

Prakiraan Beban Listrik Menggunakan Metode Jaringan Saraf Tiruan dengan Data yang Terbatas

Elang Bayu Trikora¹, Sasongko Pramonohadi², M. Isnaeni Bambang Setyonegoro³

^{1,2,3} Departemen Teknik Elektro dan Teknologi Informasi Fakultas Teknik Universitas Gadjah Mada, Jl. Grafika No. 2 Kampus UGM Yogyakarta 55281 INDONESIA (tel.: 0274-552305; fax: 0274-547506; email: ¹elangbayu2019@mail.ugm.ac.id, ²sasongko@mail.ugm.ac.id, ³isnaeni@mail.ugm.ac.id)

[Diterima: 20 Desember 2022, Revisi: 19 Mei 2023]

Corresponding Author: Elang Bayu Trikora, M. Isnaeni Bambang Setyonegoro

INTISARI — Seiring dengan perkembangan zaman, prakiraan kebutuhan beban listrik menjadi salah satu hal vital dalam perencanaan pembangkitan dan distribusi. Terdapat berbagai macam cara untuk melakukan prakiraan kebutuhan energi listrik. Salah satunya adalah dengan menggunakan metode jaringan saraf tiruan. Metode ini meniru kemampuan otak manusia untuk menerima suatu masukan lalu melakukan pemrosesan di antara neuron yang ada di dalamnya untuk menghasilkan informasi berdasarkan proses yang terjadi di dalam neuron. Tujuan penelitian ini adalah untuk melakukan prakiraan beban listrik di Kabupaten Jayawijaya menggunakan bantuan metode jaringan saraf. Penelitian ini membangun suatu arsitektur jaringan saraf yang sesuai dengan data yang diperoleh dari PT PLN (Persero) UP3 Wamena untuk menemukan model arsitektur yang sesuai dan memiliki tingkat akurasi yang tinggi. Karena data yang dimiliki untuk melakukan prakiraan beban listrik terbatas, dilakukan metode interpolasi berdasarkan data asli yang telah dimiliki untuk menambah jumlah data yang sudah ada. Dengan cara ini, data yang dapat digunakan sebagai masukan akan lebih banyak. Hal ini membuat model yang dibangun dapat melakukan prakiraan kebutuhan beban dengan lebih akurat. Data yang telah diperbanyak ini digunakan sebagai masukan data dalam model jaringan saraf tiruan. Setelah melakukan percobaan berulang-ulang menggunakan jaringan saraf, diperoleh hasil bahwa model yang sesuai dengan data adalah jaringan *feed-forward long short term memory* (LSTM). Dengan menggunakan model ini, dapat diperoleh *error* yang sesuai dengan standar suatu model untuk melakukan prakiraan, yaitu sebesar 0,04% dengan sembilan *epoch*.

KATA KUNCI — Prakiraan Beban, Jaringan Saraf Tiruan, Data Terbatas, Interpolasi.

I. PENDAHULUAN

Seiring dengan kemajuan teknologi, permasalahan pada dunia listrik bertambah banyak dan kompleks. Salah satu masalah yang sering terjadi adalah tidak terpenuhinya kebutuhan energi listrik. Kebutuhan energi listrik bertambah seiring dengan bertambahnya konsumen. Pertumbuhan bisnis, industri, ekonomi, pembangunan daerah, pertumbuhan penduduk, kondisi daerah, standar kehidupan, serta rencana pengembangan sekarang dan di masa yang akan datang membutuhkan prakiraan energi listrik [1].

Dalam rangka memenuhi kebutuhan energi listrik, dibutuhkan prakiraan beban listrik dalam perencanaan kebutuhan dan penyediaan listrik. Untuk melakukan prakiraan beban listrik, dibutuhkan data berbentuk deret waktu (*time series*) dalam kurun waktu tertentu. Data yang digunakan adalah data historis, dengan tujuan untuk mengetahui karakteristik beban listrik rentang waktu sebelumnya untuk memprakirakan beban listrik di masa depan. Selain itu, digunakan juga data karakteristik pengguna listrik, yang meliputi karakteristik pengguna rumah tangga, bisnis, industri, dan umum. Setiap pengguna mempunyai karakteristik beban puncak yang berbeda-beda [2].

Kebutuhan energi listrik bersifat tidak tentu (dinamis), sehingga diperlukan prakiraan pertumbuhan beban listrik dan penyediaan daya listrik yang akan didistribusikan sesuai dengan tuntutan kebutuhan beban listrik. Dalam sistem kelistrikan, prakiraan kebutuhan energi listrik yang tepat sangat dibutuhkan, yaitu jumlah daya listrik yang dibutuhkan untuk melayani beban dan kebutuhan energi listrik dalam distribusi energi listrik. Prakiraan yang terlalu kecil akan menyebabkan tidak cukupnya kapasitas daya yang disalurkan untuk memenuhi kebutuhan beban. Sebaliknya, prakiraan beban yang terlalu besar akan menyebabkan kelebihan kapasitas daya, sehingga menyebabkan kerugian [3].

Kabupaten Jayawijaya, dengan segala keterbatasannya, merupakan daerah yang cepat berkembang dibandingkan kabupaten lain di Pegunungan Tengah, Provinsi Papua. Berdasarkan data dari Dinas Kependudukan dan Catatan Sipil Kabupaten Jayawijaya, rata-rata pertumbuhan penduduk Kabupaten Jayawijaya dari tahun 2013 sampai 2018 sebesar 0,7% per tahun. Pendapatan domestik regional bruto (PDRB) dari tahun 2013 sampai tahun 2018 adalah rata-rata 13,33% per tahun, dengan data beban puncak dari tahun 2013 sampai tahun 2018 adalah rata-rata 12,48%. Hal ini menunjukkan bahwa Kabupaten Jayawijaya mengalami perkembangan di sektor rumah tangga, sektor komersial, sektor publik, dan sektor industri. Sektor-sektor tersebut merupakan konsumen energi listrik di Kabupaten Jayawijaya [4].

