

PREDIKSI BEBAN LISTRIK JANGKA PENDEK BERBASIS BACKWARD ELIMINATION

Veti Apriana

Manajemen Informatika, AMIK BSI Jakarta
Jl. RS. Fatmawati No. 24 Pondok Labu Jakarta Selatan
veti.vta@bsi.ac.id

ABSTRACT

Short-term electrical load prediction is one way that can be used to generate and distribute electrical energy economically, so that the provider can determine the load and power demand for some time to come. Many researchers who examined the short-term electric load by the method of Neural Network. However, the use of the data set that a lot of the neural network can result in an excessive number of neurons so that can cause over generalizes phenomenon, so that the necessary process of feature selection to reduce attributes in the data set that much. This research begins with the ability to process data loads daily system time series per-30 minutes. The method used is Neural Network based on Backward Elimination with the input data used is the data in January 2012. Several experiments were conducted to obtain the optimal architecture and generate accurate predictions. The results showed an experiment with Neural Network-based methods Backward Elimination produces a lower RMSE is 0,018 compared to RMSE produced by the method of Neural Network is 0,035.

Kata Kunci: *Electrical load, Neural Network, Backward Elimination.*

I. 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.

Peramalan beban adalah proses sentral dan integral dalam perencanaan dan operasi penggunaan listrik (Alfarez & Nazeeruddin, 2002). Oleh karena itu, Perusahaan Listrik Negara (PT. PLN (PERSERO) P3B Jawa-Bali) mengadakan peramalan beban listrik jauh sebelum waktunya *Neural Network* (NN) adalah teknik peramalan yang paling umum digunakan, karena NN bisa cepat dan akurat, banyak peneliti menggunakan NN untuk memecahkan masalah peramalan (Liao, 2007). Kekurangan *Neural Network* (NN) yaitu generalisasi yang berlebihan terjadi ketika *Neural Network*, dengan algoritma pelatihan, mulai meniru fungsi yang sangat kompleks di

tempat yang sederhana (Shukla, Tiwari& Kala, 2010).

Feature Selection adalah untuk mengidentifikasi fitur dalam kumpulan data yang sama pentingnya, dan membuang semua fitur lain seperti informasi yang tidak relevan dan berlebihan. *Feature selection* adalah salah satu faktor yang paling penting yang dapat mempengaruhi tingkat akurasi klasifikasi (Yuanning Liu, Gang Wang, Huiling Chen, Hao Dong, Xiaodong Zhu & Sujing Wang, 2011).

Permasalahan yang muncul berdasarkan uraian diatas yaitu penggunaan data set yang banyak pada *neural network* dapat berakibat pada jumlah *neuron* yang berlebihan sehingga dapat menyebabkan terjadinya fenomena overgeneralisasi (generalisasi yang berlebihan) (Shukla, Tiwari& Kala, 2010). Diperlukan proses *feature selection* untuk mengurangi atribut pada data set yang banyak. Menerapkan *backward elimination* sebagai *feature selection* untuk meningkatkan keakuratan dalam prediksi beban listrik jangka pendek dengan menggunakan algoritma *neural network*.

II. TINJAUAN PUSTAKA

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 Quantum Genetic Algorithm (QGA). Komparasi Fuzzy Neural Networks (FNN) dengan Quantum Genetic Algorithm (QGA). Hasil komparasi kedua metode mendapatkan *rate ranging* 6.2 % sampai 43.4%.

2.1. Prediksi Beban Listrik

Peramalan beban adalah proses sentral dan integral dalam perencanaan dan operasi utilitas listrik (Alfarez & Nazeeruddin, 2002).

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.

2.2. 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

masukannya 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, 2010):

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:

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

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

$$Output = \frac{1}{1 + e^{-Input}}$$

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

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

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

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

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

$$w_{ij} = w_{ij} + l \cdot Error_j \cdot Output_i$$

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

$$RMSE = \sqrt{\frac{SSE}{N \cdot K}}$$

2.3. Metode *Feature Selection*

Feature Selection adalah masalah berkaitan erat dengan pengurangan dimensi. Tujuan *Feature Selection* adalah untuk mengidentifikasi fitur dalam kumpulan data yang sama pentingnya, dan membuang semua fitur lain seperti informasi yang tidak relevan dan berlebihan. Karena *Feature Selection* mengurangi dimensi dari data, sehingga memungkinkan operasi yang lebih efektif & algoritma data mining yang cepat (yaitu data algoritma Mining dapat dioperasikan lebih cepat dan lebih efektif dengan menggunakan *Feature Selection*) (Maimon & Rokach, 2010).

