

ANALISIS ALGORITMA PREDIKSI UNTUK MENGHASILKAN PREDIKSI BEBAN LISTRIK JANGKA PENDEK

Veti Apriana¹; Rani Irma Handayani²

¹ Komputerisasi Akuntansi AMIK BSI Jakarta

² Manajemen Informatika AMIK BSI Jakarta

E-mail: *¹veti.vta@bsi.ac.id, ²rani.rih@bsi.ac.id

Abstract— *Electricity is the lifeblood for human life, both for household and industrial world. In the power supply industry, it is important to determine the power requirements for the future as soon as possible (at the earliest). Short-term electric load prediction is one way that can be used to generate and distribute electrical energy economically, so that the power provider can know the load and demand for power for the next month, previous short-term power prediction studies, generally using the Neural method Network. Neural Network is an information processing system that has characteristics similar to biological neural networks but, deficiencies in Neural Network often overfitting due to overtrained. In a short-term electrical load prediction study, using the Support Vector Machine (SVM) method, Support Vector Machines (SVM) is a technique for predicting both classification and regression. This research begins by processing daily load system load data with a time span of 30 minutes, with data input used is data in January 2017. The results show that the SVM method can be one of the reference methods for the prediction of short-term electrical load with RMSE 0.034.*

Key word: *Electricity load, Neural Networks, Support Vector Machine*

Intisari— *Listrik merupakan urat nadi bagi kehidupan manusia, baik untuk rumah tangga maupun dunia industri. Dalam industri pasokan listrik, penting untuk menentukan kebutuhan daya untuk masa depan secepat mungkin (diawal). Prediksi beban listrik jangka pendek merupakan salah satu cara yang dapat digunakan untuk membangkitkan dan menyalurkan energi listrik secara ekonomis, sehingga pihak penyedia listrik dapat mengetahui beban dan permintaan daya untuk bulan berikutnya, penelitian-penelitian prediksi beban listrik jangka pendek sebelumnya, secara umum menggunakan metode Neural Network. Neural Network adalah sistem pemroses informasi yang memiliki karakteristik mirip dengan jaringan syaraf biologi namun,*

kekurangan pada Neural Network sering mengalami overfitting karena overtrained. Dalam penelitian prediksi beban listrik jangka pendek, menggunakan metode Support Vector Machine (SVM), Support Vector Machines (SVM) adalah suatu teknik untuk melakukan prediksi, baik dalam kasus klasifikasi maupun regresi. Penelitian ini diawali dengan mengolah data beban kemampuan beban sistem harian dengan runtun waktu per-30 menit, dengan input data yang digunakan adalah data pada bulan Januari 2017. Hasil penelitian menunjukkan bahwa metode SVM dapat menjadi salah satu referensi metode untuk prediksi beban listrik jangka pendek dengan RMSE 0.034.

Kata Kunci: *Beban Listrik, Neural Network, Support Vector Machine.*

PENDAHULUAN

Listrik merupakan urat nadi bagi kehidupan manusia, baik untuk rumah tangga maupun dunia industri. Dalam industri pasokan listrik, penting untuk menentukan kebutuhan daya untuk masa depan secepat mungkin (diawal). Jika perkiraan akurat dapat dibuat untuk beban maksimum dan minimum untuk setiap jam, hari, bulan, musim dan tahun, perusahaan pengguna dapat membuat perekonomian yang signifikan untuk diwilayah seperti pengaturan cadangan operasi, penjadwalan pemeliharaan, dan manajemen persediaan bahan bakar (Witten & Frank, 2005), hal ini biasa disebut dengan peramalan beban listrik.

Oleh karena itu, Perusahaan Listrik Negara (PT. PLN (PERSERO) P3B Jawa-Bali) mengadakan peramalan beban listrik jauh sebelum waktunya. Banyak peneliti, yang meneliti beban listrik jangka pendek dengan metode *Neural Network*. Namun, kekurangan pada *Neural Network* sering mengalami *overfitting* karena *overtrained* (Santosa, 2007). *Support Vector Machines* (SVM) adalah suatu teknik untuk melakukan prediksi, baik dalam

kasus klasifikasi maupun regresi, yang sangat populer belakangan ini (Santosa, 2007). Pada SVM tidak mengenal istilah *overfitting* karena *overtrained*, karena *training* perlu dilakukan sekali saja dan akan mendapatkan solusi optimal.

