

PERAMALAN KEBUTUHAN ENERGI LISTRIK JANGKA PANJANG DI PROVINSI BALI RENTANG TAHUN 2020 – 2030 MENGGUNAKAN NEURAL NETWORK

Axel Adamma Diwanda¹, I Nyoman Setiawan², Widyadi Setiawan³

^{1,2,3} Program Studi Teknik Elektro, Fakultas Teknik, Universitas Udayana
Email : exceladamma@gmail.com¹, setiawan@unud.ac.id², widyadi@unud.ac.id³

Abstrak

Provinsi Bali adalah salah satu Provinsi di Indonesia dengan daerah yang padat penduduk, sehingga ketersediaan energi listrik menjadi sangat penting untuk kelangsungan kehidupan. Pada penelitian ini, dilakukan peramalan kebutuhan energi listrik provinsi Bali untuk rentang waktu 2020 – 2030. Metode yang digunakan untuk melakukan peramalan adalah dengan menggunakan *neural network* yang memiliki keunggulan yaitu dapat melakukan pembelajaran berdasarkan pola data historis yang digunakan dalam pelatihan. Pada proses peramalan menggunakan *neural network*, digunakan bantuan *neural network toolbox (nntool)* pada *software* MATLAB. Arsitektur jaringan menggunakan *feed-forward backpropagation*. Pada penelitian ini, menggunakan kombinasi *layer* 4 – 12 – 1, dengan 4 *input* data yaitu populasi penduduk, PDRB, PDRB per kapita serta IHK. Parameter jaringan yang digunakan antara lain fungsi pelatihan TrainGDX, fungsi aktivasi TANSIG dan PURELIN (*output*), fungsi performa MSE serta fungsi pembelajaran TrainGD. Hasil dari simulasi peramalan kebutuhan listrik Provinsi Bali pada tahun 2020 membutuhkan energi listrik sebesar 5.772 GWh, pada tahun 2025 meningkat menjadi 6.523 dan pada tahun 2030 menjadi 8.551. Peramalan ini menghasilkan MAPE terhadap RUKN 2019 sebesar 3,29% yang masih dibawah ketentuan PLN yaitu 10%.

Kata Kunci: Peramalan, Energi Listrik, *Neural Network*, RUKN 2019

Abstract

Bali Province is one of the provinces with densely populated areas, hence the availability of electricity is very important for life sustainability. In this research, electricity demand forecasting was conducted in Bali Province for the period of 2020-2030. The method used to forecast was neural network which has the advantage of being able to do an adaptive learning based on the data used for training. In this forecasting process that used neural network, the neural network toolbox (nntool) on MATLAB 2013a was used. Network architecture used was feed-forward backpropagation. In this research, layer combination applied was 4 – 12 – 1, with 4 input data such as population, PDRB, PDRB per capita and IHK. Network parameter applied in this research was training function TRAINGDX, activation function TANSIG and PURELIN (output), performance function MSE and learning function TRAINGD. The final result of Bali Province electricity demand forecasting in 2020 the demand for electricity is 5772 GWh, in 2025 it will increase to 6523 GWh and in 2030 become 8551 GWh. This forecasting MAPE againts the RUKN 2019 result was 3.29%, which is under the PLN regulation that is 10%.

Keywords: Forecasting, Electricity Energy, *Neural Network*, RUKN 2019

1. PENDAHULUAN

Kebutuhan akan energi menjadi sebuah kebutuhan yang krusial dalam kehidupan manusia. Pertumbuhan populasi penduduk yang melonjak tinggi, kebutuhan yang semakin kompleks, serta pesatnya kemajuan teknologi akan berimbas pada penggunaan energi listrik. Pertambahan

penduduk dan juga pertumbuhan pembangunan mengakibatkan pemakaian energi listrik meningkat semakin besar setiap tahun [1]. Energi listrik adalah salah satu unsur pendorong dari perkembangan perekonomian [2]. Ketersediaan dari energi listrik yang cukup, efisien serta efektif

dalam penggunaannya berperan besar dalam memacu pembangunan daerah dan dan serta merta dapat meningkatkan kualitas hidup [3]. Perencanaan dalam pengoperasian sistem tenaga listrik pada penyediaan energi yang efektif terhadap kebutuhan sangat diperlukan. Metode yang paling sering digunakan dalam peramalan adalah metode *Artificial Intelligence* (AI) atau disebut juga kecerdasan buatan adalah *Artificial Neural Network* (ANN) serta *Support Vector Machine* (SVM) [4]. Peramalan energi listrik untuk Provinsi Bali sebelumnya sudah pernah dilakukan oleh Fitriyah dkk (2011) [5] dengan metode *Neural Network* serta terdapat pada penelitian Ambaryana dkk (2019) menggunakan *software* LEAP [6]. Kedua peramalan menunjukkan hasil yang cukup baik. *Neural Network* memiliki kemampuan yang baik untuk peramalan dengan kelebihan yaitu mampu mempelajari pola data yang diberikan di tahapan pelatihan. Selain itu mampu mengeksekusi masalah secara *self organization*, dan dilengkapi *real time operation*. *Neural Network* juga memiliki toleransi kesalahan yang tinggi dan juga mampu menjalankan program secara parallel [7]. Pada penelitian ini, dilakukan peramalan energi listrik untuk Provinsi Bali rentang tahun 2020 – 2030 menggunakan metode *Neural Network*.

2. KAJIAN PUSTAKA

2.1 Hubungan Ekonomi dengan Kebutuhan Energi Listrik

Dalam pertumbuhan energi listrik, perekonomian memiliki hubungan erat dalam prosesnya. Sehingga terdapat beberapa istilah yang muncul didalam hubungan diantara kedua hal tersebut. Beberapa istilah tersebut seperti intensitas energi, elastisitas energi serta efisiensi energi.

