

Bab II Tinjauan Pustaka

1.1 Transformator Daya dan Pembebanan Transformator

Transformator daya merupakan salah satu peralatan utama dalam sistem tenaga listrik yang berfungsi untuk mengubah tingkat tegangan listrik, baik menaikkan maupun menurunkan tegangan, agar proses penyaluran energi listrik dapat berlangsung secara efisien [31]. Dalam sistem transmisi dan distribusi, transformator berperan sebagai penghubung antara jaringan dengan tingkat tegangan yang berbeda. Oleh karena itu, keandalan transformator sangat berpengaruh terhadap kontinuitas penyaluran tenaga listrik kepada konsumen. Pada gardu induk, transformator daya bekerja untuk menyalurkan energi listrik dari sisi tegangan tinggi ke sisi tegangan yang lebih rendah sesuai kebutuhan sistem distribusi. Selama beroperasi, transformator akan melayani beban listrik yang berubah-ubah sesuai dengan kebutuhan konsumen. Besarnya beban yang dilayani oleh transformator disebut sebagai pembebanan transformator. Pembebanan ini dapat dinyatakan dalam satuan daya, seperti MW atau MVA, maupun dalam bentuk persentase terhadap kapasitas nominal transformator.

Pada sistem tiga fasa, kapasitas semu transformator dapat dinyatakan dengan persamaan [32] :

$$S = \sqrt{3} \times V \times I \quad (2.1)$$

dengan S merupakan daya semu transformator dalam satuan VA, V merupakan tegangan antar-fasa dalam satuan volt, dan I merupakan arus saluran dalam satuan ampere. Persamaan ini menunjukkan bahwa kapasitas transformator dipengaruhi oleh besar tegangan dan arus yang mengalir pada sistem tiga fasa.

Dalam analisis pembebanan, daya aktif transformator dapat dihitung berdasarkan kapasitas semu dan faktor daya. Hubungan antara daya aktif, daya semu, dan faktor daya dinyatakan sebagai berikut [33] :

$$P = S \times \cos \varphi \quad (2.2)$$

dengan P merupakan daya aktif dalam satuan watt atau MW, S merupakan daya semu dalam satuan VA atau MVA, dan $\cos \varphi$ merupakan faktor daya. Daya aktif inilah yang menunjukkan daya nyata yang digunakan oleh beban listrik.

Persentase pembebanan transformator dapat dihitung dengan membandingkan beban aktual terhadap kapasitas aktif maksimum transformator. Persamaan persentase pembebanan transformator dinyatakan sebagai berikut [34] :

$$\text{Pembesanan}(\%) = \frac{P_{\text{beban}}}{P_{\text{kapasitas}}} \times 100\% \quad (2.3)$$

dengan P_{beban} merupakan beban aktual transformator, sedangkan $P_{\text{kapasitas}}$ merupakan kapasitas aktif maksimum transformator. Semakin besar nilai persentase pembebanan, semakin tinggi tingkat pemanfaatan transformator terhadap kapasitasnya.

Selain menghitung persentase pembebanan, batas evaluasi pembebanan juga dapat ditentukan berdasarkan persentase tertentu dari kapasitas aktif transformator. Persamaan batas pembebanan dapat dinyatakan sebagai berikut:

$$P_{\text{batas}} = k \times P_{\text{kapasitas}} \quad (2.4)$$

dengan P_{batas} merupakan batas pembebanan yang digunakan sebagai acuan evaluasi, k merupakan faktor batas pembebanan, dan $P_{\text{kapasitas}}$ merupakan kapasitas aktif maksimum transformator. Jika batas evaluasi pembebanan ditetapkan sebesar 80%, maka nilai k adalah 0,8.

Pada penelitian ini, transformator yang dianalisis memiliki kapasitas nominal sebesar 60 MVA. Dengan asumsi faktor daya sebesar 0,95, maka kapasitas aktif maksimum transformator dapat dihitung sebagai berikut:

$$P_{\text{kapasitas}} = 60 \times 0,95 = 57 \text{ MW} \quad (2.5)$$

Jika batas evaluasi pembebanan yang digunakan adalah 80% dari kapasitas aktif maksimum, maka batas pembebanan transformator adalah:

$$P_{\text{batas}} = 0,8 \times 57 = 45,6 \text{ MW} \quad (2.6)$$

Berdasarkan perhitungan tersebut, nilai 45,6 MW dapat digunakan sebagai acuan untuk menilai apakah pembebanan transformator masih berada dalam batas evaluasi yang aman atau telah mendekati kondisi pembebanan tinggi.

Pembebanan transformator menjadi salah satu indikator penting dalam menilai kondisi operasi transformator. Apabila pembebanan masih berada dalam batas aman, transformator dapat beroperasi secara normal. Sebaliknya, apabila pembebanan terlalu tinggi dan mendekati atau melebihi kapasitas aman, transformator berisiko mengalami pembebanan berlebih atau overload. Kondisi overload dapat menyebabkan peningkatan temperatur kerja transformator, mempercepat proses penuaan isolasi, menurunkan umur teknis peralatan, serta meningkatkan risiko gangguan operasi. Dalam pengoperasian sistem tenaga listrik, beban transformator tidak selalu berada dalam kondisi stabil. Pada periode tertentu, beban dapat mengalami kenaikan akibat meningkatnya kebutuhan energi listrik dari konsumen, aktivitas industri, perubahan pola konsumsi, atau kondisi operasional sistem. Lonjakan beban yang terjadi secara mendadak perlu memperoleh perhatian khusus karena dapat menyebabkan transformator bekerja pada kondisi yang lebih berat dibandingkan kondisi normal.

Oleh karena itu, pemantauan pembebanan transformator menjadi bagian penting dalam manajemen aset kelistrikan. Data beban historis dapat digunakan untuk mengetahui kecenderungan pembebanan, baik dalam kondisi normal maupun saat terjadi lonjakan beban. Dengan memahami pola pembebanan tersebut, operator sistem dapat melakukan perencanaan yang lebih baik, seperti pengaturan beban, penjadwalan pemeliharaan, dan antisipasi terhadap risiko pembebanan tinggi. Dalam penelitian ini, pembebanan transformator menjadi objek utama yang dianalisis melalui pendekatan peramalan beban. Data historis pembebanan transformator digunakan untuk memperkirakan kondisi beban pada periode mendatang. Hasil peramalan tersebut diharapkan dapat membantu memberikan gambaran awal mengenai potensi kenaikan beban, sehingga dapat digunakan sebagai dasar pendukung dalam pengambilan keputusan operasional dan manajemen aset transformator.

..

1.2 Transformator Daya dan Pembebanan Transformator.

Dalam sistem otomatis modern, khususnya di sektor energi dan industri, peramalan memainkan peran mendasar dalam memastikan operasi yang efisien. Prediksi yang akurat sangat penting untuk manajemen sumber daya strategis, perencanaan operasional, dan

optimalisasi efisiensi biaya. Literatur menunjukkan penerapan metodologi peramalan yang luas untuk berbagai tantangan, mulai dari memprediksi konsumsi dan permintaan daya [35], [36] hingga mengoptimalkan penjadwalan pompa drainase [37] dan mengelola permintaan rantai pasokan [38]. Teknik seperti Jaringan Saraf Buatan (ANN), Pembelajaran Mendalam, dan kerangka kerja hibrida semakin banyak digunakan untuk menangkap hubungan non-linier yang kompleks yang berada di luar kemampuan model regresi yang lebih sederhana [39]. Meskipun pendekatan ini seringkali mencapai akurasi prediksi yang lebih unggul, keuntungan ini seringkali didapatkan dengan mengorbankan transparansi dan interpretasi model, sehingga menimbulkan pertimbangan penting bagi para praktisi. Yang perlu diperhatikan dalam literatur terbaru adalah munculnya model Pembelajaran Mendalam, seperti jaringan LSTM, yang telah menunjukkan daya prediksi yang tinggi untuk data deret waktu yang sangat kompleks dan fluktuatif [40], [41]. Peramalan beban listrik merupakan proses memperkirakan kebutuhan atau penggunaan energi listrik pada periode mendatang berdasarkan data historis. Dalam sistem tenaga listrik, peramalan beban memiliki peran penting karena hasil prediksi dapat digunakan sebagai dasar dalam perencanaan operasi, pengaturan pasokan energi, penjadwalan pemeliharaan peralatan, dan pengelolaan keandalan sistem. Dengan adanya peramalan yang baik, operator sistem dapat memperkirakan kemungkinan kenaikan atau penurunan beban sehingga langkah antisipatif dapat dilakukan lebih awal [42].

Secara umum, data beban listrik yang diamati secara berurutan dapat dinyatakan sebagai deret data historis berikut:

$$D = L_1, L_2, L_3, \dots, L_t, \dots, L_n \quad (2.7)$$

Dengan D merupakan himpunan data beban historis, L_t merupakan nilai beban listrik pada periode ke- t , dan n merupakan jumlah seluruh data pengamatan. Dalam penelitian ini, L_t merepresentasikan beban mingguan transformator yang diperoleh dari data historis sistem SCADA.

Tujuan utama peramalan beban adalah memperkirakan nilai beban pada periode mendatang berdasarkan pola beban pada periode sebelumnya. Secara matematis, proses peramalan beban dapat dinyatakan sebagai berikut:

$$\hat{L}_{t+h} = f(L_t, L_{t-1}, L_{t-2}, \dots, L_{t-p}) \quad (2.8)$$

dengan $\hat{L}_{t+h}$ merupakan hasil peramalan beban pada periode $t + h$, h merupakan horizon atau jarak waktu peramalan, $f(\cdot)$ merupakan fungsi model peramalan, dan p merupakan jumlah data historis sebelumnya yang digunakan sebagai dasar prediksi. Persamaan tersebut menunjukkan bahwa nilai beban pada masa mendatang diperkirakan berdasarkan informasi beban pada periode-periode sebelumnya. Beban listrik pada suatu sistem tidak selalu bernilai tetap, tetapi berubah mengikuti aktivitas konsumen, waktu penggunaan, kegiatan industri, kondisi cuaca, hari kerja, hari libur, serta faktor operasional jaringan. Perubahan tersebut menyebabkan data beban listrik membentuk pola tertentu dari waktu ke waktu. Pola tersebut dapat berupa tren peningkatan, penurunan, kestabilan, maupun fluktuasi yang terjadi pada periode tertentu. Oleh karena itu, data historis beban dapat digunakan sebagai dasar untuk memperkirakan beban pada periode berikutnya.

Berdasarkan jangka waktunya, peramalan beban listrik dapat dibedakan menjadi peramalan jangka pendek, jangka menengah, dan jangka panjang. Peramalan jangka pendek umumnya digunakan untuk kebutuhan operasi harian atau mingguan, seperti pengaturan pembangkitan dan keseimbangan beban. Peramalan jangka menengah digunakan untuk perencanaan dalam rentang beberapa minggu hingga beberapa bulan, misalnya untuk penjadwalan pemeliharaan dan pengaturan kapasitas sistem. Sementara itu, peramalan jangka panjang digunakan untuk perencanaan investasi, pengembangan jaringan, dan penyediaan infrastruktur tenaga listrik dalam skala tahunan. Dalam konteks transformator daya, peramalan beban diperlukan untuk mengetahui kecenderungan pembebanan pada periode mendatang. Informasi ini penting karena transformator memiliki batas kemampuan operasi. Apabila beban diperkirakan mendekati atau melebihi batas aman, operator dapat melakukan tindakan pencegahan, seperti pengaturan beban, evaluasi konfigurasi jaringan, atau penjadwalan pemeliharaan. Dengan demikian, peramalan beban tidak hanya berfungsi sebagai alat prediksi, tetapi juga sebagai alat bantu dalam manajemen risiko operasional.

Hasil peramalan beban dapat dikaitkan dengan persentase pembebanan transformator untuk mengetahui tingkat kedekatan beban terhadap kapasitas transformator. Persentase hasil peramalan pembebanan transformator dapat dinyatakan sebagai berikut:

$$\widehat{\text{Pembbebanan}}_{t+h}(\%) = \frac{\hat{P}_{\text{beban},t+h}}{P_{\text{kapasitas}}} \times 100\% \quad (2.9)$$

dengan $\widehat{P_{\text{beban}}}_{t+h} + h(\%)$ merupakan persentase pembebanan hasil peramalan pada periode $t + h$, $\hat{P}_{t+h}$ beban, $t + h$ merupakan beban hasil peramalan, dan $P_{\text{kapasitas}}$ merupakan kapasitas aktif maksimum transformator. Persamaan ini menunjukkan bahwa hasil peramalan tidak hanya dapat dilihat sebagai nilai beban, tetapi juga dapat digunakan untuk menilai tingkat pembebanan transformator terhadap kapasitas operasionalnya.