Berdasarkan uraian diatas, permasalahan yang muncul yaitu adanya kasus *overfitting* pada *Neural Network* karena adanya *overtrained* (menyebabkan training dilakukan berulang kali baru mendapatkan solusi optimal) (Santosa, 2007). Untuk mengatasi permasalahan tersebut, maka diperlukan metode *Support Vector Machines* (SVM) untuk menemukan solusi optimal secara global.

BAHAN DAN METODE

Literatur-literatur yang ada mengenai prediksi beban listrik jangka pendek, dibahas dengan berbagai macam metode.

Penelitian yang dilakukan oleh peneliti-peneliti sebelumnya untuk memprediksi beban listrik jangka pendek, pernah dilakukan oleh Mohsen Hayati & Yazdan Shirvany, 2007, dimana Permasalahan yang dibahas pada penelitian ini, berdasarkan pada Multi-Layer Perceptron (MLP) dilatih dan diuji menggunakan tiga tahun (2004-2006) data untuk meramalkan beban listrik 24 jam berikutnya. Penelitian ini menggunakan metode *neural network*. Hasilnya MLP memiliki kesalahan peramalan yang kecil dan dapat dianggap sebagai metode yang baik untuk model sistem Short Term Load Forecasting (STLF).

Penelitian berikutnya dilakukan oleh G.A. Adepoju, S.O.A Ogunjuyigbe & K.O. Alawode, 2007. Pada penelitian ini, ada kecenderungan yang berkembang ke arah *unbundling* sistem kelistrikan sehingga operasi dan perencanaan dari sebuah perusahaan utilitas listrik membutuhkan model yang memadai untuk peramalan beban tenaga listrik. Penelitian ini menggunakan metode *neural network*. Hasil penelitian yang diperoleh dengan metode *Neural Network* yaitu dengan *Absolute Mean Error* 2.54%.

Penelitian juga dilakukan oleh Gwo-Ching Liao, 2011. Dalam penelitian ini, adanya penggabungan metode Fuzzy Neural Networks (FNN) dengan Quatum Genetic Algorithm (QGA). Komparasi Fuzzy Neural Networks (FNN) dengan Quatum Genetic Algorithm (QGA). Hasil komparasi kedua metode mendapatkan *rate ranging* 6.2 % sampai 43.4%.

Prediksi Beban Listrik

Menurut (Marsudi, 2006) prakiraan permintaan beban listrik berdasarkan jangka waktu dapat dikelompokkan dalam :

1. Prakiraan beban jangka panjang (*long term*) adalah prakiraan permintaan beban dengan jangka waktu di atas 1 (satu) tahun.
2. Prakiraan beban jangka menengah (*medium term*) adalah prakiraan permintaan beban dengan jangka waktu satu bulan sampai dengan satu tahun.
3. Prakiraan beban jangka pendek (*short term*) adalah prakiraan permintaan beban dengan jangka waktu beberapa jam dalam sehari sampai satu minggu.

Metode Metode Backpropagation

Pada *Neural Network* algoritma yang digunakan adalah *backpropagation*, Pelatihan *backpropagation* meliputi tiga fase, yaitu:

1. Fase pertama adalah fase maju dimana pola masukan dihitung maju mulai dari layar masukan hingga layar keluaran menggunakan fungsi aktivasi yang ditentukan.
2. Fase kedua adalah fase mundur, dimana selisih antara keluaran jaringan dengan target yang diinginkan merupakan kesalahan yang terjadi. Kesalahan tersebut dipropagasikan mundur, dimulai dari garis yang berhubungan langsung dengan unit-unit dilayar keluaran.
3. Fase ketiga adalah modifikasi bobot untuk menurunkan kesalahan yang terjadi.

