

## PERBANDINGAN METODE VECTOR AUTOREGRESSIVE NEURAL NETWORK (VAR-NN) DAN ELMAN RECURRENT NEURAL NETWORK (ERNN) UNTUK PERAMALAN JUMLAH PENUMPANG KERETA API

**Elfi Ellyana**

Program Studi Matematika, FMIPA, Universitas Negeri Semarang  
e-mail : elfiellyana26@students.unnes.ac.id\*

**Walid**

Program Studi Matematika, FMIPA, Universitas Negeri Semarang  
e-mail : walid.mat@mail.unnes.ac.id

### Abstrak

Vector Autoregressive Neural Network (VAR-NN) merupakan kombinasi VAR dan Jaringan Syaraf yang memiliki potensi untuk meningkatkan akurasi peramalan terutama dalam kasus data yang memiliki pola non-linear yang signifikan sedangkan Elman Recurrent Neural Network (ERNN) efektif dalam mengenali pola non-linier pada data runtun waktu yang kompleks. Penelitian ini bertujuan untuk mengetahui pemodelan terbaik dari VAR-NN dan ERNN untuk peramalan jumlah penumpang kereta api di Jawa (Jabotabek dan Non Jabotabek). Hasil penelitian menunjukkan bahwa model VAR-NN terbaik untuk wilayah Jabotabek adalah model VAR-NN (1-7-1) dengan nilai MSE dan MAPE pengujian sebesar 0,0137 dan 11,7% dan untuk wilayah Non Jabotabek model VAR-NN (2-14-1) dengan nilai MSE dan MAPE pengujian sebesar 0,0165 dan 21%, sedangkan model ERNN terbaik untuk wilayah Jabotabek adalah model ERNN (5-15-1) dengan nilai MSE dan MAPE sebesar 3,4983e+07 dan 38,7995% dan untuk wilayah Non Jabotabek adalah model ERNN (6-15-1) dengan nilai MSE dan MAPE sebesar 3,4591e+06 dan 50,8854%. Penelitian ini menyimpulkan bahwa model terbaik untuk meramalkan jumlah penumpang kereta api di wilayah Jabotabek adalah model VAR-NN (1-7-1) dan wilayah Non Jabotabek adalah model VAR-NN (2-14-1).

**Kata Kunci:** Time Series, Vector Autoregressive Neural Network, Elman Recurrent Neural Network.

### Abstract

Vector Autoregressive Neural Network (VAR-NN) is a combination of VAR and Neural Network that has the potential to improve forecasting accuracy especially in the case of data that has significant non-linear patterns while Elman Recurrent Neural Network (ERNN) is effective in recognizing non-linear patterns in complex time series data. This study aims to determine the best modeling of VAR-NN and ERNN for forecasting the number of train passengers in Java (Jabotabek and Non Jabotabek). The results showed that the best VAR-NN model for the Jabotabek area is the VAR-NN (1-7-1) model with MSE and MAPE test values of 0.0137 and 11.7% and for the Non Jabotabek area the VAR-NN (2-14-1) model with MSE and MAPE test values of 0.0165 and 21%, respectively, 0165 and 21%, while the best ERNN model for the Jabotabek area is the ERNN (5-15-1) model with MSE and MAPE values of 3.4983e+07 and 38.7995% and for the Non Jabotabek area is the ERNN (6-15-1) model with MSE and MAPE values of 3.4591e+06 and 50.8854%. This study concludes that the best model for forecasting the number of train passengers in the Jabotabek area is the VAR-NN (1-7-1) model and the Non Jabotabek area is the VAR-NN (2-14-1) model.

**Keywords:** Time Series, Vector Autoregressive Neural Network, Elman Recurrent Neural Network.

### PENDAHULUAN

Kecerdasan buatan (AI) telah secara signifikan meningkatkan peramalan data dengan memanfaatkan teknologi komputer yang canggih. Penggunaan teknologi AI dalam peramalan telah menghasilkan tingkat akurasi yang lebih unggul dibandingkan dengan metode konvensional yang tidak menggunakan AI (Dalimunthe *et al.*, 2023).

Machine Learning, salah satu cabang dari AI, sangat penting dalam mengenali pola yang kompleks dalam data deret waktu. Jaringan Syaraf Tiruan (JST) adalah metode pendekatan nonlinier yang digunakan untuk menangani data yang besar dan dinamis. Akurasi yang lebih tinggi menjadikannya solusi yang diinginkan dalam peramalan, mengungguli teknik dan metode lainnya.

Model *Vector Autoregressive* (VAR) merupakan metode tradisional dalam analisis ekonometrika dan peramalan. Akurasi prediksi yang lebih unggul daripada model dengan persamaan simultan yang rumit adalah salah satu keunggulan model VAR. *Vector Autoregressive Neural Network* (VAR-NN) adalah kombinasi dari model *Neural Network* dan VAR. Menggabungkan kedua model tersebut dapat meningkatkan kinerja peramalan, terutama dalam kasus data yang memiliki pola non-linear yang signifikan.