Jaringan saraf (*neural network*) merupakan sistem kecerdasan tiruan dengan kemampuan belajar dan menghimpun pengetahuan hasil pembelajaran dalam jaringan selnya (neuron), sehingga memungkinkan jaringan secara keseluruhan semakin cerdas merespons masukan yang diberikan. Kemampuan belajar dan mengakumulasi pengetahuan ini memungkinkan sistem jaringan saraf untuk dapat beradaptasi dengan lingkungan yang memberikan masukan ke dalam sistem.

Penelitian ini bertujuan untuk melakukan prakiraan beban listrik di Kabupaten Jayawijaya menggunakan jaringan saraf serta membangun suatu arsitektur jaringan saraf yang sesuai dengan data yang diperoleh dari PT PLN (Persero) UP3 Wamena agar diperoleh model arsitektur yang sesuai dan memiliki tingkat akurasi yang tinggi. Karena data yang dimiliki untuk melakukan prakiraan beban listrik ini terbatas, perlu dilakukan penambahan jumlah data yang sudah ada menggunakan metode interpolasi data berdasarkan data yang tersedia.

II. METODOLOGI

Penelitian ini dilakukan berdasarkan beberapa penelitian yang telah dilakukan sebelumnya. Salah satu penelitian melakukan prakiraan beban listrik menggunakan metode *long short term memory* LSTM [5]. Penelitian lainnya melakukan prakiraan beban menggunakan metode *convolutional neural network* [6].

Referensi [7] memprakirakan kebutuhan beban listrik jangka pendek dengan menggabungkan beberapa model jaringan saraf berdasarkan karakteristik beban dan faktor eksternal yang memengaruhinya. Model yang diajukan dapat melakukan prakiraan beban dengan baik.

Penelitian prakiraan selanjutnya menggunakan metode *convolutional neural network* dan menggabungkannya dengan *recurrent neural network* [8]. Hasilnya menunjukkan bahwa metode ini dapat melakukan prakiraan beban dengan hasil yang lebih baik dibandingkan dengan model-model jaringan saraf lain yang telah digunakan pada objek penelitian yang sama.

Penelitian mengenai prakiraan beban listrik jangka pendek dengan menggabungkan metode *improved environmental adaptation with real parameter* (IEAM-R) dan *controlled Gaussian mutation* (CGM) juga telah dilakukan [9]. Hasil dari penelitian ini adalah dengan menggabungkan kedua metode, jaringan saraf dapat melakukan prakiraan dengan lebih akurat karena jaringan saraf jenis ini dimodelkan untuk dapat beradaptasi dengan keadaan lingkungan.

A. PRAKIRAAN BEBAN LISTRIK

Prakiraan beban listrik sangat penting dalam perencanaan operasi sistem tenaga listrik. Hasil prakiraan dapat digunakan untuk merencanakan pembangkitan dan merumuskan jadwal pembangkitan yang ekonomis [10], [11]. Tujuan prakiraan beban adalah untuk meningkatkan stabilitas sistem tenaga, meningkatkan keamanan sistem tenaga, mengurangi biaya pembangkitan, meningkatkan efisiensi utilitas secara keseluruhan, dan mencapai kinerja yang optimal melalui manajemen sisi permintaan [12].

Berdasarkan jangka waktu prakiraan dan strategi suplainya, terdapat tiga macam prakiraan beban, yaitu jangka panjang, jangka menengah, dan jangka pendek [13]. Pada umumnya, prakiraan beban listrik menggunakan data runtun waktu (*time series*).

Prakiraan beban jangka pendek memiliki beberapa karakteristik, antara lain sebagai berikut.

- Beban hampir selalu sama dalam periode 24 jam, kesamaan tren dalam minggu yang berbeda pada hari yang sama dalam seminggu, kesamaan tren hari kerja atau hari libur, dan kesamaan tren libur hari besar yang sama di tahun yang berbeda.
- Dipengaruhi oleh berbagai faktor lingkungan (eksternal), seperti perubahan musim, perubahan mendadak faktor cuaca, gangguan atau perbaikan peralatan, dan kegiatan budaya atau olahraga skala besar. Faktor-faktor tersebut dapat menyebabkan beban sistem mengalami variasi yang acak dan berlangsung sementara.

Metode prakiraan menggunakan data runtun waktu memiliki dua karakteristik utama, yaitu struktur modelnya sederhana dan jumlah data yang diperlukan untuk prakiraan beban hanya sedikit. Karena metode prakiraan runtun waktu menekankan data untuk rentang waktu tertentu tanpa memperhatikan faktor eksternal, metode ini dapat menghasilkan *error* yang besar [14].

B. INTERPOLASI

Metode interpolasi adalah metode untuk mencari suatu nilai yang terkait dengan sebuah fungsi interpolasi. Fungsi interpolasi dibentuk oleh sejumlah titik yang memiliki rentang tertentu. Pencarian nilai fungsi terkait dengan titik yang letaknya ada dalam rentang tersebut disebut interpolan [15].