Ketiga fase diatas diulang-ulang terus hingga kondisi penghentian dipenuhi (jumlah iterasi atau kesalahan). Langkah dalam algoritma *backpropagation* adalah sebagai berikut (Myatt, 2007):

1. Inisialisasi bobot jaringan secara acak (biasanya antara -0.1 sampai 1.0).
2. Untuk setiap data pada data *training*, hitung input untuk simpul berdasarkan nilai input dan bobot jaringan saat itu, menggunakan rumus:

$$Input_j = \sum_{i=1}^n O_i w_{ij} + \theta_j \dots\dots\dots (1)$$

3. Berdasarkan input dari langkah dua, selanjutnya membangkitkan output untuk simpul menggunakan fungsi aktivasi sigmoid:

$$Output = \frac{1}{1 + e^{-Input}} \dots\dots\dots (2)$$

4. Hitung nilai *Error* antara nilai yang diprediksi dengan nilai yang sesungguhnya menggunakan rumus:

$$Error_j = Output_j \cdot (1 - Output_j) \cdot (Target_j - Output_j) \dots\dots\dots (3)$$

5. Setelah nilai *Error* dihitung, selanjutnya dibalik *layer* sebelumnya (*backpropagated*). Untuk menghitung nilai *Error* pada *hidden layer*, menggunakan rumus:

$$Error_j = Output_j(1 - Output_j) \sum_{k=1}^n Error_k w_{jk} \dots\dots\dots (4)$$

6. Nilai *Error* yang dihasilkan dari langkah sebelumnya digunakan untuk memperbarui bobot relasi menggunakan rumus:

$$w_{ij} = w_{ij} + l \cdot Error_j \cdot Output_i \dots\dots\dots (5)$$

Hasil akhir dari penelitian ini adalah berupa evaluasi performa prediksi yaitu dengan *Root Mean Square Error*.

$$RMSE = \sqrt{\frac{SSE}{N \cdot K}} \dots\dots\dots (6)$$

Metode Support Vector Machine

Dalam *Support Vector Machine* (SVM), terdapat fungsi pemisah adalah fungsi linier

$$g(x) := sgn(f(x)) \dots\dots\dots (7)$$

$$f(x) = w^T x + b$$

Secara matematika, formulasi problem optimisasi SVM untuk kasus klasifikasi linier di dalam *primal space* adalah

$$\min \frac{1}{2} ||w||^2 \dots\dots\dots (8)$$

Subject to

$$Y_i (WX_i + b) \geq 1, i = 1, \dots, l \dots\dots\dots (9)$$

Dimana X_i adalah data input, Y_i adalah keluaran dari data X_i , W , b adalah parameter-parameter yang kita cari nilainya. Dalam Formulasi diatas, kita ingin meminimalkan fungsi tujuan (*objective fuction*) $\frac{1}{2} ||w||^2$ atau memaksimalkan kuantitas $||w||^2$ atau

$W^T W$ dengan memperhatikan pembatas $Y_i(w x_i + b) \geq 1$. Bila output data $Y_i = +1$, maka pembatas menjadi $(w x_i + b) \geq 1$ sebaliknya bila $Y_i = -1$, pembatas menjadi $Y_i(w x_i + b) \leq -1$. Didalam kasus yang tidak *feasible* (*infisible*) dimana beberapa data mungkin tidak bisa dikelompokkan secara benar, formulasi matematikanya menjadi berikut:

$$\min \frac{1}{2} ||W||^2 + C \sum_{i=1}^l t_i \dots\dots\dots (10)$$

Subject to

$$Y_i(w x_i + b) + t_i \leq 1 \dots\dots\dots (11)$$

$$t_i \geq 0, i = 1, \dots, l$$

dimana t_i adalah *variable slack*. Dengan formulasi ini dapat memaksimalkan margin antara dua kelas dengan meminimalkan $||w||^2$, Dalam formulasi ini berusaha meminimalkan *kesalahan klasifikasi* (*misclassification error*) yang dinyatakan dengan adanya variabel *slack* t_i sementara dalam waktu yang sama dapat memaksimalkan margin $\frac{1}{||w||}$. Penggunaan variabel *slack* t_i adalah untuk mengatasi kasus ketidaklayakan (*infeasibility*) dari pembatas (*constraints*) $y_i(w x_i + b) \geq 1$ dengan cara memberi penalti untuk data yang tidak memenuhi pembatas tersebut. Untuk meminimalkan nilai t_i kita berikan pinalti dengan menerapkan konstanta ongkos C . Vektor w tegak lurus terhadap fungsi pemisah: $w x + b = 0$. Konstanta b menentukan lokasi fungsi pemisah relatif terhadap titik asal (*origin*).

