

## Studi prakiraan beban listrik menggunakan metode artificial neural network

Yuan Octavia D.P.<sup>1</sup>, A.N. Afandi<sup>2</sup>, Hari Putranto<sup>3</sup>

1. Universitas Negeri Malang, Indonesia | [yuan.odpgmail.com](mailto:yuan.odpgmail.com)
2. Universitas Negeri Malang, Indonesia | [an.afandium.ac.id](mailto:an.afandium.ac.id)
3. Universitas Negeri Malang, Indonesia | [harput160661gmail.com](mailto:harput160661gmail.com)

### Abstrak

Pada penelitian ini, dilakukan prakiraan beban listrik jangka panjang menggunakan metode Artificial Neural Network (ANN) dengan penerapan algoritma backpropagation pada studi kasus distribusi energi listrik Area Mojokerto. Pada penelitian ini digunakan 8 variabel, dimana untuk variabel dependent berupa beban listrik, sedangkan untuk variabel independent digunakan 7 variabel yaitu jumlah penduduk, PDRB, jumlah pelanggan sektor rumah tangga, jumlah pelanggan sektor industri, jumlah pelanggan sektor usaha, jumlah pelanggan sektor sosial, dan susut distribusi. Berdasarkan hasil percobaan beberapa arsitektur ANN, diperoleh hasil MAPE pengujian terbaik sebesar 0.512% yang berarti memiliki tingkat akurasi tinggi. Hal ini berarti metode ANN dengan algoritma backpropagation dapat diterapkan sebagai metode prakiraan beban listrik untuk studi kasus pada distribusi energi listrik Area Mojokerto. Model ANN-backpropagation terbaik pada penelitian ini adalah variasi bobot dan bias awal diatur secara manual dengan modifikasi menggunakan algoritma inisialisasi Nguyen Widrow, jaringan memiliki 2 hidden layer dengan penyusunan 5 neuron pada hidden layer 1 dan 15 neuron pada hidden layer 2, nilai learning rate dan momentum berturut-turut adalah 0.9 dan 0.1. Berdasarkan arsitektur ANN terbaik, prakiraan beban listrik distribusi area Mojokerto pada tahun 2018 sampai dengan 2030 cenderung mengalami kenaikan dari tahun ke tahun, meskipun ada penurunan sebesar 0.157% dari tahun 2027 ke tahun 2028. Hasil prakiraan terendah ada pada tahun 2018 dengan hasil 312.7489 MW dan beban tertinggi ada pada tahun 2030 dengan hasil 383.5597MW. Hasil prakiraan beban listrik Area Mojokerto dari tahun 2018 sampai dengan 2030 mengalami kenaikan sebesar 22.641% dengan kenaikan rata-rata 1.728% per tahunnya.

### Kata Kunci

Prakiraan, Artificial Neural Network, Beban Listrik

## 1. Pendahuluan

Kebutuhan masyarakat akan energi listrik terus mengalami peningkatan dari tahun ke tahun. Jumlah pelanggan Perusahaan Listrik Negara (PLN) pada tahun 2011 s.d. 2015 mengalami peningkatan lebih dari 33 persen (Direktorat Jendral Ketenagalistrikan, 2016). Dengan meningkatnya jumlah pelanggan, mengharuskan PLN dapat memenuhi seluruh kebutuhan permintaan energi listrik secara kontinyu.

Penyaluran energi listrik secara kontinyu merupakan hak-hak pelanggan PLN yang harus diprioritaskan oleh pihak PLN sebagai penyedia utama energi listrik di Indonesia (UUD RI, 2009). Untuk dapat memenuhi kebutuhan energi listrik secara kontinyu, maka diperlukan keseimbangan antarsupply and demand. Dengan demikian, daya yang dibangkitkan harus selalu sama dengan daya yang dikonsumsi oleh konsumen listrik (Marsudi, 1990). Oleh karenanya, diperlukan prakiraan beban listrik yang dapat memprakirakan kebutuhan beban listrik.

Prakiraan beban listrik bertujuan untuk memprakirakan kebutuhan listrik dalam jangka waktu tertentu. Prakiraan beban listrik dilakukan untuk memprakirakan kebutuhan beban pada suatu sektoral (distribusi atau wilayah) dan memegang peranan penting dalam perencanaan serta fungsi keamanan dari manajemen energi. Dengan prakiraan beban listrik yang akurat dapat menghemat biaya operasional dan kondisi aman, baik oleh sisi supply maupun demand. Prakiraan beban listrik juga dapat digunakan sebagai acuan Rencana Operasi oleh PLN dalam perencanaan kebutuhan bahan bakar maupun anggaran tahunan.

