

PREDIKSI THD TEGANGAN SISTEM TENAGA LISTRIK MENGGUNAKAN SUPPORT VECTOR MACHINE DENGAN FUNGSI KERNEL GAUSSIAN RBF

Luqman Assaffat

Universitas Muhammadiyah Semarang

assaffat@unimus.ac.id

ABSTRACT

The voltage wave distortion that occurs in the electric power system will adversely affect the operation of the power system and provide an adverse effect on the loads using the voltage. The voltage wave distortion is measured by the amount of harmonic distortion (Total Harmonics Distortion of Voltage, THD V). The level of THD V in the electric power system should always be monitored in order to anticipate the adverse effects. One method of monitoring the harmonic level is by predicting THD V. This research produces a prediction system of voltage harmonics in power system using Support Vector Machine with Gaussian Kernel RBF function. SVM is an intelligent machine system that has been proven superior when applied as a prediction method. This study uses three schemes in testing SVM system, they are the use of one variable as SVM training data, two variables as SVM training data, and three variables as SVM training data. The best result obtained in this research is when the prediction system of THD V using SVM is given train data with one variable that is past THD V variable, which yield MAPE 3,25%.

Keywords : *Forecasting, Harmonics, THD V, SVM, Gaussian RBF*

1. Pendahuluan

Harmonisa menjadi hal yang penting dalam sistem tenaga listrik pada masa sekarang, dan telah menjadi salah satu parameter kualitas daya listrik yang paling penting. Penilaian yang akurat terhadap harmonisa merupakan kebutuhan yang paling mendasar dalam bidang analisis harmonisa karena hal ini menjadi dasar untuk analisis masalah yang terkait harmonisa lainnya, seperti pemantauan harmonisa, identifikasi sumber harmonisa, desain dan operasi dari mitigasi rangkaian harmonisa, harmonisa metering, dan realisasi tarif (Rayakwar, 2014).

Peningkatan penggunaan beban nonlinear dalam industri dalam beberapa tahun terakhir mengakibatkan peningkatan langsung distorsi harmonisa pada sistem tenaga listrik. Beban non linear yang menghasilkan gelombang arus non sinusoidal berpotensi memiliki efek yang merugikan pada sistem tenaga listrik (Mazumdar dkk, 2006). Polusi harmonisa telah menjadi kekhawatiran para insinyur listrik karena adanya peningkatan penetrasi beban elektronika daya di jaringan utilitas sehingga pemantauan harmonisa di dalam sistem tenaga listrik menjadi sangat penting (Rayakwar, 2014).

Pemantauan harmonisa pada suatu sistem tenaga listrik dapat dilakukan dengan cara

pengukuran THD (*Total Harmonic Distortion*) tegangan maupun arus listrik pada PCC atau pada beban yang terindikasi menghasilkan harmonisa tinggi (Dugan, 1996). Metode pemantauan ini mempunyai kendala dalam prakteknya karena tidak banyak pengguna akhir yang memiliki alat ukur harmonisa karena harga peralatan tersebut relatif mahal.


Salah satu metode alternatif untuk pemantauan tingkat harmonisa sistem tenaga listrik adalah dengan cara melakukan prediksi THD (*Total Harmonic Distortion*). Sejumlah penelitian tentang prediksi harmonisa dan pengolahan sinyal secara intensif telah dilakukan. Teknik kecerdasan buatan telah diterapkan dalam usaha untuk mencapai akurasi yang tinggi dan beban komputasi yang rendah.

Metode kecerdasan buatan yang sering digunakan dan terkenal yaitu metode jaringan syaraf tiruan (*Artificial Neural Network*, ANN), sedangkan metode kecerdasan buatan yang relatif baru yaitu metode *Support Vector Machine* (SVM). SVM merupakan salah satu algoritma *machine learning* yang paling populer untuk klasifikasi dan regresi. Berdasarkan latar belakang tersebut, penelitian ini bertujuan membuat sistem prediksi tingkat distorsi harmonisa sistem tenaga listrik

menggunakan *Support Vector Machine* dengan fungsi Kernel Gaussian RBF (assaffat, 2015)

2. Harmonisa

Harmonisa adalah bentuk tegangan atau arus listrik yang memiliki frekuensi ganda, di mana frekuensi tersebut merupakan kelipatan bilangan bulat dari frekuensi dasar. Frekuensi dasar suatu sistem biasanya dirancang untuk beroperasi pada 50 atau 60 Hz, di Indonesia frekuensi dasar yang digunakan adalah 50 Hz. Bentuk gelombang yang terdistorsi dapat didekomposisi menjadi jumlah dari frekuensi dasar dan frekuensi harmonisa. Distorsi harmonisa berasal dari peralatan yang mempunyai karakteristik nonlinier dan beban pada sistem tenaga listrik (Assaffat, 2011).