Bentuk paling sederhana dari interpolasi adalah interpolasi yang melibatkan dua titik, (x_1, y_1) dan (x_2, y_2) . Karakteristik keterhubungan dua titik ini diwakili oleh sebuah fungsi linear $y(x)$ yang menghubungkan dua titik tersebut. Fungsi ini disebut sebagai fungsi interpolasi. Nilai fungsi interpolasi di sebuah titik yang absisnya x_3 (letaknya antara x_1 dan x_2) adalah $y(x_3)$, yang disebut sebagai interpolan dari x_3 .

Dalam praktiknya, fungsi interpolasi melibatkan sejumlah titik. Yang umum digunakan adalah interpolasi yang melibatkan tiga titik, sehingga bentuk fungsi interpolasinya adalah kuadratik. Pendekatan kuadratik lebih mencerminkan karakteristik sebaran titik [16] karena pada prakteknya titik-titik ini tersebar melalui pola acak. Diharapkan, interpolan akan mengikuti fungsi ini, yang lebih mencerminkan besaran-besaran praktis sehari-hari. Pencarian fungsi kuadratik dapat dilakukan melalui proses *curve fitting*. Nilai parameter fungsi kuadratik ditentukan atas dasar prinsip *least squares error*.

C. JARINGAN SARAF TIRUAN

Jaringan saraf adalah sebuah kecerdasan tiruan yang memiliki kemampuan untuk belajar dan memproses pengetahuan hasil pembelajaran dalam jaringannya, sehingga memungkinkan seluruh jaringan makin tanggap merespons masukan yang diberikan. Kemampuan kecerdasan tiruan dalam belajar dan memproses pengetahuan membuat jaringan saraf dapat beradaptasi dengan kumpulan variabel yang memberikan masukan ke dalamnya. Kecerdasan ini mencontoh prinsip kerja yang ada pada otak manusia dalam merespons kondisi yang berbeda-beda. Peranan jaringan saraf dalam bidang ilmu pengetahuan di masa depan sangat penting, sebagai akibat tuntutan aspek otomasi antara manusia dan alat [17]. Hasil kerja jaringan saraf dinilai dari tiga poin, yaitu arsitektur jaringan, metode pelatihan, dan fungsi aktivasi.

Di dalam sistem ini, kumpulan neuron membentuk lapisan (*layer*) yang bernama lapisan neuron. Setiap lapisan terhubung antara yang satu dan yang lainnya. Informasi dirambatkan dari satu lapisan ke lapisan berikutnya, mulai dari lapisan masukan, lapisan tersembunyi, kemudian lapisan keluaran.

Neuron adalah unit pemrosesan informasi yang merupakan dasar dari jaringan saraf. Jaringan saraf sendiri terdiri atas tiga elemen, yaitu sebagai berikut [18]. Elemen pertama adalah satu set unit yang dihubungkan oleh garis penghubung. Garis-garis ini memiliki bobot yang berbeda. Bobot dengan nilai positif memperkuat sinyal dan yang bernilai negatif melemahkan sinyal. Elemen kedua merupakan unit penjumlahan. Unit ini menjumlahkan sinyal masukan yang telah dikalikan berdasarkan bobotnya. Elemen ketiga adalah fungsi aktivasi yang menentukan keluaran neuron. Arsitektur jaringan saraf yang sering digunakan adalah jaringan lapisan tunggal (*single layer network*), jaringan lapisan jamak (*multilayer network*), dan model jaringan *recurrent*.

Dalam jaringan saraf, jaringan lapisan tunggal ini adalah yang paling sederhana. Neuron yang ada pada lapisan masukan langsung diproses menuju lapisan keluaran tanpa adanya umpan balik [19]. Apabila pada lapisan tunggal ditambahkan lapisan tersembunyi selain lapisan masukan dan keluaran, kinerja jaringan dapat terganggu. Oleh karena itu, terdapat jenis

jaringan lain yang bernama jaringan lapisan jamak. Jaringan ini terdiri atas lapisan masukan, lapisan tersembunyi, dan lapisan keluaran. Jaringan ini bekerja dengan mengirimkan sinyal dari lapisan masukan, kemudian dilakukan komputasi otomatis pada lapisan tersembunyi sebelum dikirimkan ke lapisan keluaran. Jaringan jenis ini memiliki waktu pelatihan yang lebih lama karena lebih kompleks daripada jaringan lapisan tunggal. Sementara itu, model jaringan *recurrent* dibentuk karena pada kedua jaringan sebelumnya diperlukan umpan balik pada setiap *loop* jaringannya. Pada jaringan *recurrent*, umpan balik diperoleh dari masukan yang sedang digunakan pada jaringan tersebut [20].

Fungsi aktivasi berfungsi untuk menentukan nilai keluaran suatu neuron. Fungsi aktivasi yang sering digunakan antara lain fungsi *sigmoid*, fungsi *hyperbolic tangent*, dan fungsi *leakyReLU*. Fungsi *sigmoid* merupakan fungsi yang paling sering digunakan karena nilai fungsinya memetakan nilai antara 0 sampai dengan 1. Fungsi *hyperbolic tangent*, atau biasa disebut dengan *sigmoid bipolar*, memiliki karakter yang mirip dengan *sigmoid* biasa, tetapi nilai masukan yang dipetakan adalah nilai -1 hingga 1. Sementara itu, fungsi *leakyReLU* adalah pengembangan dari *ReLU*. Perbedaannya adalah jika *ReLU* memetakan nilai masukan 0 sampai x , *leakyReLU* dapat memetakan nilai masukan tidak terbatas ($y = x * 0,01$) [21].

