

SHORT TERM LOAD FORECASTING (STLF) MELALUI PENDEKATAN LOGIKA FUZZY

Ade Gafar Abdullah¹

ABSTRAK : Telah dikembangkan suatu model prediksi beban listrik jangka pendek (*short term load forecasting*) non linier berbasis kecerdasan tiruan melalui pendekatan logika *Fuzzy* dengan menggunakan algoritma *Fuzzy Subtractive Clustering*. Kode komputer yang dikembangkan menggunakan perangkat lunak Matlab 7.1 dari Mathwork Corp. Prakiraan beban listrik dengan menggunakan *fuzzy subtractive clustering* telah dihasilkan dimana prediksi dengan logika *fuzzy* lebih mendekati data aktualnya dan memberikan arti yang signifikan dibandingkan dengan metode koefisien beban PLN (PT. Perusahaan Listrik Negara). Melalui perhitungan secara statistik didapatkan tingkat akurasi rata-rata prediksi dengan menggunakan metode koefisien beban PLN sebesar 92,41% sedangkan tingkat akurasi rata-rata prediksi dengan menggunakan algoritma *fuzzy subtractive clustering* sebesar 95,79 %. Dapat dibuktikan dan disimpulkan dari hasil simulasi bahwa prediksi beban menggunakan pendekatan kecerdasan buatan memberikan hasil prediksi yang lebih akurat dibanding dengan metode konvensional yang selama ini digunakan PLN.

ABSTRACT : It has been developed a Short Term Load Forecasting (STLF) model of non linear electric load based on Artificial Intelligence using Fuzzy Subtractive Clustering Algorithm approach of Fuzzy Logic . The developed computer code applies software Matlab 7.1 of Mathwork Corp. Electric load forecasting using Fuzzy Subtractive Clustering has been yielded where forecasting with fuzzy logic is closer to its actual data and provides significant meaning than to load coefficient method of PLN. Statistically, it was obtained accurate level of prediction using coefficient method of PLN is 92,41%, meanwhile accurate level of prediction using fuzzy subtractive clustering algorithm is 95,79 %. It is found from simulation result that electric load forecasting using artificial intelligence approach provides more accurate result than conventional method during the time used by PLN.

Kata Kunci : Prediksi Beban Listrik Harian, *Fuzzy Subtractive Clustering*.

PENDAHULUAN

Energi listrik yang dibangkitkan (dihasilkan) tidak dapat disimpan, melainkan langsung habis digunakan oleh konsumen. Oleh karena itu, daya yang dibangkitkan harus selalu sama dengan daya yang digunakan oleh konsumen. Apabila pembangkitan daya tidak mencukupi kebutuhan konsumen, maka hal ini akan ditandai oleh turunnya frekuensi dalam sistem. Sebaliknya apabila pembangkitan daya lebih besar daripada kebutuhan konsumen, maka frekuensi sistem akan naik. Penyedia tenaga listrik, misalnya PLN, harus menyediakan tenaga listrik dengan frekuensi yang konstan, yaitu : 50 Hz atau 60 Hz dalam batas-batas penyimpangan yang masih diizinkan.

Karena kebutuhan daya oleh konsumen terus berubah sepanjang waktu, maka untuk mempertahankan frekuensi (agar tetap 50 Hz atau 60 Hz), daya yang dibangkitkan di pusat listrik harus diubah-ubah sepanjang waktu untuk menyesuaikan daya tersebut dengan kebutuhan konsumen agar frekuensi dapat konstan. Pengaturan tenaga listrik yang berubah-ubah untuk mengikuti perubahan kebutuhan daya dari konsumen memerlukan perencanaan operasi pembangkitan yang cukup rumit dan menyangkut biaya bahan bakar yang tidak kecil, diperlukan prediksi beban atau prediksi kebutuhan daya konsumen sebagai dasar perencanaan operasi.

Tidak ada rumus yang eksak untuk membuat perkiraan beban ini. Oleh karena itu, perlu ada teknik membuat perkiraan beban yang umumnya mengacu kepada statistik masa lalu dan atas dasar analisis karakteristik beban yang lalu.