Pengembangan salah satu dari jaringan saraf tiruan *Backpropagation* yaitu (ERNN) *Elman Recurrent Neural Network* (Cynthia *et al.*, 2019). Menurut Pattah *et al* (2017) dalam penerapan peramalan atau prediksi data, ERNN sangat cocok karena mampu beradaptasi dengan sistem dinamis dan pola data yang non-linear. *Context layer* adalah elemen yang membedakan ERNN dari *Backpropagation* karena keberadaan *Context layer* ini mempercepat iterasi dan pembaruan parameter, memungkinkan perhitungan didasarkan pada nilai hasil perhitungan sebelumnya (Sugiarti, 2018).

Masyarakat Indonesia umumnya menggunakan kereta api sebagai moda transportasi jarak jauh karena layanannya yang efisien dan tepat waktu. Dengan waktu tempuh yang lebih singkat dan kemampuan untuk menghindari kemacetan, kereta api menjadi pilihan utama untuk transportasi massal. Memperkirakan jumlah penumpang kereta api sangat penting untuk memperluas kapasitas layanan dan meningkatkan kualitas layanan publik.

Penelitian terkait peramalan jumlah penumpang kereta api sebelumnya telah dilakukan dengan menggunakan beberapa metode yang berbeda. Penelitian yang dilakukan untuk meramalkan jumlah penumpang kereta api menggunakan metode ARIMA dan *Grey System Theory* menyimpulkan bahwa peramalan lebih cocok menggunakan model *Grey System Theory* dibandingkan metode ARIMA (Susilawati & Sunendiari, 2022). Penelitian lain dengan topik peramalan penumpang kereta api juga dilakukan oleh Nurjanah *et al* (2018) menggunakan *Autoregressive Integrated Moving Average* (ARIMA) yang dianggap cocok dan layak untuk meramalkan jumlah penumpang kereta api di Pulau Sumatera. Menurut Nurvianti *et al* (2019) dalam penelitiannya meramalkan jumlah penumpang kereta api di DKI Jakarta menggunakan metode *Double Exponential*

*Smoothing* dan *Triple Exponential Smoothing*, metode tersebut mampu melakukan prediksi secara efektif. Berdasarkan beberapa penelitian sebelumnya, ditemukan kesimpulan bahwa kasus ini membutuhkan penelitian ulang dengan metode yang berbeda.

Metode yang akan diterapkan dalam penelitian ini untuk melakukan prediksi adalah metode *Vector Autoregressive Neural Network* (VAR-NN) dan *Elman Recurrent Neural Network* (ERNN). Penelitian yang dilakukan oleh Caraka *et al* (2021) yang menggunakan pemodelan *hybrid* VAR-NN-GA dalam peramalan data polusi ruang-waktu, dimana VAR-NN-GA memberikan akurasi yang baik ketika evaluasi metrik digunakan. Penelitian Diani *et al* (2013) yang membandingkan pemodelan VAR-NN dan GSTAR-NN untuk peramalan curah hujan di Kabupaten Malang, dimana hasil perbandingannya menunjukkan model VAR-NN terbukti menjadi model terbaik dalam memberikan hasil peramalan dibandingkan model GSTAR-NN. Penelitian Yasin *et al* (2018) juga menggunakan metode VAR-NN yang digunakan untuk mengembangkan model prediksi dengan bantuan *Soft Computation* yang diterapkan pada dua seri data harga saham Bursa Efek Indonesia, hasil penelitian diperoleh bahwa VAR-NN menghasilkan kinerja yang sempurna. Tahun 2006, dilakukan perbandingan kinerja antara model VAR-NN dan VARIMA dalam meramalkan dengan data simulasi, yang mana disimpulkan bahwa model VAR-NN lebih akurat dalam meramalkan dibandingkan dengan model VARIMA (Wutsqa *et al*, 2006).

Penelitian tentang penggunaan teknik *Elman Recurrent Neural Network* (ERNN) untuk peramalan penjualan telah menghasilkan peramalan penjualan tempo yang akurat. Ditemukan bahwa jumlah iterasi yang digunakan meningkat seiring dengan nilai kesalahan, sehingga menghasilkan akurasi prediksi yang lebih tinggi (Cynthia *et al.*, 2019). Kemudian terdapat penelitian yang dilakukan oleh Butarbutar *et al* (2022) dalam mengimplementasikan jaringan syaraf tiruan menggunakan metode *Elman Recurrent Neural Network* untuk prediksi penyakit jantung koroner menghasilkan akurasi yang cukup tinggi bernilai 96,67%. Penelitian selanjutnya yang juga menerapkan metode ERNN untuk meramalkan penggunaan bandwidth menemukan bahwa sistem yang dibangun dapat mengidentifikasi pola dan

melakukan prediksi penggunaan *bandwidth* dengan menggunakan *Elman* (Radjabaycolle & Pulungan, 2016).