Gambar 1. Gelombang Terdistorsi

Gambar 1 memperlihatkan bahwa setiap periodik, bentuk gelombang terdistorsi adalah penjumlahan dari beberapa gelombang sinusoidal dengan variasi frekuensi yang berbeda. Gelombang sinusoidal yang mempunyai frekuensi berbeda tersebut merupakan hasil kelipatan bilangan bulat dengan frekuensi dasarnya (Dugan, 2006)

3. THD Tegangan

Total Harmonics Distortion (THD) adalah suatu kuantitas dari tingkat distorsi harmonisa pada suatu sistem tenaga listrik. THD Tegangan adalah ukuran dari nilai efektif komponen-komponen harmonisa dari sebuah gelombang tegangan terdistorsi. THD merupakan nilai potensial panas dari


harmonisa yang relatif terhadap nilai dasarnya. THD Tegangan atau THD V dapat dihitung :

$$THD_V = \frac{\sqrt{\sum_{h=2}^{h_{max}} V_h^2}}{V_1} \quad (1)$$

Dengan V_h adalah nilai rms komponen harmonisa h dari kuantitas V .

4. Support Vector Machines

Konsep SVM dapat dijelaskan secara sederhana sebagai usaha mencari *hyperplane* terbaik yang berfungsi sebagai pemisah dua buah kelas pada *input space*. Gambar 2a memperlihatkan beberapa pola yang merupakan anggota dari dua buah kelas : positif (dinotasikan dengan +1) dan negatif (dinotasikan dengan -1). Pola yang tergabung pada kelas negatif disimbolkan dengan kotak, sedangkan pola pada kelas positif, disimbolkan dengan lingkaran. Proses pembelajaran dalam problem klasifikasi diterjemahkan sebagai upaya menemukan garis (*hyperplane*) yang memisahkan antara kedua kelompok tersebut. Berbagai alternatif garis pemisah (*discrimination boundaries*) ditunjukkan pada Gambar 2a (Cristianni dkk, 2000).



Gambar 2– SVM Berusaha Menemukan Hyperplane Terbaik Yang Memisahkan Kedua Class Negatif Dan Positif

Hyperplane pemisah terbaik antara kedua class dapat ditemukan dengan mengukur *margin hyperplane* tersebut dan mencari titik maksimalnya. Margin merupakan jarak antara *hyperplane* tersebut dengan data terdekat dari masing-masing class. Subset data training set yang paling dekat ini disebut sebagai *support vector*. Garis solid pada Gambar 2b

menunjukkan *hyperplane* yang terbaik, yaitu yang terletak tepat pada tengah-tengah kedua kelas, sedangkan titik kotak dan lingkaran yang berada dalam lingkaran hitam merupakan *support vector*. Upaya mencari lokasi *hyperplane* optimal ini merupakan inti dari proses pembelajaran pada SVM.

Data yang tersedia dinotasikan sebagai $\vec{x}_i \in \mathbb{R}^d$ sedangkan label masing-masing dinotasikan $y_i \in \{-1, +1\}$ untuk $i = 1, 2, 3, \dots, l$ yang mana l merupakan banyaknya data. Diasumsikan kedua class -1 dan $+1$ dapat terpisah secara sempurna oleh *hyperplane* berdimensi d , yang didefinisikan :

$$\vec{w} \cdot \vec{x} + b = 0 \quad (2)$$

Sebuah pola \vec{x}_i yang termasuk kelas -1 (sampel negatif) dapat dirumuskan sebagai pola yang memenuhi pertidaksamaan :

$$\vec{w} \cdot \vec{x}_i + b \leq -1 \quad (3)$$

Sebuah pola \vec{x}_i yang termasuk kelas $+1$ (sampel positif) dapat dirumuskan sebagai pola yang memenuhi pertidaksamaan :

$$\vec{w} \cdot \vec{x}_i + b \geq -1 \quad (4)$$

Margin terbesar dapat ditemukan dengan memaksimalkan nilai jarak antara *hyperplane* dan titik terdekatnya, yaitu $1/\|\vec{w}\|$. Hal ini dapat dirumuskan sebagai *Quadratic Programming* (QP) problem, yaitu mencari titik minimal persamaan (5), dengan memperhatikan *constraint* persamaan (6).