2.1.1 Intensitas Energi

Penggunaan energi yang semakin sedikit namun dapat memberikan peningkatan yang signifikan terhadap laju PDB, maka dapat dikatakan penggunaan energi di negara tersebut efisien [8]. Jumlah konsumsi energi yang dibutuhkan untuk dapat mendorong peningkatan per PDB adalah apa yang disebut sebagai intensitas energi. Dengan begitu, semakin efisien penggunaan energi suatu negara, semakin kecil nilai intensitas energinya. Begitu pula sebaliknya.

2.1.2 Elastisitas Energi

Elastisitas energi adalah nilai dari pertumbuhan kebutuhan energi yang dibutuhkan sehingga dapat mencapai tingkat pertumbuhan ekonomi (PDB) tertentu [8]. Nilai elastisitas energi di bawah 1,0 dapat dicapai apabila jumlah energi yang tersedia mampu dimanfaatkan secara produktif. Pada tahun 2015, elastisitas energi Indonesia adalah sebesar 1,84 [9]. Artinya, untuk dapat meningkatkan pertumbuhan ekonomi sebesar 1 persen, maka rata-rata konsumsi energi di Indonesia harus naik sebesar 1,84 persen.

2.1.3 Efisiensi Energi

Pada pelaksanaan konservasi energi, efisiensi adalah salah satu langkahnya. Efisiensi energi merupakan istilah pada penggunaan energi yang mengacu pada penggunaan yang lebih sedikit namun dapat menghasilkan jumlah output yang berguna sama dari nilai sebelumnya [10]. Efisiensi energi dapat diartikan penggunaan energi lebih sedikit untuk menyediakan tingkat energi yang sama.

2.2 Faktor Sosial-Ekonomi yang Mempengaruhi

Pertumbuhan ekonomi suatu daerah yang semakin tinggi maka meningkat pula konsumsi energi daerah tersebut. Berkurangnya sumber energi dapat menyebabkan krisis energi diseluruh daerah tersebut. Kondisi ini dapat dikarenakan permintaan energi yang terus meningkat namun tidak dibarengi ketersediaan jumlah energi yang cukup. Hal tersebut menyebabkan angka konsumsi energi semakin tinggi setiap saat sehingga efektifitas serta efisiensi penggunaan energi sangatlah dibutuhkan [10].

2.2.1 Produk Domestik Bruto

Dikutip Badan Pusat Statistik (BPS), Produk Domestik Bruto (PDB) Pada dasarnya adalah total nilai tambah pada suatu jangka waktu tertentu yang dihasilkan oleh seluruh unit usaha pada suatu negara [11]. Dalam perhitungan grafik perkembangan perekonomian dari suatu negara pada suatu jangka waktu tertentu, PDB menjadi salah satu bagian penting didalamnya. PDB tersebut dapat atas dasar harga konstan ataupun atas dasar harga berlaku.

2.2.2 Produk Domestik Regional Bruto

Produk Domestik Regional Bruto (PDRB) kurang lebih sama seperti PDB namun terdapat pada skala daerah. Sehingga, dalam pembentukan ataupun perhitungan kajian pertumbuhan perkonomanian daerah, PDRB juga berfungsi sama seperti PDB. Hal tersebut dikarenakan PDRB juga merupakan total dari jumlah penghasilan dari seluruh unit usaha di tingkatan daerah. Nilai dari PDRB setiap daerah sangat beragam, dikarenakan setiap daerah memiliki karakteristik perekonomian berbeda [11].

2.2.3 Produk Domestik Regional Bruto per Kapita

Berdasarkan data dari RUED Provinsi Bali Tahun 2019, pendapatan per kapita merupakan besar pendapatan rata – rata dari penduduk di suatu negara atau daerah tertentu dalam periode tertentu [12]. PDRB (Pendapatan Domestik Regional Bruto) per kapita untuk provinsi Bali pada tahun 2017 dapat dihitung dengan menggunakan persamaan berikut:

$$PDRB \text{ per kapita} = \frac{PDRB \text{ 2017}}{\text{Jumlah Penduduk 2017}} \dots(1)$$

$$PDRB \text{ per kapita} = \frac{Rp.144.900.000.000.000}{4.242.000 \text{ jiwa}}$$

$$PDRB \text{ per kapita} = Rp.34.158.416$$

2.2.4 Indeks Harga Konsumen

Inflasi merupakan salah satu indikator penting dalam perkembangan perekonomian daerah. Sebisa mungkin inflasi dapat ditekan serendah mungkin. Salah satu indikator yang dapat dijadikan acuan dalam perhitungan tingkat inflasi adalah Indeks Harga Konsumen. Pada IHK, harga dari suatu komoditas barang maupun jasa (*market basket*) akan dibandingkan dengan daya konsumsi rumah tangga pada jangka waktu tertentu [11].

2.2.5 Populasi Penduduk

Penduduk dapat diartikan sebagai masyarakat asli yang lahir serta tinggal di suatu wilayah negara dan memiliki orangtua yang juga merupakan penduduk dari negara tersebut [12]. Pertumbuhan penduduk yang pesat akan meningkatkan permintaan kebutuhan sumber daya alam

dengan cepat pula, sehingga dapat mempengaruhi kebutuhan energi pula.

2.3 Peramalan

Dikutip dari Heizer dan Render, peramalan atau yang disebut juga *forecasting* adalah ilmu atau seni dalam memperkirakan suatu kejadian di masa depan. Peramalan dapat dilakukan dengan menggunakan data historis dan memproyeksikannya ke masa yang akan datang dengan suatu model matematis tertentu [13].