Permasalahan-permasalahan yang akan dibahas dalam penelitian yaitu Bagaimana pemodelan untuk peramalan jumlah penumpang kereta api di Jawa (Jabotabek dan Non Jabotabek) menggunakan metode *Vector Autoregressive Neural Network* (VAR-NN) dan metode *Elman Recurrent Neural Network* (ERNN)? Bagaimana pemodelan terbaik untuk peramalan jumlah penumpang kereta api di Jawa (Jabotabek dan Non Jabotabek)?.

Tujuan penelitian ini adalah untuk mengetahui pemodelan peramalan jumlah penumpang kereta api di Jawa (Jabotabek dan Non Jabotabek) menggunakan menggunakan metode *Vector Autoregressive Neural Network* (VAR-NN) dan metode *Elman Recurrent Neural Network* (ERNN). Menentukan pemodelan terbaik untuk peramalan jumlah penumpang kereta api di Jawa (Jabotabek dan Non Jabotabek).

**KAJIAN TEORI**

**ARTIFICIAL NEURAL NETWORK (ANN)**

Jaringan Syaraf Tiruan (*Artificial Neural Network* atau ANN) system dari pengetahuan yang mengambil tentang struktur dan fungsi sel syaraf biologis dalam otak manusia (Kristianto, 2004). JST adalah suatu model matematis dan komputasi yang memiliki beragam kegunaan, seperti untuk mendekati fungsi nonlinear, mengklasifikasikan data, mengelompokkan data, dan melakukan regresi non-parametrik. Selain itu, JST juga dapat berfungsi sebagai simulasi dari model syaraf biologi. JST menampilkan kecakapan dalam berbagai bidang seperti prediksi, asosiasi, analisis, dan emulasi. Kapabilitas JST ini bisa digunakan untuk mempelajari dan mengekstraksi aturan atau operasi dari contoh yang diberikan, menghasilkan output yang sesuai dari input yang diberikan, dan untuk membuat prediksi tentang kemungkinan output yang akan dihasilkan atau menyimpan fitur-fitur dari input yang disimpan di dalamnya.

Neuron Jaringan Syaraf Tiruan memiliki parameter yang bekerja bersama-sama untuk memproses input, menghitung output, dan mengoptimalkan kinerja jaringan selama proses pembelajaran. Berikut ini adalah parameter yang

menggambarkan sebuah neuron dalam JST berdasarkan Gambar 1 (Shanmuganathan, 2016).

1. Koneksi masukan (*input connections*)  
Koneksi masukan dilambangkan  $x_1, x_2, \dots, x_n$ . dan  $w_1, w_2, \dots, w_n$  adalah bobot yang terikat pada koneksi masukan. Satu masukan ke neuron yang disebut bias, memiliki nilai konstan 1 dan biasanya diwakili sebagai masukan terpisah. Dalam hal ini, masukan bias disebut  $x_0$  dan digunakan untuk keperluan kesederhanaan, di mana nilainya dijaga konstan.

2. Fungsi masukan (*input functions*)  
Fungsi masukan dilambangkan sebagai  $f$ , yaitu digunakan untuk menghitung simyal masukan jaringan yang terhubung ke neuron

$$U = f(x, w)$$

$x$  dan  $w$  merupakan *input vector* dan bobot *vector* yang sesuai,  $f$  biasanya merupakan fungsi penjumlahan.

$$U = \sum_{i=1}^n x_i \cdot w_i$$

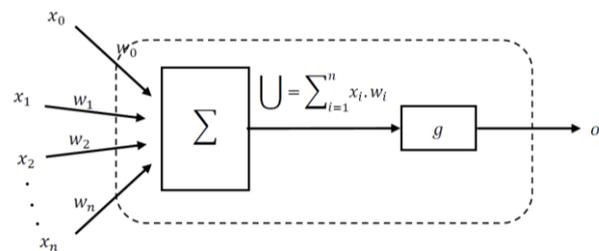
3. Fungsi aktivasi  
Tingkat aktivasi neuron ditentukan dengan menggunakan fungsi aktivasi (a).

$$a = \sum_{i=1}^n x_i w_i$$

4. Fungsi keluaran  
Fungsi keluaran untuk menghitung nilai sinyal keluaran yang dipancarkan melalui output atau akson dari neuron,

$$o = \sum_{i=1}^n x_i w_{ij} ; j = 1, 2, \dots, m,$$

sinyal keluaran biasanya diasumsikan setara dengan tingkat aktivasi neuron, yaitu  $o = a$ .