Problem (10) adalah *programa nonlinear*. Ini bisa dilihat dari *fungsi tujuan* (*objective function*) yang berbentuk kuadrat. Untuk menyelesaikannya lebih mudah dan efisien untuk diselesaikan, masalah ini bisa ditransformasikan ke dalam *dual space*. Untuk itu, pertama kita ubah problem (12) menjadi *fungsi Lagrangian* :

$$J(w, b, \alpha) = \frac{1}{2} w^T w - \sum_{i=1}^l \alpha_i [y_i (w^T x_i + b) - 1] \dots\dots (12)$$

dimana variabel *non-negatif*, α_i dinamakan *Lagrange multiplier*. Solusi dari problem optimisasi dengan pembatas seperti di atas ditentukan dengan mencari *saddle point* dari fungsi Lagrangian $J(w, b, \alpha)$. Fungsi ini harus diminimalkan terhadap variabel w dan b dan harus dimaksimalkan terhadap variable α . Kemudian cari turunan pertama dari fungsi $J(w, b, \alpha)$ terhadap variabel w dan b kita samakan dengan 0. Dengan melakukan proses ini, kita akan mendapatkan dua kondisi optimalitas berikut:

1. Kondisi 1:

$$\frac{\partial J(w, b, \alpha)}{\partial w} = 0$$

2. Kondisi 2:

$$\frac{\partial J(w,b,\alpha)}{\partial b} = 0$$

Penerapan kondisi optimalitas 1 pada fungsi Lagrangian (12) akan menghasilkan

$$w = \sum_{i=1}^l \alpha_i y_i x_i \quad (13)$$

Penerapan kondisi optimalitas 2 pada fungsi Lagrangian (12) akan menghasilkan

$$\sum_{i=1}^l \alpha_i y_i = 0 \quad (14)$$

Untuk mendapatkan problem dual dari problem kita, kita jabarkan persamaan (14), sebagai berikut:

$$J(w, b, \alpha) = \frac{1}{2} w^T w - \sum_{i=1}^l \alpha_i y_i W^T X_i - b \sum_{i=1}^l \alpha_i y_i + \sum_{i=1}^l \alpha_i \quad (15)$$

Menurut kondisi optimalitas ke dua dalam (14), term ketiga sisi sebelah kanan dalam persamaan di atas sama dengan 0. Dengan memakai nilai-nilai W di (2.5), kita dapatkan

$$w^T w = \sum_{i=1}^l \alpha_i y_i w^T x_i \sum_{j=1}^l \alpha_j y_j x_j^T x_i \quad (16)$$

Maka persamaan (15) menjadi

$$Q(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l y_i y_j \alpha_i \alpha_j x_i^T x_j \quad (17)$$

Selanjutnya kita dapatkan formulasi dual dari problem (10):

$$\max \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l y_i y_j \alpha_i \alpha_j x_i^T x_j \quad (18)$$

Subject to

$$\sum_{i=1}^l \alpha_i y_i = 0$$

$$0 \leq \alpha_i = i = 1, \dots, l$$

dimana k adalah fungsi kernel yang dijelaskan dalam bagian (12) formulasi (17) adalah *Quadratic Programming* (QP) dengan pembatas (Constraint) linear. Melatih SVM ekuivalen dengan menyelesaikan problem *convex optimization*. Karena itu solusi dari SVM adalah unik (dengan asumsi bahwa k adalah *positively definite*) dan global optimal.

Untuk mengukur seberapa baik model yang digunakan, maka dilakukan penghitungan seberapa besar nilai *error* yang ada pada data tersebut dengan rumus sebagai berikut:

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (19)$$

Setelah dihitung MSE, maka langkah selanjutnya adalah menghitung RMSE, dengan rumus sebagai berikut:

$$RMSE = \sqrt{MSE} \quad (20)$$

Metode Kernel

Banyak teknik data mining atau machine learning yang dikembangkan dengan asumsi kelinearan. Sehingga algoritma yang dihasilkan terbatas untuk kasus-kasus yang linear. Karena itu, bila suatu kasus klasifikasi memperlihatkan ketidaklinearan, algoritma perceptron tidak bisa mengatasinya. Secara umum, kasus-kasus di dunia nyata adalah kasus yang tidak linear salah satu cara untuk mengatasinya adalah dengan metode kernel. Dengan metode kernel suatu data x di input space dimapping ke feature space F dengan dimensi yang lebih tinggi melalui map ϕ sebagai berikut $\phi: x \rightarrow \phi(x)$. Karena itu data x di input space menjadi $\phi(x)$ di feature space. Sering kali fungsi $\phi(x)$ tidak tersedia atau tidak bisa dihitung. Tetapi *dot product* dari dua vektor dapat dihitung baik dalam input space maupun di *feature space*.