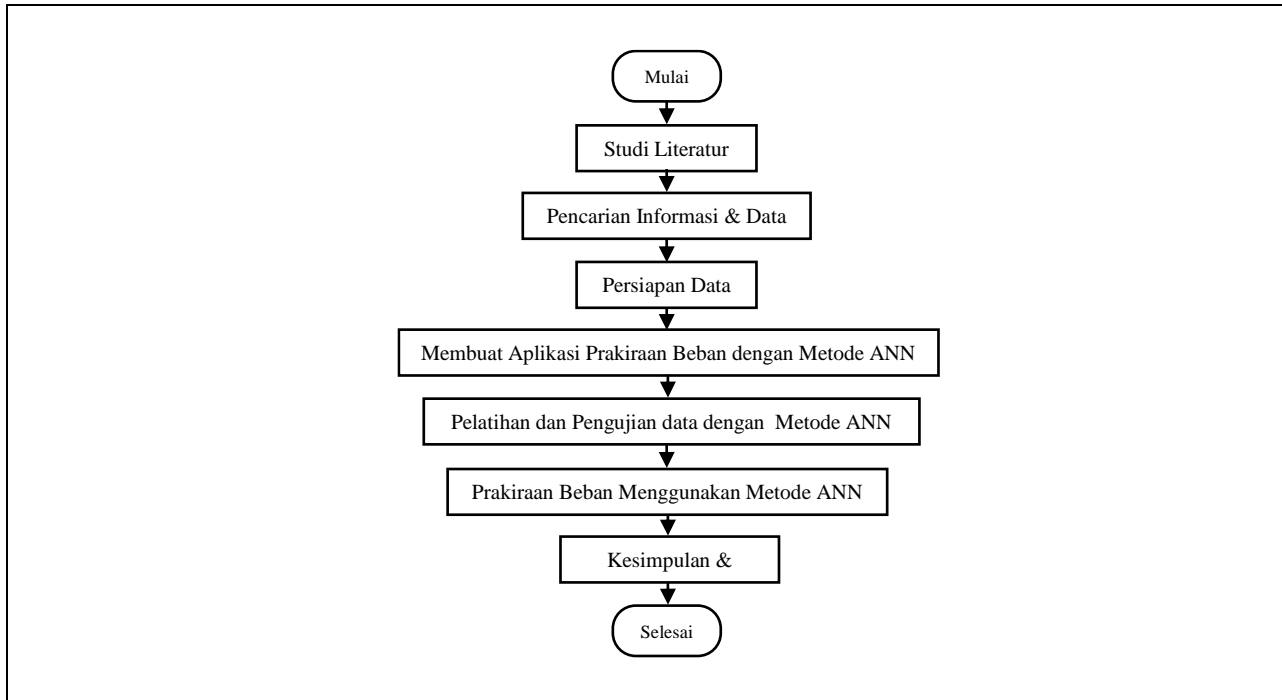
Dalam penerapannya, prakiraan beban listrik dikategorikan dalam model kausal dan model runtut waktu (Mukhyi, 2008). Model kausal prakiraan didasarkan pada hubungan antara variabel yang terlibat, sedangkan pada model runtut waktu prakiraan didasarkan pada data historis dari variabel tanpa dipengaruhi oleh variabel lain. Prakiraan beban listrik berbasis kausal mungkin untuk dilakukan karena didasarkan pada konsumsi energi listrik (Binoto, 2015; Setiabudi, 2015) jangka panjang yang dipengaruhi oleh pola perilaku masyarakat yang berubah-ubah bergantung dengan faktor lain seperti pertumbuhan penduduk, PDRB (Aji, 2010; Iqbal, 2013; Kebijakan Kementerian Energi dan Sumber Daya Mineral Direktorat Jenderal Ketenagalistrikan, 2016) dan lain sebagainya (Suswanto, 2009).

Ada beberapa metode prakiraan berbasis kausal yang dapat digunakan dalam pengambilan keputusan. Metode yang rumit, tidak menjamin tingkat akurasi yang tinggi dari hasil prakiraan (Fitriani, dkk, 2015). Salah satu metode yang dapat diterapkan sebagai prakiraan beban adalah Artificial Neural Network (ANN) dengan algoritma backpropagation (Kuldeep & Anitha, 2018). ANN-backpropagation dinilai cukup efektif digunakan sebagai metode prakiraan karena memiliki kemampuan komputasi yang paralel dengan cara belajar dari pola-pola yang diajarkan (Sutojo dkk, 2014; Siang J, 2005). Hal ini dibuktikan dalam penerapannya sebagai metode prakiraan, tingkat error hasil prakiraan bernilai cukup kecil (Triwulan dkk, 2013; Mataram, 2008). Dengan demikian, memungkinkan ANN dapat melakukan prakiraan beban listrik dengan baik.

## 2. Metode

### Kerangka

Gambar 1. menunjukkan kerangka penelitian.



Gambar 1. Blok Diagram Kerangka Penelitian

### Data Penelitian

Dalam penelitian ini diperlukan data yang mendukung dan dapat digunakan dalam melaksanakan proses penelitian. Pada penelitian ini digunakan 8 variabel, dimana untuk variabel dependent berupa beban listrik, sedangkan untuk variabel independent digunakan 7 variabel yaitu jumlah penduduk, PDRB, jumlah pelanggan sektor rumah tangga, jumlah pelanggan sektor industri, jumlah pelanggan sektor usaha, jumlah pelanggan sektor sosial, dan susut distribusi. Data yang akan digunakan merupakan data dalam periode waktu tahunan pada tahun 2000 sampai dengan 2017.