$$\min \tau(w) = \frac{1}{2} \|\vec{w}\|^2 \quad (5)$$

$$y_i(\vec{x}_i \cdot \vec{w} + b) - 1 \geq 0, \forall i \quad (6)$$

Problem ini dapat dipecahkan dengan berbagai teknik komputasi, di antaranya *Lagrange multiplier* sebagaimana ditunjukkan pada persamaan (7).

$$L(\vec{w}, b, \alpha) = \frac{1}{2} \|\vec{w}\|^2 - \sum_{i=1}^l \alpha_i (y_i((\vec{x}_i \cdot \vec{w}) + b) - 1); i = 1, 2, \dots, l \quad (7)$$

α_i merupakan *Lagrange multipliers*, yang bernilai nol atau positif $\alpha_i \geq 0$. Nilai optimal dari persamaan (7) dapat dihitung dengan meminimalkan L terhadap \vec{w} dan b , dan memaksimalkan L terhadap α_i . Dengan memperhatikan sifat bahwa pada titik optimal gradient $L=0$, persamaan (7) dapat dimodifikasi sebagai maksimalisasi problem yang hanya mengandung saja α_i , sesuai persamaan (8).

Maximize :

$$\sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j \vec{x}_i \cdot \vec{x}_j \quad (8)$$

$$\alpha_i \geq 0 (i = 1, 2, \dots, l), \sum_{i=1}^l \alpha_i y_i = 0 \quad (9)$$

Dari hasil dari perhitungan ini diperoleh α_i yang kebanyakan bernilai positif. Data yang berkorelasi dengan α_i yang positif inilah yang disebut sebagai *support vector*.


5. Kernel Trick Dan Non Linear Classification Pada SVM

Pada umumnya masalah dalam domain dunia nyata (*real world problem*) jarang yang bersifat *linear separable* dan kebanyakan bersifat *non linear*. Untuk menyelesaikan permasalahan *non linear*, SVM dimodifikasi dengan memasukkan fungsi Kernel. Dalam *non linear SVM*, pertama-tama data \vec{x} dipetakan oleh fungsi $\Phi(\vec{x})$ ke ruang vektor yang berdimensi lebih tinggi. Pada ruang vektor yang baru ini, *hyperplane* yang memisahkan kedua kelas 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, di mana pola-pola tersebut pada probabilitas tinggi dapat dipisahkan secara linear" (Vapnik, 1999).

Ilustrasi dari konsep ini dapat dilihat pada gambar 3. Pada gambar 3a diperlihatkan data pada kelas kuning dan data pada kelas merah yang berada pada *input space* berdimensi dua tidak dapat dipisahkan secara linear. Selanjutnya gambar 3b menunjukkan bahwa

fungsi Φ memetakan tiap data pada *input space* tersebut ke ruang vektor baru yang berdimensi lebih tinggi (dimensi 3), di mana kedua kelas dapat dipisahkan secara linear oleh sebuah *hyperplane*. Notasi matematika dari pemetaan ini sebagai berikut :

$$\Phi: \mathcal{R}^d \rightarrow \mathcal{R}^q \quad d < q \quad (10)$$



Gambar 3. Fungsi memetakan data ke ruang vektor

Pemetaan ini dilakukan dengan menjaga topologi data, dalam artian dua data yang berjarak dekat pada *input space* akan berjarak dekat juga pada *feature space*, sebaliknya dua data yang berjarak jauh pada *input space* akan juga berjarak jauh pada *feature space*.