Prediksi beban listrik jangka pendek adalah prediksi beban untuk jangka waktu beberapa jam sampai satu minggu. Prediksi beban jangka pendek ini digunakan untuk pengendalian dan penjadwalan sistem tenaga, juga sebagai masukan untuk studi aliran beban. Pada prediksi beban jangka pendek terdapat batas atas untuk beban maksimum dan batas bawah untuk beban minimum yang ditentukan oleh prediksi beban jangka menengah. Besarnya beban untuk setiap jam ditentukan dengan memperhatikan berbagai informasi yang dapat mempengaruhi besarnya beban sistem seperti acara televisi, cuaca dan suhu udara.

Dispatcher yang bertugas di Pusat Pembagi Beban PLN, bertugas menghitung dan mengestimasi beban per jam setiap hari, beban puncak harian hingga merencanakan pengeluaran beban pembangkitan harian atau mingguan. Data hasil prediksi beban digunakan berbagai keperluan diantaranya :

- Sistem koordinasi *hydro-thermal* untuk menentukan modus operasi biaya pembangkitan paling minimum.

¹ Ade Gafar Abdullah, S.Pd., M.Si. adalah dosen Jurusan Pendidikan Teknik Elektro UPI

- Unit *Commitment* : pemilihan generator yang beroperasi, start up/ shutdown generator untuk minimisasi biaya operasi.
- Pembebanan saluran transmisi.
- *Assesment* keamanan sistem tenaga listrik diantaranya untuk studi aliran daya dan studi stabilitas transien.

Beberapa metode prediksi beban jangka pendek :

- Expert Judgments yaitu mengandalkan pendapat para pakar untuk mengambil keputusan.
- Model Linier : misalnya dengan model regresi linier dan menggunakan pendekatan model deret waktu (*time series*).
- Model Non Linier : misalnya dengan menggunakan Jaringan Syaraf Tiruan, Pendekatan Logika *Fuzzy*, Regresi Non Linier, dan Bayesian Network.

Pada makalah ini akan dipaparkan metode prediksi beban listrik harian menggunakan model non linier melalui pendekatan logika *Fuzzy* dengan algoritma *Fuzzy Subtractive Clustering*.

FUZZY SUBTRACTIVE CLUSTERING

Cluster dikatakan *fuzzy* jika tiap-tiap objek dihubungkan dengan menggunakan derajat keanggotaan (bukan dengan keanggotaan *crisp*). Pada prakteknya, biasanya perlu dilakukan *preprocessing* terlebih dahulu. Akan tetapi lebih menguntungkan apabila data beban listrik yang akan diolah dalam keadaan normal, misalkan pada interval [0 1]. Dengan demikian perlu dilakukan normalisasi nilai u , menjadi \hat{u} normal (\hat{u}) dengan rumus :

$$\hat{u} = \frac{u - u_{\min}}{u_{\max} - u_{\min}} \quad \dots (1)$$

Dengan u_{\min} adalah nilai terkecil yang terukur dan u_{\max} adalah nilai terbesar yang terukur. Dengan melakukan standarisasi, dapat mentransformasikan nilai rata-rata (*mean*) tiap variabel menjadi nol, dan deviasi standar menjadi 1. Jika data distribusi normal dengan *mean* m dan deviasi standar σ , maka akan kita dapatkan nilai standar :

$$u^* = \frac{u - m}{\sigma} \quad \dots (2)$$

Perlu juga dilakukan penskalaan nilai pada interval tertentu. Apabila penskalaan dilakukan secara linier pada interval $[u_1, u_2]$, maka :

$$u' = \frac{u - u_1}{u_2 - u_1} (u_2 - u_1) + u_1 \quad \dots (3)$$

Subtractive clustering didasarkan atas ukuran densitas (potensi) titik-titik data dalam suatu ruang (variabel). Konsep dasar dari *subtractive clustering* adalah menentukan daerah-daerah dalam suatu variabel yang memiliki densitas tinggi terhadap titik-titik di

sekitarnya. Titik dengan jumlah tetangga terbanyak akan dipilih sebagai pusat *cluster* kemudian akan dikurangi densitasnya. Selanjutnya algoritma akan memilih titik lain yang memiliki tetangga terbanyak untuk dijadikan pusat *cluster* yang lain. Hal ini akan dilakukan berulang-ulang hingga semua titik diuji.

Apabila terdapat N buah data $:u_1, u_2, \dots, u_N$ dan dengan menganggap bahwa data-data sudah dalam keadaan normal, maka densitas titik dapat dihitung sebagai berikut :

$$D_k = \sum_{j=1}^N \exp \left(- \frac{\|u_k - u_j\|}{\left(\frac{r_a}{2}\right)^2} \right) \quad \dots (4)$$

Dengan r_a adalah konstanta positif. Dengan demikian, suatu titik data akan memiliki densitas yang besar jika dia memiliki banyak tetangga.

