada data.

### C. Exploratory Analysis

Prediktor yang dipilih secara *a priori* diuji dengan menggunakan *Spearman Correlation Coefficient* untuk memastikan adanya hubungan antara prediktor-prediktor tersebut terhadap masa studi. Korelasi *Spearman* dipilih karena tidak membutuhkan asumsi distribusi dan normalitas data [11]. Hasil perhitungan korelasi dapat dilihat pada Tabel III. Pada tabel tersebut nilai signifikansi korelasi kurang dari nilai kritis ( $\alpha=0.05$ ), sehingga berdasarkan pengujian korelasi, semua prediktor memiliki korelasi signifikan terhadap variabel masa studi, sehingga variabel tersebut dimasukkan ke dalam model prediksi.

TABEL III  
PERHITUNGAN KORELASI MASA STUDI

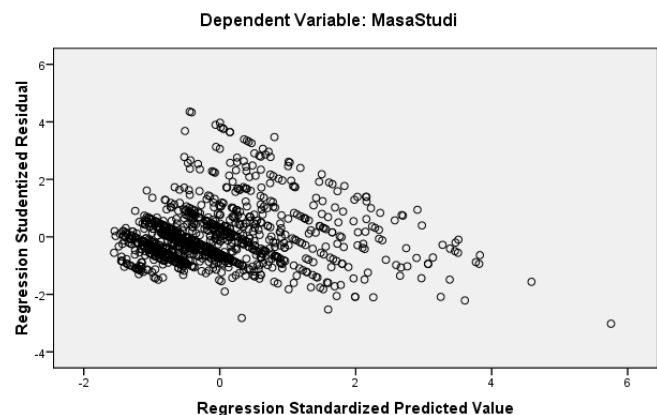
Spearman's rho		Bobot	Jumlah MataKul	Jumlah Mengulang	SKS
Masa Studi	Correlation Coef,	-0.60	0.76	0.78	0.43
	Sig. (2-tailed)	0	0	0	0
	N	1221	1221	1221	1221

Untuk keperluan validasi, data dibagi ke dalam dua kelompok (*split-sample*) yakni data *training* dan data *testing*. Data *training* merupakan data yang digunakan untuk membangun model. Data *training* dipilih secara *random* dengan jumlah data 80% dari seluruh data. Data *testing* digunakan untuk keperluan validasi.

### D. Pembuatan Model Prediksi Masa Studi

Model yang dapat digunakan untuk memprediksi variabel metrik dengan prediktor metrik adalah model *multiple regression* dan *neural network*. Model yang pertama kali dibangun dan diuji adalah model regresi. Pengujian asumsi model regresi baru dapat dilakukan ketika model regresi sudah terbentuk. Model regresi memiliki asumsi normalitas *error*, konstant *error variance (homoscedasticity)*, dan independensi *error* [7]. Semua asumsi tersebut harus dapat dipenuhi agar model regresi tidak bias. Setelah melakukan pembuatan model regresi menggunakan parameter *Minimum Least Square*

didapat bahwa variansi dari error tidak konstan (Gambar 1). Berdasarkan *scatterplot* antara *standarized residual* terhadap *z-predicted* variansi titik residu membesar dengan membesarnya *predicted value*. Oleh karena itu, model regresi tidak efisien digunakan karena asumsi *homoscedasticity* tidak dipenuhi.



Gambar. 1. Plot Pengujian Homoscedasticity dari Error

Model lain yang digunakan dalam melakukan prediksi masa studi adalah *Artificial Neural Network (ANN)*. Jenis *Artificial Neural Network* yang digunakan adalah *Multilayer Perceptron (MLP)*. *Multilayer Perceptron* dapat digunakan untuk memprediksi data ril dengan *supervised training*. Arsitektur yang digunakan dipilih yang terbaik secara otomatis oleh *SPSS 16*. Tipe *training* yang dipilih adalah *batch training*. *Batch training* mampu menghasilkan error paling kecil dibanding metoda *training* lainnya. *Initial learning rate* di-set = 0.4, momentum 0.9. *Training epoch* ditentukan secara otomatis. Performansi model dapat dilihat pada Tabel IV.

TABEL IV  
RINGKASAN MODEL MLP MASA STUDI

Training	Sum of Squares Error	184.346
	Relative Error	.357
Dependent Variable: MASASTUDI		


E. Improvement Model Masa Studi

Untuk memperkecil *Sum of Squares Error (SSE)*, peneliti kembali mengevaluasi prediktor yang digunakan. Peneliti memasukan prediktor tambahan berupa jumlah berapa kali mahasiswa mengambil mata kuliah tertentu. Mata kuliah yang dipilih adalah mata kuliah yang paling banyak diambil oleh mahasiswa. Mata kuliah yang paling banyak diambil mengindikasikan mata kuliah tersebut banyak diulang mahasiswa. Variabel tersebut dimasukan satu persatu ke dalam model kemudian dilakukan evaluasi *SSE* yang dihasilkannya (Tabel V).