Informasi data beban harian listrik dan kondisi lapangan diperoleh dari PT. PLN (Persero) APD Jawa Timur, PT. PLN (Persero) Area Mojokerto, dan Badan Pusat Statistik (BPS) Kota Mojokerto, BPS Kabupaten Mojokerto, BPS Kabupaten Jombang, dan BPS Kabupaten Nganjuk (PT. PLN Jawa Timur, 2018). Data beban listrik, data jumlah pelanggan, dan data susut distribusi yang digunakan merupakan data historis beban listrik pada distribusi listrik Area Mojokerto. Data jumlah penduduk dan PDRB merupakan data hasil pencatatan statistik Kota Mojokerto, Kabupaten Mojokerto, Kabupaten Jombang dan Kabupaten Nganjuk.

## Pengolahan Data Awal

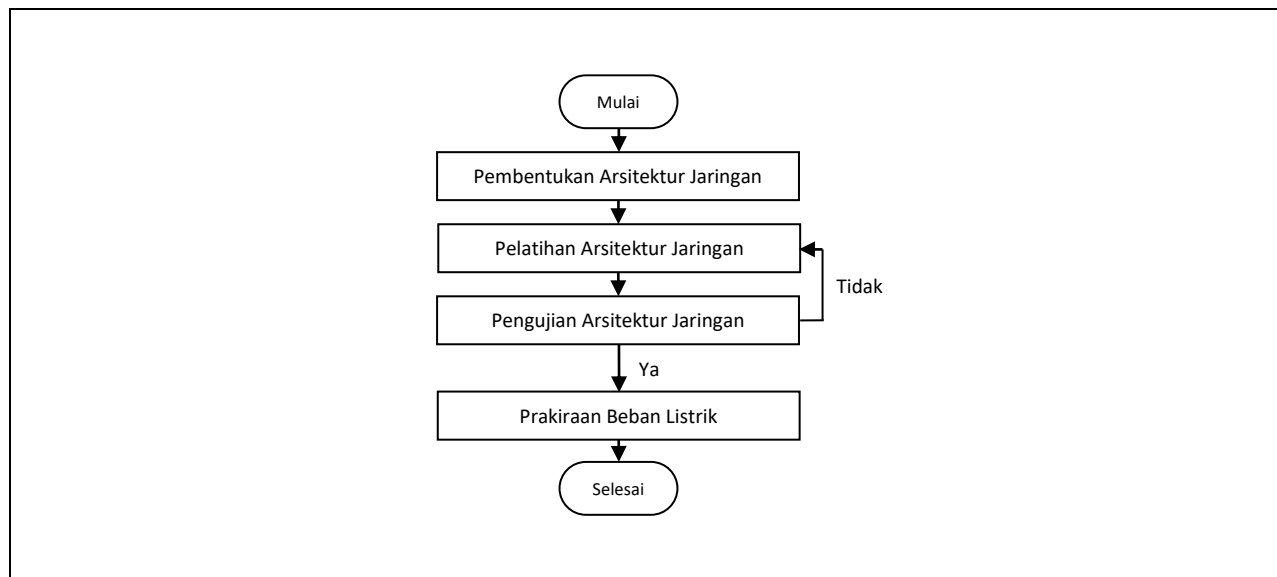
Pada penelitian ini, prakiraan beban dilakukan menggunakan metode ANN-backpropagation yang mana fungsi aktivasi yang digunakan adalah sigmoid biner (Sutojo dkk, 2014). Maka diharuskan mentransformasi data untuk menyesuaikan range keluarannya menjadi (0,1). Persamaan 1 adalah persamaan transformasi data.

$$x' = (0.8(x-a))/(b-a) + 0.1 \dots \dots \dots \text{Pers(1)}$$

Nilai a menunjukkan data minimum dan nilai b menunjukkan nilai maksimum, sedangkan x adalah data yang ditransformasikan dan x' adalah hasil transformasi.

## Analisis Data

Gambar 2 menunjukkan tahapan prakiraan beban.



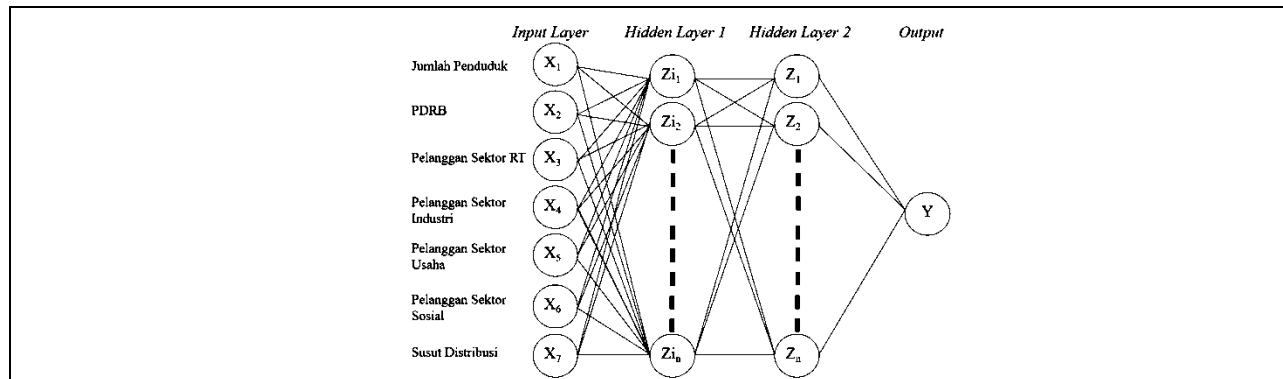
**Gambar 2.** Tahapan Prakiraan Beban

### 1. Pembentukan Arsitektur Jaringan

Pembentukan arsitektur jaringan terbaik didasarkan pada model kuantitatif manakah yang paling mudah beradaptasi pada setiap kemungkinan. Pemodelan ANN-backpropagation yang digunakan pada penelitian ini media bantu software aplikasi. Gambar 3. menunjukkan arsitektur jaringan. Sedangkan Tabel 1. menunjukkan susunan arsitektur jaringan.