2.4 Pengolahan Data Penelitian

2.4.1 Normalisasi Data

Sebelum data digunakan dalam proses peramalan, pada data perlu untuk dilakukan tahapan awal yaitu normalisasi terhadap data. Tahap ini diperlukan agar didapatkan hasil analisa data yang lebih akurat pada metode *machine learning* [14]. Skala normalisasi data dapat dipilih antara (0,1), (-1,1) ataupun skala lainnya yang diinginkan. Jika data akan dinormalisasi ke dalam skala (-1,1), maka data dapat dinormalisasi dengan persamaan berikut.

$$X_n = 2 \times \frac{X - X_{min}}{X_{max} - X_{min}} - 1 \dots\dots\dots(2)$$

Dengan:

- Xn = Data Normalisasi
- X = Data Real
- Xmin = Nilai Minimum Data
- Xmax = Nilai Maksimum Data

2.5 MAPE

Mean Absolute Percentage Error (MAPE) adalah salah satu perhitungan kesalahan dengan menggunakan nilai kesalahan absolut pada setiap periode dan dibagi dengan nilai asli untuk periode tersebut [14]. Selanjutnya merata-rata kesalahan dari persentase absolut nilai tersebut. MAPE di klaim lebih akurat dari MSE. Untuk menghitung MAPE dari suatu proses peramalan, maka dapat dilakukan dengan persamaan berikut.

$$MAPE = \frac{\sum_{t=1}^n \left| \frac{xt - ft}{xt} \right|}{n} \times 100\% \dots\dots\dots(3)$$

Dengan :

- N = Jumlah Sampel
- xt = Nilai Aktual Indeks periode ke-t
- ft = Nilai Prediksi Indeks periode ke-t

3. Metode Penelitian

Penelitian ini dilakukan di Perusahaan Listrik Negara Unit Induk Distribusi Provinsi Bali. Penelitian dilaksanakan dari bulan Maret 2020 sampai dengan Agustus 2020. Adapun tahapan dalam melakukan penelitian adalah sebagai berikut.



Gambar 1. Tahapan Penelitian

3.1 Data Peramalan

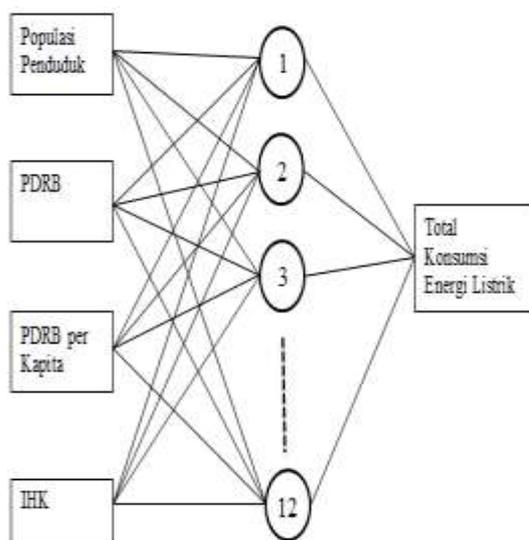
Pada penelitian ini, data yang digunakan sebagai *input*, *output* serta *target* pelatihan menggunakan data yang berhubungan dengan pertumbuhan kebutuhan listrik. Data yang digunakan adalah sebagai berikut.

Tabel 1. Data *Input* Peramalan

| Kelompok Data | Data <i>Input</i> | Data <i>Target</i> |
|---------------|---|--|
| Data Latih | <ul style="list-style-type: none"> a. Populasi Penduduk (2001 – 2019) b. Produk Domestik Regional Bruto (2001 – 2019) c. Produk Domestik Regional Bruto per Kapita (2001 – 2019) d. Indeks Harga Konsumen (2001 – 2019) | Total Beban Listrik Historis tahun 2001 – 2019. |
| Data Simulasi | <ul style="list-style-type: none"> a. Populasi Penduduk (2020 – 2030) b. Produk Domestik Regional Bruto (2020 – 2030) c. Produk Domestik Regional Bruto per Kapita (2020 – 2030) d. Indeks Harga Konsumen (2020 – 2030) | Tidak ada target, karena <i>output</i> simulasi merupakan hasil akhir peramalan. |

3.2 Arsitektur Jaringan Peramalan

Arsitektur dan parameter jaringan akan dilakukan percobaan secara *trial and error* dengan kriteria sesuai tabel. Setelah dilakukan beberapa, pembentukan jaringan menghasilkan *output* terbaik setelah menggunakan kombinasi *layer input – hidden – output* yaitu 4 – 12 – 1 seperti yang tercantum pada gambar 2.



Gambar 2. Arsitektur Jaringan Peramalan

3.3 Parameter Jaringan

Pada penelitian kali ini, proses pembentukan jaringan menggunakan parameter – parameter dibawah ini.

a. Jumlah *hidden layer* dan *node* pada *hidden layer*

Hidden layer adalah tempat dimana bobot diberikan pada input yang didapatkan *input layer* pada setiap *node*. Pemilihan jumlah *hidden layer* dan jumlah *node* yang tepat untuk sebuah jaringan belum pernah bisa dijelaskan pada satu formula tertentu. Pada penelitian ini, ditentukan jumlah *hidden layer* hanya sejumlah 1 *hidden layer* karena terbukti memberikan hasil lebih cepat namun masih memberikan hasil yang cukup akurat [13]. Pada pemilihan jumlah *node*, penelitian kali ini menggunakan sistem *trial and error* untuk menentukannya. Dalam menciptakan sebuah jaringan yang akurat, penentuan jumlah *node* sangat berpengaruh. Pada penelitian ini, jumlah *node* terbaik didapatkan pada jumlah 12 *node* pada *hidden layer*.