Gambar 1. Model Neuron Buatan

**BACKPROPAGATION**

Metode *Neural Network* dengan banyak lapisan. Teknik ini melatih jaringan untuk menyeimbangkan pengenalan pola yang diperoleh selama pelatihan dengan kapasitas untuk merespons pola input secara tepat. Sebelum melatih jaringan, data harus diubah terlebih dahulu. Tujuan pengubahan data dalam

*Neural Network* adalah untuk mencapai stabilisasi distribusi data. Selain itu, akan sangat bermanfaat untuk memodifikasi nilai data agar sesuai dengan variasi fungsi aktivasi yang telah diterapkan oleh jaringan.

Secara umum, Suhartono & Endharta (2009) menyatakan bahwa persamaan *Neural Network* pada peramalan runtun waktu menggunakan algoritma *backpropagation* dengan satu lapisan tersembunyi, dengan  $n$  unit input dan  $p$  unit pada lapisan tersembunyi dituliskan:

$$\hat{Y}_t = f^0 \left( \sum_{j=1}^p w_{kj} \cdot f_j^h \left( v_{j0} + \sum_{i=1}^n X_i v_{ji} \right) \right) + w_{k0}$$

$\hat{Y}_t$  merupakan output variabel ke- $t$ ,  $f^0$  adalah fungsi aktivasi neuron pada lapisan output,  $w_{kj}$  merupakan bobot neuron output ke- $k$  dari neuron tersembunyi ke- $j$ , kemudian  $f_j^h$  adalah fungsi aktivasi neuron ke- $j$  pada lapisan tersembunyi,  $v_{j0}$  adalah bobot bias pada lapisan tersembunyi  $j = 1, 2, \dots, p$ , lalu  $X_i$  adalah neuron input ke- $i$  dengan  $i = 1, 2, \dots, n$ ,  $v_{ji}$  adalah bobot neuron tersembunyi ke- $j$  dari neuron input ke- $i$ , dan  $w_{k0}$  adalah bobot bias pada lapisan output  $k = 1, 2, \dots, m$ .

#### VECTOR AUTOREGRESSIVE NEURAL NETWORK (VAR-NN)

*Vector Autoregressive Neural Network* (VAR-NN) gabungan model VAR dan NN, dimana keduanya digunakan meramalkan data runtun waktu. Model VAR secara umum dapat digunakan untuk melakukan perhitungan lebih dari satu variabel secara bersamaan, jadi model VAR termasuk salah satu model runtun waktu multivariat (Pratama *et al*, 2018). Model VAR sering digunakan untuk menganalisis perubahan makroekonomi dikarenakan model VAR dapat menunjukkan perubahan koefisien dengan baik dari masing-masing variabel secara bersamaan pada data runtun waktu. Sedangkan model NN sering digunakan untuk mendapatkan pendekatan yang lebih fleksibel untuk mengestimasi dan memprediksi model non-linear dalam kasus runtun waktu multivariat. Model VAR-NN dihasilkan dari model VAR dan termasuk dalam kelas *Neural Network* yang sangat kuat yang disebut *Feed Forward Neural Network* (FFNN) (Wutsqa *et al.*, 2006).

#### ELMAN RECURRENT NEURAL NETWORK (ERNN)

Salah satu teknik dalam jaringan saraf tiruan yang melibatkan lapisan input, konteks, tersembunyi, dan output (Butarbutar *et al.*, 2022). Tujuan dari lapisan konteks adalah untuk menyimpan informasi dari lapisan tersembunyi, yang kemudian digunakan bersama dengan data masukan untuk menghitung fungsi pembelajaran, dan lapisan ini bertujuan untuk mempercepat proses pelatihan dengan menghasilkan hasil yang lebih cepat dari data yang diproses (Salim *et al.*, 2017).

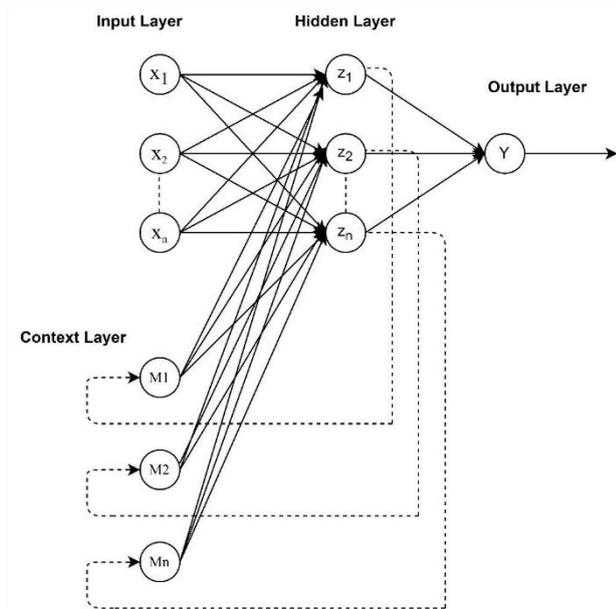
ERNN mengalami penyesuaian dari arsitektur feed forward dengan menambahkan lapisan neuron yang terhubung untuk menghasilkan keluaran jaringan yang memberikan umpan balik ke masukan jaringan, sehingga menghasilkan keluaran pada urutan selanjutnya. Pemanfaatan umpan balik ERNN sebagai sarana untuk memahami, mengidentifikasi, dan menghasilkan pola temporal dan spasial (Wang & Wang, 2016).