Tahapan klasifikasi dokumen pada sistem digambarkan oleh Gambar 1. Pada tahap *training*, judul skripsi dan tugas akhir dikelompokkan ke dalam sembilan kategori yang telah ditentukan, kemudian dianalisis guna membentuk aturan klasifikasi (*classifier*). Pada tahap klasifikasi,

sebuah dokumen baru yang belum dikenali dikelompokkan ke dalam kategori tertentu menggunakan *classifier*.



**Gambar 3.** Arsitektur Jaringan

**Tabel 1.** Arsitektur ANN-backpropagation

Parameter	Jumlah	Deskripsi
<i>Input Layer</i>	7 <i>Neuron</i>	1. Data jumlah penduduk
		2. Data PDRB
		3. Data pelanggan sektor RT
		4. Data pelanggan sektor Industri
		5. Data pelanggan sektor usaha
		6. Data pelanggan sektor social
		7. Data susut distribusi
<i>Hidden Layer</i>	1 sampai 2 <i>Hidden Layer</i>	Hasil Percobaan
<i>Output Layer</i>	1 <i>Neuron</i>	Prakiraan beban
Iterasi	Percobaan untuk jumlah iterasi <i>Traingdx</i>	Setting iterasimaksimum
Fungsi <i>Training</i>	Percobaan untuk nilai <i>Learning Rate</i> dan <i>Momentum</i>	Hasil Percobaan
Fungsi <i>Aktivasi</i>	Sigmoid Biner dan Pureline	-

## 2. Pelatihan dan Pengujian Arsitektur Jaringan

Hasil pelatihan yang didapatkan berupa pembaruan bobot jaringan yang akan digunakan dalam tahapan pengujian. Hasil pelatihan diterapkan pada pola data pengujian. Hal ini untuk melihat apakah bobot dan bias dapat digunakan dan menunjukkan hasil baik untuk data diluar data input pelatihan. Pada pengujian hanya diterapkan fase *feedforward*. Tabel 2. menunjukkan penyusunan pola input dan target pelatihan, sedangkan Tabel 3. menunjukkan penyusunan pola input dan target pengujian pada penelitian ini.

**Tabel 2.** Pola Data Input dan Target Pelatihan

Pola	Data Masukan	Target
1.	X1-X7 adalah Variabel independent pada tahun 2000	Variabel dependent pada tahun 2000
2.	X1-X7 adalah Variabel independent pada tahun 2001	Variabel dependent pada tahun 2001
.	.	.
9.	X1-X7 adalah Variabel independent pada tahun 2008	Variabel dependent pada tahun 2008

**Tabel 3.** Pola Data Input dan Target Pelatihan

Pola	Data Masukan	Target
1.	X1-X7 adalah Variabel independent pada tahun 2009	Variabel dependent pada tahun 2009
2.	X1-X7 adalah Variabel independent pada tahun 2010	Variabel dependent pada tahun 2010
.	.	.
9.	X1-X7 adalah Variabel independent pada tahun 2017	Variabel dependent pada tahun 2017

### 3. Prakiraan Beban Listrik

Model dengan tingkat pengenalan terbaik dalam proses pengujian akan digunakan untuk proses prakiraan dimasa yang akan datang. Tujuan dari prakiraan ini adalah untuk memprakirakan beban listrik untuk beberapa tahun kedepan, yang pada penelitian ini adalah dari tahun 2018 sampai dengan tahun 2030. Pada tahapan ini, masukan dari prakiraan diperoleh dengan prakiraan berbasis *time series* dengan metode ANN *backpropagation* pada setiap variabel masukannya. Selanjutnya hasil prakiraan setiap variabel digunakan untuk prakiraan beban listrik.

### 3. Hasil

Studi prakiraan beban listrik (Stevenson, 1983) menggunakan metode *Artificial Neural Network* (ANN) dengan algoritma *backpropagation*. Pada penelitian yang dilakukan memiliki beberapa tahapan, antara lain yaitu (1) pengolahan data awal, (2) mencari arsitektur jaringan terbaik dari ANN-*backpropagation* sebagai metode prakiraan beban listrik pada suatu area distribusi, dan (3) prakiraan beban listrik pada suatu area distribusi pada tahun 2018 sampai dengan tahun 2030.

#### Pengolahan Data Awal

Dalam prakiraan beban listrik dengan metode ANN, data akan dibagi menjadi dua untuk keperluan pelatihan dan pengujian. Pada penelitian ini, pelatihan menggunakan data historis tahun 2000 sampai dengan 2008, sedangkan pengujian menggunakan data historis tahun 2009 sampai dengan 2017. Keseluruhan data yang didapat diperlukan transformasi data sesuai persamaan 3.1. Transformasi data dilakukan pada setiap variabel.