Selanjutnya proses pembelajaran pada SVM dalam menemukan titik-titik *support vector*, hanya bergantung pada *dot product* dari data yang sudah ditransformasikan pada ruang baru yang berdimensi lebih tinggi, yaitu $\Phi(x_i) \cdot \Phi(x_j)$. Karena umumnya transformasi Φ ini tidak diketahui, dan sangat sulit untuk difahami secara mudah, maka perhitungan *dot product* tersebut sesuai teori Mercer dapat digantikan dengan fungsi Kernel $K(\vec{x}_i, \vec{x}_j)$ yang mendefinisikan secara implisit transformasi Φ . Hal ini disebut sebagai Kernel Trick, yang dirumuskan :

$$K(\vec{x}_i, \vec{x}_j) = \Phi(\vec{x}_i) \cdot \Phi(\vec{x}_j) \quad (11)$$

Kernel trick memberikan berbagai kemudahan, karena dalam proses pembelajaran SVM, untuk menentukan *support vector*, dan hanya cukup mengetahui fungsi kernel yang dipakai, dan tidak perlu mengetahui wujud dari fungsi *non linear* Φ . Selanjutnya hasil klasifikasi dari data \vec{x} diperoleh dari persamaan berikut :

$$f(\Phi(\vec{x})) = \vec{w} \cdot \Phi(\vec{x}) + b \quad (12)$$

$$f(\Phi(\vec{x})) = \sum_{i=1, \vec{x}_i \in SV}^n \alpha_i y_i \Phi(\vec{x}) \cdot \Phi(\vec{x}_i) + b \quad (13)$$

$$f(\Phi(\vec{x})) = \sum_{i=1, \vec{x}_i \in SV}^n \alpha_i y_i K(\vec{x}, \vec{x}_i) + b \quad (14)$$

SV pada persamaan di atas dimaksudkan dengan subset dari *training set* yang terpilih sebagai *support vector*, dengan kata lain data \vec{x}_i yang berkorespondensi pada $\alpha_i \geq 0$

6. Fungsi Kernel Gaussian RBF

Beberapa fungsi Kernel yang digunakan pada metode Support Vector Machine antara lain Linier, Polinomial, Gaussian RBF, Sigmoid (Tangen Hiperbolik), Invers MultiKuadratik, dan Additive. Kernel Gaussian RBF merupakan fungsi Kernel non-linear yang digunakan ketika data hanya dapat dipisahkan dengan garis lengkung atau sebuah bidang pada ruang dimensi tinggi. Fungsi Kernel Gaussian RBF didefinisikan sebagai berikut (Praseto, 2014) :

$$K(\vec{x}_i, \vec{x}_j) = \exp\left(-\frac{\|(\vec{x}_i, \vec{x}_j)\|^2}{2\sigma^2}\right) \quad (15)$$

7. Metode Penelitian

Objek dalam penelitian ini adalah prediksi harmonisa Tegangan (THD V) pada sistem tenaga listrik, sebagai indeks keakuratan metode prediksi menggunakan nilai persentase kesalahan absolut rata-rata (*Mean Absolute Error Percentage*, MAPE). Data penelitian yang dibutuhkan yaitu data tegangan listrik, data THD tegangan dan THD arus listrik sistem tenaga listrik. Objek pengukuran dan pengambilan data terletak pada transformator distribusi yang merupakan PCC dari sistem tenaga listrik dengan menggunakan *power quality meter*.

Alur metode SVM dalam prediksi THD V menggunakan fungsi Kernel Gaussian RBF diperlihatkan pada gambar 4.

Ukuran akurasi dari suatu metode prediksi dapat ditentukan dengan nilai kesalahan persentase absolut rata-rata (*Mean Absolute Percentage Error*, MAPE) (Mazumdar dkk, 2006) yaitu :

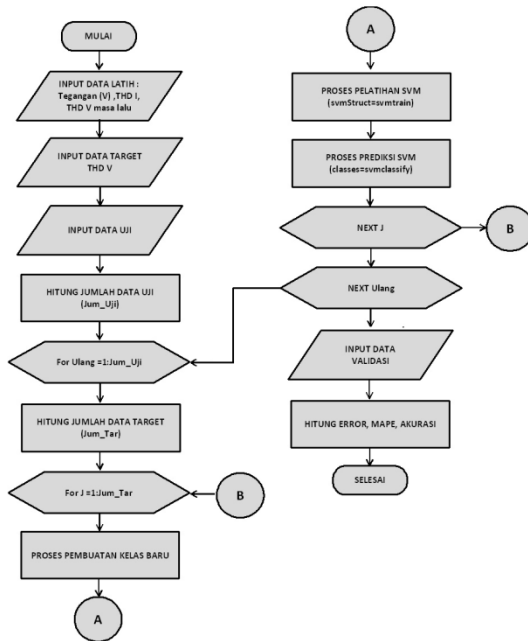
$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - f_i}{y_i} \right| \quad (16)$$

