

EVALUASI KINERJA JARINGAN SYARAF TIRUAN PADA PERAMALAN KONSUMSI LISTRIK KELOMPOK TARIF RUMAH TANGGA

I Putu Eka N. Kencana

Laboratorium Komputasi Jurusan Matematika, FMIPA UNUD

e-mail: i.putu.enk@gmail.com

Ketut Jayanegara

Laboratorium Matematika Terapan Jurusan Matematika, FMIPA UNUD

e-mail: ketut_jayanegar@yahoo.com

Abstract: Many methods have been applied in forecasting technics, varied from Statistical Forecasting Methods (SFM) or Mathematical Modelling and Forecasting Methods (MMFM) to Artificial Neural Methods (ANM). This research aimed to implement and evaluate performance of Artificial Neural Network (ANN), one method in ANM group; for forecasting electricity consumption by household in Province of Bali. This research used electricity consumption data from January 2001 to December 2009 as basis for network's training and validating its result. The actual data from January to December 2010 is used to evaluate the performance of network prediction. Research shows the Mean Absolute Prediction Error (MAPE) of the ANN's prediction is 7,56%.

Keywords: forecasting, electricity consumption, artificial neural network, MAPE

1. Pendahuluan

Konsumsi listrik di Propinsi Bali pada periode 2001 hingga 2009 meningkat rata-rata sebesar 7,04 persen per tahun. Pada tahun 2001 konsumsi listrik di Bali tercatat sebesar 1 630 361 MWh dan meningkat menjadi 2 788 646 MWh pada tahun 2009. Ditinjau dari komposisi penggunaan energi listrik, tercatat sektor industri menduduki peringkat pertama sebesar 47,91 persen, disusul oleh sektor rumah tangga dan sektor publik masing-masing sebesar 45,01 dan 5,24 persen.

Seiring dengan pertambahan penduduk dan jumlah rumah tangga di Provinsi Bali, maka kebutuhan energi listrik pun mengalami peningkatan. Rata-rata per tahun terjadi peningkatan jumlah pelanggan listrik sebesar 2,84 persen (PT. PLN (Persero) Distribusi Bali, 2005). Meningkatnya jumlah pelanggan listrik mengharuskan pasokan energi listrik harus ditambah, yang bermuara pada investasi di bidang tenaga kelistrikan.

Mempertimbangkan investasi di sektor tenaga kelistrikan tergolong investasi bernilai tinggi (*high cost investment*), maka dibutuhkan perencanaan pada penyediaan energi listrik sehingga dapat melayani kebutuhan pelanggan lama dan atau baru secara op-

timal. Dengan demikian, pe-ramalan pada permintaan konsumsi listrik menjadi permasalahan yang penting bagi PT. PLN (Persero) Distribusi Bali.

1.1. Permasalahan dan Tujuan Penelitian

Proses peramalan kuantitatif dengan berbagai metode peramalan telah banyak dilakukan pada ranah dan jenis permasalahan komputasi yang beragam. Penelitian ini beranjak dari keinginan untuk menerapkan Jaringan Syaraf Tiruan (JST) sebagai metode peramal konsumsi listrik sektor rumah tangga di Provinsi Bali. Memperhatikan terdapat sejumlah arsitektur jaringan yang bisa dibangun, ingin diketahui arsitektur terbaik yang dihasilkan dari proses pelatihan dan validasi jaringan. Arsitektur JST terbaik selanjutnya dievaluasi kinerjanya dengan menghitung besar dari *Mean Absolute Prediction Error* (MAPE).

1.2. Batasan Masalah


Terdapat beberapa hal yang menjadi batasan pada penelitian ini, yaitu:

1. Lapisan masukan, lapisan tersembunyi dan lapisan luaran masing-masing berjumlah satu untuk setiap arsitektur JST yang diujicobakan;
2. Jumlah neuron pada lapisan tersembunyi bervariasi dari satu hingga 10 neuron;
3. Fungsi-fungsi aktivasi pada lapisan masukan dan lapisan luaran secara *a priori* ditetapkan berbentuk *sigmoid biner* dan *hard limit*;
4. Nilai dari *mean square error* (MSE) ditetapkan sebesar 0,01 dengan maksimum *epoch* yang dicoba sebesar 5000; 5. Algoritma pelatihan jaringan yang dipilih adalah *back propagation*.