TABEL V  
PERFORMANSI MODEL (SSE) SETELAH PENAMBAHAN VARIABEL

Penambahan Variabel	Sum Square Error
15	150.5
20	93.3
25	89.1
30	86.4
35	81.0

Variable Add. vs SSE



Gambar. 2. Plot Penambahan Variabel v.s. SSE

Dari Gambar 2, penurunan terhadap *SSE* terjadi signifikan pada penambahan sejumlah 22 variabel. Oleh karena itu, pada model ditambahkan 22 variabel yang berisi data jumlah berapa kali mahasiswa tertentu mengambil mata kuliah yang terbanyak diambil mahasiswa secara keseluruhan. Performansi dari model perbaikan dapat dilihat pada Tabel VI.

TABEL VI  
RINGKASAN MODEL MLP MASA STUDI PERBAIKAN

Training	Sum of Squares Error	97.004
	Relative Error	.159
Dependent Variable: MASASTUDI		

Model tersebut selanjutnya di-validasi menggunakan set data *testing*. Validasi dilakukan dengan membandingkan apakah ada perbedaan signifikan terhadap data masa studi aktual dengan data masa studi prediksi. Berdasarkan hasil uji normalitas data prediksi menggunakan *Kolmogorov-Smirnov* dengan tingkat kepercayaan 95%, didapatkan bahwa data prediksi tidak berdistribusi normal, sehingga uji beda yang dilakukan dengan *Wilcoxon Signed-Ranks* (Tabel VII).

TABEL VII  
UJI BEDA VARIABEL MASA STUDI AKTUAL DENGAN PREDIKSI

Test Statistics <sup>b</sup>	
	Pred - MasaStudi
Z	-1.842 <sup>a</sup>
Asymp. Sig. (2-tailed)	.065
a. Based on negative ranks.	
b. Wilcoxon Signed Ranks Test	

Uji beda menghasilkan nilai *p-value* sebesar 0.65. Nilai tersebut lebih besar dari nilai kritis 0.05. Oleh karena itu, dengan tingkat kepercayaan 95%, tidak ada perbedaan signifikan antara nilai masa studi aktual dengan nilai masa studi berdasarkan model prediksi.

VI. PENUTUP

Berdasarkan hasil eksperimen, evaluasi, dan analisis yang dilakukan, maka dapat disimpulkan bahwa (a) variabel Indeks Prestasi Kumulatif, jumlah mata kuliah yang diambil, jumlah mata kuliah mengulang, dan jumlah pengambilan mata kuliah tertentu mempengaruhi masa studi (b) Dalam melakukan prediksi masa studi, model regresi akan menghasilkan prediksi masa studi yang bias karena asumsi *Homoscedasticity Error* tidak dapat dipenuhi (c) *Artificial Neural Network* dengan

arsitektur *Multilayer Perceptron* dalam penelitian ini merupakan model terbaik untuk memprediksi lama masa studi.

Mengingat data yang digunakan merupakan data hipotetik pada kontes Data Mining Pagelaran Mahasiswa Nasional Teknologi Informasi (Gemastik 2009), maka simpulan penelitian akan berbeda jika diaplikasikan pada data akademis aktual. Penelitian lebih lanjut mengenai prediksi performansi akademik mahasiswa dapat dilakukan dalam bentuk: (a) penelitian menggunakan data akademis aktual pada perguruan tinggi tertentu (b) pembuatan model prediksi terhadap status *Drop Out* sehingga dapat digunakan sebagai *early warning* (c) perancangan perangkat lunak untuk mengimplementasikan model sehingga praktis digunakan pada sistem nyata.

## VII. DAFTAR PUSTAKA

- [1] J. Williams and L. Yan, "A case study using neural network algorithms: horse racing prediction in jamaica" in *International Conf. on Artificial Intelligence (ICAI'08)*, Las Vegas, 2008.
- [2] A. Lapedes and R. Farber, "How neural nets works," *Evolution, Learning, and Cognition*, pp. 331-345, 1998, submitted for publication.
- [3] Al Cripps, "Using Artificial Neural Nets to Predict Academic Performance," in *ACM Symposium on Applied Computing*, 1996.
- [4] N. Bijayananda dan R. Srinivasan, "Predicting M.B.A. student performance: An empirical comparison of neural network vis-à-vis statistical models," in *Midwest Decision Sciences*, Lincoln Institute, 1998.
- [5] Y. Bar-Yam, *Dynamics of Complex Systems*. 2008.
- [6] P.V. Balakrishnan, M.C. Cooper, V.S. Jacob, dan P.A. Lewis, "A study of the classification capabilities of neural networks using unsupervised learning: A comparasion with k-means clustering," *Psychometrika*. Vol. 59, 1994.
- [7] J. Hair dan R. Anderson, *Multivariate Data Analysis*. New York : Prentice Hall, 1998.
- [8] D. Pyle, *Data Preparation for Data Mining*. Morgan Kaufmann Publisher, 1999.
- [9] C.M. Bishop, *Neural Networks for Pattern Recognition, 3rd ed.* Oxford : Oxford University Press, 1995.
- [10] D.T. Larose, *Discovering Knowledge In Data – An Introduction to Data Mining*. New Jersey : John Wiley & Sons, 2005.
- [11] E.L. Lehmann dan H.J.M D' Abrera. *Nonparametrics: Statistical Methods Based on Ranks*. rev. ed. NJ : Prentice-Hall, 1998.