Selisih antara nilai aktual dan nilai hasil peramalan disebut sebagai kesalahan peramalan atau forecasting error. Secara umum, kesalahan peramalan dapat dinyatakan sebagai berikut:

$$e_{t+h} = L_{t+h} - \hat{L}_{t+h} \quad (2.10)$$

dengan e_{t+h} merupakan kesalahan peramalan pada periode $t + h$, L_{t+h} merupakan nilai beban aktual, dan $\hat{L}_{t+h}$ merupakan nilai beban hasil peramalan. Nilai kesalahan ini menjadi dasar dalam mengevaluasi kinerja model peramalan, baik menggunakan MAE, RMSE, maupun MAPE.

Peramalan beban transformator dapat dilakukan dengan berbagai metode, mulai dari metode statistik sederhana hingga metode komputasi yang lebih kompleks. Model statistik seperti regresi linear, eksponensial, logaritmik, dan polinomial banyak digunakan karena mudah diterapkan dan mudah dipahami. Di sisi lain, model stokastik seperti Error, Trend, Seasonality (ETS) digunakan karena mampu mempertimbangkan unsur kesalahan, tren, dan pola musiman dalam data deret waktu. Pemilihan metode peramalan perlu disesuaikan dengan karakteristik data, tujuan penelitian, serta kebutuhan operasional.

Dalam penelitian ini, peramalan beban listrik dilakukan terhadap data beban mingguan transformator di Gardu Induk 150 kV Pekalongan. Data historis digunakan untuk membangun model peramalan, sedangkan data aktual pada periode pengujian digunakan untuk mengevaluasi kemampuan model dalam memprediksi beban. Hasil peramalan kemudian dibandingkan menggunakan beberapa ukuran kesalahan, yaitu MAE, RMSE, dan MAPE, serta dianalisis lebih lanjut melalui interval prediksi dan uji statistik. Dengan pendekatan tersebut, penelitian ini tidak hanya menilai model berdasarkan kedekatan hasil prediksi terhadap data

aktual, tetapi juga menilai keandalan model dalam mendukung pengambilan keputusan operasional.

1.3 Model Deret Waktu dalam Peramalan Beban

Model deret waktu atau time series model merupakan pendekatan statistik yang digunakan untuk menganalisis data yang tersusun berdasarkan urutan waktu [43]. Pada model deret waktu, setiap data tidak dipandang sebagai nilai yang berdiri sendiri, tetapi sebagai bagian dari rangkaian pengamatan yang memiliki keterkaitan antarperiode. Dengan demikian, nilai pada waktu tertentu dapat dipengaruhi oleh pola atau nilai pada periode sebelumnya.

Secara umum, data deret waktu dapat dinyatakan sebagai sekumpulan pengamatan yang tersusun menurut waktu sebagai berikut:

$$Y = Y_1, Y_2, Y_3, \dots, Y_t, \dots, Y_n \quad (2.11)$$

dengan Y_t menyatakan nilai pengamatan pada periode ke- t , sedangkan n menyatakan jumlah seluruh data pengamatan. Dalam konteks penelitian ini, Y_t merepresentasikan nilai beban transformator pada minggu ke- t . Karena data yang digunakan berupa beban historis mingguan, maka setiap nilai Y_t merupakan bagian dari deret waktu beban listrik transformator.

Dalam peramalan deret waktu, tujuan utama pemodelan adalah memperkirakan nilai masa depan berdasarkan pola data masa lalu. Secara umum, nilai ramalan untuk periode mendatang dapat dinyatakan sebagai berikut:

$$\hat{Y}_{t+h} = f(Y_t, Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}) \quad (2.12)$$

dengan $\hat{Y}_{t+h}$ merupakan nilai hasil peramalan pada periode $t+h$, h merupakan horizon peramalan, $f(\cdot)$ merupakan fungsi pemodelan, dan p merupakan jumlah periode historis yang digunakan sebagai dasar peramalan. Persamaan tersebut menunjukkan bahwa nilai beban pada masa mendatang diperkirakan berdasarkan informasi beban pada periode-periode sebelumnya.

Dalam praktiknya, data deret waktu sering kali memiliki beberapa komponen utama, yaitu tren, musiman, siklus, dan komponen acak. Tren menunjukkan kecenderungan perubahan data dalam jangka panjang, baik meningkat, menurun, maupun relatif tetap. Komponen musiman

menunjukkan pola berulang dalam periode tertentu. Komponen siklus menggambarkan perubahan yang terjadi dalam periode yang lebih panjang, sedangkan komponen acak menunjukkan perubahan yang tidak dapat dijelaskan sepenuhnya oleh pola historis.

Secara matematis, komponen data deret waktu dapat dinyatakan dalam bentuk model aditif sebagai berikut:

$$Y_t = T_t + S_t + C_t + e_t \quad (2.13)$$

dengan Y_t merupakan nilai aktual pada waktu ke- t , T_t merupakan komponen tren, S_t merupakan komponen musiman, C_t merupakan komponen siklus, dan e_t merupakan komponen acak atau galat pada periode ke- t . Model aditif digunakan apabila pengaruh masing-masing komponen dianggap saling menjumlahkan.

Selain model aditif, data deret waktu juga dapat dinyatakan dalam bentuk model multiplikatif sebagai berikut:

$$Y_t = T_t \times S_t \times C_t \times e_t \quad (2.14)$$

Model multiplikatif digunakan apabila besar fluktuasi data cenderung berubah mengikuti tingkat data. Dengan kata lain, semakin besar nilai data, maka variasi atau fluktuasinya juga dapat menjadi semakin besar. Dalam peramalan beban listrik, pemilihan model aditif atau multiplikatif bergantung pada karakteristik data historis yang dianalisis. Pada penelitian ini, pendekatan deret waktu digunakan untuk memodelkan beban transformator berdasarkan data historis beban mingguan. Karena model yang digunakan hanya memanfaatkan satu variabel utama, yaitu beban transformator, maka pendekatan ini disebut sebagai model deret waktu univariat. Secara umum, model deret waktu univariat dapat dinyatakan sebagai berikut:

$$Y_t = f(t) + e_t \quad (2.15)$$

dengan Y_t merupakan nilai beban aktual pada periode ke- t , $f(t)$ merupakan fungsi yang menggambarkan pola perubahan beban terhadap waktu, dan e_t merupakan selisih atau kesalahan antara nilai aktual dan nilai yang diperkirakan oleh model. Persamaan ini menjadi dasar bagi model deterministik, seperti Linear, Eksponensial, Logaritmik, dan Polinomial, yang memandang perubahan beban sebagai fungsi dari waktu.

Kesalahan peramalan atau error merupakan selisih antara nilai aktual dan nilai hasil prediksi. Secara matematis, error pada periode ke- t dapat dinyatakan sebagai berikut:

$$e_t = Y_t - \hat{Y}_t \quad (2.16)$$

dengan e_t merupakan error pada periode ke- t , Y_t merupakan nilai aktual, dan $\hat{Y}_t$ merupakan nilai hasil peramalan. Nilai error ini menjadi dasar dalam menghitung metrik evaluasi model, seperti MAE, RMSE, dan MAPE.

Dalam peramalan beban listrik, data historis umumnya dibagi menjadi dua bagian, yaitu data latih dan data uji. Data latih digunakan untuk membentuk model, sedangkan data uji digunakan untuk mengevaluasi kemampuan model dalam memprediksi data yang belum digunakan pada proses pembentukan model. Secara umum, pembagian data deret waktu dapat dinyatakan sebagai berikut:

$$D_{\text{train}} = Y_1, Y_2, \dots, Y_m \quad (2.17)$$

$$D_{\text{test}} = Y_{m+1}, Y_{m+2}, \dots, Y_n \quad (2.18)$$

dengan D_{train} merupakan data latih, D_{test} merupakan data uji, m merupakan batas akhir data latih, dan n merupakan jumlah seluruh data pengamatan. Dalam penelitian ini, data historis beban transformator digunakan untuk membangun model peramalan, kemudian hasil peramalan dibandingkan dengan data aktual pada periode pengujian. Karakteristik penting dalam model deret waktu adalah adanya hubungan antarperiode. Hubungan ini menunjukkan bahwa nilai beban pada suatu waktu dapat memiliki keterkaitan dengan nilai beban pada periode sebelumnya. Secara sederhana, hubungan tersebut dapat dinyatakan sebagai berikut:

$$Y_t = \alpha Y_{t-1} + e_t \quad (2.19)$$

dengan Y_t merupakan nilai beban pada periode ke- t , Y_{t-1} merupakan nilai beban pada periode sebelumnya, α merupakan parameter yang menunjukkan tingkat pengaruh periode sebelumnya terhadap periode saat ini, dan e_t merupakan komponen error. Persamaan ini menunjukkan bahwa data deret waktu memiliki sifat ketergantungan temporal, yaitu kondisi saat ini dapat dipengaruhi oleh kondisi sebelumnya.

Dalam konteks beban transformator, penggunaan model deret waktu menjadi relevan karena beban listrik umumnya memiliki pola historis tertentu. Beban pada minggu tertentu

dapat berkaitan dengan beban pada minggu sebelumnya, baik karena pola konsumsi masyarakat, aktivitas industri, maupun kondisi operasional sistem. Oleh karena itu, pola historis tersebut dapat dimanfaatkan untuk memperkirakan beban pada periode berikutnya. Namun, model deret waktu juga memiliki keterbatasan. Apabila terjadi perubahan mendadak yang tidak tercermin dalam data historis, seperti lonjakan beban ekstrem, perubahan konfigurasi jaringan, gangguan sistem, atau pengaruh faktor eksternal lainnya, maka model dapat mengalami peningkatan kesalahan prediksi. Hal ini terjadi karena model deret waktu univariat hanya belajar dari pola masa lalu dan tidak memasukkan variabel eksternal secara langsung.

Dengan demikian, model deret waktu dalam penelitian ini digunakan sebagai dasar untuk membandingkan kemampuan beberapa model peramalan beban transformator. Model-model tersebut kemudian dievaluasi untuk mengetahui tingkat akurasi, kestabilan, dan keandalannya dalam menghadapi karakteristik beban yang berbeda pada masing-masing transformator.

1.4 Model Peramalan Deterministik

Model peramalan deterministik merupakan model yang memandang perubahan data sebagai fungsi tertentu terhadap waktu [44]. Dalam pendekatan ini, nilai beban pada suatu periode diasumsikan dapat dijelaskan oleh pola hubungan matematis antara variabel waktu dan nilai beban historis. Dengan kata lain, waktu digunakan sebagai variabel independen, sedangkan beban transformator digunakan sebagai variabel dependen.

Secara umum, model deterministik dalam peramalan beban dapat dinyatakan sebagai berikut:

$$Y_t = f(t) + e_t \quad (2.20)$$

dengan Y_t merupakan nilai beban aktual pada periode ke- t , $f(t)$ merupakan fungsi matematis yang menggambarkan pola perubahan beban terhadap waktu, dan e_t merupakan komponen error atau selisih antara nilai aktual dan nilai yang diperkirakan oleh model. Persamaan ini menunjukkan bahwa perubahan beban dipandang sebagai fungsi dari waktu.

Hasil peramalan dari model deterministik dapat dinyatakan sebagai:

$$\hat{Y}_t = f(t) \quad (2.21)$$

dengan $\hat{Y}_t$ merupakan nilai hasil peramalan pada periode ke- t . Apabila model telah terbentuk berdasarkan data historis, maka nilai beban pada periode mendatang dapat diperkirakan dengan memasukkan nilai waktu ke dalam fungsi model tersebut.

Model deterministik memiliki beberapa keunggulan, yaitu sederhana, mudah diterapkan, mudah diinterpretasikan, dan tidak membutuhkan proses komputasi yang rumit. Model ini sesuai digunakan apabila data memiliki pola tren yang relatif jelas. Namun, model deterministik juga memiliki keterbatasan karena umumnya hanya mengikuti pola rata-rata historis, sehingga kurang responsif terhadap perubahan mendadak atau lonjakan beban ekstrem.

Dalam penelitian ini, model deterministik yang digunakan terdiri atas model Linear, Eksponensial, Logaritmik, Polinomial Orde 2, Polinomial Orde 3, dan Polinomial Orde 4.