## Mencari Arsitektur ANN Terbaik

Studi prakiraan beban listrik pada penelitian ini dilakukan menggunakan metode ANN dengan algoritma *backpropagation*. Pelatihan dan pengujian dilakukan beberapa kali (*trial and error*) untuk mendapatkan nilai *Mean Absolute Percentage Error* (MAPE) (Vananjakshi, 2004) terendah hasil pengujian berdasarkan pelatihan. Percobaan yang dilakukan antara lain yaitu:

### 1) Penentuan Bobot Dan Bias Awal

Pada penelitian ini, untuk menentukan bobot dan bias awal dilakukan dengan dua cara, yaitu bobot dan bias awal ditentukan secara acak dari *software* dan pengaturan bobot dan bias awal secara manual dengan modifikasi menggunakan algoritma inialisasi Nguyen Widrow.

Pengaturan arsitektur jaringan pada percobaan untuk satu *hidden layer* yaitu 7-15-1, *lr* 0.3, *mc* 0.7, dan 10000 iterasi. Sedangkan arsitektur jaringan pada percobaan untuk dua *hidden layer* yaitu 7-20-15-1, *lr* 0.3, *mc* 0.7, dan 10000 iterasi. Tabel 4. menunjukkan nilai MAPE (Gatriansyah, 2017) hasil pengujian terhadap pelatihan yang dilakukan berdasarkan penentuan nilai bobot dan bias awal.

**Tabel 4.** MAPE Pengujian Berdasarkan Bobot dan Bias Awal

Percobaan Ke-	Acak		Inialisasi Nguyen Windrow	
	MAPE (%)	MAPE (%)	MAPE (%)	MAPE (%)
	7-15-1	7-20-15-1	7-15-1	7-20-15-1
1	4,158	4,856		
2	2,361	4,254		
3	3,440	4,689		
4	3,740	3,427		
5	2,717	2,522		
6	4,463	4,551	1,023	1,118
7	6,602	6,625		
8	4,978	3,738		
9	2,992	4,063		
10	13,178	2,141		
<i>Min</i> MAPE	2,361	2,141	1,023	1,118
<i>Max</i> MAPE	13,178	6,625	1,023	1,118
<i>Ave</i> MAPE	4,863	4,087	1,023	1,118

Berdasarkan Tabel, hasil MAPE pengujian terhadap pelatihan yang dilakukan dengan penentuan bobot dan bias awal menggunakan modifikasi algoritma inialisasi Nguyen Widrow

menunjukkan nilai MAPE yang lebih kecil daripada nilai *min*, *max*, dan *ave* MAPE menggunakan bobot dan bias awal acak oleh *software*.

## 2) Penentuan Kombinasi Jumlah Neuron Pada Hidden Layer

Pengaturan arsitektur jaringan pada percobaan yaitu bobot dan bias diatur menggunakan inisias Nguyen Widraw dengan *layer* 7-20-15-1, *lr* 0.3, *mc* 0.7, dan 10000 iterasi. Tabel 5. menunjukkan MAPE hasil pengujian terhadap pelatihan berdasarkan kombinasi *neuronhidden*.

**Tabel 5.** MAPE Pengujian Berdasarkan Neuron Hidden

No.	Arsitektur		No.	Arsitektur	
	<i>Input</i> -HL- <i>Output</i> / <i>Input</i> -HL1-HL2- <i>Output</i>	MAPE (%)		<i>Input</i> -HL- <i>Output</i> / <i>Input</i> -HL1-HL2- <i>Output</i>	MAPE (%)
1	7-5-1	1,368	16	7-15-5-1	1,127
2	7-10-1	1,194	17	7-15-10-1	1,384
3	7-15-1	1,023	18	7-15-15-1	1,217
4	7-20-1	1,021	19	7-15-20-1	1,076
5	7-25-1	1,275	20	7-15-25-1	1,015
6	7-5-5-1	1,137	21	7-20-5-1	1,065
7	7-5-10-1	1,024	22	7-20-10-1	1,250
8	7-5-15-1	0,916	23	7-20-15-1	1,118
9	7-5-20-1	1,131	24	7-20-20-1	0,951
10	7-5-25-1	1,069	25	7-20-25-1	1,093
11	7-10-5-1	1,182	26	7-25-5-1	1,165
12	7-10-10-1	1,604	27	7-25-10-1	1,189
13	7-10-15-1	2,206	28	7-25-15-1	1,218
14	7-10-20-1	1,222	29	7-25-20-1	1,118
15	7-10-25-1	1,267	30	7-25-25-1	1,093
				<i>Min</i> MAPE	0,916
				<i>Max</i> MAPE	2,206
				<i>Ave</i> MAPE	1,191

Berdasarkan Tabel, MAPE terendah diperoleh pada percobaan ke-8 dengan kombinasi 7-5-15-1. Sedangkan MAPE tertinggi diperoleh dari percobaan ke-12 dengan kombinasi 7-10-10-1.