b. Fungsi pelatihan (*training function*)

Fungsi pelatihan berfungsi melatih *network* dalam memahami *pattern* atau pola pada jaringan untuk dapat melakukan peramalan dengan akurat. Dari total 12 fungsi pelatihan pada MATLAB, beberapa fungsi pelatihan yang digunakan pada penelitian ini, yaitu Lavenberg-Marquardt (LM), BFGS Quasi-Newton (BFG), *Gradient Descent with Momentum* (GDM), *Gradient Descent with Momentum and Adaptive*

Learning (GDx) serta *Bayesian Regularization* (BR). Fungsi pelatihan ini dipilih dengan berdasarkan dari beberapa percobaan yang dilakukan oleh MATLAB terhadap beberapa fungsi pembelajaran lainnya serta penelitian yang dilakukan oleh Binoto (2015) [1] dan Kristianto (2018) [16].

c. Fungsi Aktivasi (*activation function*)

Nilai yang sebelumnya terfapat di *node* pada bagian *hidden layer* telah diolah dan dihitung. Perhitungan pada proses pengolahan data tersebut dilakukan oleh fungsi aktivasi. Pada setiap *hidden layer* terdapat fungsi aktivasi untuk menghitung prosesnya lalu dikirimkan ke *output layer*. Dari *output layer* untuk terakhir menghasilkan *output* juga terdapat fungsi aktivasi pada *hidden layer*-nya. Pada penelitian ini, fungsi aktivasi yang digunakan pada *hidden layer* adalah tansigmoid (Tansig), karena data penelitian telah dinormalisasi pada skala (-1,1) sebelum dimasukkan pada jaringan. Pada bagian *output layer* hanya menggunakan fungsi Purelin.

d. Fungsi Performa (*performance function*)

Fungsi performa pada *Neural Network* menggunakan metode *Mean Square Error* (MSE). Fungsi dari fungsi performa itu sendiri adalah untuk mengitung kesalahan berdasarkan perbedaan hasil dari nilai pada data asli dengan nilai dari hasil pelatihan. Dengan begitu dapat diketahui bagaimana performa dari proses peramalan tersebut, sehingga dapat ditentukan metode mana yang menghasilkan peramalan terbaik.

e. Fungsi Pembelajaran (*learning function*)

Dalam menentukan seberapa cepat jaringan dapat mempelajari serta menentukan *gradient* yang sesuai dengan bobot dan nilai dalam menghasilkan peramalan yang baik, *neural network* memiliki fungsi pembelajaran (*learning function*) untuk melakukan tugas tersebut. Terdapat dua fungsi pembelajaran, yaitu *learningdm* serta *learningdm*.

Setelah melakukan beberapa percobaan secara *trial and error*, didapatkan parameter pelatihan jaringan dengan hasil terbaik. Parameter terbaik yang telah didapat adalah sebagai berikut.

Tabel 2. Parameter Jaringan Peramalan

| Parameter | Digunakan |
|----------------------------|---|
| Jumlah <i>Hidden Layer</i> | 1 |
| Jumlah <i>Node</i> | 12 |
| Fungsi Pelatihan | TrainGDX (<i>Gradient Descent with Momentum and Adaptive Learning Rate</i>) |
| Fungsi Aktivasi | - TANSIG - PURELIN (<i>Output</i>) |
| Fungsi Performa | MSE |
| Fungsi Pembelajaran | LearnGD (<i>Gradient Descent</i>) |

Pada jalannya pelatihan, terdapat parameter pelatihan pada bagian jendela pelatihan *neural network toolbox*. Adapun parameter untuk pelatihan adalah sebagai berikut.

a. Epoch

Pada proses pelatihan, satu kali siklus pelatihan terhadap sebuah jaringan disebut iterasi atau *Epoch*. Berhentinya iterasi adalah jika pelatihan sudah memenuhi kriteria parameter lain atau sudah mencapai batas maksimum iterasi. Pada percobaan ini batas maksimum *epoch* yang digunakan yaitu 1000 dan 100000 untuk *traingdm* dan *trainbr*.

b. Goal

Goal adalah target error yang ingin dicapai pada pelatihan jaringan. *Goal* mempengaruhi performa pelatihan, pada percobaan ini nilai target yaitu 0. Dengan begitu pelatihan akan terus berjalan hingga mendekati nilai dari target atau berhenti bila parameter yang lainnya sudah terpenuhi.

c. Time

Pada pelatihan *neural network* salah satu parameter lainnya adalah *time*. Parameter ini berfungsi menjadi *timer* pada proses pelatihan. Pada percobaan waktu ditetapkan *infinite* / tak terbatas sehingga parameter akan berhenti bergantung pada parameter lain.

d. Fail

Parameter *fail* dapat ditentukan pada bagian (*max_fail*) yang berfungsi memberikan Batasan kegagalan pada

pelatihan saat performa pelatihan menurun. Pada pelatihan ini kegagalan dibatasi sebanyak 100 kali.

e. Learning Rate

Perubahan atau penambahan bobot dan bias secara otomatis dapat dilakukan dengan mengatur *Learning Rate*. Pada percobaan ini nilai rasio (*lr*) yang digunakan yaitu 0,001 yang bertujuan untuk memperkecil perubahan nilai bobot agar mendapatkan hasil yang lebih maksimal.

Untuk lebih jelasnya, berikut dibawah telah dirangkum parameter pelatihan yang digunakan terdapat pada tabel 3.