2.4.1 Model Linear

Model Linear merupakan model deterministik paling sederhana yang menggambarkan hubungan antara waktu dan beban dalam bentuk garis lurus. Model ini mengasumsikan bahwa perubahan beban dari waktu ke waktu cenderung konstan, baik meningkat maupun menurun. Model Linear sesuai digunakan apabila data historis menunjukkan pola pertumbuhan atau penurunan yang relatif stabil.

Bentuk umum model Linear dinyatakan sebagai berikut:

$$\hat{Y}_t = a + bt \quad (2.22)$$

dengan $\hat{Y}_t$ merupakan nilai hasil peramalan pada periode ke- t , a merupakan konstanta atau intersep, b merupakan koefisien kemiringan garis atau slope, dan t merupakan indeks waktu. Nilai a menunjukkan nilai awal ketika $t = 0$, sedangkan nilai b menunjukkan arah dan besar perubahan beban setiap satu periode waktu.

Apabila $b > 0$, maka model menunjukkan tren beban yang meningkat. Apabila $b < 0$, maka model menunjukkan tren beban yang menurun. Sementara itu, apabila b mendekati nol, maka data cenderung stabil atau tidak mengalami perubahan yang signifikan.

Parameter a dan b dapat diperoleh dengan metode kuadrat terkecil atau least squares, yaitu metode yang mencari parameter model dengan meminimalkan jumlah kuadrat error. Fungsi minimisasi pada model Linear dapat dituliskan sebagai berikut:

$$\min \sum_{t=1}^n (Y_t - \hat{Y}_t)^2 \quad (2.23)$$

atau

$$\min \sum_{t=1}^n (Y_t - a - bt)^2 \quad (2.24)$$

dengan Y_t merupakan nilai aktual, $\hat{Y}_t$ merupakan nilai hasil estimasi model, dan n merupakan jumlah data pengamatan. Semakin kecil jumlah kuadrat error, semakin baik model dalam mengikuti pola data historis.

2.4.2 Model Eksponensial

Model Eksponensial digunakan untuk menggambarkan pola perubahan data yang meningkat atau menurun dengan laju pertumbuhan tertentu. Model ini sesuai digunakan apabila data beban menunjukkan pertumbuhan yang semakin cepat atau penurunan yang tidak bersifat linear.

Bentuk umum model Eksponensial dinyatakan sebagai berikut:

$$\hat{Y}_t = ae^{bt} \quad (2.25)$$

dengan $\hat{Y}_t$ merupakan nilai hasil peramalan pada periode ke- t , a merupakan konstanta awal, e merupakan bilangan eksponensial, b merupakan parameter laju pertumbuhan atau penurunan, dan t merupakan indeks waktu.

Apabila $b > 0$, maka model menunjukkan pola pertumbuhan eksponensial. Apabila $b < 0$, maka model menunjukkan pola penurunan eksponensial. Model ini dapat menangkap perubahan beban yang bergerak lebih cepat dibandingkan model Linear.

Untuk memudahkan estimasi parameter, model Eksponensial dapat diubah ke bentuk linear melalui transformasi logaritma natural sebagai berikut:

$$\ln(\hat{Y}_t) = \ln(a) + bt \quad (2.26)$$

Jika dinyatakan dalam bentuk regresi linear, maka persamaan tersebut dapat ditulis sebagai:

$$Z_t = A + bt \quad (2.27)$$

dengan $Z_t = \ln(Y_t)$ dan $A = \ln(a)$. Setelah parameter A diperoleh, nilai a dapat dihitung kembali dengan:

$$a = e^A \quad (2.28)$$

Model Eksponensial memiliki kelebihan dalam mengikuti pola pertumbuhan yang cepat. Namun, model ini perlu digunakan secara hati-hati karena dapat menghasilkan prediksi yang terlalu tinggi apabila data mengalami kenaikan tajam hanya pada periode tertentu.

2.4.3 Model Logaritmik

Model Logaritmik digunakan untuk menggambarkan pola perubahan data yang meningkat cepat pada awal periode, kemudian pertumbuhannya melambat pada periode berikutnya. Model ini sesuai digunakan apabila beban mengalami peningkatan, tetapi laju peningkatannya semakin kecil seiring bertambahnya waktu.

Bentuk umum model Logaritmik dinyatakan sebagai berikut:

$$\hat{Y}_t = a + b \ln(t) \quad (2.29)$$

dengan $\hat{Y}_t$ merupakan nilai hasil peramalan pada periode ke- t , a merupakan konstanta, b merupakan koefisien perubahan logaritmik, dan $\ln(t)$ merupakan logaritma natural dari indeks waktu.

Model Logaritmik menunjukkan bahwa pengaruh waktu terhadap perubahan beban tidak selalu konstan. Pada awal periode, perubahan nilai t dapat memberikan pengaruh

yang cukup besar terhadap hasil prediksi. Namun, pada periode yang lebih besar, pengaruh tambahan waktu terhadap perubahan beban menjadi semakin kecil.

Parameter model Logaritmik dapat diperoleh dengan pendekatan regresi linear setelah variabel waktu ditransformasikan menjadi $\ln(t)$. Dengan demikian, model Logaritmik dapat dipandang sebagai regresi linear terhadap variabel waktu yang telah ditransformasi.

Fungsi minimisasi model Logaritmik dapat dinyatakan sebagai berikut:

$$\min \sum_{t=1}^n (Y_t - a - b \ln(t))^2 \quad (2.30)$$

Model Logaritmik memiliki kelebihan dalam menggambarkan pola pertumbuhan yang cenderung melambat. Namun, model ini kurang sesuai apabila data menunjukkan lonjakan tajam atau pola pertumbuhan yang terus meningkat secara cepat.

2.4.4 Model Polinomial

Model Polinomial merupakan model deterministik yang digunakan untuk menggambarkan pola data yang berbentuk lengkung. Model ini lebih fleksibel dibandingkan model Linear karena mampu mengikuti pola perubahan data yang tidak membentuk garis lurus. Semakin tinggi orde polinomial, semakin besar fleksibilitas model dalam mengikuti variasi data historis.

Bentuk umum model Polinomial orde ke- k dapat dinyatakan sebagai berikut:

$$\hat{Y}_t = a_0 + a_1 t + a_2 t^2 + \dots + a_k t^k \quad (2.31)$$

dengan $\hat{Y}_t$ merupakan nilai hasil peramalan pada periode ke- t , a_0 merupakan konstanta, $a_1, a_2, \dots, a_k$ merupakan koefisien model, t merupakan indeks waktu, dan k merupakan orde polinomial.

Dalam penelitian ini, model Polinomial yang digunakan terdiri atas Polinomial Orde 2, Polinomial Orde 3, dan Polinomial Orde 4.

Model Polinomial Orde 2 dinyatakan sebagai berikut:

$$\hat{Y}_t = a_0 + a_1 t + a_2 t^2 \quad (2.32)$$

Model Polinomial Orde 2 dapat menggambarkan pola perubahan beban yang berbentuk lengkung sederhana. Model ini sesuai apabila data menunjukkan kecenderungan naik lalu melambat, atau turun lalu meningkat kembali.

Model Polinomial Orde 3 dinyatakan sebagai berikut:

$$\hat{Y}_t = a_0 + a_1 t + a_2 t^2 + a_3 t^3 \quad (2.33)$$

Model Polinomial Orde 3 memiliki fleksibilitas lebih tinggi dibandingkan Polinomial Orde 2 karena dapat menggambarkan pola perubahan yang memiliki lebih dari satu arah lengkungan. Model ini dapat mengikuti pola data yang mengalami perubahan tren lebih kompleks.

Model Polinomial Orde 4 dinyatakan sebagai berikut:

$$\hat{Y}_t = a_0 + a_1 t + a_2 t^2 + a_3 t^3 + a_4 t^4 \quad (2.34)$$

Model Polinomial Orde 4 memiliki fleksibilitas lebih besar dalam mengikuti pola data historis. Namun, semakin tinggi orde polinomial, semakin besar pula risiko model menjadi terlalu menyesuaikan diri terhadap data latih. Kondisi tersebut dikenal sebagai overfitting.

Secara umum, parameter model Polinomial diperoleh dengan meminimalkan jumlah kuadrat error sebagai berikut:

$$\min \sum_{t=1}^n (Y_t - \hat{Y}_t)^2 \quad (2.35)$$

atau untuk model Polinomial orde ke- k dapat dituliskan sebagai:

$$\min \sum_{t=1}^n \left(Y_t - (a_0 + a_1 t + a_2 t^2 + \dots + a_k t^k) \right)^2 \quad (2.36)$$

Model Polinomial memiliki kelebihan karena mampu mengikuti pola data yang tidak linear. Namun, penggunaan orde yang terlalu tinggi dapat menyebabkan model tampak sangat baik pada data latih, tetapi kurang baik ketika digunakan untuk memprediksi data baru. Oleh karena itu, pemilihan model Polinomial perlu mempertimbangkan keseimbangan antara fleksibilitas model dan kemampuan generalisasi.

2.4.5 Prinsip Parsimoni dalam Model Deterministik

Dalam pemilihan model peramalan, model yang lebih kompleks tidak selalu lebih baik dibandingkan model yang lebih sederhana. Prinsip parsimoni menyatakan bahwa model yang lebih sederhana lebih disukai apabila mampu memberikan hasil yang setara atau tidak jauh berbeda dengan model yang lebih kompleks. Prinsip ini penting dalam peramalan beban transformator karena model yang sederhana lebih mudah diterapkan, lebih mudah dijelaskan, dan lebih efisien secara komputasi.

Pada model deterministik, peningkatan kompleksitas dapat dilihat dari bertambahnya jumlah parameter model. Model Linear hanya memiliki dua parameter, yaitu a dan b . Model Polinomial Orde 2 memiliki tiga parameter, Polinomial Orde 3 memiliki empat parameter, dan Polinomial Orde 4 memiliki lima parameter. Semakin banyak parameter, semakin fleksibel model dalam mengikuti pola data, tetapi semakin besar pula risiko overfitting.

Secara sederhana, kompleksitas model deterministik dapat dilihat dari jumlah parameter sebagai berikut:

$$q = k + 1 \quad (2.37)$$

dengan q merupakan jumlah parameter model dan k merupakan orde tertinggi pada model Polinomial. Pada model Linear, nilai $k = 1$, sehingga jumlah parameternya adalah dua. Pada Polinomial Orde 4, nilai $k = 4$, sehingga jumlah parameternya adalah lima.

Dalam penelitian ini, penggunaan beberapa model deterministik bertujuan untuk membandingkan apakah model sederhana seperti Linear sudah cukup mampu memprediksi beban transformator, atau apakah model yang lebih kompleks seperti Polinomial Orde 3 dan Orde 4 memberikan peningkatan akurasi yang berarti. Dengan

demikian, evaluasi model tidak hanya didasarkan pada nilai kesalahan paling kecil, tetapi juga mempertimbangkan kestabilan model, kemudahan interpretasi, dan kesesuaian dengan kebutuhan operasional.

2.5 Model Peramalan Stokastik ETS

Model peramalan stokastik merupakan model yang mempertimbangkan adanya unsur ketidakpastian dalam data. Berbeda dengan model deterministik yang memandang perubahan beban sebagai fungsi langsung terhadap waktu, model stokastik menganggap bahwa data aktual terdiri atas pola sistematis dan komponen acak. Dalam peramalan beban listrik, pendekatan stokastik penting karena beban transformator tidak selalu berubah secara teratur, tetapi dapat dipengaruhi oleh fluktuasi yang tidak sepenuhnya dapat diprediksi dari pola historis.

Secara umum, model stokastik dapat dinyatakan sebagai berikut:

$$Y_t = \mu_t + e_t \quad (2.38)$$

dengan Y_t merupakan nilai aktual pada periode ke- t , μ_t merupakan komponen sistematis atau nilai harapan dari data pada periode ke- t , dan e_t merupakan komponen acak atau error. Komponen error menunjukkan bagian dari data yang tidak dapat dijelaskan sepenuhnya oleh model.

Dalam model stokastik, error biasanya diasumsikan memiliki nilai rata-rata nol dan variansi tertentu. Secara matematis, asumsi tersebut dapat dinyatakan sebagai berikut:

$$E(e_t) = 0 \quad (2.39)$$

$$Var(e_t) = \sigma^2 \quad (2.40)$$

dengan $E(e_t)$ merupakan nilai harapan error, $Var(e_t)$ merupakan variansi error, dan σ^2 merupakan besar penyebaran error. Asumsi ini menunjukkan bahwa error dapat bernilai positif atau negatif, tetapi secara rata-rata tidak condong ke arah tertentu.