Setelah menghitung densitas tiap-tiap titik, maka titik dengan densitas tertinggi akan dipilih sebagai pusat *cluster*. Misalkan u_{c1} adalah titik yang dipilih terpilih sebagai pusat *cluster*, sedangkan d_{c1} adalah ukuran densitasnya. Selanjutnya densitas dari titik di sekitarnya akan dikurangi menjadi :

$$D'_k = D_k - D_{c1} * \exp \left(- \frac{\|u_k - u_{c1}\|}{\left(\frac{r_b}{2}\right)^2} \right) \quad \dots (5)$$


Dengan r_b adalah konstanta positif. Hal ini berarti bahwa titik-titik yang berada dekat dengan pusat *cluster* u_{c1} akan mengalami pengurangan densitas besar-besaran. Hal ini akan berakibat titik-titik tersebut akan sangat sulit untuk menjadi pusat *cluster* berikutnya. Nilai r_b menunjukkan suatu lingkungan yang mengakibatkan titik-titik berkurang densitasnya. r_b bernilai lebih besar dibanding dengan r_a . $r_b = \text{squash_factor} * r_a$ (biasanya *squash_factor* = 1.5) Setelah densitas tiap-tiap titik diperbaiki, maka selanjutnya akan dicari pusat *cluster* yang kedua yaitu u_{c2} . sesudah u_{c2} didapat, ukuran densitas setiap titik data akan diperbaiki kembali, demikian seterusnya.

HASIL DAN PEMBAHASAN

Pola kegiatan konsumen pada hari kerja yaitu hari Senin sampai hari Jumat dan hari akhir pekan, pada setiap minggunya tidak akan banyak berubah. Pola kegiatan konsumen akan berulang pada setiap minggunya. Pengulangan ini juga akan terjadi pada pola kurva beban dari minggu ke minggu, dimana hari yang sama pada suatu minggu mempunyai pola kurva beban yang mirip. Misalnya pola kurva beban hari Kamis dalam minggu ini akan mirip dengan pola kurva beban pada hari Kamis dalam minggu yang akan datang. Hal yang sama juga

terjadi pada hari-hari lain. Gambar 5.1. memperlihatkan pola kurva beban untuk hari Senin selama 10 minggu mulai dari tanggal 6 Maret 2006 sampai dengan 8 Mei 2008. Pengalaman praktis operator UPB PLN Cigereleng Bandung Jawa Barat menunjukkan bahwa beban listrik pada suatu hari dipengaruhi oleh beban pada hari-hari sebelumnya.

Pola Pengeluaran Beban Listrik Hari Senin (Selama 10 Minggu)







Gbr.1 Pola Pengeluaran Beban Listrik Harian

Data pengeluaran beban yang digunakan pada makalah ini menggunakan data selama 70 hari mulai tanggal 1 Maret 2006 sampai dengan 9 Mei 2006. Sesuai dengan karakteristik *Fuzzy Subtractive Clustering*, secara umum sistem prakiraan beban dalam penelitian ini terdiri dari dua mode, yaitu mode tahap belajar (*training*) dan mode tahap pengujian. Dalam mode ini diberikan data pola pelatihan yaitu pasangan masukan dan keluaran target yang disimpan dalam satu bentuk matriks ukuran 10 x 24 dalam format "Nama Hari.dat" (contoh : senin.dat, selasa.dat dsb).

Kode komputer yang digunakan untuk membuat rancangan awal model prediksi beban harian berbasis logika *fuzzy* dikembangkan dengan menggunakan bahasa pemrograman Matlab. Hasil running program mengeluarkan data prediksi beban dari jam 01.00-24.00 mulai dari data pelatihan dengan data pengujian, RMSE, Grafik hasil *clustering* dan grafik error prediksinya.