*Elman Recurrent Neural Network* merupakan sebuah jenis jaringan yang terdiri dari lapisan tersembunyi sebanyak  $n$ , dimana  $n$  ditentukan berdasarkan kompleksitas permasalahan yang ingin dipecahkan. Keempat lapisan ERNN memiliki bobot yang bisa disesuaikan dengan setiap dua lapisan yang saling berdekatan. Dalam membuat jaringan *Elman*, penting untuk memperhatikan penyesuaian beberapa parameter seperti jumlah neuron dalam lapisan tersembunyi, iterasi maksimum, fungsi inisialisasi, fungsi pembelajaran, dan fungsi pembaharuan (Wu *et al.*, 2019). Parameter jaringan dioptimalkan dengan kuadrat rata-rata yaitu *Mean Squared Error* (MSE). Output dari neuron dipastikan dengan menggunakan fungsi aktivasi. Aktivasi sigmoid bipolar berfungsi karena memiliki rentang nilai antara 0 dan 1. Aktivasi sigmoid bipolar dirumuskan sebagai berikut:

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

*Elman Recurrent Neural Network* (ERNN) adalah bentuk variasi dari *MultiLayer Perceptron*. Gambar 2 menunjukkan Arsitektur ERNN, yang hampir identik dengan arsitektur *feedforward backpropagation*. Input jaringan, yang terdiri dari nilai output dari neuron tersembunyi dan nilai input dari luar

jaringan, adalah tempat di mana perbedaan ditemukan.



Gambar 2. Arsitektur Elman Recurrent Neural Network

**NORMALISASI DATA**

Menyederhanakan nilai-nilai sehingga data memiliki skala yang lebih kecil tetapi tetap mempertahankan karakteristik asli dari data tersebut. Berikut ini adalah persamaan yang digunakan untuk normalisasi data menurut (Giusti *et al.*, 2017) yaitu:

$$normalisasi = \frac{x - min}{max - min}$$

Dimana  $x$  adalah data,  $min$  adalah data minimum dan  $max$  adalah data maksimum.

**DENORMALISASI DATA**

Mengonversi kembali nilai-nilai desimal ke dalam nilai-nilai aslinya (nilai real). Berikut adalah persamaan untuk melaksanakan denormalisasi (Giusti *et al.*, 2017) yaitu:

$$d = d'(max - min) + min$$

Dimana  $d$  adalah nilai setelah didenormalisasi,  $d'$  adalah nilai prediksi sebelumnya,  $min$  adalah data minimum dan  $max$  adalah data maksimum.

**MEAN SQUARE ERROR (MSE)**

Metode pengujian yang digunakan sebagai alat ukur analisis kuantitatif untuk menilai kualitas output dan keunggulan metode yang diterapkan

(Cynthia *et al.*, 2019). Rumus berikut ini dapat digunakan untuk menentukan MSE:

$$MSE = \sum \frac{E_t^2}{n} = \frac{(t_i - y_i)^2}{n}$$

Dimana  $n$  adalah banyak data,  $t_i$  adalah nilai pengamatan di periode ke- $i$ , dan  $y_i$  adalah prediksi nilai di periode ke- $i$ .

**MEAN ABSOLUTE PERCENTAGE ERROR (MAPE)**

Metrik statistik yang digunakan untuk mengevaluasi akurasi peramalan. Menurut Makridakis *et al* (1995) nilai MAPE dituliskan sebagai berikut

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

Dimana  $n$  adalah banyaknya data pengamatan,  $Y_t$  adalah data asli pada periode  $t$ ,  $\hat{Y}_t$  adalah data pendekatan model dan  $t$  merupakan periode pengamatan.

**METODE**

**DATA PENELITIAN**

Situs resmi Badan Pusat Statistik menyediakan data sekunder untuk penelitian ini, termasuk informasi mengenai jumlah penumpang kereta api di Jawa (Jabotabek dan Non Jabotabek) antara bulan Januari 2013 sampai Desember 2022. Data sekunder berasal dari sumber yang sudah ada atau tersedia dalam bentuk yang sudah jadi setelah dikumpulkan dan diolah oleh sumber lain. Jenis data yang digunakan adalah data runtun waktu (*time series*).