2. Tinjauan Pustaka

2.1. Jaringan Syaraf Tiruan

Jaringan Syaraf Tiruan (JST) merupakan salah satu bentuk penerapan *Artificial Intelligence* (AI) yang mengadopsi sistem syaraf biologis makhluk hidup (Jones,[3]). Sebuah JST akan memiliki satu atau lebih neuron yang berperan sebagai elemen pengolah dari satu atau lebih masukan (*input*) pada *dendrit*. Masing-masing masukan akan memiliki bobot tersendiri saat diproses dan neuron pengolah bisa menghasilkan satu atau lebih luaran (*axon*) yang juga memiliki bobot saat memasuki neuron pengolah lainnya. Sebuah neuron memiliki sebuah fungsi yang berperan pada pengolahan masukan beserta bobotnya dan fungsi transfer yang bertanggung jawab pada pengaliran luarannya ke neuron pengolah lain. Skema JST dapat diilustrasikan seperti gambar berikut:



Gambar 1. Skema JST dengan 3 *Input*, 1 *Neuron* dan 1 *Output*

Untuk masing-masing masukan I_i Gambar 1, bobot w_i diberikan. Selanjutnya masukan dengan pembobotannya dijumlahkan oleh fungsi Σ dan fungsi transfer \int digunakan untuk menentukan luarannya. Persamaan berikut menunjukkan model matematis dari skema tersebut:

$$O_1 = \int \left(\sum_{i=1}^3 I_i w_i \right) \quad (1)$$

Jika dibandingkan dengan metode peramal lainnya, JST memiliki karakteristik yang unik; diantaranya (Tarassenko, [8]):

1. Kemampuan untuk 'belajar': JST memiliki kapabilitas untuk 'belajar' dari data yang diberikan. Karakteristik ini memungkinkan JST digunakan untuk menangani permasalahan yang bersifat kompleks dan sulit untuk disolusikan;
2. Kemampuan untuk 'men-generalisasi': JST yang 'diajari' dengan baik bisa digunakan untuk mencari solusi permasalahan dengan set data yang berbeda, dan;
3. Kemampuan untuk menyelesaikan permasalahan yang tidak bisa atau kurang baik bila dimodelkan sebagai sistem linier, yang menjadi persyaratan pada beberapa metode peramalan lainnya, seperti model data deret waktu (*time series model*).

2.2. Multiple Layer *Perceptrons* (MLP)

Pada MLP, luaran yang dihasilkan oleh neuron-neuron pada lapisan depan dilewatkan sebagai masukan pada lapisan berikutnya. Seperti dinyatakan oleh (Jones, [3]), keunggulan MLP jika dibandingkan dengan *Single Layer Perceptrons* (SLP) terletak pada kemampuan MLP untuk mengakomodasi permasalahan yang bersifat non-linear.

Pada jaringan non-linear, masing-masing elemen penyusun memiliki bobot yang bisa diubah (*adjustable*) sedemikian hingga kinerja jaringan optimal (Nilsson, [5]). Proses penyesuaian bobot dari masing-masing elektron dilakukan selama fase pelatihan jaringan. Pada perceptron, proses pelatihan yang diberikan tergolong pelatihan terawasi (*supervised learning*) yang dicirikan dengan adanya target yang harus dicapai pada fase pelati-

han. Sebagai contoh, proses pelatihan terawasi dari *perceptron* yang digunakan untuk pengklasifikasian biner, dapat dijelaskan sebagai berikut:

Misalkan, terdapat *perceptron* yang mengolah 2 masukan (i_1 dan i_2) masing-masing dengan bobot w_1 dan w_2 . Misalkan pula, terdapat sebuah bias dengan bobot w_b dan T_i sebagai target pelatihan untuk masukan ke- i . Maka:

$$R_i = \text{Step}\left(\sum_{j=1}^2 i_j w_j + w_b\right) \quad (2)$$

Pada persamaan (2), fungsi tangga (*step function*) R akan bernilai 1 jika suku $\sum_{j=1}^2 i_j w_j + w_b$ melebihi nilai *threshold* yang ditetapkan, sebaliknya R_i bernilai -1 pada proses pengklasifikasian. Selanjutnya, mengacu kepada T_i yang ditetapkan, dihitung *error*-selisih dari R_i dengan T_i -yang digunakan sebagai kriteria pada proses penyesuaian bobot dari masing-masing masukan. Penyesuaian bobot dilakukan dengan menggunakan persamaan berikut:

$$w_i = w_i + \alpha T_i \quad (3)$$

Pada persamaan (3), α merupakan besaran lebih kecil 1 yang digunakan sebagai penyesuaian bobot-disebut juga *learning rate*; T adalah nilai yang ditargetkan dengan menggunakan masukan i_i .

3. Data dan Metode Penelitian

3.1. Data Penelitian

Data pada penelitian ini merupakan data sekunder yang diperoleh dari PT. PLN (Persero) Distribusi Bali. Data tersusun dari konsumsi listrik bulanan golongan rumah tangga periode Januari 2001 - Desember 2009. Total amatan sebanyak 108 titik.

3.2. Metode Penelitian

Pemilihan arsitektur terbaik dan evaluasi kinerja jaringan dengan arsitektur terpilih dilakukan melalui tahapan-tahapan berikut:

1. Memeriksa pola sebaran data. Pemeriksaan pola dilakukan dengan membuat plot deret waktu (*time series plot*) dan dilakukan pemeriksaan komponen *trend* dan musiman dari data. Jika kedua komponen terindikasi cukup kuat keberadaannya, maka dilakukan pemeriksaan pada *Autocorrelation Function* (ACF) untuk menduga *lag* pada data;
2. *Lag* yang teridentifikasi pada tahap (1) selanjutnya digunakan sebagai 'nilai tebakan awal' jumlah *perceptron* pada lapisan *input* dengan masukan pada masing-masing *perceptron* adalah nilai-nilai konsumsi listrik pada bulan yang terpilih dan bobot masukan ditetapkan secara acak;
3. Dengan tujuan agar arsitektur jaringan yang diperoleh merupakan arsitektur terbaik, maka data dipilah menjadi 2 *set* data, masing-masing digunakan pada fase pelatihan dan validasi kinerja jaringan secara terpisah. Pada kedua fase, fungsi

aktivasi dan fungsi transfer yang digunakan adalah sigmoid biner dan fungsi identitas, seperti dinyatakan pada dua persamaan berikut:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (4)$$


$$f(x) = x \quad (5)$$

4. Kinerja jaringan pada proses pelatihan diukur dengan mencatat nilai dari *mean square error* (MSE), dan arsitektur dengan MSE terkecil dipilih sebagai arsitektur terbaik pada proses pelatihan;
5. Arsitektur terbaik yang dihasilkan pada proses pelatihan selanjutnya divalidasi dan kinerjanya diukur dari MSE validasi (MSE_v);
6. Arsitektur terbaik pada kedua proses selanjutnya ditetapkan dengan memperhatikan nilai MSE dan MSE_v, dan;
7. Arsitektur dengan MSE dan MSE_v terkecil selanjutnya ditetapkan sebagai arsitektur akhir terbaik dan digunakan untuk meramalkan konsumsi listrik pada tahun 2010. Dengan menggunakan data riil tahun tersebut, maka dihitung nilai MAPE yang digunakan sebagai indikator dari kinerja jaringan syaraf tiruan yang dibangun.

4. Hasil dan Diskusi

4.1. Pola Data Konsumsi Listrik


Plot data deret waktu konsumsi listrik golongan rumah tangga di Propinsi Bali pada periode Januari 2001 - Desember 2009 mengindikasikan adanya kecenderungan peningkatan konsumsi dan pengaruh musiman, seperti ditunjukkan pada Gambar 1. Memperhatikan hal tersebut, maka pemeriksaan ACF dan PACF dilakukan untuk menduga *lag* yang bersifat nyata pada konsumsi listrik. Analisis data dengan program Minitab 14 menunjukkan bahwa *lag* 5 merupakan *lag* yang bersifat nyata. Dengan demikian, jumlah *neuron* dari lapisan input pada fase pelatihan ditetapkan 5 dan ditingkatkan secara bertahap.