Tujuan dari simulasi perangkat lunak *fuzzy subtractive clustering* ini adalah untuk menentukan *influence range* dan jumlah *cluster(rule)* agar diperoleh suatu prediksi beban listrik harian dengan *error* minimum dan diperoleh secara tepat. Tabel 1 memperlihatkan hasil akhir yang diperoleh dengan percobaan beberapa nilai *influence range* dan menghasilkan *RMSE (Root Mean Square Error)* yang beragam. Penetapan nilai *influence range* (ra) yang tepat akan menentukan keakuratan hasil prediksi beban listrik. Hasil inferensi menunjukkan hubungan antara *influence range*, *RMSE* dan jumlah *cluster*. Apabila *influence range* semakin kecil, maka jumlah *cluster* yang dihasilkan akan lebih banyak, yang berarti tingkat keakuratan hasil penalaran juga akan semakin baik. Apabila jumlah *cluster* yang dihasilkan terlalu banyak justru akan menimbulkan adanya *redundancy* yang berakibat semakin bertambahnya beban komputasi.



Gbr.2 Grafik Hasil *Clustering* Data Pelatihan

KESIMPULAN

1. Metoda prediksi beban listrik yang selama ini digunakan PLN menggunakan metode konvensional melalui pendekatan statistik berbasis deret waktu (*times series*) yang diberi nama Metoda Koefisien Beban, ternyata dapat dikembangkan dengan melalui pendekatan model komputasi berbasis Kecerdasan Buatan (*Artificial Intelligence*) yang salah satunya menggunakan logika *fuzzy* dengan algoritma *Fuzzy Subtractive Clustering*.
2. Kelebihan Logika *Fuzzy* dengan algoritma *Fuzzy Subtractive Clustering* terletak pada kemampuan belajar yang dimilikinya. Dengan kemampuan tersebut pengguna tidak perlu merumuskan kaidah atau fungsinya. Dengan demikian logika *fuzzy* mampu digunakan untuk menyelesaikan masalah yang rumit dan atau masalah yang terdapat kaidah atau fungsi yang tidak diketahui (seperti prakiraan beban listrik).
3. Hasil prakiraan beban listrik dengan menggunakan *fuzzy subtractive clustering* telah dihasilkan dimana prediksi dengan logika *fuzzy* lebih mendekati data aktualnya dan memberikan arti yang signifikan dibandingkan dengan metode koefisien beban PLN. Melalui perhitungan secara statistik didapatkan tingkat akurasi rata-rata prediksi dengan menggunakan metode koefisien beban PLN sebesar 92,41% sedangkan tingkat akurasi rata-rata prediksi dengan menggunakan algoritma *fuzzy subtractive clustering* sebesar 95,79 %. Sehingga dapat dibuktikan bahwa hasil simulasi menyimpulkan bahwa prediksi beban menggunakan pendekatan kecerdasan buatan memberikan hasil prediksi yang lebih akurat dibanding dengan metode konvensional yang selama ini digunakan PLN.