Salah satu model stokastik yang banyak digunakan dalam peramalan deret waktu adalah ETS [45]. ETS merupakan singkatan dari Error, Trend, dan Seasonality. Model ini menjelaskan bahwa data deret waktu dapat dipengaruhi oleh tiga komponen utama, yaitu komponen kesalahan atau error, komponen tren, dan komponen musiman. Komponen error menunjukkan penyimpangan antara nilai aktual dan nilai hasil prediksi. Komponen trend menunjukkan arah perubahan data dari waktu ke waktu, sedangkan komponen seasonality menunjukkan pola berulang dalam periode tertentu.

Secara sederhana, struktur umum model ETS dapat dinyatakan sebagai berikut:

$$Y_t = l_{t-1} + b_{t-1} + s_{t-m} + e_t \quad (2.41)$$

dengan Y_t merupakan nilai aktual pada periode ke- t , l_{t-1} merupakan komponen level pada periode sebelumnya, b_{t-1} merupakan komponen tren pada periode sebelumnya, s_{t-m} merupakan komponen musiman dari periode sebelumnya yang bersesuaian, m merupakan panjang periode musiman, dan e_t merupakan error pada periode ke- t .

Komponen level menunjukkan nilai dasar atau posisi rata-rata data pada suatu periode. Pada metode exponential smoothing, level diperbarui dengan memberikan bobot lebih besar pada data terbaru. Persamaan pembaruan level dapat dinyatakan sebagai berikut:

$$l_t = \alpha(Y_t - s_{t-m}) + (1 - \alpha)(l_{t-1} + b_{t-1}) \quad (2.42)$$

dengan l_t merupakan level pada periode ke- t , α merupakan parameter pemulusan level, Y_t merupakan nilai aktual, s_{t-m} merupakan komponen musiman, l_{t-1} merupakan level sebelumnya, dan b_{t-1} merupakan tren sebelumnya. Nilai α berada pada rentang 0 sampai 1. Semakin besar nilai α , semakin besar pengaruh data terbaru terhadap pembentukan level.

Komponen tren menunjukkan arah perubahan data dari waktu ke waktu. Pembaruan tren dapat dinyatakan sebagai berikut:

$$b_t = \beta(l_t - l_{t-1}) + (1 - \beta)b_{t-1} \quad (2.43)$$

dengan b_t merupakan tren pada periode ke- t , β merupakan parameter pemulusan tren, l_t merupakan level saat ini, l_{t-1} merupakan level sebelumnya, dan b_{t-1} merupakan tren sebelumnya. Nilai β juga berada pada rentang 0 sampai 1. Parameter ini mengatur seberapa besar perubahan level terbaru memengaruhi estimasi tren.

Komponen musiman menunjukkan pola berulang yang muncul dalam periode tertentu. Pada data beban listrik mingguan, pola musiman dapat terjadi apabila terdapat pola berulang dalam periode tahunan, bulanan, atau periode tertentu lainnya. Pembaruan komponen musiman dapat dinyatakan sebagai berikut:

$$s_t = \gamma(Y_t - l_t) + (1 - \gamma)s_{t-m} \quad (2.44)$$

dengan s_t merupakan komponen musiman pada periode ke- t , γ merupakan parameter pemulusan musiman, Y_t merupakan nilai aktual, l_t merupakan level saat ini, dan s_{t-m} merupakan komponen musiman pada periode sebelumnya yang bersesuaian. Nilai γ berada pada rentang 0 sampai 1.

Setelah komponen level, tren, dan musiman diperbarui, nilai ramalan untuk periode mendatang dapat dihitung. Secara umum, ramalan model ETS untuk periode $t + h$ dapat dinyatakan sebagai berikut:

$$\hat{Y}_{t+h} = l_t + hb_t + st + h - m \quad (2.45)$$

dengan $\hat{Y}_{t+h}$ merupakan nilai hasil peramalan untuk periode $t + h$, l_t merupakan level terakhir, b_t merupakan tren terakhir, h merupakan horizon peramalan, dan $st + h - m$ merupakan komponen musiman yang sesuai dengan periode ramalan. Persamaan ini menunjukkan bahwa nilai ramalan ETS dibentuk dari gabungan level, tren, dan pola musiman.

Error pada model ETS dapat dihitung sebagai selisih antara nilai aktual dan nilai hasil peramalan. Persamaan error dinyatakan sebagai berikut:

$$e_t = Y_t - \hat{Y}_t \quad (2.46)$$

dengan e_t merupakan error pada periode ke- t , Y_t merupakan nilai aktual, dan $\hat{Y}_t$ merupakan nilai hasil peramalan. Error ini digunakan untuk menilai sejauh mana model ETS mampu mengikuti pola data aktual.

Parameter pemulusan dalam model ETS terdiri atas α , β , dan γ . Parameter α digunakan untuk mengatur pembaruan level, β digunakan untuk mengatur pembaruan tren, dan γ digunakan untuk mengatur pembaruan musiman. Ketiga parameter tersebut berada pada rentang sebagai berikut:

$$0 \leq \alpha \leq 1 \quad (2.47)$$

$$0 \leq \beta \leq 1 \quad (2.48)$$

$$0 \leq \gamma \leq 1 \quad (2.49)$$

Pemilihan nilai parameter yang tepat sangat penting karena berpengaruh terhadap kemampuan model dalam menyesuaikan diri terhadap pola data. Jika parameter terlalu besar, model dapat menjadi terlalu sensitif terhadap perubahan data terbaru. Sebaliknya, jika parameter terlalu kecil, model dapat menjadi kurang responsif terhadap perubahan pola beban.

Dalam peramalan beban transformator, model ETS memiliki keunggulan karena mampu menangkap perubahan level, arah tren, dan kemungkinan pola musiman pada data beban. Model ini lebih adaptif dibandingkan model deterministik sederhana karena pembaruan komponennya dilakukan secara berulang mengikuti perubahan data terbaru. Oleh karena itu, ETS dapat digunakan untuk menganalisis data beban yang memiliki pola dinamis.

Namun, model ETS juga memiliki keterbatasan. Pada kondisi beban yang mengalami lonjakan ekstrem atau load spike, model dapat menghasilkan prediksi yang kurang akurat apabila lonjakan tersebut tidak pernah muncul pada pola historis sebelumnya. Selain itu, apabila model terlalu sensitif terhadap data ekstrem, hasil prediksi dapat mengalami overshooting, yaitu kondisi ketika model memberikan respons terlalu besar terhadap perubahan sesaat.

Dalam penelitian ini, model ETS digunakan sebagai wakil dari pendekatan stokastik dan dibandingkan dengan model-model deterministik, yaitu Linear, Eksponensial, Logaritmik, Polinomial Orde 2, Polinomial Orde 3, dan Polinomial Orde 4. Perbandingan ini dilakukan untuk mengetahui apakah model ETS mampu memberikan hasil peramalan yang lebih akurat dan reliabel dibandingkan model tren deterministik, terutama pada kondisi beban transformator yang stabil maupun mengalami volatilitas ekstrem.

2.6 Volatilitas Beban, Load Spike, dan Kestabilan Model

Volatilitas beban listrik menunjukkan tingkat perubahan atau fluktuasi beban dalam suatu periode waktu [46]. Beban dikatakan stabil apabila perubahan nilainya relatif kecil, teratur, dan masih mengikuti pola historis yang dapat dikenali. Sebaliknya, beban dikatakan volatil apabila mengalami perubahan yang besar, tidak teratur, atau mendadak. Dalam sistem transformator daya, volatilitas beban menjadi perhatian penting karena perubahan beban yang tinggi dapat menyebabkan transformator bekerja lebih berat dan berpotensi mendekati batas aman pembebanan.

Secara sederhana, perubahan beban antarperiode dapat dinyatakan sebagai selisih antara beban pada periode saat ini dan beban pada periode sebelumnya. Persamaan perubahan beban dinyatakan sebagai berikut:

$$\Delta Y_t = Y_t - Y_{t-1} \quad (2.50)$$

dengan ΔY_t merupakan perubahan beban pada periode ke- t , Y_t merupakan beban pada periode ke- t , dan Y_{t-1} merupakan beban pada periode sebelumnya. Nilai ΔY_t yang positif menunjukkan adanya kenaikan beban, sedangkan nilai negatif menunjukkan adanya penurunan beban.

Selain dalam bentuk selisih absolut, perubahan beban juga dapat dinyatakan dalam bentuk persentase. Persentase perubahan beban dapat dituliskan sebagai berikut:

$$\Delta Y_t(\%) = \frac{Y_t - Y_{t-1}}{Y_{t-1}} \times 100\% \quad (2.51)$$

dengan ΔY_t merupakan persentase perubahan beban antarperiode. Persamaan ini berguna untuk melihat seberapa besar perubahan beban relatif terhadap beban pada periode sebelumnya. Semakin besar nilai persentase perubahan, semakin tinggi tingkat fluktuasi beban yang terjadi.

Untuk menggambarkan tingkat penyebaran beban terhadap nilai rata-ratanya, volatilitas dapat dilihat melalui simpangan baku. Rata-rata beban dinyatakan sebagai berikut:

$$\bar{Y} = \frac{1}{n} \sum_{t=1}^n Y_t \quad (2.52)$$

dengan $\bar{Y}$ merupakan rata-rata beban, Y_t merupakan nilai beban pada periode ke- t , dan n merupakan jumlah data pengamatan. Rata-rata beban menunjukkan nilai pusat dari data beban selama periode pengamatan. Simpangan baku beban dapat dinyatakan sebagai berikut:

$$\sigma = \sqrt{\frac{1}{n-1} \sum_{t=1}^n (Y_t - \bar{Y})^2} \quad (2.53)$$

dengan σ merupakan simpangan baku beban. Semakin besar nilai σ , semakin besar penyebaran data beban terhadap rata-ratanya. Hal ini menunjukkan bahwa beban mengalami fluktuasi yang lebih tinggi.

Untuk membandingkan tingkat variasi antartransformator yang memiliki nilai rata-rata beban berbeda, dapat digunakan koefisien variasi atau coefficient of variation. Persamaannya dinyatakan sebagai berikut:

$$CV = \frac{\sigma}{\bar{Y}} \times 100 \quad (2.54)$$

dengan CV merupakan koefisien variasi. Nilai CV yang lebih tinggi menunjukkan bahwa beban lebih berfluktuasi dibandingkan rata-ratanya. Sebaliknya, nilai CV yang rendah menunjukkan bahwa beban relatif lebih stabil.

Salah satu bentuk volatilitas yang penting dalam peramalan beban transformator adalah load spike atau lonjakan beban. Load spike merupakan kondisi ketika beban meningkat secara tajam

dalam waktu tertentu dibandingkan pola normalnya. Lonjakan beban dapat terjadi akibat peningkatan kebutuhan konsumen, aktivitas industri, perubahan konfigurasi jaringan, kondisi cuaca, hari libur, gangguan sistem, atau faktor operasional lainnya.

Secara umum, suatu data beban dapat dikategorikan sebagai lonjakan apabila nilainya jauh lebih tinggi daripada rata-rata historis. Salah satu pendekatan sederhana untuk mengidentifikasi lonjakan beban adalah menggunakan batas berbasis rata-rata dan simpangan baku sebagai berikut:

$$Y_t > \bar{Y} + z\sigma \quad (2.55)$$

dengan Y_t merupakan nilai beban pada periode ke- t , $\bar{Y}$ merupakan rata-rata beban historis, σ merupakan simpangan baku, dan z merupakan faktor pengali simpangan baku. Jika nilai Y_t melebihi batas tersebut, maka data tersebut dapat dianggap sebagai indikasi lonjakan beban. Nilai z dapat ditentukan sesuai tingkat sensitivitas analisis, misalnya 2 atau 3 simpangan baku.

Selain menggunakan pendekatan rata-rata dan simpangan baku, lonjakan beban juga dapat dilihat dari perubahan beban antarperiode. Suatu periode dapat dicurigai mengalami lonjakan apabila persentase perubahan beban melebihi ambang batas tertentu. Secara umum dapat dituliskan sebagai berikut:

$$Y_t > \bar{Y} + z\sigma \quad (2.55)$$

$$\Delta Y_t(\%) > \theta \quad (2.56)$$

dengan θ merupakan ambang batas perubahan beban yang ditentukan oleh peneliti atau operator sistem. Apabila persentase perubahan beban lebih besar dari nilai θ , maka periode tersebut dapat dikategorikan sebagai periode dengan perubahan beban yang tinggi.