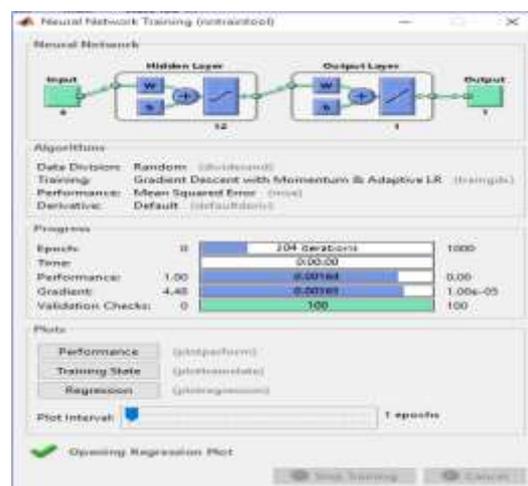
Tabel 3. Parameter Pelatihan Jaringan Peramalan

| Parameter Pelatihan | Value |
|---------------------|--|
| Epoch | - 1000 - 100000 (<i>traingdm</i> & <i>trainbr</i>) |
| Goal | 0 |
| Time | Inf |
| Fail | 100 |
| Learning Rate | 0,001 |

4. Hasil dan Pembahasan

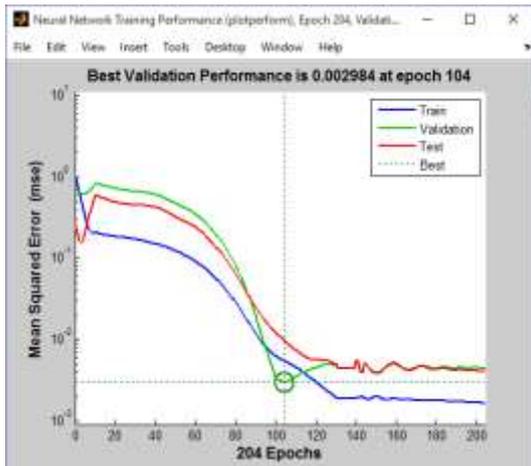
4.1 Hasil Pelatihan

Setelah pelatihan dilakukan akan muncul pop-up jendela *progress* dari pelatihan yang memuat beberapa informasi pelatihan seperti arsitektur, jumlah *epoch*, *goal*, *time*, *performance*, *gradient* serta beberapa grafik tambahan seperti *performance*, *training state* dan *regression*. Berikut ini jendela hasil *training* dari pelatihan jaringan.

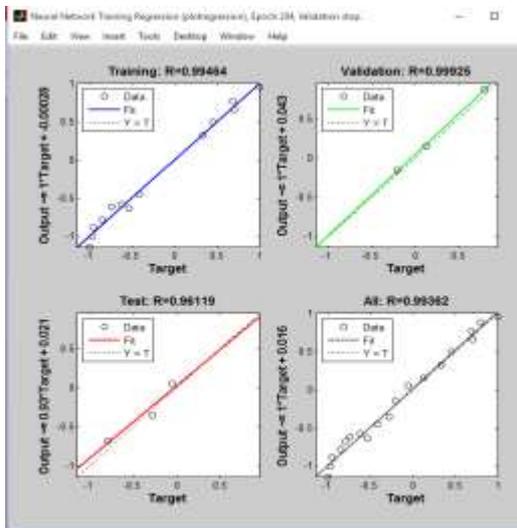


Gambar 3. Hasil Pelatihan Jaringan Peramalan

Pada gambar 3 menunjukkan bahwa jaringan diatur untuk maksimal dapat melakukan hingga 1000 *epoch*, namun berhenti pada *epoch* 204. Hal ini dikarenakan *validation checks* telah memenuhi jumlah yang ditentukan yaitu 100 sehingga pelatihan dihentikan. Selanjutnya, pelatihan jaringan menghasilkan grafik pelatihan, uji, dan validasi sebagai berikut.



Gambar 4.1 Grafik Performance Output Pelatihan Jaringan Peramalan



Gambar 5. Grafik Regression Output Pelatihan Jaringan Peramalan

Sejatinya, *neural network* Matlab secara *default* akan membagi persentase data yang dilatih menjadi 70% untuk *training*, 15% untuk *testing*, dan 15% untuk *validation*. Pada grafik yang ditunjukkan oleh gambar 4 menunjukkan bahwa grafik *training* memberikan R (*regression*)

sebesar 0,99464. Pada bagian *testing* R = 0,96119. Pada bagian *validation* R = 0,99925. Secara keseluruhan R = 0,99362. *Regression* pelatihan ini menunjukkan hasil yang baik karena semakin dekat dengan nilai 1 maka akan semakin baik. Selain itu, grafik yang semakin mendekati garis putus – putus juga merupakan indikator bahwa pelatihan berjalan dengan baik.

Tahapan pelatihan jaringan peramalan energi listrik Provinsi Bali rentang tahun 2020 – 2030 dilakukan pada *Neural Network Toolbox*. Setelah dilakukan beberapa percobaan pelatihan, didapatkan parameter pelatihan terbaik seperti yang ditunjukkan pada tabel 4. Hasil dari pelatihan jaringan peramalan adalah sebagai berikut.