Prinsip kerja jaringan saraf kurang lebih sama seperti cara otak manusia melakukan pemrosesan informasi. Setiap neuron yang terdapat dalam otak manusia terhubung satu sama lain, kemudian menyebarkan informasi yang telah diterima oleh otak ke setiap unitnya. Neuron kemudian menerima masukan dan melakukan proses dengan sebuah *weight*, lalu menjumlahkannya (*weighted sum*) dan menambahkan *bias* atau masukan tambahan. Hasil dari operasi ini akan menjadi parameter dari fungsi aktivasi neuron tersebut. Pada pembelajaran menggunakan jaringan saraf, terdapat dua proses yang dilakukan, yaitu pelatihan dan evaluasi. Terdapat satu proses opsional, yaitu pengujian. Saat pelatihan, *weight* dan *bias* setiap neuron akan diperbarui secara berulang sampai nilai keluaran yang dihasilkan sesuai dengan yang diinginkan. Pada setiap *loop* dilakukan evaluasi untuk menentukan bahwa jaringan masih membutuhkan pelatihan atau sudah dapat menghentikan proses pelatihan [22].

D. TES VALIDASI

Validasi model prakiraan dilakukan dengan mengevaluasi hasil prakiraan. Metode yang sering dilakukan dalam proses evaluasi adalah *mean squared error* (MSE) [23]. MSE merupakan nilai rata-rata kesalahan kuadrat. Kesalahan yang dimaksud adalah selisih antara nilai aktual dan nilai prakiraan. Nilai MSE yang rendah atau mendekati nol menunjukkan bahwa model yang diperoleh baik, hasil prakiraan sangat dekat dengan nilai aktual, dan akhirnya model ini dapat dijadikan sebagai acuan untuk melakukan prakiraan di periode mendatang. Rumus MSE adalah sebagai berikut.

$$MSE = \frac{\sum_{t=1}^n (A_t - F_t)^2}{n} \tag{1}$$

dengan

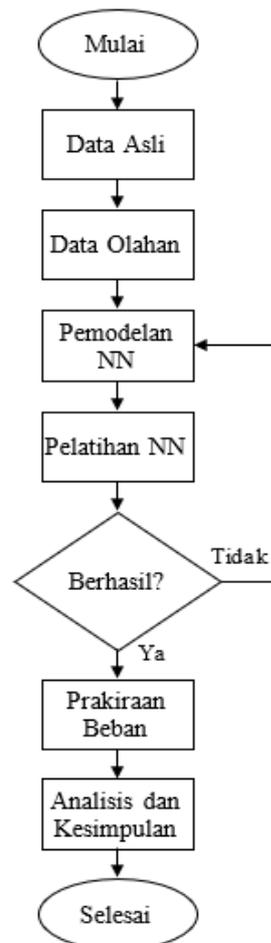
A_t = nilai aktual

F_t = nilai hasil prakiraan

n = jumlah data.

III. STUDI KASUS

Penelitian ini membahas prakiraan beban listrik menggunakan jaringan saraf yang dimodelkan dalam



Gambar 1. Diagram alir penelitian.

MATLAB. Dalam prosesnya, terdapat beberapa tahap, yaitu memodelkan jaringan saraf yang sesuai dengan karakteristik data, melakukan pelatihan, menguji kinerja model, melakukan analisis, dan diakhiri dengan menarik kesimpulan.

Gambar 1 menampilkan diagram alir penelitian. Sesuai diagram alir tersebut, langkah pertama yang dilakukan adalah mendapatkan data asli yang tersedia melalui metode pengumpulan data dari instansi terkait. Kemudian, dilakukan penyeleksian data yang sesuai dengan tujuan pembuatan prakiraan ini. Setelah data yang dibutuhkan diperoleh, dilakukan interpolasi data. Data yang terbatas ini diperbanyak melalui cara interpolasi kuadratik. Pada hasil interpolan dari fungsi interpolasi kuadratik ini ditambahkan derau sebagai cerminan keadaan nyata di lapangan, yang selalu mengalami perubahan. Dengan membangkitkan interpolan yang cukup jumlahnya, data yang awalnya terbatas dapat diperbanyak. Dengan jumlah data yang banyak, akan dihasilkan model yang lebih akurat. Setelah tahapan memperbanyak data ini berhasil dilakukan, selanjutnya dilakukan perancangan struktur atau arsitektur jaringan saraf.

Arsitektur jaringan saraf digunakan untuk melakukan prakiraan beban listrik di Kabupaten Jayawijaya. Pemodelan pada penelitian ini menggunakan jaringan saraf dengan jenis *feed-forward backpropagation LSTM* karena data yang dimiliki berbentuk runtun waktu tahunan dan bulanan. Pelatihan dan pengujian jaringan saraf ini dilakukan dengan beberapa kali percobaan dan modifikasi struktur, yaitu jumlah lapisan tersembunyi, jumlah neuron, dan jumlah *epoch*, untuk mendapatkan bentuk pemodelan terbaik dengan *error* yang rendah.

TABEL I
DATA MASUKAN

Tahun	Beban Puncak	Data Penduduk	PDRB
2013	5.436	204.954	415.665
2014	5.560	206.568	419.194
2015	6.070	212.533	421.928
2016	6.280	214.740	424.294
2017	6.648	216.861	427.595
2018	6.645	216.360	430.543

IV. HASIL DAN DISKUSI

A. PENYIAPAN DATA

Data yang digunakan sebagai masukan adalah data historis beban puncak PT PLN (Persero) UP3 Wamena Kabupaten Jayawijaya, jumlah penduduk, dan PDRB dari tahun 2013 sampai dengan tahun 2018. Setelah diperoleh data masukan yang dibutuhkan, dilakukan penyortiran data untuk memilah data yang akan digunakan sebagai data masukan. Pada awalnya, data yang dimiliki adalah data per tahun selama kurun waktu enam tahun, yang tertera pada Tabel I.