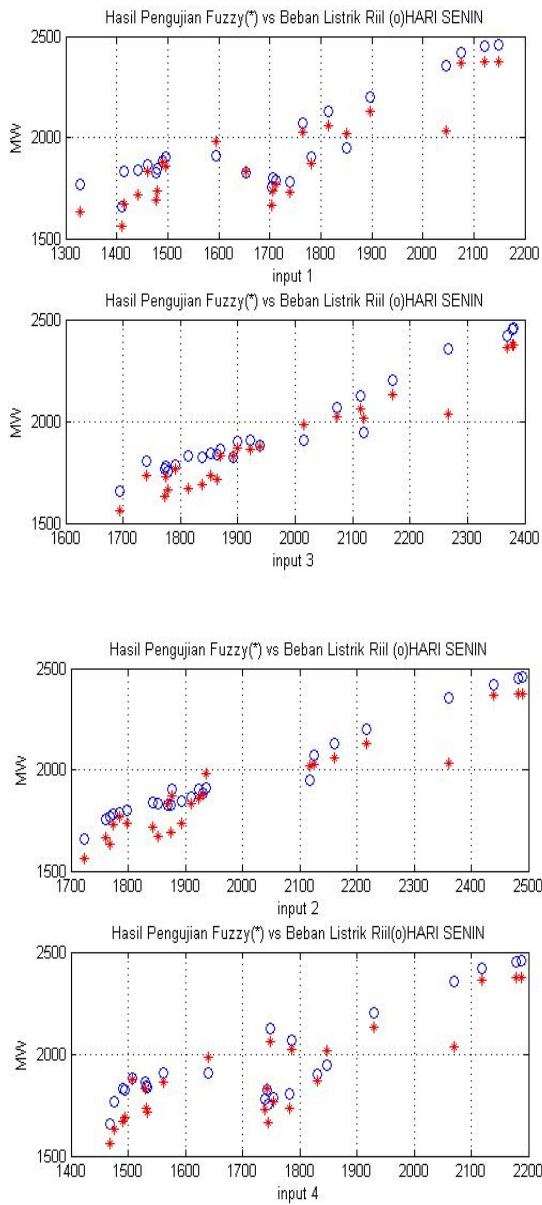
DAFTAR PUSTAKA

A. Bakirtzis, S. Kiartzis, V. Petridis and Ath. Kehagias (1997) :”Short Term Load Forecasting using a Bayesian Combination Method”, International Journal of Electrical Power and Energy Systems, Vol. 19, pp.171-177.

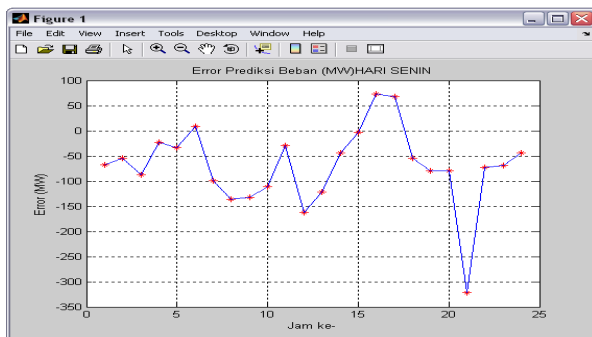
A.D.P.Lotufu dan C. R. Minussi (1999) “Electric Power Systems Load Forecasting: A Survey”, Paper BPT99-028-25 accepted for presentation at the IEEE Power Tech '99 Conference, Budapest, Hungary.

A. Sfetos(2003), “Short-term Load Forecasting with a Hybrid clustering algorithm” *IEEE Proc.- Gener, Transm. Dsitrib.*, Greece, vol.150, pp. 257-262.

Azzam Ul ASAR, Syed Riaz ul HASSNAIN dan Amjad Ullah KHATTACK (2005), “A Multi-Agent Approach To Short Term Load Forecasting Problem, International Journal of Inteligent



Gbr. 3 Grafik Hasil Clustering Data Pengujian



Gbr. 4 Grafik Error Prediksi

- Control and Systems”, Vol 10, No 1, March 2005, p 55-59
- Box, G.G. Jenkins, G.M., Holde n-day (1976), “*Time series analysis- forecasting and control*”, San Francisco.
- Drezga, S. Rehman (1999), “STLF with Local ANN Predictors”, *IEEE Transactions on Power Systems*, Vol 14, No 3.
- Dipti Srinivasan, Swee Sien Ten and C S.Chang (1999), “Parallel Neural Network –Fuzzy expert system strategy for STLF: System implementation and performance evaluation”, *IEEE Transactions on Power Systems*, vol 14, pp. 1100–1106.
- Du Tao and Wang Xiuli (2002), “Combined model of wavelet and NN for STLF”, *Proceedings of IEEE International Conference on Power System Technology*, vol. 4, pp. 2331-2335.
- Kun-Long Ho, Yuan-Yih Hsu, Chien –Cluen Yang (1992), “Short term load forecasting using multiplayer neural network with an adaptive learning algorithm”, *IEEE Trans. On power systems*, Vol.7,No.1.
- Kwang –Ho Kim , Hyoung Sun Youn and Yong Cheol kang (2000), “ STLF for Special Days in Anomalous Load Conditions Using Neural Networks and Fuzzy Inference Method”. *IEEE Transactions on Power Systems*, vol. 15, pp. 559-565.
- L. C. Jain and N. M. Martin (1999), “*Fusion of neural networks, fuzzy sets, and genetic algorithms: Industrial applications*”, CRC Press.
- L. Rutkowski (2004), “*Flexible neuro-Fuzzy systems*”, Kluwer Academic Publishers.
- Muhammad Riaz Khan dan Ajith Abraham (2002) “Short Term Load Forecasting Models in Czech Republic Using Soft Computing Paradigms”, Department of Computer Science, Oklahoma State University, Tulsa.
- Ma-WenXiao, Bai-XiaoMin and Mu-LianShun (2002), “Short-term Load Forecasting With Artificial Neural Network and Fuzzy Logic”, *Proceedings of the IEEE international Conference on Power System Technology*, vol.2, pp.1101-1104, Oct.
- M.A. Abu El Magd and R.D. Findlay(2003), “New approach using ANN and Time Series Models for STLF”, *IEEE Canadian Conference on elect. and Comp. Engg.*, Canada, vol.3, pp. 1723-1726,
- P. Stavroulakis (2004), “*Neuro-Fuzzy and Fuzzy Neural Applications in telecommunications*”, Springer-Verlag.
- P.K Dash , S. Dash dan S.Rahman (1993) “A Fuzzy Adaptive Correction Scheme For Short Term Load Forecasting Using Fuzzy Layered Neural Network”, IEEE, pp 132-147.
- P.K.Dash , H.P.Satpathy dan S.Rahman (1995) “Short Term Daily Average and Peak Load Predications Using A Hybrid Intelligent Approach”, IEEE, pp 565-570
- R. Khosla and T. Dillon (1997), “*Engineering Intelligent Hybrid Multi-agent Systems*”, Kluwer Academic Publishers.
- Stefan E Karman and Evileno Jgonzalus(1997), “*STLF using Fuzzy Artmap N N*”. University of Central Florida.
- S.H. Ling, H.K. Lam, F.H.F. Leung and P.K.S.Tam (2002), “A Novel GA- Based Neural Network For Short-term Load Forecasting”, *Proceedings of the IEEE Joint international Conference on Neural Networks*, Honolulu, HI, USA, vol.3, pp. 2761-2766.
- S.H. Ling, H.K. Lam, F.H.F. Leung and P.K.S. Tam (2001), “Neural Fuzzy network with optimal Number of rules for STLF in Intelligent Home” *IEEE International Conference on Fuzzy Systems*.