Dalam konteks transformator daya, load spike penting untuk diperhatikan karena dapat meningkatkan risiko pembebanan berlebih. Meskipun rata-rata beban transformator tidak terlalu tinggi, lonjakan sesaat dapat menyebabkan transformator mendekati atau bahkan melampaui batas evaluasi pembebanan. Oleh karena itu, analisis beban tidak cukup hanya dilihat dari rata-rata, tetapi juga perlu memperhatikan nilai maksimum, fluktuasi, dan perubahan mendadak pada periode tertentu.

Nilai maksimum beban dapat dinyatakan sebagai berikut:

$$Y_{\text{maks}} = \max(Y_1, Y_2, Y_3, \dots, Y_n) \quad (2.57)$$

dengan Y_{maks} merupakan beban maksimum selama periode pengamatan. Nilai ini penting untuk melihat puncak beban tertinggi yang pernah terjadi pada transformator.

Selain nilai maksimum, rentang beban juga dapat digunakan untuk menggambarkan variasi beban. Rentang beban dinyatakan sebagai berikut:

$$R = Y_{\text{maks}} - Y_{\text{min}} \quad (2.58)$$

dengan R merupakan rentang beban, Y_{maks} merupakan nilai beban maksimum, dan Y_{min} merupakan nilai beban minimum. Semakin besar nilai rentang beban, semakin besar perbedaan antara kondisi beban terendah dan tertinggi.

Volatilitas beban memiliki hubungan erat dengan kinerja model peramalan. Pada kondisi beban yang stabil, model peramalan umumnya lebih mudah mengikuti pola historis karena perubahan data relatif teratur. Model deterministik sederhana, seperti Linear atau Polinomial, dapat memberikan hasil yang cukup baik apabila data memiliki tren yang jelas. Namun, pada kondisi beban yang sangat fluktuatif atau mengalami lonjakan ekstrem, model dapat mengalami peningkatan error karena pola lonjakan tersebut sulit diprediksi hanya dari data historis. Kestabilan model peramalan menunjukkan kemampuan model untuk menghasilkan prediksi yang konsisten dan tidak terlalu sensitif terhadap perubahan kecil maupun data ekstrem. Model yang stabil tidak hanya memiliki nilai error yang rendah, tetapi juga menghasilkan pola prediksi yang wajar, tidak berfluktuasi secara berlebihan, dan tetap dapat digunakan pada berbagai kondisi beban.

Secara umum, kestabilan model dapat diamati dari sebaran error yang dihasilkan [47]. Jika error model memiliki penyebaran yang kecil, maka model dapat dikatakan lebih stabil. Rata-rata error dapat dinyatakan sebagai berikut:

$$\bar{e} = \frac{1}{n} \sum_{t=1}^n e_t \quad (2.59)$$

dengan $\bar{e}$ merupakan rata-rata error dan e_t merupakan error pada periode ke- t . Namun, karena error dapat bernilai positif maupun negatif, analisis kestabilan biasanya lebih tepat dilakukan dengan melihat error absolut atau kuadrat error.

Simpangan baku error dapat digunakan untuk melihat konsistensi kesalahan model. Persamaannya dinyatakan sebagai berikut:

$$\sigma_e = \sqrt{\frac{1}{n-1} \sum_{t=1}^n (e_t - \bar{e})^2} \quad (2.60)$$

dengan σ_e merupakan simpangan baku error. Semakin kecil nilai σ_e , semakin stabil error yang dihasilkan oleh model. Sebaliknya, nilai σ_e yang besar menunjukkan bahwa model menghasilkan error yang sangat bervariasi pada periode tertentu.

Kestabilan model juga berkaitan dengan kemampuan model dalam melakukan generalisasi. Generalisasi menunjukkan kemampuan model yang dibangun dari data latih untuk tetap menghasilkan prediksi yang baik pada data uji. Model yang terlalu menyesuaikan diri terhadap data latih dapat mengalami overfitting. Overfitting terjadi ketika model tampak sangat baik pada data latih, tetapi kurang baik ketika digunakan untuk memprediksi data baru.

Secara konseptual, overfitting dapat dilihat dari perbedaan error antara data latih dan data uji. Selisih error tersebut dapat dinyatakan sebagai berikut:

$$G = E_{\text{test}} - E_{\text{train}} \quad (2.61)$$

dengan G merupakan selisih kemampuan generalisasi, E_{test} merupakan error pada data uji, dan E_{train} merupakan error pada data latih. Jika nilai G sangat besar, maka model berpotensi mengalami overfitting karena performanya pada data uji jauh lebih buruk dibandingkan data latih.

Dalam peramalan beban transformator, kestabilan model sangat penting karena hasil peramalan digunakan untuk mendukung pengambilan keputusan operasional. Model dengan error rata-rata rendah tetapi sangat sensitif terhadap lonjakan beban dapat memberikan hasil prediksi yang kurang dapat diandalkan. Sebaliknya, model yang stabil dan memiliki error yang

konsisten dapat lebih berguna dalam perencanaan pembebanan, meskipun tingkat akurasinya tidak selalu menjadi yang paling tinggi pada setiap periode.

Dengan demikian, volatilitas beban, load spike, dan kestabilan model merupakan konsep yang saling berkaitan. Volatilitas beban menggambarkan tingkat perubahan beban, load spike menunjukkan adanya lonjakan beban ekstrem, sedangkan kestabilan model menggambarkan kemampuan model dalam menghadapi variasi data tersebut. Dalam penelitian ini, ketiga konsep tersebut digunakan sebagai dasar untuk menilai apakah model peramalan mampu memberikan hasil yang akurat, stabil, dan layak digunakan dalam perencanaan pembebanan transformator.

2.7 Evaluasi Akurasi Model Peramalan

Evaluasi akurasi model peramalan merupakan tahap penting untuk menilai seberapa baik model mampu menghasilkan prediksi yang mendekati nilai aktual. Dalam peramalan beban listrik, evaluasi akurasi dilakukan dengan membandingkan hasil peramalan terhadap data beban aktual pada periode pengujian [48]. Semakin kecil nilai kesalahan yang dihasilkan, semakin baik kemampuan model dalam memprediksi beban.

Secara umum, kesalahan peramalan atau forecasting error dinyatakan sebagai selisih antara nilai aktual dan nilai hasil peramalan. Persamaan error dapat dituliskan sebagai berikut:

$$e_t = Y_t - \hat{Y}_t \quad (2.62)$$

dengan e_t merupakan kesalahan peramalan pada periode ke- t , Y_t merupakan nilai aktual, dan $\hat{Y}_t$ merupakan nilai hasil peramalan. Jika nilai e_t bernilai positif, maka hasil peramalan lebih rendah daripada nilai aktual. Sebaliknya, jika nilai e_t bernilai negatif, maka hasil peramalan lebih tinggi daripada nilai aktual.

Selain error biasa, evaluasi model juga dapat menggunakan error absolut. Error absolut menunjukkan besar kesalahan tanpa memperhatikan arah kesalahan, sehingga nilai kesalahan negatif dan positif tidak saling meniadakan. Error absolut dinyatakan sebagai berikut:

$$|e_t| = |Y_t - \hat{Y}_t| \quad (2.63)$$

dengan $|e_t|$ merupakan nilai absolut dari kesalahan peramalan. Nilai ini digunakan sebagai dasar dalam menghitung Mean Absolute Error dan Mean Absolute Percentage Error.

Dalam penelitian ini, evaluasi akurasi model dilakukan menggunakan tiga metrik utama, yaitu Mean Absolute Error (MAE), Root Mean Square Error (RMSE), dan Mean Absolute Percentage Error (MAPE). Ketiga metrik tersebut digunakan secara bersama-sama agar evaluasi model tidak hanya bergantung pada satu ukuran kesalahan.

2.7.1 Mean Absolute Error

Mean Absolute Error atau MAE merupakan ukuran kesalahan rata-rata yang dihitung dari nilai absolut selisih antara data aktual dan data hasil peramalan. MAE menunjukkan besarnya kesalahan rata-rata model dalam satuan yang sama dengan data asli. Dalam konteks penelitian ini, MAE menunjukkan rata-rata selisih antara beban aktual dan beban hasil peramalan[49].

Persamaan MAE dinyatakan sebagai berikut:

$$MAE = \frac{1}{n} \sum_{t=1}^n |Y_t - \hat{Y}_t| \quad (2.64)$$

dengan MAE merupakan Mean Absolute Error, n merupakan jumlah data pada periode pengujian, Y_t merupakan nilai aktual pada periode ke- t , dan $\hat{Y}_t$ merupakan nilai hasil peramalan pada periode ke- t .

Semakin kecil nilai MAE, semakin kecil rata-rata kesalahan yang dihasilkan oleh model. Kelebihan MAE adalah mudah dipahami karena nilainya berada dalam satuan yang sama dengan data aktual. Namun, MAE tidak memberikan penalti yang besar terhadap kesalahan ekstrem karena seluruh error dihitung secara linear.

2.7.2 Mean Squared Error

Mean Squared Error atau MSE merupakan ukuran kesalahan rata-rata yang dihitung dari kuadrat selisih antara nilai aktual dan nilai hasil peramalan. MSE digunakan sebagai dasar dalam perhitungan RMSE. Persamaan MSE dinyatakan sebagai berikut:

$$MSE = \frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2 \quad (2.65)$$

dengan *MSE* merupakan Mean Squared Error. Karena error dikuadratkan, kesalahan yang besar akan memiliki pengaruh lebih kuat terhadap nilai MSE. Oleh karena itu, MSE sensitif terhadap error besar atau lonjakan kesalahan pada periode tertentu.

2.7.3 Root Mean Square Error

Root Mean Square Error atau RMSE merupakan akar kuadrat dari rata-rata kuadrat error. RMSE digunakan untuk mengukur besarnya kesalahan model dengan memberikan bobot lebih besar pada error yang bernilai besar[50]. Persamaan RMSE dinyatakan sebagai berikut:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2} \quad (2.66)$$

dengan *RMSE* merupakan Root Mean Square Error, *n* merupakan jumlah data pengujian, Y_t merupakan nilai aktual, dan $\hat{Y}_t$ merupakan nilai hasil peramalan.

RMSE memiliki satuan yang sama dengan data aktual karena nilai MSE telah diakarkan. Dalam peramalan beban transformator, RMSE penting digunakan karena mampu menunjukkan apakah model menghasilkan kesalahan besar pada periode tertentu, terutama ketika terjadi lonjakan beban atau kondisi beban ekstrem. Semakin kecil nilai RMSE, semakin baik performa model dalam menghasilkan prediksi yang mendekati nilai aktual.

2.7.4 Absolute Percentage Error

Absolute Percentage Error atau APE merupakan persentase kesalahan absolut pada setiap periode pengamatan. APE digunakan untuk melihat besar kesalahan relatif terhadap nilai aktual. Persamaan APE dinyatakan sebagai berikut:

$$APE_t = \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| \times 100 \quad (2.67)$$

dengan APE_t merupakan persentase kesalahan absolut pada periode ke- t , Y_t merupakan nilai aktual, dan $\hat{Y}_t$ merupakan nilai hasil peramalan. Nilai APE menunjukkan seberapa besar kesalahan peramalan dalam bentuk persentase pada setiap periode.

2.7.5 Mean Absolute Percentage Error

Mean Absolute Percentage Error atau MAPE merupakan rata-rata dari nilai persentase kesalahan absolut. MAPE banyak digunakan dalam evaluasi peramalan karena hasilnya dinyatakan dalam bentuk persentase, sehingga lebih mudah dibandingkan antar model[51]. Persamaan MAPE dinyatakan sebagai berikut:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| \times 100 \quad (2.68)$$

dengan $MAPE$ merupakan Mean Absolute Percentage Error, n merupakan jumlah data pengujian, Y_t merupakan nilai aktual, dan $\hat{Y}_t$ merupakan nilai hasil peramalan.

Semakin kecil nilai MAPE, semakin baik tingkat akurasi model. Karena dinyatakan dalam persentase, MAPE memudahkan interpretasi hasil peramalan. Misalnya, MAPE sebesar 5% menunjukkan bahwa rata-rata kesalahan prediksi model adalah sekitar 5% dari nilai aktual. Namun, MAPE memiliki keterbatasan apabila nilai aktual mendekati nol karena dapat menghasilkan nilai persentase kesalahan yang sangat besar. Dalam konteks peramalan beban transformator, keterbatasan ini relatif dapat diminimalkan karena nilai beban transformator umumnya tidak bernilai nol.