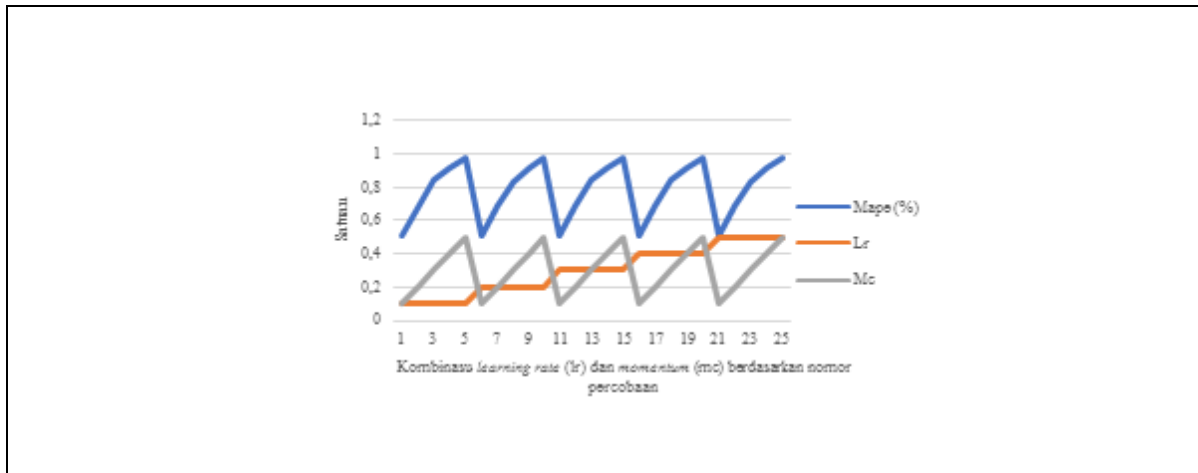
## 3) Penentuan Kombinasi Nilai Learning Rate Dan Momentum

Pengaturan arsitektur jaringan yaitu bobot dan bias diatur menggunakan inisias Nguyen Widraw dengan *layer* 7-5-15-1, *lr* 0.3, *mc* 0.7, dan 10000 iterasi. Tabel 6. dan Gambar 4. menunjukkan MAPE hasil pengujian terhadap pelatihan berdasarkan *learning rate* dan *momentum*.



**Tabel 6.** MAPE Pengujian Berdasarkan *Learning Rate* dan *Momentum*

No.	Arsitektur	MAPE (%)
	<i>Learning Rate / Momentum</i>	
1	0,1/0,1	0,514
2	0,1/0,3	0,682
3	0,1/0,5	0,839
4	0,1/0,7	0,916
5	0,1/0,9	0,979
6	0,3/0,1	0,514
7	0,3/0,3	0,687
8	0,3/0,5	0,838
9	0,3/0,7	0,916
10	0,3/0,9	0,980
11	0,5/0,1	0,515
12	0,5/0,3	0,685
13	0,5/0,5	0,840
14	0,5/0,7	0,915
15	0,5/0,9	0,980
16	0,7/0,1	0,512
17	0,7/0,3	0,685
18	0,7/0,5	0,839
19	0,7/0,7	0,919
20	0,7/0,9	0,979
21	0,9/0,1	0,512
22	0,9/0,3	0,685
23	0,9/0,5	0,838
24	0,9/0,7	0,917
25	0,9/0,9	0,980
<i>Min MAPE</i>		0,512
<i>Max MAPE</i>		0,980
<i>Ave MAPE</i>		0,787



**Gambar 4.** Grafik MAPE Pengujian Berdasarkan Learning Rate dan Momentum

Berdasarkan Tabel dan Gambar, MAPE terendah diperoleh dari percobaan ke-21 dengan kombinasi nilai 0.9 untuk *learning rate* dan 0.1 untuk *momentum*. Sedangkan MAPE tertinggi diperoleh dari percobaan ke-15 dengan kombinasi nilai 0.5 untuk *learning rate* dan 0.9 untuk *momentum*. Pada Gambar 2 juga dapat dilihat jika semakin tinggi nilai *momentum* maka nilai MAPE yang dihasilkan juga semakin tinggi, sebaliknya semakin tinggi nilai *learning rate* maka nilai MAPE yang dihasilkan semakin rendah.

#### 4) Penentuan Jumlah Iterasi

Pengaturan arsitektur jaringan yaitu bobot dan bias diatur menggunakan inisias Nguyen Widraw dengan *layer* 7-5-15-1, *lr* 0.9, *mc* 0.1. Tabel 7. menunjukkan MAPE hasil pengujian terhadap pelatihan berdasarkan iterasi.

**Tabel 7.** MAPE Pengujian Berdasarkan Iterasi

Epoch	Status Pelatihan	Waktu Pelatihan Dihentikan (s)	Waktu untuk 1 iterasi (s)	MAPE (%)
5000	Iterasi	17	0,003	0,838
7500	Iterasi	24	0,003	0,518
10000	Iterasi	33	0,003	0,512
20000	Iterasi	68	0,003	0,882
30000	Iterasi	102	0,003	0,984
100000	Goal di Iterasi 94900	523	0,006	1,367
<i>Min</i> MAPE				0,512
<i>Max</i> MAPE				1,367
<i>Ave</i> MAPE				0,850


Pada Tabel dapat dilihat jika semakin banyak jumlah iterasi yang diatur, membutuhkan waktu yang semakin lama untuk jaringan melakukan proses pelatihan. Jaringan yang mencapai nilai *goal* tidak menjamin memiliki akurasi yang tinggi dalam pengenalan pola, sebagaimana ditunjukkan pada percobaan ke-6. Nilai *minimum* MAPE sebesar 0.512% dengan pengaturan iterasi sebanyak 10000. Nilai *maximum* MAPE sebesar 1.367% dengan pengaturan iterasi sebanyak 100000.