Keterangan :

N : jumlah data dalam periode prediksi

y_i : data aktual pada periode ke i

f_i : data prediksi pada periode ke i



Gambar 4. Alur metode SVM dalam prediksi THD V

Variabel bebas sebagai parameter prediksi THD Tegangan pada sistem tenaga listrik adalah : 1. Nilai THD V masa lalu sebagai data historis 2. Nilai THD I masa lalu, 3. Nilai Tegangan Fasa Netral. Semua data merupakan data primer yang di ukur menggunakan alat *power quality meter*. Data latih dan data target yang digunakan pada pelatihan SVM sebanyak 301 data, sedangkan data uji dan data validasi yang digunakan untuk menguji sistem sebanyak 60 data.

8. Hasil Penelitian

Sistem prediksi THD Tegangan menggunakan SVM ini diuji dengan beberapa skema. Pertama menggunakan sebuah data latih, yaitu variasi antara Tegangan (V), THD I dan THD V masa lalu. Skema kedua menggunakan 2 jenis data latih, yaitu kombinasi antara Tegangan (V) dengan THD I masa lalu, Tegangan (V) dengan THD V masa

lalu, serta THD I dan THD V masa lalu. Skema ketiga menggunakan 3 jenis data latih, yaitu Tegangan (V), THD I dan THD V. Semua skema pengujian dilakukan terhadap data pada saluran fasa A(R), fasa B (S) dan fasa (T). Hasil pengujian sistem adalah sebagai berikut.

A. Pengujian Dengan Satu Variabel Data Latih

Pengujian sistem prediksi menggunakan SVM dengan satu variabel data latih terdiri dari tiga skema, yaitu pengujian sistem dengan data latih variabel nilai tegangan fasa (V), THD I masa lalu, dan THD V masa lalu. Pengujian sistem prediksi SVM menggunakan data latih tegangan (V) untuk semua fasa dipergunakan pada Tabel 1. berikut :

Tabel 1. Hasil Pengujian dengan data latih nilai tegangan fasa (V)

Saluran Fasa	MAPE (%)	Akurasi (%)
FASA A	11,77	88,23
FASA B	18,41	81,59
FASA C	15,30	84,70

Tabel 1 memperlihatkan hasil bahwa dengan data nilai tegangan fasa sebagai data latih, sistem prediksi THD V menghasilkan MAPE terkecil 11,77% untuk data penelitian yang di ambil dari Fasa A.

Pengujian sistem prediksi SVM menggunakan satu variabel data latih, yaitu data THD I masa lalu menghasilkan MAPE terkecil 15,80% pada fasa C. Hal ini dipergunakan pada Tabel 2

Tabel 2. Hasil Pengujian dengan data latih nilai THD I masa lalu

Saluran Fasa	MAPE (%)	Akurasi (%)
FASA A	16,62	83,38
FASA B	19,16	80,84
FASA C	15,80	84,20

Pengujian sistem prediksi SVM menggunakan data latih THD V masa lalu untuk semua fasa diperlihatkan pada Tabel 3. berikut :

Tabel 3. Hasil Pengujian dengan data latih nilai THD V masa lalu

Saluran Fasa	MAPE (%)	Akurasi (%)
FASA A	3,25	96,75
FASA B	8,31	91,69
FASA C	3,25	96,75

Tabel 3 memperlihatkan hasil bahwa dengan data nilai THD V masa lalu sebagai data latih, sistem prediksi THD V menghasilkan MAPE terkecil 3,25% untuk data penelitian yang di ambil dari Fasa A dan Fasa C

B. Pengujian Dengan Dua Variabel Data Latih

Pengujian sistem prediksi menggunakan SVM dengan dua variabel data latih terdiri dari tiga skema, yaitu pengujian sistem dengan data latih variabel nilai tegangan fasa (V) dan THD I masa lalu, variabel nilai tegangan fasa (V) dan THD V masa lalu, serta variabel nilai THD I dan THD V masa lalu. Pengujian sistem prediksi SVM menggunakan data latih tegangan (V) dan THD I masa lalu untuk semua fasa diperlihatkan pada Tabel 4, dengan hasil pengujian MAPE terendah 8,89% yang didapatkan dengan data pada fasa C atau fasa T.