2.7.6 Interpretasi Hasil Evaluasi

MAE, RMSE, dan MAPE memiliki karakteristik yang berbeda dalam menilai performa model. MAE menunjukkan rata-rata besar kesalahan dalam satuan asli data. RMSE memberikan perhatian lebih besar pada kesalahan yang besar, sehingga sesuai untuk mendeteksi model yang kurang baik saat menghadapi lonjakan beban. MAPE menunjukkan kesalahan dalam bentuk persentase, sehingga memudahkan perbandingan antar model dan antartransformator.

Hubungan umum antara nilai aktual, nilai prediksi, dan error dapat dinyatakan sebagai berikut:

$$Y_t = \hat{Y}_t + e_t \quad (2.69)$$

Persamaan tersebut menunjukkan bahwa nilai aktual terdiri atas nilai hasil peramalan ditambah error. Semakin kecil nilai error, semakin dekat hasil peramalan terhadap nilai aktual.

Dalam penelitian ini, ketiga metrik tersebut digunakan untuk mengevaluasi tujuh model peramalan, yaitu ETS, Linear, Eksponensial, Logaritmik, Polinomial Orde 2, Polinomial Orde 3, dan Polinomial Orde 4. Model dengan nilai MAE, RMSE, dan MAPE yang lebih kecil dianggap memiliki performa prediksi yang lebih baik. Namun, penentuan model terbaik tidak hanya didasarkan pada nilai kesalahan terkecil, tetapi juga perlu mempertimbangkan kestabilan model, karakteristik error, kemampuan menghadapi beban ekstrem, serta hasil validasi statistik.

Dengan demikian, evaluasi akurasi model peramalan dalam penelitian ini berfungsi sebagai dasar untuk mengetahui kemampuan masing-masing model dalam memprediksi beban transformator. Hasil evaluasi ini kemudian digunakan untuk membandingkan performa model secara kuantitatif dan menjadi dasar bagi analisis lebih lanjut, seperti analisis distribusi kesalahan, interval prediksi, dan uji signifikansi statistik.

2.8 Evaluasi Akurasi Model Peramalan

Dalam peramalan beban listrik, hasil prediksi tidak selalu tepat sama dengan nilai aktual. Hal ini terjadi karena beban listrik dipengaruhi oleh berbagai faktor yang berubah dari waktu ke waktu, seperti pola konsumsi konsumen, aktivitas industri, kondisi operasional jaringan, serta faktor eksternal lain yang tidak selalu tercermin dalam data historis. Oleh karena itu, hasil peramalan tidak hanya perlu dinilai berdasarkan satu nilai prediksi tunggal, tetapi juga perlu dilengkapi dengan informasi mengenai tingkat ketidakpastian.

Prediksi tunggal atau point forecast hanya memberikan satu nilai ramalan untuk periode mendatang. Secara matematis, prediksi tunggal dapat dinyatakan sebagai berikut:

$$\hat{Y}_{t+h} \quad (2.70)$$

dengan $\hat{Y}_{t+h}$ merupakan nilai hasil peramalan pada periode $t + h$. Prediksi tunggal berguna untuk memberikan gambaran utama mengenai nilai beban yang diperkirakan. Namun, dalam

praktik operasional transformator, satu nilai prediksi saja belum cukup karena nilai aktual dapat berada di atas atau di bawah nilai hasil peramalan.

Untuk mengatasi keterbatasan tersebut, digunakan prediction interval atau interval prediksi. Prediction interval merupakan rentang nilai yang menunjukkan kemungkinan posisi nilai aktual pada periode mendatang dengan tingkat kepercayaan tertentu. Dengan adanya prediction interval, hasil peramalan tidak hanya menyajikan nilai tengah prediksi, tetapi juga memberikan batas bawah dan batas atas kemungkinan beban [52] .

Secara umum, prediction interval dapat dinyatakan sebagai berikut:

$$PI_{t+h} = L_{t+h}, U_{t+h} \quad (2.71)$$

dengan PI_{t+h} merupakan interval prediksi pada periode $t + h$, L_{t+h} merupakan batas bawah interval prediksi, dan U_{t+h} merupakan batas atas interval prediksi. Nilai aktual dikatakan tercakup dalam interval prediksi apabila berada di antara batas bawah dan batas atas tersebut.

Kondisi nilai aktual yang berada di dalam interval prediksi dapat dinyatakan sebagai berikut:

$$L_{t+h} \leq Y_{t+h} \leq U_{t+h} \quad (2.72)$$

dengan Y_{t+h} merupakan nilai aktual pada periode $t + h$. Apabila nilai aktual memenuhi kondisi tersebut, maka interval prediksi dianggap berhasil mencakup nilai aktual pada periode tersebut.

Batas bawah dan batas atas interval prediksi dapat dibentuk berdasarkan nilai hasil peramalan dan estimasi ketidakpastian error. Secara umum, batas interval prediksi dapat dinyatakan sebagai berikut:

$$L_{t+h} = \hat{Y}t + h - z_{\alpha/2}\sigma_e \quad (2.73)$$

$$U_{t+h} = \hat{Y}t + h + z_{\alpha/2}\sigma_e \quad (2.74)$$

dengan $\hat{Y}t + h$ merupakan nilai hasil peramalan pada periode $t + h$, $z_{\alpha/2}$ merupakan nilai kritis distribusi normal sesuai tingkat kepercayaan yang digunakan, dan σ_e merupakan simpangan baku error. Pada tingkat kepercayaan 95%, nilai $z_{\alpha/2}$ umumnya mendekati 1,96. Dengan demikian, semakin besar simpangan baku error, semakin lebar interval prediksi yang dihasilkan.

Secara sederhana, interval prediksi 95% dapat dituliskan sebagai berikut:

$$PI_{95} \quad (2.75)$$

Persamaan tersebut menunjukkan bahwa batas interval prediksi dibentuk dengan menambahkan dan mengurangi nilai ketidakpastian terhadap hasil peramalan. Semakin kecil ketidakpastian error, semakin sempit interval prediksi. Sebaliknya, semakin besar ketidakpastian error, semakin lebar interval prediksi yang dihasilkan.

Dalam peramalan beban transformator, interval prediksi memiliki peran penting karena dapat membantu operator memahami risiko pembebanan. Misalnya, apabila nilai prediksi titik masih berada di bawah batas aman, tetapi batas atas interval prediksi mendekati atau melebihi batas pembebanan, maka operator perlu tetap waspada. Dengan demikian, interval prediksi dapat digunakan sebagai alat bantu dalam pengambilan keputusan berbasis risiko.

Untuk mengevaluasi kualitas interval prediksi, digunakan dua indikator utama, yaitu Prediction Interval Coverage Probability dan Prediction Interval Normalized Average Width.

Prediction Interval Coverage Probability atau PICP menunjukkan persentase nilai aktual yang berhasil tercakup di dalam interval prediksi. PICP mengukur tingkat keandalan interval prediksi. Semakin tinggi nilai PICP, semakin banyak data aktual yang berada di dalam interval prediksi.

Sebelum menghitung PICP, terlebih dahulu didefinisikan indikator cakupan interval sebagai berikut:

$$c_t = \begin{cases} 1, & \text{jika } L_t \leq Y_t \leq U_t \\ 0, & \text{jika } Y_t < L_t \text{ atau } Y_t > U_t \end{cases} \quad (2.76)$$

dengan c_t merupakan indikator cakupan pada periode ke- t . Nilai $c_t = 1$ menunjukkan bahwa nilai aktual berada di dalam interval prediksi, sedangkan nilai $c_t = 0$ menunjukkan bahwa nilai aktual berada di luar interval prediksi.

Berdasarkan indikator tersebut, PICP dapat dinyatakan sebagai berikut:

$$PICP = \frac{1}{n} \sum_{t=1}^n c_t \times 100 \quad (2.77)$$

dengan *PICP* merupakan Prediction Interval Coverage Probability, n merupakan jumlah data pengujian, dan c_t merupakan indikator cakupan interval pada periode ke- t . Jika tingkat kepercayaan interval prediksi yang digunakan adalah 95%, maka model yang baik diharapkan memiliki nilai *PICP* yang mendekati 95%. Meskipun nilai *PICP* yang tinggi menunjukkan interval prediksi mampu mencakup banyak nilai aktual, *PICP* saja belum cukup untuk menilai kualitas interval. Hal ini karena interval yang sangat lebar dapat menghasilkan *PICP* tinggi, tetapi kurang informatif bagi pengambilan keputusan. Oleh karena itu, perlu digunakan indikator lain untuk menilai lebar interval prediksi.

Prediction Interval Normalized Average Width atau *PINAW* digunakan untuk mengukur lebar rata-rata interval prediksi yang telah dinormalisasi terhadap rentang data aktual. *PINAW* menunjukkan seberapa lebar interval prediksi yang dihasilkan oleh model. Persamaan *PINAW* dinyatakan sebagai berikut:

$$PINAW = \frac{1}{nR} \sum_{t=1}^n (U_t - L_t) \times 100 \quad (2.78)$$

dengan *PINAW* merupakan Prediction Interval Normalized Average Width, U_t merupakan batas atas interval prediksi, L_t merupakan batas bawah interval prediksi, n merupakan jumlah data pengujian, dan R merupakan rentang nilai aktual.

Rentang nilai aktual dapat dinyatakan sebagai berikut:

$$R = Y_{\text{maks}} - Y_{\text{min}} \quad (2.79)$$

dengan Y_{maks} merupakan nilai aktual maksimum dan Y_{min} merupakan nilai aktual minimum pada periode pengujian. Normalisasi menggunakan rentang data diperlukan agar lebar interval dapat dibandingkan secara lebih proporsional.

Model peramalan yang baik seharusnya memiliki nilai *PICP* yang tinggi dan nilai *PINAW* yang tidak terlalu besar. Nilai *PICP* yang tinggi menunjukkan bahwa interval prediksi cukup andal dalam mencakup nilai aktual, sedangkan nilai *PINAW* yang rendah menunjukkan bahwa interval prediksi cukup tajam atau tidak terlalu lebar. Dengan kata lain, kualitas interval prediksi ditentukan oleh keseimbangan antara keandalan cakupan dan ketajaman interval.

Hubungan antara *PICP* dan *PINAW* menunjukkan adanya trade-off. Apabila interval prediksi dibuat terlalu lebar, maka *PICP* cenderung meningkat karena lebih banyak nilai aktual

yang masuk ke dalam interval. Namun, interval yang terlalu lebar menjadi kurang bermanfaat karena memberikan rentang risiko yang terlalu besar. Sebaliknya, apabila interval prediksi dibuat terlalu sempit, maka PINAW menjadi kecil, tetapi PICP dapat menurun karena banyak nilai aktual berada di luar interval.

Dalam konteks manajemen transformator, interval prediksi yang terlalu sempit dapat menimbulkan risiko keyakinan berlebih terhadap hasil peramalan. Model mungkin tampak akurat, tetapi gagal memberikan margin keamanan ketika terjadi lonjakan beban. Sebaliknya, interval prediksi yang terlalu lebar dapat membuat operator sulit mengambil keputusan karena rentang kemungkinan beban terlalu besar. Oleh karena itu, model yang baik adalah model yang mampu menghasilkan interval prediksi dengan cakupan yang tinggi dan lebar yang masih wajar.

Secara operasional, batas atas interval prediksi dapat digunakan untuk menilai potensi risiko pembebanan tinggi. Apabila batas atas interval prediksi mendekati batas pembebanan transformator, maka kondisi tersebut dapat dianggap sebagai indikasi perlunya perhatian operator. Hubungan tersebut dapat dinyatakan sebagai berikut:

$$U_{t+h} \geq P_{\text{batas}} \quad (2.80)$$

dengan U_{t+h} merupakan batas atas interval prediksi pada periode $t + h$, sedangkan P_{batas} merupakan batas evaluasi pembebanan transformator. Jika kondisi tersebut terpenuhi, maka terdapat potensi risiko bahwa beban aktual dapat mendekati atau melampaui batas evaluasi pembebanan.

Dengan demikian, prediction interval tidak hanya berfungsi sebagai pelengkap hasil peramalan, tetapi juga sebagai alat bantu untuk memahami ketidakpastian dan risiko operasional. Dalam penelitian ini, analisis interval prediksi digunakan untuk mengevaluasi kemampuan model ETS, Linear, Eksponensial, Logaritmik, Polinomial Orde 2, Polinomial Orde 3, dan Polinomial Orde 4 dalam merepresentasikan ketidakpastian beban transformator. Evaluasi dilakukan menggunakan indikator PICP dan PINAW agar model tidak hanya dinilai berdasarkan akurasi prediksi titik, tetapi juga berdasarkan keandalan dan ketajaman interval prediksinya.