Tabel 4. Hasil Pelatihan Jaringan Peramalan (Normalisasi)

| Tahun | Konsumsi Energi Listrik (kWh) |
|-------|-------------------------------|
| | Total |
| 2001 | -1,014201616 |
| 2002 | -1,000517329 |
| 2003 | -0,921597818 |
| 2004 | -0,836605223 |
| 2005 | -0,751353757 |
| 2006 | -0,698782807 |
| 2007 | -0,581742972 |
| 2008 | -0,564476311 |
| 2009 | -0,444178783 |
| 2010 | -0,351478333 |
| 2011 | -0,153440561 |
| 2012 | 0,007425304 |
| 2013 | 0,153124926 |
| 2014 | 0,324065638 |
| 2015 | 0,501146604 |
| 2016 | 0,653672681 |
| 2017 | 0,771089561 |
| 2018 | 0,878400178 |
| 2019 | 0,949601852 |

Hasil pelatihan diatas masih dalam bentuk normalisasi. Untuk merubah menjadi bentuk aslinya maka perlu dilakukan proses denormalisasi. Proses denormalisasi dapat dilakukan dengan menggunakan persamaan 2. Persamaan 2

dapat diubah dan dibalikkan menjadi untuk melakukan denormalisasi. Berikut merupakan contoh denormalisasi dengan menggunakan hasil tahun 2019.

$$Konsumsi_{2019} = 0,5 \times (0.949601852 + 1) \times (5.706.724.677 - 1.590.360.554) + 1.590.360.554$$

$$Konsumsi_{2019} = 5.602.996.113 \text{ kWh}$$

Dengan cara yang sama seperti denormalisasi konsumsi energi listrik tahun 2019 diatas, maka hasil dari bentuk denormalisasi tahun lainnya dapat dicari dengan cara yang sama. Maka, didapatkan hasil denormalisasi sebagai berikut.

Tabel 5. Hasil Pelatihan Jaringan Peramalan (Denormalisasi)

| Tahun | Konsumsi Energi Listrik (kWh) |
|-------|-------------------------------|
| | Total |
| 2001 | 1.561.131.044 |
| 2002 | 1.589.295.796 |
| 2003 | 1.751.726.518 |
| 2004 | 1.926.656.753 |
| 2005 | 2.102.119.792 |
| 2006 | 2.210.320.378 |
| 2007 | 2.451.209.667 |
| 2008 | 2.486.747.597 |
| 2009 | 2.734.341.812 |
| 2010 | 2.925.136.216 |
| 2011 | 3.332.734.006 |
| 2012 | 3.663.825.242 |
| 2013 | 3.963.701.592 |
| 2014 | 4.315.528.698 |
| 2015 | 4.679.993.567 |
| 2016 | 4.993.920.001 |
| 2017 | 5.235.585.317 |
| 2018 | 5.456.450.105 |
| 2019 | 5.602.996.113 |

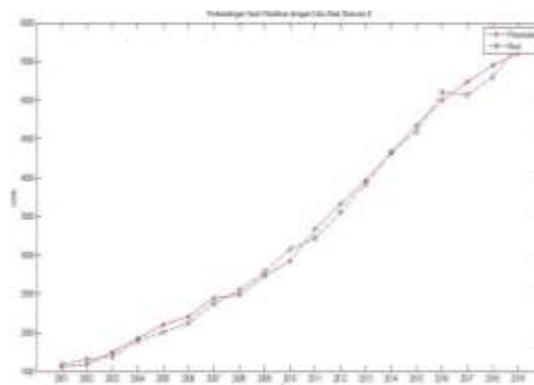
Hasil *output* pelatihan jaringan selanjutnya dibandingkan dengan nilai *real* dari konsumsi energi listrik pada periode tahun yang sama (*target*). Dengan menggunakan MAPE sebagai indikator, perbandingan hasil peramalan dengan target pelatihan dapat dicari menggunakan

persamaan 3, yang menghasilkan MAPE sebagai berikut.

Tabel 6. MAPE Hasil Pelatihan dengan Target Pelatihan Jaringan Peramalan

| Tahun | MAPE Konsumsi Energi Listrik (%) |
|-------------------|----------------------------------|
| | Total |
| 2001 | 1,837917221 |
| 2002 | 3,900942241 |
| 2003 | 3,455198123 |
| 2004 | 1,629043659 |
| 2005 | 4,562142241 |
| 2006 | 4,013560449 |
| 2007 | 3,207999339 |
| 2008 | 2,522447339 |
| 2009 | 1,947326073 |
| 2010 | 4,901760964 |
| 2011 | 3,37418193 |
| 2012 | 3,305302365 |
| 2013 | 1,261558294 |
| 2014 | 0,449790172 |
| 2015 | 1,868231891 |
| 2016 | 2,062798623 |
| 2017 | 3,273366511 |
| 2018 | 2,900137656 |
| 2019 | 1,817654963 |
| Total MAPE | 2,75 |

Berikut dibawah ini penyajian perbandingan MAPE antara hasil pelatihan dengan target pelatihan jaringan peramalan dalam bentuk grafik.



Gambar 5. Grafik MAPE Hasil Pelatihan dengan Target Pelatihan Jaringan Peramalan

Perbandingan antara hasil pelatihan terhadap target pelatihan menghasilkan perbandingan MAPE seperti pada tabel 6 dan gambar 5. Pada tabel 6 dapat diperhatikan bahwa MAPE antara hasil pelatihan dengan target pelatihan menghasilkan MAPE yang cukup kecil yaitu 2,75%. Untuk MAPE terkecil terdapat pada

tahun 2014 dengan MAPE sebesar 0,45%. Untuk MAPE terbesar terdapat pada tahun 2010 dengan MAPE sebesar 4,90%. Secara keseluruhan, nilai MAPE pelatihan jaringan peramalan ini sebesar 2,75% masih berada dibawah standar yang ditentukan yaitu 10%, sehingga pelatihan jaringan peramalan dapat dikatakan berjalan dengan baik. Pada gambar 5 dapat dilihat grafik pelatihan dibandingkan dengan target pelatihan yang merupakan data *real* pada tahun yang sama. Terlihat bahwa hasil pelatihan dengan data *real* hanya berbeda sedikit sehingga kedua grafik cukup berimpitan.