**RANCANGAN PENELITIAN**

Rancangan penelitian digunakan untuk mencapai tujuan dari penelitian yang dilakukan. Langkah-langkah yang dilakukan dalam perbandingan metode *Vector Autoregressive Neural Network* (VAR-NN) dan *Elman Recurrent Neural Network* (ERNN) untuk peramalan jumlah penumpang kereta api dengan bantuan *software* R dan Matlab adalah sebagai berikut:

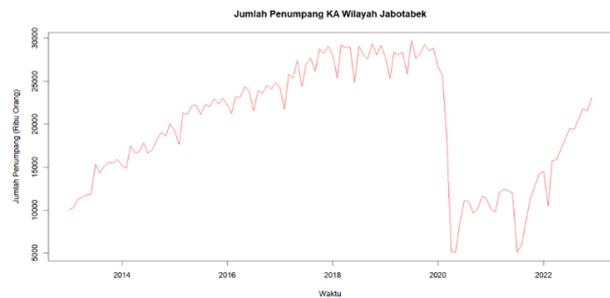
1. Mengumpulkan dan menyiapkan data  
Menyiapkan data jumlah penumpang kereta api di Jawa (Jabotabek dan Non Jabotabek).
2. Membangun model VAR-NN

Langkah-langkah yang harus dilakukan untuk membangun model VAR-NN adalah sebagai berikut:

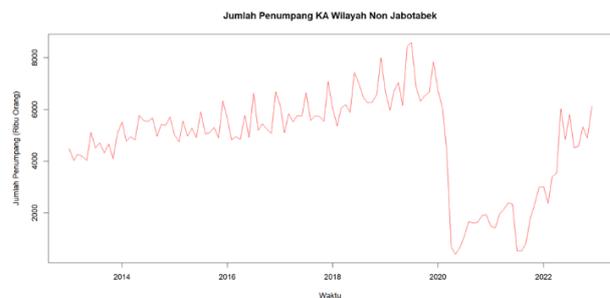
- a. Melakukan pemodelan VAR
  - b. Hasil dari pemodelan VAR menghasilkan nilai residual model VAR yang akan dijadikan input untuk model NN.
  - c. Jumlah neuron di lapisan input ditetapkan sejumlah lag yang signifikan pada plot PACF.
  - d. Data residual dibagi menjadi dua bagian, yakni data pelatihan (training) dan data pengujian (testing).
  - e. Menormalisasi data input dan data target.
  - f. Melakukan pemodelan NN.
  - g. Melakukan pengembalian data ke bentuk aslinya melalui proses denormalisasi.
3. Membangun model ERNN
- Langkah-langkah yang harus diikuti untuk membangun model ERNN adalah:
- a. Mengidentifikasi lag-lag yang signifikan dalam plot PACF untuk menentukan input dan target jaringan.
  - b. Pisahkan data menjadi dua set yaitu set pelatihan dan pengujian.
  - c. Menormalisasi data input dan data target.
  - d. Membangun jaringan ERNN
  - e. Melakukan pengujian dan pelatihan data.
  - f. Mengembalikan data ke bentuk aslinya dengan denormalisasi data.
4. Memilih model yang paling sesuai
- Model terbaik dari setiap pemodelan ditentukan dengan mengamati nilai MSE dan MAPE terkecil selama tahap pengujian.

## HASIL DAN PEMBAHASAN

Penerapan metode *Vector Autoregressive Neural Network* dan *Elman Recurrent Neural Network* (ERNN) digunakan untuk meramalkan jumlah penumpang kereta api di wilayah Jabotabek dan Non Jabotabek (Jawa). Data volume penumpang kereta api yang digunakan terdiri dari 120 data, mulai dari Bulan Januari 2013 sampai dengan Bulan Desember 2022. Plot data jumlah penumpang ditampilkan pada Gambar 3 dan Gambar 4.



Gambar 3. Grafik jumlah penumpang kereta api di Jabotabek dari Januari 2013 - Desember 2022



Gambar 4. Grafik jumlah penumpang kereta api di Non Jabotabek (Jawa) dari Januari 2013 - Desember 2022

## Pemodelan VAR

Tabel 1. Variabel masukan model VAR

Variabel	Keterangan
$Y_1$	Jumlah Penumpang Kereta Api Wilayah Jabotabek
$Y_2$	Jumlah Penumpang Kereta Api Wilayah Non Jabotabek (Jawa)

Menguji stasioneritas rata-rata data adalah tahap pertama dalam membuat model VAR. Uji ADF digunakan untuk memeriksa stasioneritas rata-rata pada kedua variabel masukan pada Tabel 1. Pada uji ADF ini, dikatakan bahwa variabel tidak memiliki stasioneritas dalam rata-rata. Oleh karena itu, untuk membuat data menjadi stasioner, dilakukan differencing dengan nilai 1. Hasil pengujian differencing 1 menunjukkan  $p - value$   $0,001 < 5\%$ .

Model harus diidentifikasi untuk memastikan urutan model VAR. Memilih lag yang ideal berdasarkan nilai AIC terendah akan menentukan orde model VAR. Nilai AIC terkecil terjadi pada lag 4 dengan nilai  $-7,3668$ . Oleh karena itu, model VAR dengan orde 4 (VAR (4)) dipilih.