Tujuan *Feature Selection* adalah untuk pengurangan fitur, untuk menghilangkan dari dataset subset dari variabel yang tidak dianggap relevan untuk tujuan dari kegiatan data mining dan fitur.

Metode seleksi dapat diklasifikasikan kedalam tiga kategori utama (Vercellis, 2009) antara lain:

1. Metode filter

Metode Filter adalah memilih atribut yang relevan sebelum pindah ketahap pembelajaran berikutnya, atribut yang dianggap paling penting yang dipilih untuk pembelajar, sedangkan sisanya dikecualikan.

2. Metode *wrapper*

Metode *wrapper* menilai sekelompok variable dengan menggunakan klasifikasi yang sama atau algoritma regresi digunakan untuk memprediksi nilai dari variabel target.

3. Metode *embedded*

Untuk metode *embedded*, proses seleksi atribut terletak di dalam algoritma pembelajaran, sehingga pemilihan set optimal atribut secara langsung dibuat selama fase generasi model.

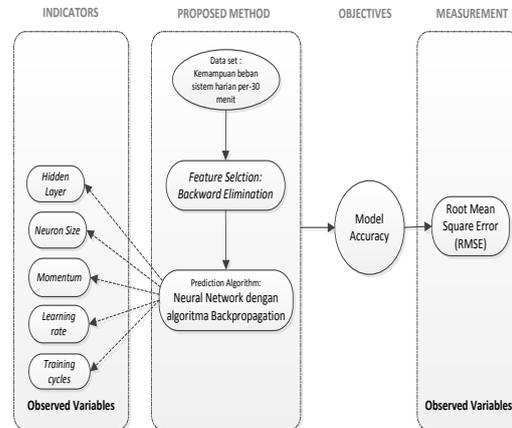
Backward elimination adalah metode untuk mengidentifikasi fitur dalam kumpulan data yang sama pentingnya, dan membuang semua fitur lain seperti informasi yang tidak relevan dan berlebihan, kemudian data yang sudah diolah dengan *backward elimination* diolah kembali dengan menggunakan metode *neural network* sampai didapatkan hasil berupa model yang digunakan untuk memprediksi beban listrik jangka pendek.

Berikut langkah-langkah dalam *backward elimination*:

1. Mulailah dengan semua prediktor dalam model.
2. Hapus prediktor dengan *p-value* tertinggi atau lebih besar dari target.
3. Perbaiki model dan ulangi langkah ke-2.

4. Hentikan ketika semua jika *p-value* kurang dari target.

2.4. Kerangka Pemikiran



Gambar 1. Kerangka Pemikiran

Pada gambar 1, menjelaskan kerangka pemikiran pada penelitian ini, dari data set kemampuan beban sistem harian per-30 menit, digunakan *feature selection* (*backward elimination*), kemudian data diolah lagi dengan metode *neural network* dimana objek indikatornya adalah:

1. **Training cycle**, fungsinya adalah untuk jaringan dapat melatih data secara terus-menerus hingga semua pola dikenali dengan benar (Jong Jek Siang, 2009), besarnya *training cycle* yaitu mulai dari 1 sampai tak terhingga.
2. **Learning rate** adalah variabel yang digunakan oleh algoritma pembelajaran untuk menentukan bobot dari *neuron*. Nilai yang besar menyebabkan pembelajaran lebih cepat tetapi ada osilasi bobot, sedangkan nilai yang kecil menyebabkan pembelajaran lebih lambat. Nilai *learning rate* harus berupa angka positif kurang dari 1.
3. **Momentum** adalah melakukan perubahan bobot yang didasarkan atas arah gradient pola terakhir dan pola sebelumnya, penambahan momentum dimaksudkan untuk menghindari perubahan bobot yang mencolok akibat adanya data yang sangat berbeda dengan yang lain (*outlier*). Apabila beberapa data terakhir yang diberikan memiliki pola serupa, maka perubahan bobot dilakukan secara cepat. Namun, apabila data terakhir yang dimasukkan memiliki pola yang berbeda dengan pola sebelumnya, maka perubahan dilakukan secara lambat (Jong Jek Siang, 2009).

Learning rate harus berupa angka positif kurang dari 1.