Fungsi kernel yang biasa digunakan dalam literatur SVM:

Linear : $x^T x$


Polynomial : $(x^T x + 1)^p$

Radial basis function:

$$(RBF): \exp\left(-\frac{1}{2\sigma^2} \|x - x_i\|^2\right)$$

Tangen hyperbole (sigmoid): $\tanh((\beta x^T x_i + \beta_1))$ dimana $\beta, \beta_1 \in \mathbb{R}$

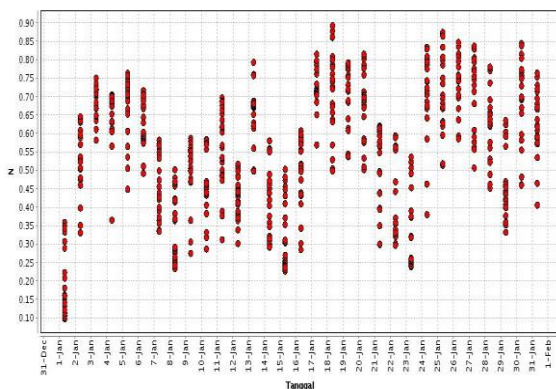
Fungsi kernel mana yang harus digunakan untuk substitusi *dot product* di *feature space* sangat bergantung pada data. Pada Persiapan data awal, data set yang digunakan adalah data per-30 menit, kemudian pada data set tersebut dilakukan transform dengan sigmoid biner sehingga pada data set yang akan diolah berada pada range [0,1..0,9].



Sumber: Apriana & Handayani (2017)

Gambar 1. Data kemampuan beban sistem harian per-30 menit pada bulan Januari

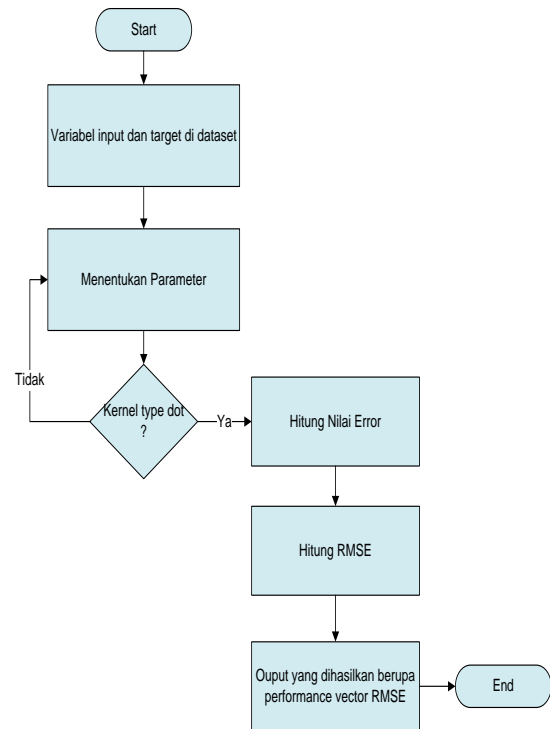
Pada Gambar 1 menunjukkan data beban sistem harian per-30 menit pada salah satu atribut yang ada data kemampuan beban sistem harian yaitu atribut X1, titik yang paling atas menunjukkan beban puncak listrik pada setiap harinya.



Sumber: Apriana & Handayani (2017)

Gambar 2. Data target prediksi beban listrik

Pada Gambar 2 menunjukkan data target prediksi beban listrik berdasarkan data kemampuan beban sistem harian per-30 menit.




Sumber: Apriana & Handayani (2017)
Gambar 3. Metode yang diusulkan

Gambar 3 menggambarkan metode yang diusulkan dalam penelitian ini metode *Support Vector Machines* dengan parameter yang digunakan adalah *kernel type* dengan *range dot* sampai didapatkan hasil berupa model yang digunakan untuk memprediksi beban listrik jangka pendek.