Setiap variabel dalam model VAR dengan orde empat dipengaruhi oleh masa lalu dan masa lalu variabel lainnya selama periode lima unit waktu.

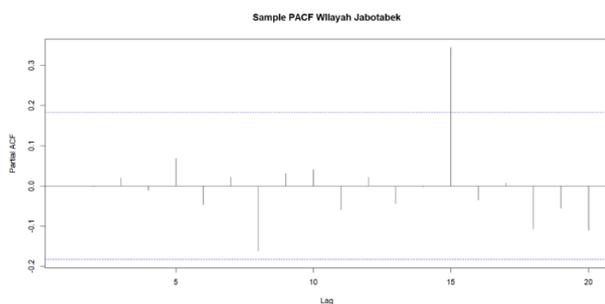
Metode OLS digunakan untuk mengestimasi parameter-parameter dalam model VAR(4), menunjukkan bahwa dari 16 parameter yang diestimasi, terdapat 4 parameter yang signifikan terhadap variabel  $Y_2$  (Wilayah Non Jabodetabek) pada tingkat signifikansi 5%, yang ditunjukkan oleh nilai  $p - value < \alpha = 5\%$ . Dengan memilih nilai parameter yang penting, persamaan akhir model VAR(4) untuk variabel  $Y_2$  dapat dinyatakan sebagai berikut.

$$Y_{2,t} = 1,039Y_{1,t-1} - 0,464Y_{2,t-1} - 0,425Y_{2,t-2} - 0,4089Y_{2,t-4} - 0,0079$$

Autokorelasi dari residual model diperiksa dengan menggunakan uji *Portmanteau*. Dari uji Portmanteau menunjukkan bahwa nilai  $p - value$  lebih besar dari  $\alpha = 0,05$ , yang mengindikasikan penerimaan  $H_0$ . Hal ini menunjukkan bahwa model tidak memiliki autokorelasi atau residualnya memenuhi syarat untuk *multivariate white noise*.

#### Pemodelan VAR-NN wilayah Jabotabek

Model VAR(4) merupakan model VAR terbaik yang sudah dianalisis sebelumnya, dan pemodelan VAR-NN dilakukan dengan menggunakan residual sebagai variabel input. Input untuk VAR-NN ditentukan oleh lag-lag yang signifikan pada plot PACF dari residual VAR(4) untuk wilayah Jabotabek pada Gambar 5 berikut.



Gambar 5. Plot PACF Residual Model VAR(4) Wilayah Jabotabek

Residual model VAR(4) untuk wilayah Jabotabek menunjukkan lag PACF yang signifikan pada lag 15, yang akan digunakan untuk membangun jaringan VAR-NN dengan satu variabel input  $x_{t-15}$  dan target  $x_t$ , yang mencakup 100 titik data mulai data ke-16 hingga data ke-115.

Algoritma *Backpropagation* digunakan untuk membangun jaringan NN, dengan 80% data digunakan untuk pelatihan dan 20% sisanya untuk pengujian. sehingga dari 100 data terdapat 80 data untuk data latih dan 20 data untuk data uji. Setelah pembagian data dilakukan, selanjutnya dilakukan normalisasi data pada data input dan data target dengan bantuan *software* RStudio. Setelah data dinormalisasi, dilakukan pembentukan jaringan untuk mendapatkan model jaringan terbaik.

Langkah selanjutnya membentuk model terbaik untuk membangun jaringan VAR-NN algoritma *Backpropagation*. Prosedur pemodelan terbaik untuk membangun jaringan VAR-NN, yaitu menentukan banyaknya neuron dari hidden layer. Lapisan tersembunyi yang digunakan pada arsitektur jaringan VAR-NN adalah random antara 1-15 neuron. Model terbaik akan dipilih berdasarkan nilai MAPE yang paling minimum. Fungsi aktivasi yang digunakan pada lapisan tersembunyi, yaitu fungsi sigmoid bipolar. *Learning rate* yang digunakan pada penelitian sebesar 0.01. Pada hasil learning diperoleh model terbaik sebagai berikut.

Tabel 2. Neuron terbaik model VAR-NN wilayah Jabotabek

Hidden Neuron	MSE Testing	MAPE Testing
7	0,0137	11,7%

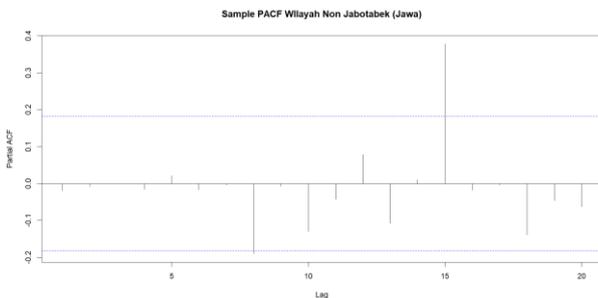
Tabel 2 menunjukkan model terbaik dengan nilai MAPE terkecil dengan neuron pada hidden layer yaitu 7 neuron dengan nilai MAPE sebesar 11,7%.