Jaringan saraf bekerja seperti otak manusia, yaitu belajar dari suatu contoh, kemudian jaringan yang dibentuk mencoba memecahkan suatu masalah tertentu, seperti pengenalan pola atau klasifikasi. Oleh karena itu, makin banyak contoh yang diterima dan diproses oleh otak, hasil analisis otak akan makin baik.

Berdasarkan hal tersebut, dapat dikatakan bahwa jaringan saraf membutuhkan data yang banyak untuk melakukan pelatihan pemodelan dan prakiraan. Dengan makin banyaknya data yang dimiliki, makin besar juga kemungkinan jaringan tersebut dapat menghasilkan keluaran yang lebih akurat. Karena data yang dimiliki sangat terbatas, dilakukan interpolasi dengan tujuan menambah jumlah data, tetapi tetap sesuai dengan *range* data real yang ada dan juga sesuai dengan nilai data yang bervariasi dan tidak linier. Maka, interpolasi yang dilakukan adalah interpolasi kuadrat, yang dilakukan secara sepotong-sepotong (*piecewise*), dengan masing-masing tiga data (tiga tahun).

Interpolasi kuadrat yang dilakukan dilakukan per tiga tahun untuk mendapatkan interpolan, dengan model kuadrat seperti pada (2).

$$q(x) = ax^2 + bx + c. \quad (2)$$

Setelah interpolasi berhasil dilakukan, data hasil interpolasi tersebut (interpolan) ditambah derau, yang mencerminkan bervariasinya data, agar dapat menggambarkan perkembangan data yang terjadi di lapangan. Berikut ini contoh proses pembangkitan data melalui interpolasi kuadrat menggunakan data tahun 2013 dan 2014. Fungsi kuadrat untuk beban puncak, data penduduk, dan PDRB (y) dinyatakan dalam (3) sampai (5).

Beban puncak:

$$y = 40,5x^2 - 90,5x + 5.485 \quad (3)$$

Penduduk:

$$y = -10763x^2 + 53642x + 140.820 \quad (4)$$

PDRB:

$$y = 81,5x^2 + 3093,5x + 409.411 \quad (5)$$

TABEL II
DATA MASUKAN SETELAH INTERPOLASI

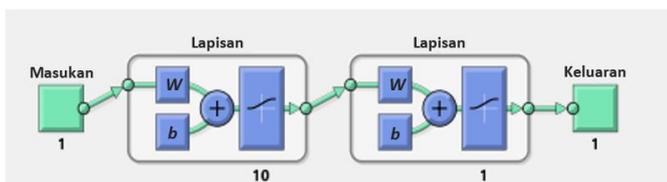
Tahun	Beban Puncak	Data Penduduk	PDRB	Tahun
2013	1,08	5.436	185.431	412.716
	1,16	5.436	188.255	413.065
	1,24	5.435	189.913	413.411
	1,32	5.437	193.009	413.815
	1,4	5.436	195.497	413.798
	1,48	5.438	197.108	414.354
	1,56	5.445	199.967	414.387
	1,64	5.446	201.481	414.719
	1,72	5.447	200.036	414.897
	1,8	5.452	203.085	415.186
	1,88	5.459	203.096	415.739
	1,96	5.462	203.098	415.537
2014	2,08	5.475	205.902	416.034
	2,16	5.484	206.523	416.675
	2,24	5.480	206.949	416.678
	2,32	5.501	207.338	417.047
	2,4	5.498	207.626	417.249
	2,48	5.513	207.691	417.456
	2,56	5.520	207.675	417.827
	2,64	5.529	207.484	418.055
	2,72	5.540	207.080	418.425
	2,8	5.547	206.672	418.892
	2,88	5.554	206.095	418.978
	2,96	5.576	205.342	419.403

dengan x adalah tahun. Untuk keperluan interpolasi, nilai x diperbanyak dalam satuan bulan, sehingga dalam satu tahun terdapat 12 data. Nilai interpolan $y(x)$ setiap bulan akhirnya dapat dihitung untuk nilai $x = 1,08; 1,16; \dots; 1,88; 1,96$ dalam satu tahun. Untuk tahun berikutnya, dapat dilakukan dengan cara yang sama dengan nilai awal $x = 2,08$ dan kenaikan 0,8.

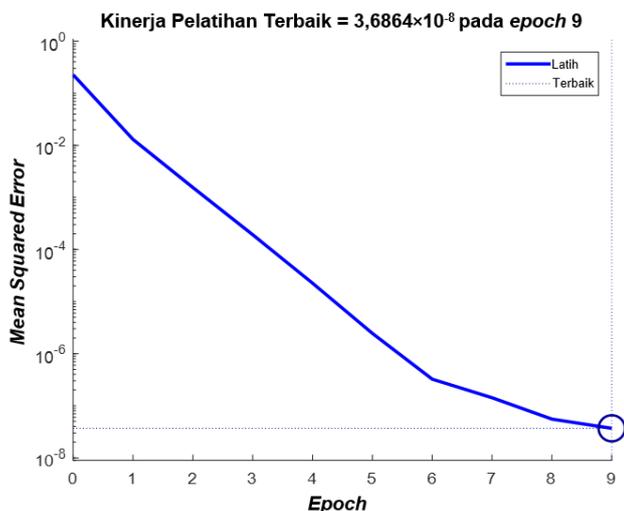
Tabel II menyajikan data dua tahun pertama yang telah dilakukan interpolasi. Untuk jenis data yang lain, dilakukan hal yang sama dan sesuai dengan ketentuan pada Tabel II. Hasil yang diperoleh berjumlah 84 data, yang akan digunakan sebagai masukan jaringan saraf.