2.9 Validasi Statistik dengan Uji Friedman

Dalam penelitian komparatif, perbedaan nilai kesalahan antar model peramalan tidak selalu menunjukkan bahwa satu model benar-benar lebih baik daripada model lainnya. Selisih nilai MAE, RMSE, atau MAPE yang kecil dapat terjadi karena variasi data, karakteristik periode pengujian, atau faktor kebetulan. Oleh karena itu, diperlukan uji statistik untuk mengetahui apakah perbedaan performa antar model memiliki makna secara ilmiah atau hanya merupakan perbedaan yang bersifat deskriptif.

Uji Friedman merupakan salah satu uji statistik non-parametrik yang digunakan untuk membandingkan lebih dari dua metode atau perlakuan pada data yang saling berpasangan [53]. Uji ini sesuai digunakan apabila beberapa model diuji pada objek atau periode pengujian yang sama. Dalam konteks peramalan beban transformator, Uji Friedman dapat digunakan untuk membandingkan performa beberapa model peramalan berdasarkan peringkat kesalahan yang dihasilkan pada data uji. Uji Friedman tidak mengharuskan data berdistribusi normal, sehingga sesuai digunakan pada data error peramalan yang sering kali tidak memenuhi asumsi normalitas. Uji ini bekerja dengan cara mengubah nilai performa model menjadi peringkat atau rank. Model dengan kesalahan terkecil memperoleh peringkat terbaik, sedangkan model dengan kesalahan terbesar memperoleh peringkat terburuk. Setelah itu, peringkat dari masing-masing model dibandingkan secara keseluruhan untuk mengetahui apakah terdapat perbedaan yang signifikan.

Misalkan terdapat k model peramalan yang dibandingkan dan N blok pengujian. Dalam penelitian ini, k merepresentasikan jumlah model peramalan, sedangkan N merepresentasikan jumlah data atau blok evaluasi yang digunakan dalam pengujian. Nilai performa model pada blok ke- i dan model ke- j dapat dinyatakan sebagai:

$$E_{ij}, \quad i = 1, 2, \dots, N; \quad j = 1, 2, \dots, k \quad (2.81)$$

dengan E_{ij} merupakan nilai error atau ukuran performa model ke- j pada blok pengujian ke- i . Nilai E_{ij} dapat berupa MAE, RMSE, MAPE, atau nilai error lain yang digunakan sebagai dasar pemeringkatan model.

Setiap nilai E_{ij} kemudian diubah menjadi peringkat. Peringkat model ke- j pada blok ke- i dinyatakan sebagai:

$$r_{ij} \quad (2.82)$$

dengan r_{ij} merupakan peringkat model ke- j pada blok ke- i . Dalam konteks evaluasi error, model dengan nilai error paling kecil diberikan peringkat terbaik. Apabila digunakan peringkat menaik, maka model dengan error terkecil memperoleh peringkat 1.

Jumlah peringkat untuk model ke- j dapat dinyatakan sebagai berikut:

$$R_j = \sum_{i=1}^N r_{ij} \quad (2.83)$$

dengan R_j merupakan jumlah peringkat model ke- j dari seluruh blok pengujian. Jumlah peringkat ini digunakan untuk melihat kecenderungan performa setiap model secara keseluruhan. Rata-rata peringkat model ke- j dapat dihitung dengan persamaan:

$$\bar{R}_j = \frac{R_j}{N} \quad (2.84)$$

dengan $\bar{R}_j$ merupakan rata-rata peringkat model ke- j . Model dengan rata-rata peringkat lebih kecil menunjukkan performa yang lebih baik apabila pemeringkatan dilakukan berdasarkan nilai error terkecil.

Statistik Uji Friedman dapat dinyatakan sebagai berikut:

$$\chi_F^2 = \frac{12}{Nk(k+1)} \sum_{j=1}^k R_j^2 - 3N(k+1) \quad (2.85)$$

dengan χ_F^2 merupakan nilai statistik Uji Friedman, N merupakan jumlah blok pengujian, k merupakan jumlah model yang dibandingkan, dan R_j merupakan jumlah peringkat model ke- j . Nilai statistik ini digunakan untuk menguji apakah perbedaan peringkat antar model cukup besar untuk dinyatakan signifikan secara statistik.

Selain menggunakan jumlah peringkat, statistik Uji Friedman juga dapat dinyatakan berdasarkan rata-rata peringkat sebagai berikut:

$$\chi_F^2 = \frac{12N}{k(k+1)} \sum_{j=1}^k \bar{R}_j^2 - 3N(k+1) \quad (2.86)$$

dengan $\bar{R}_j$ merupakan rata-rata peringkat model ke- j . Kedua bentuk persamaan tersebut memiliki makna yang sama, hanya berbeda pada penggunaan jumlah peringkat atau rata-rata peringkat.

Hipotesis dalam Uji Friedman dapat dirumuskan sebagai berikut:

H_0 : Tidak terdapat perbedaan performa yang signifikan antar model peramalan.

H_1 : Terdapat setidaknya satu model peramalan yang memiliki performa berbeda secara signifikan.

Pengambilan keputusan dalam Uji Friedman dilakukan dengan membandingkan nilai probabilitas atau p -value terhadap tingkat signifikansi yang digunakan. Secara umum, tingkat signifikansi yang banyak digunakan adalah $\alpha = 0,05$. Kriteria pengambilan keputusan dapat dinyatakan sebagai berikut:

$$p\text{-value} \leq \alpha \Rightarrow H_0 \text{ ditolak} \quad (2.87)$$

$$p\text{-value} > \alpha \Rightarrow H_0 \text{ gagal ditolak} \quad (2.88)$$

Apabila H_0 ditolak, maka dapat disimpulkan bahwa terdapat perbedaan performa yang signifikan antar model peramalan. Sebaliknya, apabila H_0 gagal ditolak, maka tidak terdapat cukup bukti statistik untuk menyatakan bahwa performa antar model berbeda secara signifikan.

Dalam beberapa kasus, apabila hasil Uji Friedman menunjukkan adanya perbedaan signifikan, maka analisis dapat dilanjutkan dengan uji post-hoc. Uji post-hoc digunakan untuk mengetahui pasangan model mana yang berbeda secara signifikan. Salah satu uji post-hoc yang dapat digunakan setelah Uji Friedman adalah uji Nemenyi.

Pada uji Nemenyi, perbedaan rata-rata peringkat antar dua model dibandingkan dengan nilai Critical Difference atau CD. Persamaan CD dapat dinyatakan sebagai berikut:

$$CD = q_\alpha \sqrt{\frac{k(k+1)}{6N}} \quad (2.89)$$

dengan CD merupakan critical difference, q_α merupakan nilai kritis berdasarkan tingkat signifikansi dan jumlah model, k merupakan jumlah model, dan N merupakan jumlah blok

pengujian. Dua model dinyatakan berbeda signifikan apabila selisih rata-rata peringkatnya lebih besar daripada nilai CD .

Kriteria perbandingan antar dua model dapat dituliskan sebagai berikut:

$$|\bar{R}_a - \bar{R}_b| > CD \quad (2.90)$$

dengan $\bar{R}_a$ dan $\bar{R}_b$ merupakan rata-rata peringkat dari dua model yang dibandingkan. Jika selisih rata-rata peringkat kedua model lebih besar daripada CD , maka kedua model tersebut memiliki perbedaan performa yang signifikan.

Selain melihat signifikansi statistik, kekuatan perbedaan antar model juga dapat dinilai menggunakan ukuran efek. Salah satu ukuran efek yang dapat digunakan pada Uji Friedman adalah Kendall's W . Persamaan Kendall's W dapat dinyatakan sebagai berikut:

$$W = \frac{\chi_F^2}{N(k-1)} \quad (2.91)$$

dengan W merupakan koefisien Kendall, χ_F^2 merupakan statistik Uji Friedman, N merupakan jumlah blok pengujian, dan k merupakan jumlah model yang dibandingkan. Nilai W berada pada rentang 0 sampai 1. Nilai yang mendekati 0 menunjukkan kesesuaian peringkat yang lemah, sedangkan nilai yang mendekati 1 menunjukkan perbedaan atau kesesuaian peringkat yang kuat.

Dalam penelitian ini, Uji Friedman digunakan untuk memvalidasi hasil perbandingan model peramalan beban transformator. Model yang dibandingkan meliputi ETS, Linear, Eksponensial, Logaritmik, Polinomial Orde 2, Polinomial Orde 3, dan Polinomial Orde 4. Uji ini dilakukan agar pemilihan model terbaik tidak hanya didasarkan pada nilai error terkecil secara deskriptif, tetapi juga memiliki dasar statistik yang lebih kuat.

Dengan adanya Uji Friedman, penelitian ini dapat menjawab apakah perbedaan performa antar model benar-benar signifikan atau tidak. Jika perbedaan tidak signifikan, maka model yang lebih sederhana dapat dipertimbangkan sebagai pilihan yang lebih efisien berdasarkan prinsip parsimoni. Sebaliknya, jika terdapat perbedaan signifikan, maka model dengan peringkat terbaik dapat dipertimbangkan sebagai model yang lebih unggul secara statistik. Dengan demikian, validasi statistik melalui Uji Friedman menjadi bagian penting dalam memperkuat kesimpulan penelitian.

2.10 Penelitian Terdahulu dan Kesenjangan Penelitian

Penelitian mengenai peramalan beban listrik, optimasi pembebanan transformator, dan manajemen risiko transformator telah banyak dilakukan dengan berbagai pendekatan. Secara umum, penelitian-penelitian sebelumnya dapat dikelompokkan menjadi beberapa fokus utama, yaitu peramalan beban listrik berbasis model gabungan atau hybrid, optimasi pembebanan dan ukuran transformator, pengendalian beban akibat penetrasi kendaraan listrik, serta identifikasi risiko overload transformator berbasis peramalan beban. Beberapa penelitian terdahulu berfokus pada peningkatan akurasi peramalan beban listrik. Penelitian pada jurnal Energy tahun 2015 mengembangkan model gabungan berbasis pra-analisis data dan optimasi koefisien bobot untuk peramalan beban listrik. Model tersebut menunjukkan bahwa kombinasi beberapa model dapat menghasilkan performa peramalan yang lebih baik dibandingkan model tunggal [1]. Penelitian lain pada Applied Soft Computing tahun 2019 juga mengusulkan model gabungan berbasis algoritma optimasi hibrida, praproses data, dan beberapa metode peramalan klasik. Hasil penelitian tersebut menunjukkan bahwa model hibrida mampu menghasilkan prediksi yang lebih mendekati nilai aktual dan dapat digunakan untuk mendukung perencanaan jaringan pintar [54].

Pendekatan berbasis kecerdasan komputasional juga banyak digunakan dalam peramalan beban listrik. Penelitian pada jurnal Energies tahun 2012 menggunakan Least Squares Support Vector Machine yang dikombinasikan dengan Fruit Fly Optimization Algorithm untuk peramalan beban tahunan. Hasilnya menunjukkan bahwa kombinasi LSSVM dan algoritma optimasi mampu memberikan performa yang lebih baik dibandingkan beberapa metode pembandingan [55]. Selain itu, penelitian pada jurnal Energy tahun 2010 menggunakan model gabungan yang melibatkan ARIMA musiman, exponential smoothing musiman, dan support vector machine berbobot dengan adaptive particle swarm optimization. Penelitian tersebut menunjukkan bahwa model gabungan memiliki potensi untuk meningkatkan kinerja peramalan beban listrik [56].

Selain peramalan beban, beberapa penelitian terdahulu juga membahas optimasi ukuran dan pemanfaatan transformator. Penelitian pada Rural Electric Power Conference tahun 2009 membahas optimasi ukuran transformator distribusi berdasarkan peramalan beban pelanggan. Penelitian tersebut menunjukkan bahwa estimasi ukuran transformator yang tepat dapat memberikan manfaat finansial dan meningkatkan efisiensi pemanfaatan aset [57]. Penelitian pada IEEE Transactions on Power Delivery tahun 2019 mengembangkan

metode desain empiris untuk optimasi pemanfaatan transformator distribusi. Penelitian tersebut menyoroti bahwa aliran energi yang semakin tinggi, tidak stabil, dan dua arah dapat memengaruhi pemanfaatan transformator sehingga diperlukan strategi desain dan pemanfaatan yang lebih tepat [58].