Tabel 4. Hasil Pengujian dengan data latih nilai tegangan fasa dan THD I masa lalu

Saluran Fasa	MAPE (%)	Akurasi (%)
FASA A	11,32	88,68
FASA B	17,74	82,56
FASA C	8,89	91,11

Pengujian sistem prediksi SVM menggunakan dua variabel data latih, yaitu

data tegangan fasa (V) dan THD V masa lalu menghasilkan MAPE terkecil 5,95% pada fasa A. Hal ini diperlihatkan pada Tabel 5

Tabel 5. Hasil Pengujian dengan data latih nilai tegangan fasa dan THD V masa lalu

Saluran Fasa	MAPE (%)	Akurasi (%)
FASA A	5,95	94,05
FASA B	8,35	91,65
FASA C	15,71	84,29

Pengujian sistem prediksi SVM menggunakan dua variabel data latih, yaitu data THD I dan THD V masa lalu menghasilkan MAPE terkecil 3,82% pada fasa A. Hal ini diperlihatkan pada Tabel 6

Tabel 6. Hasil Pengujian dengan data latih nilai THD I dan THD V masa lalu

Saluran Fasa	MAPE (%)	Akurasi (%)
FASA A	3,82	96,18
FASA B	6,48	93,52
FASA C	7,40	92,60

C. Pengujian Dengan Tiga Variabel Data Latih

Pengujian sistem prediksi menggunakan SVM dengan tiga variabel data latih terdiri hanya satu skema, yaitu data latih dengan variabel nilai tegangan fasa (V), THD I dan THD V masa lalu. Hasil terbaik yang didapatkan pada pengujian ini adalah MAPE 3,61% yang didapatkan pada pengujian dari data Fasa A. Hal ini diperlihakan pada Tabel 7.

Tabel 7. Hasil Pengujian dengan data latih nilai tegangan fasa (V), THD I dan THD V masa lalu

Saluran Fasa	MAPE (%)	Akurasi (%)
FASA A	3,61	96,39
FASA B	7,32	92,68

FASA C	3,89	96,11
--------	------	-------

melakukan penelitian melalui skema dana hibah penelitian dosen pemula (PDP tahun anggaran 2017).

9. Kesimpulan

Kesimpulan yang didapatkan dari hasil penelitian adalah bahwa Support Vector Machine dengan fungsi Kernel Gaussian RBF dapat digunakan untuk memprediksi Tingkat Harmonisa Tegangan THD V pada sistem tenaga listrik, dengan MAPE terbaik 3,25% atau AKURASI terbaik 96,75%. Akurasi terbaik ini didapatkan pada saat sistem di uji menggunakan satu variabel data latih menggunakan data THD V masa lalu.

10. Referensi

- Assaffat, L., 2011, Evaluasi Distorsi Harmonisa Tegangan Pada Sistem Tenaga Listrik Di Rumah Sakit Panti Wilasa Citarum Semarang, Media ElektriKa, Vol 4, No 2
- Assaffat, L., Adi, K., Widodo, A., 2015, Support Vector Machine Untuk Prakiraan Beban Listrik Harian Pada Sektor Industri, Tekno, Vol 24, No. 2
- Dugan, R. C., McGranaghan, M. F., Beaty, H. W., 1996, Electrical Power System Quality, McGraw-Hill Book Company, New York
- Mazumdar, J., Lambert, F. C., Venayagamoorthy, G. K., Harley, R. G., 2006, Predicting Load Harmonics in Three Phase Systems Using Neural Networks, Missouri University of Science and Technology Scholars' Mine Faculty Research & Creative Works
- Rayakwar, S. P., Burange, M. S., 2014, Adaptive Wavelet Neural Network a Efficient Technique for Estimating Low Order Dominant Harmonic, International Journal of Application or Innovation in Engineering & Management (IJAIEEM), Volume 3, Issue 2
- Vapnik, V.N., 1999, The Nature of Statistical Learning Theory 2nd edition, Springer-Verlag, New York Berlin Heidelberg

Ucapan Terimakasih

Penulis mengucapkan terimakasih kepada Kementerian Riset Teknologi dan Pendidikan Tinggi yang telah memberikan kesempatan