B. PEMODELAN JARINGAN SARAF

Setelah persiapan data selesai, dilakukan pemodelan arsitektur jaringan saraf menggunakan parameter yang telah dijelaskan pada subbagian sebelumnya. Yang pertama dilakukan adalah menentukan jenis jaringan yang akan digunakan. Jaringan yang akan digunakan pada prakiraan ini merupakan jaringan *multilayer* dengan metode jaringan saraf *backpropagation* LSTM. Jaringan jenis ini digunakan karena data yang dimiliki berbentuk deret waktu. Setelah mendapatkan jenis jaringan yang akan digunakan, selanjutnya arsitektur jaringan tersebut dirancang karena model jaringan yang baik untuk prakiraan kebutuhan beban adalah jaringan yang memiliki tingkat akurasi yang tinggi. Tingkat akurasi ini didapatkan dengan melakukan banyak variasi jumlah lapisan tersembunyi dan jumlah neuron pada masing-masing lapisan tersembunyi. Tingkat akurasi dapat dinilai dari besar atau kecilnya *error* yang dihasilkan. Selanjutnya, dilakukan pelatihan berulang dengan melakukan penyesuaian pada jumlah lapisan, jumlah neuron, dan jumlah *epoch* sampai diperoleh hasil terbaik. Setelah melakukan percobaan berulang-ulang, didapatkan hasil bahwa model jaringan yang



Gambar 2. Arsitektur jaringan saraf.



Gambar 3. Kinerja pelatihan.

baik untuk prakiraan ini adalah model jaringan yang terdiri atas:

- satu neuron pada lapisan masukan,
- sepuluh neuron pada lapisan tersembunyi pertama,
- satu neuron pada lapisan tersembunyi kedua, dan
- satu neuron pada lapisan keluaran.

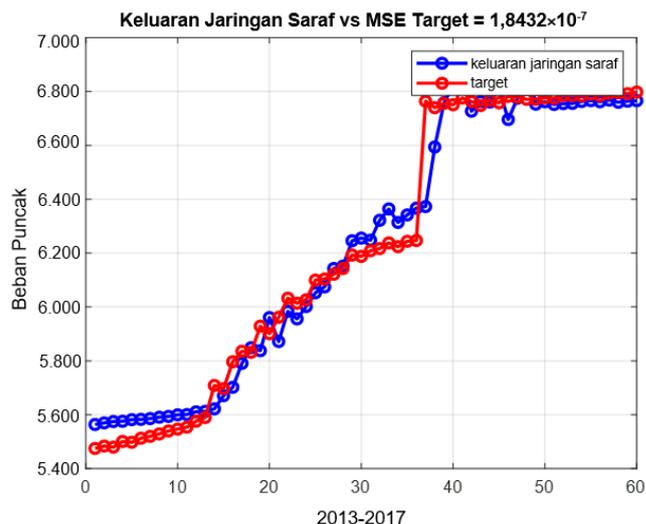
Hasil akhir pemodelan ini diperlihatkan pada Gambar 2.

C. PRAKIRAAN BEBAN

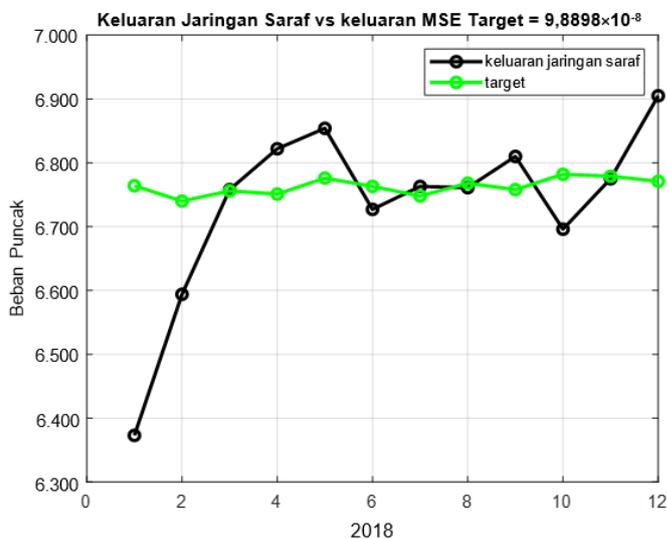
Arsitektur model ditunjukkan pada Gambar 2. Pada model terdapat dua lapisan tersembunyi, sepuluh neuron pada lapisan tersembunyi 1, dan satu neuron pada lapisan tersembunyi 2. Kinerja pelatihan dengan struktur model tersebut ditunjukkan pada Gambar 3.

Gambar 3 memperlihatkan bahwa pada epoch ke-1 sampai dengan ke-6, terjadi penurunan MSE yang sangat signifikan, sedangkan pada epoch ke-6 sampai dengan ke-8 masih terjadi penurunan MSE, tetapi tidak terlalu signifikan. Hasil terbaik tercapai pada epoch ke-9, yaitu saat jaringan berhasil melakukan perhitungan dengan error terkecil. Saat itu, secara otomatis jaringan saraf memberhentikan proses pelatihan. MSE yang kecil digambarkan oleh garis biru yang makin lama makin turun mendekati angka 0. Dapat dikatakan bahwa pemodelan sudah memenuhi harapan, yang ditandai dengan nilai MSE sebesar $3,6864 \times 10^8$.