Kemudian berdasarkan data tersebut, untuk menjawab permasalahan yang telah diuraikan diatas maka, dilakukan pegujian data set dengan dua metode yaitu *Neural Network* dengan algoritma *backpropagation* yang meliputi 3 fase maju, fase mundur dan fase perbaikan bobot dan bias. Dan metode *Support Vector Machines* dengan parameter yang digunakan adalah *kernel type* dengan *range dot*.

HASIL DAN PEMBAHASAN

Hasil eksperimen dengan *Neural Network* dengan indikator yang ada dan data set dengan variabel x1-x12 dan target sebagai label. Dalam pengujian dengan metode ini, setiap indikator yang ada diolah kembali untuk mendapatkan hasil *RMSE* dengan nilai terendah. Hasil akhir pada *Neural Network* didapat arsitektur jaringan terbaik yaitu dengan *RMSE* yang dihasilkan 0.035.



Sumber: Apriana & Handayani (2017)

Gambar 4 Arsitektur Jaringan yang didapat dari Hasil Eksperimen

Dengan parameter yang digunakan yaitu :

<i>Training cycles</i>	: 100
<i>Learning rate</i>	: 0.1
<i>Momentum</i>	: 0.4
Jumlah <i>Hidden layer</i>	: 1
<i>Size hidden layer</i>	: 3

Hasil eksperimen dengan *Support Vector Machine* dengan parameter *kernel type* dengan *range dot* dan data set dengan variabel x_1 - x_{12} dan target sebagai label, berikut penentuan parameternya:

Tabel 1. Parameter *Support Vector Machine* hasil eksperimen

Nilai Parameter C	RMSE
0.001	0.041
0.005	0.035
0.01	0.035
0.02	0.034
0.1	0.034
0.5	0.034
1.0	0.035
2.0	0.035
10	0.041
100	0.049

Sumber: Apriana & Handayani (2017)

KESIMPULAN

Berdasarkan hasil ujicoba dan analisis prediksi beban listrik menggunakan metode *Neural Network* dan metode *Support Vector Machine* dapat disimpulkan bahwa pengujian dengan *Neural Network* yaitu menghasilkan *RMSE* 0.035

dan hasil pengujian dengan menggunakan metode *Support Vector Machine (SVM)* didapatkan *RMSE* terendah yaitu 0.034.

Dengan demikian dari hasil pengujian dapat disimpulkan bahwa *Support Vector Machine (SVM)* memberikan pemecahan untuk prediksi beban listrik jangka pendek lebih akurat jika dibandingkan dengan *Neural Network*.

REFERENSI

- Adepoju, A, G. Ogunjuyigbe, A, O, S. Alawode, O, K.** 2007. *Application of Neural Network to Load Forecasting in Nigerian Electrical Power System.*The Pacific Journal of Science and Technology.8(1): 68-72.
- Apriana, V., & Handayani, R. I.** (2017). Laporan Kemajuan PDP 2017-Analisis Algoritma Prediksi Untuk Menghasilkan Prediksi Beban Listrik Jangka Pendek. Jakarta: AMIK BSI Jakarta
- Hayati, Mohsen & Shirvany, Yazdan.** (2007). *Artificial Neural Network Approach for Short Term Load Forecasting for Illam Region.* World Academy of Science, Engineering and Technology. 28.
- Liao, Warren. T. & Triantaphyllou, Evangelos.** (2007). *Recent Advances in Data Mining of Enterprise Data: Algorithms and Applications.* Series : Computer and Operation Research.
- Marsudi, Djiteng.** (2006). Operasi Sistem Tenaga Listrik. Yogyakarta: Graha Ilmu.
- Myatt, Glenn J.** (3rd ed). (2007). *Making Sense of Data: A Practical Guide to Exploratory Data Analysis and Data Mining.* New Jersey: John Wiley & Sons, Inc. Mitchell, T.R., & Larson, J.R. (1987). *People in organizations: An Introduction to organizational behavior.* New York: McGraw-Hill.
- Santosa, Budi.** (2007). Data mining Teknik Pemanfaatan Data untuk Keperluan Bisnis. Yogyakarta: Graha Ilmu.
- Witten, H, Ian & Frank, Eibe.** (2nded). (2005). *Data Mining Practical Machine Learning Tools and Techniques.* San Francisco: Morgan Kaufmann.