4. **Hidden Layer**

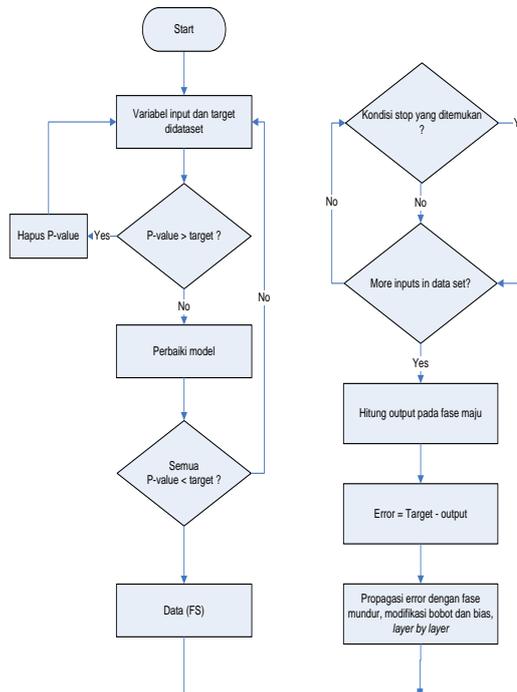
Hasil teoritis yang didapat menunjukkan bahwa jaringan dengan 1 *hidden layer* sudah cukup bagi *Backpropagation* untuk mengenali pola antara masukan dan target dengan tingkat ketelitian yang ditentukan. Akan tetapi penambahan jumlah layer tersembunyi kadangkala membuat pelatihan lebih mudah (Jong Jek Siang, 2009).

Hasil akhir penelitian adalah didapatnya model akurasi berupa *RMSE* (*Root Mean Square Error*).

III. METODE PENELITIAN

Pada persiapan data awal, data set yang digunakan adalah data kemampuan beban sistem harian 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].

3.1. Metode Neural Network Berbasis Backward Elimination (Usulan)



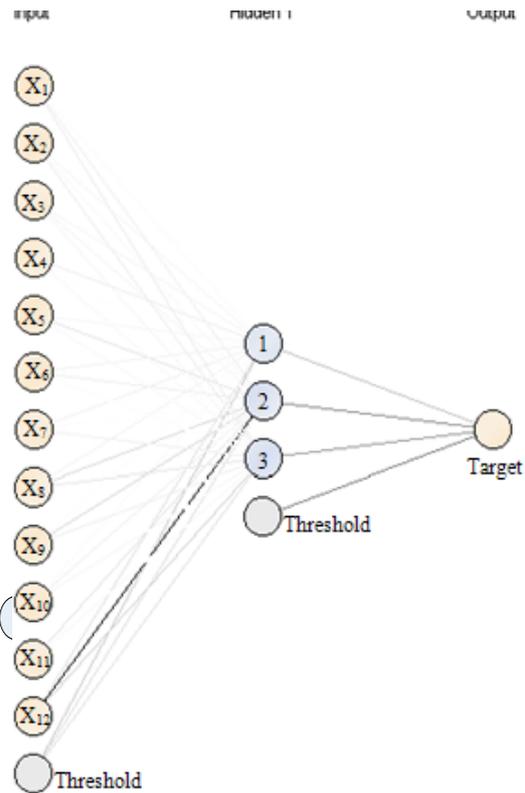
Gambar 2. Metode Neural Network Berbasis Backward Elimination (Usulan)

Gambar 2, menggambarkan metode yang diusulkan dalam penelitian ini yaitu *neural network* berbasis *backward elimination*, pada *neural network* dengan algoritma

backpropagation yang meliputi 3 fase maju, fase mundur dan fase perbaikan bobot dan bias.

IV. HASIL DAN PEMBAHASAN

Hasil eksperimen dengan *neural network* dengan indikator yang ada dan data set dengan variabel x_1-x_{12} dan target sebagai label, sehingga didapat arsitektur jaringan terbaik yaitu dengan *RMSE* yang dihasilkan 0.035.

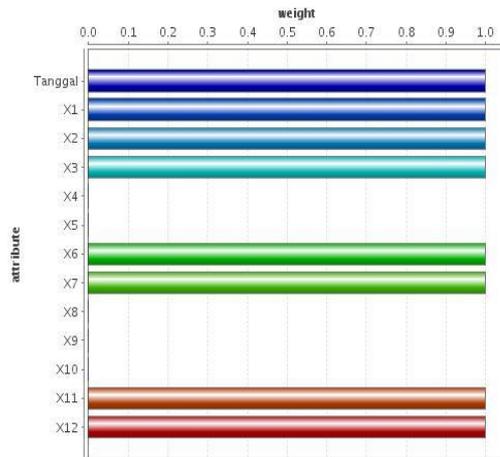


Gambar 3. Arsitektur Jaringan yang didapat dari Hasil Eksperimen

Dengan parameter yang digunakan yaitu :