Ilustrasi keberhasilan proses pelatihan diperlihatkan pada Gambar 4, untuk 48 data masukan dan 48 data keluaran jaringan saraf, khususnya beban puncak. Dalam ilustrasi tersebut dapat dilihat hasil dari pelatihan jaringan yang dilakukan menggunakan jaringan saraf *feed-forward backpropagation* dengan tiga jenis data masukan. Garis merah menunjukkan target pelatihan, sedangkan garis biru menunjukkan keluaran jaringan saraf. Setelah diperhatikan dengan seksama, pelatihan jaringan ini dapat dikatakan sebagai pelatihan yang sukses karena perbedaan antara target dan keluaran jaringan saraf tidak besar, yang menandakan arsitektur tersebut dapat mengolah data masukan dengan baik.



Gambar 4. Nilai keluaran jaringan saraf vs keluaran target.



Gambar 5. Nilai keluaran jaringan saraf vs keluaran target.

Perbandingan antara hasil tes dan target ditunjukkan pada grafik dalam Gambar 5. Pada gambar tersebut tampak hasil pengujian jaringan setelah dilakukan pelatihan sebelumnya. Data yang dimasukkan adalah data baru yang belum pernah digunakan saat pelatihan. Tujuan pengujian jaringan ini adalah untuk melihat kemampuan jaringan yang sudah dibangun dalam mengenali dan mempelajari data yang baru dengan cepat dan adaptif, tanpa mengurangi kinerja jaringan tersebut secara signifikan. Tampak pada Gambar 5 bahwa terdapat perbedaan yang tidak terlalu besar antara target pengujian dan hasil pengujian. Namun, jika dibandingkan dengan hasil pelatihan, error hasil pengujian lebih besar. Perlu diketahui bahwa data yang dilakukan untuk melakukan pengujian merupakan data baru yang belum dikenali oleh jaringan tersebut dan hasil pengujian masih sesuai dengan standar MSE yang seharusnya. Hal ini menandakan bahwa jaringan yang dibangun sudah memenuhi persyaratan untuk melakukan prakiraan kebutuhan listrik dan siap untuk diberi masukan data yang belum pernah digunakan sebelumnya.

V. KESIMPULAN

Jaringan saraf dapat bekerja dengan data yang terbatas dengan menggunakan bantuan interpolasi data untuk memperbanyak jumlah data yang ada, melalui proses yang

sesuai dengan ketentuan. Setelah dilakukan percobaan berulang-ulang, diperoleh hasil bahwa model yang sesuai dengan data yang diperoleh adalah jaringan *feed-forward long short term memory*. Dengan menggunakan model ini, dapat diperoleh *error* yang sangat kecil, yaitu sebesar 0,04%, dengan sembilan *epoch*.

KONFLIK KEPENTINGAN

Penulis menyatakan bahwa tidak terdapat konflik kepentingan dalam penyusunan penelitian dengan judul “Prakiraan Beban Listrik Menggunakan Metode Jaringan Saraf Tiruan dengan Data yang Terbatas” ini, baik dalam kepentingan pribadi yang mungkin ditafsirkan akan memengaruhi representasi atau interpretasi hasil penelitian.

KONTRIBUSI PENULISAN

Tema penelitian, Elang Bayu Trikora dan Sasongko Pramonoahadi; perangkat lunak, Elang Bayu Trikora; validasi, Elang Bayu Trikora, Sasongko Pramonoahadi, dan M. Isnaeni Bambang Setyonegoro; analisis formal, Elang Bayu Trikora dan Sasongko Pramonoahadi; penyiapan data parameter, Elang Bayu Trikora; penulisan—penyusunan draf asli, Elang Bayu Trikora dan Sasongko Pramonoahadi; penulisan—peninjauan dan penyuntingan, Elang Bayu Trikora dan Sasongko Pramonoahadi; pemrograman, Elang Bayu Trikora, Sasongko Pramonoahadi, dan M. Isnaeni Bambang Setyonegoro.