## Prakiraan Beban

Pengaturan arsitektur jaringan berdasarkan arsitektur terbaik yaitu bobot dan bias diatur menggunakan inisias Nguyen Widraw dengan *layer* 7-5-15-1, *lr* 0.9, *mc* 0.1, 10000 iterasi. Tabel 8. menunjukkan hasil prakiraan beban listrik area Mojokerto tahun 2018 sampai dengan tahun 2030 menggunakan metode ANN-*backpropagation*, sedangkan Gambar 5. menunjukkan grafik pola prakiraan beban listrik area Mojokerto tahun 2018 sampai dengan tahun 2030 menggunakan metode ANN-*backpropagation*.

**Tabel 8.** Prakiraan Beban Listrik Area Mojokerto Tahun 2018 s.d 2030

Tahun	Prakiraan Beban (MW)	Prosentase Kenaikan Beban Per Tahun (%)
2018	312,7489	-
2019	329,6183	5,394
2020	343,0768	4,083
2021	352,4419	2,730
2022	359,5960	2,030
2023	365,9111	1,756
2024	369,5645	0,998
2025	372,3597	0,756
2026	378,7624	1,719
2027	380,8354	0,547
2028	380,2382	-0,157
2029	381,2301	0,261
2030	383,5597	0,611
Prosentase Rata-rata Kenaikan Beban per Tahun (%)		1,728
Prosentase Kenaikan Beban Tahun 2018 s.d. 2030 (%)		22,641



**Gambar 5.** Grafik Pola Prakiraan Beban Listrik Area Mojokerto Tahun 2018 s.d 2030

Berdasarkan Tabel dan Gambar, prakiraan beban listrik Area Mojokerto menggunakan metode *ANN-backpropagation* cenderung mengalami kenaikan pertahunnya yang ditunjukkan dengan prosentase kenaikan tahunan bernilai positif, namun terdapat prosentase kenaikan tahunan yang bernilai negatif, yaitu dari tahun 2027 ke tahun 2028 yang berarti prakiraan kebutuhan beban listrik mengalami penurunan sebesar sebesar 0.157%. Hasil prakiraan beban listrik terendah ada pada tahun 2018 dengan hasil 312.7489MW dan beban tertinggi ada pada tahun 2030 dengan hasil 383.5597 MW. Hasil prakiraan beban listrik Area Mojokerto dari tahun 2018 sampai dengan 2030 mengalami kenaikan sebesar 22.641% dengan kenaikan rata-rata 1.728% per tahunnya.

#### 4. Kesimpulan

Berdasarkan pembahasan yang telah dipaparkan, dapat ditarik kesimpulan sebagai berikut ini.

1. Hasil percobaan beberapa arsitektur ANN untuk studi prakiraan beban listrik pada sistem distribusi energi listrik area Mojokerto menghasilkan MAPE pengujian terbaik sebesar 0.512% yang berarti memiliki tingkat akurasi tinggi. Metode ANN dengan algoritma *backpropagation* dapat diterapkan sebagai metode prakiraan beban listrik untuk studi kasus pada distribusi energi listrik Area Mojokerto. Percobaan menghasilkan arsitektur jaringan ANN terbaik sebagai berikut ini.
  - a. Variasi bobot dan bias awal diatur secara manual dengan modifikasi menggunakan algoritma inisialisasi Nguyen Widrow.
  - b. Jumlah *neuron* pada *hidden* 1 yaitu 5 *neuron* dan pada *hidden layer* 2 yaitu 15 *neuron*.
  - c. Kombinasi *learning rate* dan *momentum* yaitu 0.9 untuk *learning rate* dan 0.1 untuk *momentum*.
  - d. Jumlah iterasi maksimum yaitu 10000 iterasi.
2. Berdasarkan arsitektur jaringan ANN terbaik, prakiraan beban listrik distribusi area Mojokerto pada tahun 2018 sampai dengan 2030 cenderung mengalami kenaikan dari tahun ke tahun, meskipun ada penurunan sebesar 0.157% dari tahun 2027 ke tahun 2028.

Hasil prakiraan terendah ada pada tahun 2018 dengan hasil 312.7489 MW dan beban tertinggi ada pada tahun 2030 dengan hasil 383.5597 MW. Hasil prakiraan beban listrik Area Mojokerto dari tahun 2018 sampai dengan 2030 mengalami kenaikan sebesar 22.641% dengan kenaikan rata-rata 1.728% per tahunnya.