Tabel 1. Hasil Perhitungan dengan *Influence Range* Secara *Random*

SENIN									
Performance	Influence Range ra								
Measure	0.06	0.07	0.08	0.09	0.1	0.9	0.92	0.94	0.95
RMSE	104.1519	187.0798	213.0082	218.5220	221.5825	282.885	288.2312	292.3937	294.0910
Accuracy(%)	95.56	91.77	90.60	90.35	90.2	84.83	84.48	84.2	84.09
SELASA									
Performance	Influence Range ra								
Measure	0.06	0.07	0.08	0.09	0.1	0.9	0.92	0.94	0.95
RMSE	109.0116	109.2133	117.9961	119.5989	107.9621	208.3200	207.7263	207.1171	202.7223
Accuracy(%)	95.02	95.02	94.50	94.42	95.10	90.07	90.10	90.14	90.25
RABU									
Performance	Influence Range ra								
Measure	0.02	0.03	0.04	0.05	0.07	0.08	0.09	0.1	0.12
RMSE	228.1349	114.4418	114.3717	113.6423	125.9994	160.4383	215.7097	416.9488	363.3094
Accuracy(%)	93.70	94.80	94.80	94.92	94.03	92.63	90.83	89.30	85.58
KAMIS									
Performance	Influence Range ra								
Measure	0.03	0.05	0.07	0.1	0.13	0.15	0.17	0.19	0.2
RMSE	66.1613	67.1466	65.2073	71.4601	106.3173	139.8192	130.9508	377.0406	334.4535
Accuracy(%)	97.10	97.06	97.13	96.92	95.62	94.35	94.55	81.41	84.35
JUMAT									
Performance	Influence Range ra								
Measure	0.03	0.05	0.07	0.08	0.09	0.1	0.11	0.12	0.13
RMSE	145.5767	180.9148	167.1672	162.1107	161.9984	161.491	160.8815	169.6222	241.3381
Accuracy(%)	94.51	93.50	93.99	94.33	94.31	94.31	94.31	93.61	93.30
SABTU									
Performance	Influence Range ra								
Measure	0.03	0.05	0.07	0.1	0.11	0.88	0.9	0.95	0.98
RMSE	128.8645	128.9292	128.8484	129.6685	128.1449	381.3581	371.0230	366.9604	386.1696
Accuracy(%)	96.28	96.27	96.27	96.24	96.54	83.28	83.95	84.22	83.15
MINGGU									
Performance	Influence Range ra								
Measure	0.03	0.05	0.07	0.09	0.1	0.11	0.12	0.13	0.15
RMSE	66.5791	67.1354	68.8950	70.6041	83.7776	73.2725	73.9363	73.6382	133.0127
Accuracy(%)	96.80	96.74	96.65	96.53	96.05	96.43	96.44	96.47	93.48