REFERENSI

- [1] Q. Feng dan S. Qian, “Research on Power Load Forecasting Model of Economic Development Zone Based on Neural Network,” *Energy Rep.*, Vol. 7, hal. 1447–1452, Nov. 2021, doi: 10.1016/j.egy.2021.09.098.
- [2] W. Kong dkk., “Short-Term Residential Load Forecasting Based on LSTM Recurrent Neural Network,” *IEEE Trans. Smart Grid*, Vol. 10, No. 1, hal. 841–851, Jan. 2019, doi: 10.1109/TSG.2017.2753802.
- [3] S.N. Fallah, M. Ganjkhani, S. Shamshirband, dan K.-W. Chau, “Computational Intelligence on Short-Term Load Forecasting: A Methodological Overview,” *Energies*, Vol. 12, No. 3, hal. 1-21, Jan. 2019, doi: 10.3390/en12030393.
- [4] “Kabupaten Jayawijaya dalam Angka 2017,” Badan Pusat Statistik Kabupaten Jayawijaya, 2017.
- [5] Y. Liang, D. Niu, dan W.-C. Hong, “Short Term Load Forecasting Based on Feature Extraction and Improved General Regression Neural Network Model,” *Energy*, Vol. 166, hal. 653–663, Jan. 2019, doi: 10.1016/j.energy.2018.10.119.
- [6] J. Kim, J. Moon, E. Hwang, dan P. Kang, “Recurrent Inception Convolution Neural Network for Multi Short-Term Load Forecasting,” *Energy, Build.*, Vol. 194, hal. 328–341, Jul. 2019, doi: 10.1016/j.enbuild.2019.04.034.
- [7] X. Liu, Z. Zhang, dan Z. Song, “A Comparative Study of the Data-Driven Day-Ahead Hourly Provincial Load Forecasting Methods: From Classical Data Mining to Deep Learning,” *Renew. Sustain. Energy Rev.*, Vol. 119, hal. 1-17, Mar. 2020, doi: 10.1016/j.rser.2019.109632.
- [8] L. Yin, Z. Sun, F. Gao, dan H. Liu, “Deep Forest Regression for Short-Term Load Forecasting of Power Systems,” *IEEE Access*, Vol. 8, hal. 49090–49099, Mar. 2020, doi: 10.1109/ACCESS.2020.2979686.
- [9] P. Singh, P. Dwivedi, dan V. Kant, “A Hybrid Method Based on Neural Network and Improved Environmental Adaptation Method Using Controlled Gaussian Mutation with Real Parameter for Short-Term Load Forecasting,” *Energy*, Vol. 174, hal. 460–477, Mei. 2019, doi: 10.1016/j.energy.2019.02.141.
- [10] L. Wu, C. Kong, X. Hao, dan W. Chen, “A Short-Term Load Forecasting Method Based on GRU-CNN Hybrid Neural Network Model,” *Math. Probl. Eng.*, Vol. 2020, hal. 1-10, Mar. 2020, doi: 10.1155/2020/1428104.
- [11] C. Tian, J. Ma, C. Zhang, dan P. Zhan, “A Deep Neural Network Model for Short-Term Load Forecast Based on Long Short-Term Memory Network and Convolutional Neural Network,” *Energies*, Vol. 11, No. 12, hal. 1-13, Des. 2018, doi: 10.3390/en11123493.
- [12] A. Sherstinsky, “Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) Network,” *Phys. D Nonlinear Phenom.*, Vol. 404, hal. 1-28, Mar. 2020, doi: 10.1016/j.physd.2019.132306.
- [13] M.S. Hossain dan H. Mahmood, “Short-Term Load Forecasting Using an LSTM Neural Network,” *2020 IEEE Power Energy Conf. Illinois (PECI)*, 2020, hal. 1-6, doi: 10.1109/PECI48348.2020.9064654.
- [14] L. Sehovac dan K. Grolinger, “Deep Learning for Load Forecasting: Sequence Recurrent Neural Networks with Attention,” *IEEE Access*, Vol. 8, hal. 36411–36426, Feb. 2020, doi: 10.1109/ACCESS.2020.2975738.
- [15] J. Ma dkk., “A Temporal-Spatial Interpolation and Extrapolation Method Based on Geographic Long Short-Term Memory Neural Network for PM2.5,” *J. Clean. Prod.*, Vol. 237, hal. 1-11, Nov. 2019, doi: 10.1016/j.jclepro.2019.117729.
- [16] Y. Sun, T. Yang, dan Z. Liu, “A Whale Optimization Algorithm Based on Quadratic Interpolation for High-Dimensional Global Optimization Problems,” *Appl. Soft Comput.*, Vol. 85, Des. 2019, doi: 10.1016/j.asoc.2019.105744.
- [17] Z. Deng dkk., “Multi-Scale Convolutional Neural Network with Time-Cognition for Multi-Step Short-Term Load Forecasting,” *IEEE Access*, Vol. 7, hal. 88058–88071, Jul. 2019, doi: 10.1109/ACCESS.2019.2926137.
- [18] S. Muzaffar dan A. Afshari, “Short-Term Load Forecasts Using LSTM Networks,” *Energy Procedia*, Vol. 158, hal. 2922–2927, Feb. 2019, doi: 10.1016/j.egypro.2019.01.952.
- [19] O.I. Abiodun dkk., “State-of-the-Art in Artificial Neural Network Applications: A Survey,” *Heliyon*, Vol. 4, No. 11, hal. 1-41, Nov. 2018, doi: 10.1016/j.heliyon.2018.e00938.
- [20] A. Tealab, “Time Series Forecasting Using Artificial Neural Networks Methodologies: A Systematic Review,” *Future Comput., Inform. J.*, Vol. 3, No. 2, hal. 334–340, Dec. 2018, doi: 10.1016/j.fcij.2018.10.003.
- [21] S.M.J. Jalali dkk., “A Novel Evolutionary-Based Deep Convolutional Neural Network Model for Intelligent Load Forecasting,” *IEEE Trans. Ind. Inform.*, Vol. 17, No. 12, hal. 8243–8253, Des. 2021, doi: 10.1109/TII.2021.3065718.
- [22] B.-S. Kwon, R.-J. Park, dan K.-B. Song, “Short-Term Load Forecasting Based on Deep Neural Networks Using LSTM Layer,” *J. Elect. Eng., Technol.*, Vol. 15, hal. 1501–1509, Jul. 2020, doi: 10.1007/s42835-020-00424-7.
- [23] M.A. Al Amin dan M.A. Hoque, “Comparison of ARIMA and SVM for Short-Term Load Forecasting,” *2019 9th Annu. Inf. Technol. Electromech. Eng., Microelectron. Conf. (IEMECON)*, 2019, hal. 205–210, doi: 10.1109/IEMECONX.2019.8877077.