4.2 Hasil Simulasi

Setelah menemukan jaringan peramalan terbaik dari pelatihan jaringan peramalan, selanjutnya jaringan peramalan tadi dapat digunakan untuk simulasi peramalan energi listrik Provinsi Bali rentang tahun 2020 – 2030. Pada tahap simulasi, data *input* yang digunakan adalah data simulasi sesuai tabel 1. Data simulasi merupakan *input* data baru yang berbeda dari *input* data pelatihan serta pengujian. Simulasi dilakukan melalui jendela “*simulate*” pada *neural network toolbox*. Hasil *output* dari simulasi adalah peramalan energi listrik Provinsi Bali rentang tahun 2020 – 2030 pada masing – masing sektor. Berikut hasil *output* dari simulasi peramalan energi listrik Provinsi Bali rentang tahun 2020 – 2030 dengan menggunakan jaringan peramalan yang telah dilatih sebelumnya.

Tabel 7. Hasil Simulasi Peramalan

| Tahun | Konsumsi Energi Listrik (kWh) |
|-------|-------------------------------|
| | Total |
| 2020 | 5.771.730.632 |
| 2021 | 5.910.919.304 |
| 2022 | 6.038.913.778 |
| 2023 | 6.169.330.774 |
| 2024 | 6.311.739.977 |
| 2025 | 6.522.599.024 |
| 2026 | 6.860.454.809 |
| 2027 | 7.348.243.427 |
| 2028 | 7.881.258.821 |
| 2029 | 8.323.562.618 |
| 2030 | 8.550.991.982 |

Hasil dari simulasi peramalan ditunjukkan pada tabel 7. Dari hasil diatas dapat diperhatikan bahwa prediksi konsumsi energi listrik Provinsi Bali untuk tahun 2020 – 2030 mengalami peningkatan setiap tahunnya. Secara keseluruhan, prediksi untuk total konsumsi energi listrik Provinsi Bali pada tahun 2020 sebesar 5.771.730.632 kWh atau 5.772 GWh. Pada tahun 2025 meningkat menjadi 6.522.599.024 kWh atau 6.523 GWh dan pada tahun 2030 akan menjadi 8.550.991.982 kWh atau 8.551 GWh.

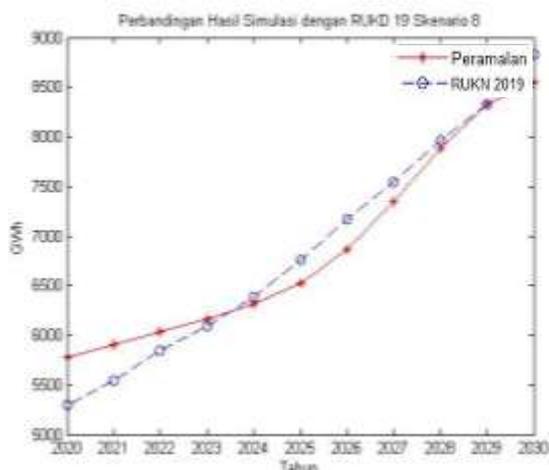
4.3 Perbandingan Hasil Peramalan Neural Network dengan RUKN

RUKN (Rencana Umum Ketenagalistrikan Nasional) tahun 2019 telah memprediksi kebutuhan energi listrik Provinsi Bali rentang tahun 2019 - 2038. Hasil peramalan dengan menggunakan *Neural Network* selanjutnya akan dibandingkan dengan RUKN sebagai validasi peramalan. Berikut ini perbandingan antara peramalan RUKN dengan peramalan menggunakan *Neural Network*.

Tabel 8. Perbandingan Peramalan Neural Network dengan RUKN 2019

| Tahun | MAPE Konsumsi Energi Listrik (%) |
|-------------------|----------------------------------|
| | Total |
| 2020 | 9,024001357 |
| 2021 | 6,676038698 |
| 2022 | 3,335280248 |
| 2023 | 1,319276954 |
| 2024 | 1,100909171 |
| 2025 | 3,483293516 |
| 2026 | 4,290530004 |
| 2027 | 2,620680791 |
| 2028 | 1,051364457 |
| 2029 | 0,077279501 |
| 2030 | 3,225532116 |
| Total MAPE | 3,29 |

Secara grafik, perbandingan antara hasil peramalan menggunakan *Neural Network* dengan RUKN 2019 adalah sebagai berikut.



Gambar 6. Grafik Perbandingan Peramalan *Neural Network* dengan RUKN 2019

Perbandingan antara hasil simulasi peramalan menggunakan *Neural Network* terhadap peramalan RUKN 2019 menghasilkan perbandingan MAPE seperti pada tabel 8 dan gambar 6. Pada tabel 8 MAPE untuk peramalan menggunakan *Neural Network* dengan nilai terkecil didapatkan pada tahun 2029 dengan MAPE 0,077%. MAPE terbesar pada total konsumsi energi listrik terdapat pada tahun 2020 dengan MAPE 9,02%. Secara keseluruhan, total MAPE dari peramalan *Neural Network* yaitu sebesar 3,29%. Nilai tersebut berada dibawah standar yang ditentukan PLN yaitu 10%, sehingga peramalan menggunakan *Neural Network* dengan arsitektur dan parameter yang telah ditentukan pada penelitian ini dapat dikatakan cukup baik. Pada gambar 6 dapat dilihat grafik simulasi peramalan *Neural Network* dibandingkan dengan RUKN 2019 pada tahun yang sama. Terlihat bahwa hasil simulasi menunjukkan nilai yang lebih tinggi selama tahun 2020 – 2023 namun memiliki nilai lebih rendah selama tahun 2024 – 2030 terhadap peramalan RUKN 2019. Grafik diantara hasil simulasi dan RUKN 2019 pada dapat dikatakan cukup dekat dikarenakan perbedaan yang cukup kecil. Hasil simulasi peramalan menggunakan *Neural Network* menunjukkan peningkatan pada setiap tahunnya.