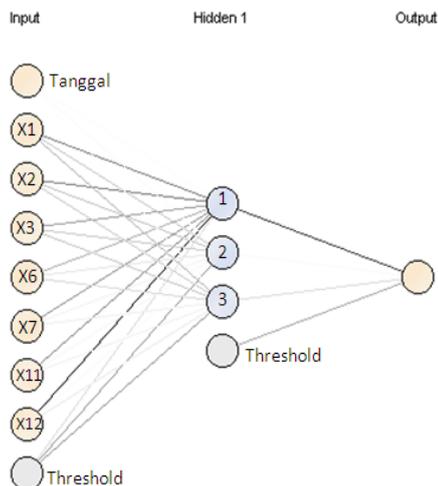
- Training cycles* : 100
- Learning rate* : 0.1
- Momentum* : 0.4
- Jumlah Hidden layer* : 1
- Size hidden layer* : 3

Hasil eksperimen dengan menggunakan *neural network* berbasis *backward elimination*. Dalam pengujian dengan metode ini, setiap indikator yang ada juga diolah kembali untuk mendapatkan hasil *RMSE* dengan nilai terendah. Berikut hasil akhir yang didapat :



Gambar 4. Plot nilai bobot setiap atribut pada 1 hidden layer sizes 3

Pada gambar 4 menunjukkan, atribut yang dipakai setelah *neural network* berbasis *backward elimination* di *running* dengan 1 *hidden layer sizes* 3 maka, atribut yang terdapat pengurangan dimensi yaitu pada X4, X5, X8, X9 dan X10 sehingga bobotnya adalah nol (0). Terakhir adalah implementasi data set hasil *Backward Elimination* kedalam metode *neural network*, hal ini guna mendapatkan arsitektur jaringan yang terbaik. Setelah data di *running* maka, telah didapatkan arsitektur jaringan yang terbaik dari hasil eksperimen adalah sebagai berikut:



Gambar 5. Arsitektur Jaringan yang didapat dari Hasil Eksperimen

Dengan parameter yang digunakan yaitu :

<i>Training cycles</i>	:100
<i>Learning rate</i>	: 0.7
<i>Momentum</i>	: 0.4
<i>Jumlah Hidden layer</i>	: 1
<i>Size hidden layer</i>	: 3

Berdasarkan gambar 3, model yang didapat adalah model dengan pola 9-4-1 dengan *RMSE* 0.018.

V. KESIMPULAN

Berdasarkan hasil ujicoba dan analisa peramalan beban listrik menggunakan metode *neural network* berbasis *backward elimination* dapat disimpulkan bahwa pengujian dengan *Neural Network* yaitu dengan *RMSE* 0.035 dan hasil pengujian dengan menggunakan *Neural Network* berbasis *Backward Elimination* didapatkan *RMSE* terendah yaitu 0.018.

Dengan demikian dari hasil pengujian model diatas dapat disimpulkan bahwa *neural network* berbasis *Backward Elimination* memberikan pemecahan untuk prediksi beban listrik jangka pendek lebih akurat jika dibandingkan dengan *Neural Network* saja.

DAFTAR PUSTAKA

- 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.
- Alfarez, K, Hesham & Nazeeruddin, Mohammad. (2002). *Electric Load Forecasting: Literature Survey and Classification Of Methods*. International journal of System Science. 1. 23-34.
- 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. 6. 190.
- Maimon, Oded & Rokach, Lior. (2010). *Data Mining and Knowledge Discovery Handbook*. (2nd ed). New York: Springer.
- Marsudi, Djiteng. (2006). *Operasi Sistem Tenaga Listrik*. Yogyakarta: Graha Ilmu.
- Myatt, Glenn J. (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* (3rd ed.). New York: McGraw-Hill.
- Shukla, Anupam. Tiwari, Ritu. & Kala, Rahul. (2010). *Real Life Application of Soft Computing*. New York: Taylor and Francis Groups, LLC.
- Vercelis, C. (2009). *Business Intelligence Data Mining And Optimization For Decision Making*. United Kingdom : A John Wiley And Sons. Ltd., Publication.
- Witten, H, Ian & Frank, Eibe. (2005). *Data Mining Practical Machine Learning Tools and Techniques*. (2nded). San Francisco: Morgan Kaufmann.
- Yuanning Liu. Gang Wang. Huiling Chen. Hao Dong. Xiaodong Zhu. Sujing Wang. (2011). *An Improved Particle Swarm Optimization for Feature Selection*. Journal of Bionic Engineering, 8.191-2