## Daftar Rujukan

- Direktorat Jendral Ketenagalistrikan. 2016. *Statistik Ketenagalistrikan Tahun Anggaran 2016*. Jakarta: Kementerian Energi dan Sumber Daya Mineral.
- Undang-undang Republik Indonesia Pasal 29 Nomor 30 Tahun 2009 tentang Sistem Kelistrikan. (online), (<http://djke.esdm.go.id/>), diakses 29 September 2017.
- Marsudi, D. 1990. *Operasi Sistem Tenaga Listrik*. Jakarta: ISTN.
- Mukhyi, M, A. 2008. *Forecasting*, (Online), ([mukhyi.staff.gunadarma.ac.id/Downloads/files/9309/FORECASTING.pdf](http://mukhyi.staff.gunadarma.ac.id/Downloads/files/9309/FORECASTING.pdf)), diakses 5 Oktober 2017.
- Suswanto, D. 2009. *Sistem Distribusi Tenaga Listrik*, Edisi Pertama, Diktat kuliah: Universitas Negeri Padang.
- Fitriani, B. E., Ispriyanti, D., & Prahutama, A. 2015. Peramalan Beban Pemakaian Listrik Jawa Tengah dan Daerah Istimewa Yogyakarta Dengan Menggunakan Hybrid Autoregressive Integrated Moving Average – Neural Network. *Jurnal Gaussian*, Vol: 4 (No. 4). Dari <http://ejournal-s1.undip.ac.id/index.php/gaussian>.
- Kuldeep, S., & Anitha, G. S. 2018. Short Term Load Forecasting Using Time Series Neural Network. *Proceedings of Conference for a 3<sup>rd</sup> International Conference*. Dari [http://researchgate.net/publication/319903506\\_SHORT\\_TERM\\_LOAD\\_FORECASTING\\_METHODS\\_A\\_COMPARATIVE\\_STUDY](http://researchgate.net/publication/319903506_SHORT_TERM_LOAD_FORECASTING_METHODS_A_COMPARATIVE_STUDY).
- Sutojo, T., Mulyanto, E., & Suhartono, V. 2014. *Kecerdasan Buatan*. Yogyakarta: Andi.
- Triwulan, Y., Hariyanto, N., & Anwari, S. 2013. Peramalan Beban Puncak Listrik Jangka Pendek Menggunakan Metode Jaringan Syaraf Tiruan. *Jurnal Reka Elkomika*. Dari <http://jurnalonline.itenas.ac.id>.
- Mataram, I. M. 2008. Peramalan Beban Hari Libur Menggunakan Artificial Neural Network. *Jurnal Teknologi Elektro*, Vol: 7 (No.2). Dari <http://ojs.uud.ac.id>.
- Siang, J. J. 2005. *Jaringan Syaraf Tiruan dan Pemrogramannya Menggunakan Matlab*. Yogyakarta: Andi.
- Vanajakshi, L., & Rilett, I. R. 2004. A Comparison Of The Performance Of Artificial Neural Network And Support Vector Machines For The Prediction Of Traffic Speed. *IEEE Intelligent Vehicles Symposium*, pp. 194-199.
- Gustriansyah, R. 2017. Analisis Metode Single Exponential Smoothing dengan Brown Exponential Smoothing pada Studi Kasus Memprediksi Kuantiti Penjualan Produk Farmasi

- di Apotek. *Seminar Nasional Teknologi Informasi dan Multimedia 2017*. Dari <http://researchgate.net/publication/314237520>.
- PT. PLN (Persero) Distribusi Jawa Timur Area Pengatur Distribusi. 2018. *Laporan Bulanan Data Pengusahaan APD Jatim Januari 2018*. Surabaya: Kementerian Badan Usaha Milik Negara.
- Stevenson, W. D. 1983. *Analisis Sistem Tenaga Listrik*. Terjemahan Kamal Idris. Jakarta: Erlangga. Tanpa tahun.
- Aji, C. S. 2010. Faktor-Faktor Yang Mempengaruhi Konsumsi Listrik PLN Pada Kelompok Pelanggan Rumah Tangga (R-1 900 VA) di Kabupaten Purworejo, *skripsi*, Fakultas Ekonomi, Universitas Sebelas Maret, Surakarta.
- Iqbal. 2013. Faktor-Faktor yang Mempengaruhi Pertumbuhan Kontribusi Sektor Listrik dan Air Bersih di Kabupaten Aceh Barat. Universitas Teuku Umar, Meulaboh, Aceh Barat.
- Kebijakan Kementerian Energi dan Sumber Daya Mineral Direktorat Jenderal Ketenagalistrikan dalam Pembangunan Infrastruktur Penyediaan Tenaga Listrik Tahun 2016 tentang Percepatan Akses Energi Indonesia : Opsi Peluang dan Tantangannya*, IESR (online). (<http://goo.gl/4cHeh1>), diakses 28 Maret 2018.
- Binoto, M., & Kristiawan, Y. 2015. Peramalan Energi Listrik yang Terjual dan Daya Listrik Tersambung Pada Sistem Ketenagalistrikan Untuk Jangka Panjang di Solo Menggunakan Metode Artificial Neural Network. *SNATIF 2015*. ISBN: 978-602-1180-21-1.
- Setiabudi, D. 2015. Sistem Informasi Peramalan Beban Listrik Jangka Panjang di Kabupaten Jember Menggunakan JST Backpropagation. *SMARTICS Journal*, Vol: 1 (No. 1). Dari <http://repository.unej.ac.id>.