Gambar 2. Pola Konsumsi Listrik Periode Jan. 2001 - Des. 2009

4.2. Pelatihan Jaringan

Diagram alir proses pelatihan jaringan MLP dengan algoritma pelatihan back *propagation* dapat digambarkan seperti berikut:



Gambar 3. Diagram Alir Fase Pelatihan Jaringan dengan Algoritma *Back Propagation*

Hasil dari fase pelatihan jaringan dengan mengacu kepada diagram alir di atas dapat diringkas pada tabel berikut:

Tabel 1. Hasil Fase Pelatihan dari Jaringan

Jenis <i>Set Data</i>	Konfigurasi Terbaik	MSE Akhir Pelatihan	$RMSE_s^2$
Set Data Ganjil	5 – 8 – 1	0,022886	1 948,55
	6 – 8 – 1	0,014243	1 527,62
	7 – 8 – 1	0,009997 ¹	1 271,65
Set Data Genap	5 – 8 – 1	0,038684	2 469,32
	6 – 8 – 1	0,013910	1 465,40
	7 – 8 – 1	0,009961 ¹	1 228,99

Keterangan:

¹ MSE lebih kecil dari MSE target = 0,01

² $RMSE_s$ dihitung dengan menggunakan arsitektur terbaik masing-masing konfigurasi dan set *data* yang yang bersesuaian sebagai data simulasi.

Pertama, pada fase pelatihan terlihat bertam-bahnya jumlah neuron pada lapisan tersembunyi tidak selalu diikuti dengan menurunnya nilai MSE jaringan. Saat jumlah neuron ditingkatkan menjadi 9 dan 10, MSE secara gradual meningkat pada seluruh arsitektur yang dilatih. Hal ini sejalan hasil penelitian dari (Hayati & Shirvany, [2]) tentang arsitektur JST pada peramalan jangka pendek beban listrik di daerah Illam, Republik Islam Iran, yang memiliki 17 neuron pada lapisan tersembunyinya. Penambahan neuron dari 17 juga mengakibatkan meningkatnya MSE dan RMSE jaringan.

Kedua, bertambahnya jumlah masukan pada lapisan *input* menyebabkan MSE akhir dan RMSE simulasi menurun. Kecendrungan ini teramati pada berbagai jumlah neuron yang dicoba pada lapisan tersembunyi arsitektur jaringan. Berbeda halnya dengan penelitian (Kuncoro & Dalimi, [4]) yang secara *priori* menetapkan jumlah masukan pada lapisan *input* sebesar 10 mengacu kepada banyaknya faktor ekonomi yang mempengaruhi beban tenaga listrik jangka panjang Indonesia, maka saat jumlah masukan tidak bisa ditentukan secara pasti, pemeriksaan ACF dan PACF pada data deret waktu merupakan salah satu alternatif yang bisa digunakan.

4.3. Validasi Model

Proses validasi merupakan salah satu proses krusial pada pemodelan matematika. Seperti dinyatakan oleh (Arlot & Celisse, [1]), *cross-validation*(CV) mencegah terjadinya *overfitting* memperhatikan *set data* untuk fase pelatihan dari model/ algoritma yang dibentuk bersifat saling bebas dengan *set data* untuk validasi. Arlot & Celisse menyatakan prinsip dasar CV adalah melakukan pemilahan data, satu *set data* digunakan untuk melatih model; dan *set data* lainnya untuk keperluan menduga resiko dari digunakannya model. Resiko yang timbul biasanya dihitung dengan memperhatikan nilai MSE. Validasi dari arsitektur JST pada penelitian ini dilakukan dengan prosedur CV. Masing-masing konfigurasi terbaik dari setiap jenis *set data* divalidasi dengan menggunakan *set data* lawannya yang bersesuaian sebagai target. Sebagai contoh, untuk arsitektur JST 5 – 8 – 1 dengan *set data* ganjil; akan divalidasi dengan menggunakan *set data* genap. Hasil selengkapnya dari validasi arsitektur terbaik dicantumkan pada tabel 2 berikut:


Tabel 2. Hasil Validasi Arsitektur dengan Konfigurasi Terbaik

Jenis <i>Set Data</i>	Konfigurasi Terbaik	RMSE _s (Simulasi)	RMSE _v (Validasi)
Set Data Ganjil	5 – 8 – 1	1 948,55	7 357,84
	6 – 8 – 1	1 527,62	5 305,35
	7 – 8 – 1	1 271,65	5 384,77
Set Data Genap	5 – 8 – 1	2 469,32	5 232,66
	6 – 8 – 1	1 465,40	5 990,03
	7 – 8 – 1	1 228,99	4 869,19

Seperti yang diduga, RMSE validasi memiliki nilai yang lebih besar bila dibandingkan dengan RMSE simulasi pada seluruh konfigurasi terbaik kedua *set data* mengingat pada tahapan simulasi *set data* yang digunakan untuk pelatihan sama dengan yang digunakan untuk menghitung kinerja arsitektur JST yang dihasilkan.

Mengacu kepada Tabel 2, maka konfigurasi terbaik 6 – 8 – 1 dengan *set data* ganjil dipilih sebagai arsitektur JST untuk meramalkan bulan genap dan konfigurasi 7 – 8 – 1 den-

gan *set data* genap untuk meramalkan bulan-bulan ganjil dari konsumsi listrik kelompok tarif rumah tangga di Provinsi Bali. Kedua konfigurasi dipilih memperhatikan RMSEv masing-masing terkecil jika dibandingkan dengan dua konfigurasi lainnya. Gambar berikut menunjukkan pola data aktual dan hasil peramalan JST:



Gambar 4. *Scatter Plot* dari Data Aktual dan Prediksi JST untuk Konsumsi Listrik di Provinsi Bali (MWh) Periode Januari 2002 - Desember 2009

RMSE validasi dengan menggabungkan *set data* ganjil dengan *set data* genap adalah 5094,23. Memperhatikan tidak ada kriteria mutlak untuk menyatakan 'berapakah nilai RMSE yang dianggap baik?' dan RMSE merupakan besaran yang sangat dipengaruhi oleh nilai yang digunakan untuk menghitungnya, maka angka ini relatif sulit untuk diinterpretasikan (Swanson, Tayman, & Bryan, [7]). Berdasarkan alasan ini, akan digunakan *Mean Absolut Percentage Error* (MAPE) seperti dinyatakan persamaan berikut:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|Aktual_i - prediksi_i|}{Aktual_i} 100\% \quad (6)$$

Tidak seperti RMSE, MAPE tidak dipengaruhi oleh besaran nilai yang digunakan untuk menghitungnya. Penghitungan MAPE untuk model JST akhir memberikan nilai sebesar 4,88 persen.

4.4. Peramalan Konsumsi Listrik Tahun 2010

Mempertimbangkan nilai MAPE yang relatif kecil dan bisa diterima, model JST yang diperoleh selanjutnya digunakan untuk meramalkan konsumsi listrik golongan rumah tangga pada tahun 2010. Hasil peramalan ditunjukkan pada tabel berikut:

Tabel 3. Peramalan Konsumsi Listrik Tahun 2010 (dalam MWh)

Periode	Konsumsi Aktual	Konsumsi Diramalkan	Error	Percent Error
Januari	108 262	98 858	9 404	8,69
Februari	106 554	119 524	12 970	12,17
Maret	99 156	90 975	8 181	8,25
April	112 685	100 538	12 147	10,78
Mei	108 771	111 057	2 286	2,10
Juni	113 457	113 054	403	0,36
Juli	108 788	96 255	12 533	11,52
Agustus	109 389	125 980	16 591	15,17
September	108 735	113 193	4 458	4,10
Oktober	104 931	110 942	6 011	5,73
November	104 931	113 478	8 547	8,15
Desember	119 140	114 645	4 495	3,77
Mean Absolut Percentage Error (MAPE)				7,56