5. Simpulan

Adapun simpulan yang diperoleh dari penelitian ini yaitu menghasilkan peramalan sebesar 5.772 GWh (sebesar 5.294 GWh pada RUKN 2019) pada tahun 2020,

meningkat menjadi 6.523 GWh (sebesar 6.758 GWh pada RUKN 2019) pada tahun 2025 dan sebesar 8.551 GWh (sebesar 8.836 GWh pada RUKN 2019) pada tahun 2030. MAPE dari peramalan menggunakan *Neural Network* terhadap data asli (*target*) pada tahap pelatihan jaringan peramalan *Neural Network* didapatkan MAPE sebesar 2,75%. Sedangkan MAPE hasil simulasi peramalan *Neural Network* terhadap peramalan RUKN 2019 memberikan MAPE sebesar 3,29%. MAPE hasil peramalan menggunakan *Neural Network* dengan RUKN 2019 memeberikan MAPE yang cukup kecil. MAPE masih berada dibawah ketentuan PLN yaitu 10%, sehingga dapat dikatakan bahwa peramalan kebutuhan energi listrik dengan karakteristik Provinsi Bali menggunakan *Feed-forward Backpropagation* cukup akurat untuk meramalkan kebutuhan energi listrik.

6. Daftar Pustaka

- [1] Binoto, M. (2015). *Peramalan Energi Listrik Yang Terjual Dan Daya Listrik Tersambung Pada Sistem Ketenaglistrikan Untuk Jangka Panjang Di Solo Menggunakan Model Artificial Neural Network*. Pros Iding SNATIF Ke -2, 235–242.
- [2] Zhang, P., & Wang, H. (2012). Fuzzy Wavelet Neural Networks for City Electric Energy Consumption Forecasting. *Energy Procedia*, 17, 1332–1338. <https://doi.org/10.1016/j.egypro.2012.02.248>
- [3] Rajagukguk, A. S. F., Pakiding, I. M., Rumbayan, E. M., & Eng, M. (2015). *Kajian Perencanaan Kebutuhan Dan Pemenuhan Energi Listrik Di Kota Manado*. *E-Journal Teknik Elektro Dan Komputer*, 4(3), 1–11. <https://doi.org/10.35793/jtek.4.3.2015.7972>
- [4] Yi-Shian, L. & TongL-I (2012). *Forecasting Timeseries Using a Methodology Based on Autoregressive Integrated Moving Average and Genetic Programming*. *Knowl- Based Syst* 2011;24(1) : 66–72
- [5] Fitriyah, Q., & Istardi, D. (2011). *Prediksi Beban Listrik Pulau Bali Dengan Menggunakan Metode Backpropagasi*. *Seminar Nasional Informatika 2011 (SemnasIF 2011)*

- UPN "Veteran" Yogyakarta, 2011(July 2011), 208–214.
- [6] Ambaryana, W, Giriantari IAD, dan Setiawan IN. (2019). *Proyeksi Konsumsi Energi Industri Pengolahan di Bali Sampai Dengan Tahun 2050 Menggunakan Software LEAP*. Jurnal SPEKTRUM, Vol. 6, No. 4, Desember 2019.
- [7] Somantri, O. (2015). *Prediksi Kebutuhan Permintaan Energi Listrik Menggunakan Neural Network Berbasiskan Algoritma Genetika*. September, 1–135.
- [8] Putra, N. (2018). *Analisis Prakiraan Kebutuhan Dan Penyediaan Energi Listrik Di Provinsi Riau Tahun 2018 - 2022 Menggunakan Perangkat Lunak LEAP*. Riau : Universitas Islam Negeri Sultan Syarif Kasim
- [9] Sekjen Dewan Energi Nasional, 2019. *Indonesia Energy Outlook 2019*. Jakarta Selatan : DEN
- [10] Kartika, S. (2018). *Analisis Konsumsi Energi dan Program Konservasi Energi (Studi Kasus: Gedung Perkantoran dan Kompleks Perumahan TI)*. Sebatik, 22(2), pp. 41-50.
- [11] Badan Pusat Statistik Provinsi Bali, (2019). *Provinsi Bali Dalam Angka 2001 - 2019*. Provinsi Bali.
- [12] Pemerintah Provinsi Bali. 2018. Draft Rencana Umum Energi Daerah (RUED) Provinsi Bali tahun 2018. Provinsi Bali.
- [13] Render, B. & Heizer, J. (2005). *Prinsip-Prinsip Manajemen Operasi (Edisi ke-7, Buku ke-1)*. Jakarta: Salemba Empat.
- [14] Ryandhi, R. (2017). *Penerapan Metode Artificial Neural Network (ANN) Untuk Peramalan Inflasi di Indonesia*. Surabaya : Institut Teknologi Sepuluh Nopember.
- [15] Nakama, T. (2012). Systematic comparisons of single- and multiple-hidden-layer neural networks. *Neurocomputing: Learning, Architectures and Modeling*, 1, 147–162.
- [16] Kristianto, A. dkk. (2018). *Aplikasi Jaringan Syaraf Tiruan untuk Proyeksi Kebutuhan Enargi Listrik Provinsi D. I. Yogyakarta Tahun 2016 – 2025*. *Transient*, Vol. 7, No. 2, Juni 2018.