Kajian terkait pembebanan transformator juga banyak dikaitkan dengan batas termal dan keandalan operasi. Penelitian pada IEEE Transactions on Power Delivery tahun 2021 mengusulkan model optimasi pemindahan beban dengan mempertimbangkan batas hot-spot temperature dan top-oil temperature transformator. Hasil penelitian tersebut menunjukkan bahwa pengaturan pemindahan beban dapat membantu mengatasi kondisi overload dan menjaga batas termal transformator [59]. Penelitian lain pada Scientific African tahun 2023 mengembangkan model pembebanan termal adaptif untuk transformator pada jaringan distribusi rendah karbon dengan penetrasi kendaraan listrik dan heat pump. Penelitian tersebut menunjukkan bahwa pembebanan termal adaptif dapat meningkatkan kemampuan operasi transformator dalam menghadapi perubahan pola beban [60].

Penelitian terdahulu juga menunjukkan bahwa peningkatan beban akibat kendaraan listrik dapat memengaruhi kondisi transformator. Penelitian pada IEEE Transactions on Smart Grid tahun 2014 membahas pengisian kendaraan listrik berbasis multiagent dengan tetap memperhatikan batas pembebanan transformator dan tegangan jaringan. Hasil penelitian tersebut menunjukkan bahwa pengisian kendaraan listrik dapat dilakukan tanpa membahayakan jaringan apabila dikendalikan dengan tepat [61]. Penelitian pada jurnal Energy tahun 2017 mengusulkan algoritma kontrol sederhana untuk memanfaatkan kendaraan listrik plug-in dalam mengurangi overload transformator distribusi. Penelitian tersebut menunjukkan bahwa strategi vehicle-to-grid dan pengisian terkontrol dapat membantu menurunkan beban puncak transformator [62]. Selain itu, penelitian pada IEEE Transactions on Transportation Electrification tahun 2020 mengembangkan ko-optimasi rugi energi dan biaya operasi transformator akibat pengisian kendaraan listrik. Hasil penelitian tersebut menunjukkan bahwa pengelolaan daya aktif dan reaktif dapat mengoptimalkan biaya operasi jaringan distribusi [63].

Penelitian terbaru juga mulai menghubungkan identifikasi overload transformator dengan perencanaan energi baru. Penelitian pada PLoS ONE tahun 2024 mengembangkan pendekatan identifikasi overload transformator dan perencanaan energi baru berbasis

peramalan beban. Penelitian tersebut menunjukkan bahwa hasil peramalan beban dapat digunakan untuk mengidentifikasi pelanggan atau sistem yang berpotensi mengalami overload, kemudian dikaitkan dengan perencanaan kapasitas photovoltaic dan sistem penyimpanan energi [64]. Ringkasan penelitian terdahulu yang relevan dengan penelitian ini disajikan pada Tabel 2.1.

Tabel 2.1 Perbandingan Penelitian Terdahulu, Keterbatasan, dan Kebaruan Penelitian

No.	Penelitian Terdahulu	Fokus Penelitian	Metode/Pendekatan	Keterbatasan Penelitian Terdahulu	Perbedaan dengan Penelitian Ini	Kebaruan/Posisi Penelitian Ini
1	Energy, 2015 [1]	Peramalan beban listrik	Model kombinasi berbasis pra-analisis data dan optimasi bobot	Fokus utama penelitian adalah peningkatan akurasi model gabungan, tetapi belum secara khusus mengkaji pembebanan transformator pada kondisi beban ekstrem.	Penelitian ini berfokus pada data beban mingguan transformator di gardu induk dan membandingkan model stokastik serta deterministik.	Penelitian ini menilai model peramalan tidak hanya dari akurasi, tetapi juga dari signifikansi statistik dan ketidakpastian prediksi.
2	Applied Soft Computing, 2019 [54]	Peramalan beban listrik	Model hibrida dengan algoritma optimasi	Model yang digunakan relatif kompleks sehingga membutuhkan proses komputasi dan interpretasi yang lebih tinggi.	Penelitian ini menggunakan model statistik yang lebih sederhana dan mudah diterapkan untuk kebutuhan operasional gardu induk.	Penelitian ini menguji prinsip parsimoni, yaitu apakah model sederhana dapat memberikan performa yang layak dibandingkan model yang lebih kompleks.
3	Energies, 2012 [55]	Peramalan beban tahunan	Least Squares Support Vector Machine dan Fruit	Penelitian berfokus pada peramalan tahunan dan	Penelitian ini menggunakan data	Penelitian ini memberikan evaluasi

No.	Penelitian Terdahulu	Fokus Penelitian	Metode/Pendekatan	Keterbatasan Penelitian Terdahulu	Perbedaan dengan Penelitian Ini	Kebaruan/Posisi Penelitian Ini
			Fly Optimization Algorithm	model machine learning, belum menekankan peramalan beban mingguan transformator.	beban mingguan transformator untuk mendukung perencanaan pembebanan jangka menengah.	model pada skala operasional mingguan yang lebih relevan untuk pemantauan transformator.
4	Energy, 2010 [56]	Peramalan beban listrik	Gabungan ARIMA musiman, exponential smoothing, SVM, dan adaptive particle swarm optimization	Penelitian menekankan kombinasi beberapa metode, tetapi belum menilai apakah perbedaan antar model signifikan secara statistik.	Penelitian ini membandingkan beberapa model secara terpisah dan memvalidasi perbedaannya menggunakan Uji Friedman.	Penelitian ini memperkuat pemilihan model dengan dasar statistik, bukan hanya berdasarkan nilai error terkecil.
5	Rural Electric Power Conference, 2009 [57]	Optimasi ukuran transformator distribusi	Peramalan beban pelanggan untuk menentukan ukuran transformator	Penelitian berfokus pada penentuan ukuran transformator, bukan pada evaluasi model peramalan	Penelitian ini menganalisis transformator eksisting berdasarkan data beban historis aktual.	Penelitian ini mengaitkan hasil peramalan dengan kondisi pembebanan transformator yang sedang beroperasi.

No.	Penelitian Terdahulu	Fokus Penelitian	Metode/Pendekatan	Keterbatasan Penelitian Terdahulu	Perbedaan dengan Penelitian Ini	Kebaruan/Posisi Penelitian Ini
				untuk transformator yang sedang beroperasi.		
6	IEEE Transactions on Power Delivery, 2019 [58]	Optimasi pemanfaatan transformator distribusi	Metode desain empiris untuk pemanfaatan transformator	Penelitian lebih menekankan optimasi pemanfaatan transformator, belum membandingkan berbagai model peramalan beban secara komprehensif.	Penelitian ini mengevaluasi tujuh model peramalan untuk menentukan model yang paling sesuai dengan karakteristik beban transformator.	Penelitian ini memberikan dasar pemilihan model peramalan untuk mendukung manajemen aset transformator.
7	IEEE Transactions on Power Delivery, 2021 [59]	Optimasi pemindahan beban transformator	Load Transfer Optimization dengan batas suhu hot-spot dan top-oil	Penelitian berfokus pada solusi teknis pemindahan beban dan batas termal, bukan pada pemilihan model peramalan beban.	Penelitian ini tidak membahas solusi pemindahan beban, tetapi fokus pada prediksi dan evaluasi risiko pembebanan transformator.	Penelitian ini dapat menjadi dasar peringatan dini sebelum operator melakukan evaluasi pembebanan atau tindakan operasional lanjutan.

No.	Penelitian Terdahulu	Fokus Penelitian	Metode/Pendekatan	Keterbatasan Penelitian Terdahulu	Perbedaan dengan Penelitian Ini	Kebaruan/Posisi Penelitian Ini
8	Scientific African, 2023 [60]	Pembebanan termal adaptif transformator	Adaptive Thermal Loading	Penelitian menekankan aspek termal transformator, sedangkan aspek ketidakpastian hasil peramalan beban belum menjadi fokus utama.	Penelitian ini menitikberatkan pada peramalan beban berbasis data historis dan analisis ketidakpastian prediksi.	Penelitian ini menambahkan evaluasi Prediction Interval dengan PICP dan PINAW untuk menilai reliabilitas model.
9	IEEE Transactions on Smart Grid, 2014 [61]	Pengisian kendaraan listrik dan batas transformator	Multiagent charging dengan batas pembebanan transformator dan tegangan	Penelitian berfokus pada pengendalian pengisian kendaraan listrik, bukan pada perbandingan model peramalan beban transformator.	Penelitian ini berfokus pada pembacaan pola beban historis transformator tanpa memasukkan variabel kendaraan listrik secara khusus.	Penelitian ini menunjukkan pentingnya model peramalan sebagai alat bantu mendeteksi potensi pembebanan tinggi.
10	Energy, 2017 [62]	Pengurangan overload transformator akibat kendaraan listrik	Algoritma kontrol dan vehicle-to-grid	Penelitian membahas strategi pengendalian overload, tetapi belum menitikberatkan pada validasi statistik antar model peramalan.	Penelitian ini membandingkan performa model peramalan dan menguji apakah perbedaannya	Penelitian ini menekankan evaluasi model melalui kombinasi error, Uji Friedman, dan interval prediksi.

No.	Penelitian Terdahulu	Fokus Penelitian	Metode/Pendekatan	Keterbatasan Penelitian Terdahulu	Perbedaan dengan Penelitian Ini	Kebaruan/Posisi Penelitian Ini
					signifikan secara statistik.	
11	IEEE Transactions on Transportation Electrification, 2020 [63]	Optimasi rugi energi dan biaya operasi transformator	Smart charging dan optimasi daya aktif-reaktif	Penelitian berfokus pada optimasi biaya dan rugi energi akibat pengisian kendaraan listrik, bukan pada pemilihan model peramalan beban transformator.	Penelitian ini berfokus pada akurasi, kestabilan, dan reliabilitas model peramalan beban transformator.	Penelitian ini memperkuat evaluasi model dengan MAE, RMSE, MAPE, Uji Friedman, PICP, dan PINAW.
12	PLoS ONE, 2024 [64]	Identifikasi overload transformator dan perencanaan energi baru	Peramalan beban, photovoltaic, dan sistem penyimpanan energi	Penelitian menghubungkan peramalan dengan perencanaan energi baru, tetapi belum secara khusus membandingkan model deterministik dan stokastik pada kondisi beban ekstrem transformator.	Penelitian ini membandingkan ETS dengan model Linear, Eksponensial, Logaritmik, dan Polinomial Orde 2–4 pada data beban transformator.	Kebaruan penelitian ini terletak pada evaluasi komparatif tujuh model peramalan berdasarkan akurasi titik, signifikansi statistik, dan ketidakpastian prediksi.

Berdasarkan Tabel 2.1, dapat diketahui bahwa penelitian terdahulu telah banyak membahas peramalan beban listrik, optimasi pembebanan transformator, pengendalian overload, dan integrasi energi baru. Namun, sebagian besar penelitian tersebut memiliki fokus yang berbeda dengan penelitian ini. Beberapa penelitian lebih menekankan peningkatan akurasi menggunakan model hibrida atau algoritma optimasi yang relatif kompleks. Penelitian lain lebih berfokus pada optimasi ukuran transformator, pembebanan termal, pemindahan beban, atau pengendalian beban akibat kendaraan listrik.

Keterbatasan utama dari penelitian terdahulu dalam kaitannya dengan penelitian ini adalah belum banyak kajian yang secara khusus membandingkan model stokastik dan deterministik sederhana pada data beban mingguan transformator dalam kondisi beban ekstrem. Selain itu, sebagian besar penelitian masih berfokus pada nilai akurasi seperti MAE, RMSE, atau MAPE, tetapi belum selalu menguji apakah perbedaan performa antar model signifikan secara statistik. Evaluasi ketidakpastian peramalan melalui Prediction Interval juga belum banyak dijadikan sebagai bagian utama dalam pemilihan model peramalan beban transformator.

Penelitian ini berbeda karena membandingkan tujuh model peramalan, yaitu ETS sebagai model stokastik serta Linear, Eksponensial, Logaritmik, Polinomial Orde 2, Polinomial Orde 3, dan Polinomial Orde 4 sebagai model deterministik. Evaluasi dilakukan menggunakan tiga aspek utama, yaitu akurasi titik dengan MAE, RMSE, dan MAPE; validasi statistik dengan Uji Friedman; serta ketidakpastian prediksi dengan Prediction Interval, PICP, dan PINAW.

Dengan demikian, kebaruan penelitian ini terletak pada pendekatan evaluasi yang lebih komprehensif. Penelitian ini tidak hanya mencari model dengan nilai error terkecil, tetapi juga menilai apakah perbedaan antar model signifikan secara statistik dan apakah model mampu memberikan interval prediksi yang reliabel. Selain itu, penelitian ini juga menguji prinsip parsimoni, yaitu menilai apakah model yang lebih sederhana dapat digunakan secara layak dibandingkan model yang lebih kompleks dalam peramalan beban transformator pada kondisi beban ekstrem.