5. Simpulan dan Saran

5.1. Simpulan

Peramalan konsumsi listrik untuk kelompok tarif rumah tangga di Provinsi Bali yang dilakukan dengan JST MLP - terdiri dari 1 lapisan *input*, 1 lapisan tersembunyi dan 1 lapisan *output* -dan *back propagation* digunakan sebagai algoritma pelatihan menghasilkan arsitektur terbaik berikut:

1. Pada fase pelatihan, terdapat 6 arsitektur JST yang merupakan kandidat sebagai arsitektur terbaik untuk masing-masing *set data* yang dicobakan. Pada kedua *set data*, jumlah *input* pada lapisan masukan bernilai 5, 6, dan 7, sedangkan pada lapisan tersembunyi jumlah neuron optimal sebesar 8. Penambahan neuron pada lapisan ini justru mengakibatkan meningkatnya nilai MSE dan RMSE;
2. Pemilihan model terbaik dari 6 kandidat dilakukan pada fase validasi dengan memilih kandidat yang memiliki RMSE validasi terkecil. Arsitektur terbaik untuk meramalkan data konsumsi listrik bulan-bulan genap adalah arsitektur JST 6–8–1 dengan *set data* ganjil sedangkan untuk bulan-bulan ganjil diperoleh arsitektur 7–8–1 dengan *set data* genap. Melalui penggunaan kedua arsitektur ini diperoleh MAPE sebesar 4,88 persen;
3. Selanjutnya kedua model terbaik ini digunakan untuk meramalkan konsumsi listrik pada tahun 2010, dengan nilai galat peramalan MAPE sebesar 7,56 persen.

5.2. Saran

Memperhatikan nilai MAPE peramalan yang relatif masih di atas 5 persen, maka beberapa alternatif pembentukan arsitektur JST dengan kinerja yang lebih baik dapat dipertimbangkan, diantaranya:

1. Pada tahapan pemeriksaan pola data, perlu dilakukan eksplorasi data lebih mendalam diantaranya pemeriksaan keberadaan pencilan (outlier) maupun amatan yang berpengaruh (*influential observation*). Peneliti menduga, dengan set data yang 'bersih' dari pencilan dan amatan berpengaruh maka model yang terbentuk bisa lebih baik;
2. Perlu dicoba untuk membangun arsitektur JST dengan algoritma pembelajaran dan fungsi aktivasi yang berbeda dengan yang dicoba pada penelitian ini. Hal ini memper-timbangkan tidak ada algoritma dan fungsi aktivasi yang secara spesifik diketahui tepat digunakan untuk menangani permasalahan peramalan konsumsi, dan;
3. Perlu dicoba untuk membangun arsitektur JST dengan 2 unit luaran, masing-masing untuk bulan ganjil dan genap; untuk setiap kandidat arsitektur JST yang dibentuk.

Daftar Pustaka

- [1] Arlot, S., & Celisse, A. (2010). *A Survey of Cross-Validation Procedures for Model Selection*. Statistics Surveys, Vol. 4 , 40-79.
- [2] Hayati, M., & Shirvany, Y. (2007). *Artificial Neural Network Approach for Short Term Load Forecasting for Illam Region*. Word Academy of Science, Engineering and Technology , 28: 280-284.
- [3] Jones, M. T. (2008). *Artificial Intelligence: A System Approach*. Hingham, MA: Infinity Science Press LLC.
- [4] Kuncoro, A. H., & Dalimi, R. (2005). *Aplikasi Jaringan Syaraf Tiruan untuk Peramalan Beban Tenaga Listrik Jangka Panjang pada Sistem Kelistrikan di Indonesia*. Jurnal Teknologi, Edisi No. 3 Tahun XIX , 211-217.
- [5] Nilsson, N. J. (1996). *Introduction to Machine Learning*. Stanford, CA: Stanford University Press.
- [6] PT. PLN (Persero) Distribusi Bali. (2005). *Statistik 2005*. Denpasar: PT. PLN (Persero) Distribusi Bali.
- [7] Swanson, D. A., Tayman, J., & Bryan, T. M. (2007). *MAPE-R: A Rescaled Measure of Accuracy for Cross-Sectional Forecasts*. Riverside, CA: University California Riverside.
- [8] Tarassenko, L. (2004). *A Guide to Neural Computing Applications*. Burlington, MA: Elsevier Ltd.