Setelah pemodelan selesai dilakukan, maka hasil output yang telah dinormalisasi dikembalikan lagi seperti semula, proses ini disebut denormalisasi.

Model optimal menggunakan jaringan yang paling sederhana dan memiliki MSE dan MAPE terendah berdasarkan hasil pelatihan jaringan. Untuk data wilayah Jabotabek, model VAR-NN terbaik memiliki arsitektur jaringan 1-7-1 dengan *learning rate* sebesar 0,01 dan menggunakan fungsi aktivasi sigmoid bipolar. Model VAR-NN (1-7-1) memberikan nilai MSE sebesar 0,0137 dan MAPE sebesar 11,7% pada hasil pengujian. Oleh karena itu, arsitektur NN terbaik untuk data residual VAR jumlah penumpang kereta api wilayah Jabotabek adalah VAR-NN (1-7-1).

### Pemodelan VAR-NN wilayah Non Jabotabek (Jawa)

Model VAR(4) merupakan model VAR terbaik yang sudah dianalisis sebelumnya, dan pemodelan VAR-NN dilakukan dengan menggunakan residual sebagai variabel input. Input untuk VAR-NN ditentukan oleh lag-lag yang signifikan pada plot PACF dari residual VAR(4) untuk wilayah Non Jabotabek (Jawa) pada Gambar 6 berikut.



Gambar 6. Plot PACF Residual Model VAR(4) Wilayah Non Jabotabek (Jawa)

Residual model VAR(4) untuk wilayah Jabotabek menunjukkan lag PACF yang signifikan pada lag 8 dan lag 15, yang akan digunakan untuk membangun jaringan VAR-NN dengan satu variabel input  $x_{t-8}$ ,  $x_{t-15}$  dan target  $x_t$ , yang mencakup 100 titik data mulai data ke-16 hingga data ke-115.

Algoritma *Backpropagation* digunakan untuk membangun jaringan NN, dengan 80% data digunakan untuk pelatihan dan 20% sisanya untuk pengujian. sehingga dari 100 data terdapat 80 data untuk data latih dan 20 data untuk data uji. Setelah pembagian data dilakukan, selanjutnya dilakukan normalisasi data pada data input dan data target dengan bantuan software RStudio. Setelah data dinormalisasi, dilakukan pembentukan jaringan untuk mendapatkan model jaringan terbaik.

Langkah selanjutnya membentuk model terbaik untuk membangun jaringan VAR-NN algoritma *Backpropagation*. Prosedur pemodelan terbaik untuk membangun jaringan VAR-NN, yaitu menentukan banyaknya neuron dari hidden layer. Lapisan tersembunyi yang digunakan pada arsitektur jaringan VAR-NN adalah random antara 1-15 neuron. Model terbaik akan dipilih berdasarkan nilai MAPE yang paling minimum. Fungsi aktivasi yang digunakan pada lapisan tersembunyi, yaitu fungsi sigmoid bipolar. *Learning rate* yang digunakan pada

penelitian sebesar 0.01. Pada hasil learning diperoleh model terbaik sebagai berikut.

Tabel 3. Neuron terbaik model VAR-NN wilayah Non Jabotabek (Jawa)

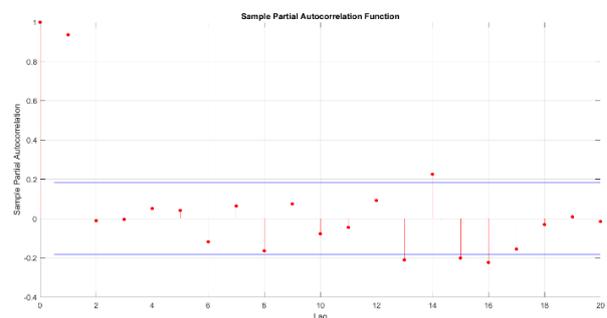
Hidden Neuron	MSE Testing	MAPE Testing
14	0,0165	21%

Tabel 3 menunjukkan model terbaik dengan nilai MAPE terkecil dengan neuron pada hidden layer yaitu 14 neuron dengan nilai MAPE sebesar 21%.

Setelah pemodelan selesai dilakukan, maka hasil output yang telah dinormalisasi dikembalikan lagi seperti semula, proses ini disebut denormalisasi

Model optimal menggunakan jaringan yang paling sederhana dan memiliki MSE dan MAPE terendah berdasarkan hasil pelatihan jaringan. Untuk data wilayah Non Jabotabek (Jawa), model VAR-NN terbaik memiliki arsitektur jaringan 2-14-1 dengan *learning rate* sebesar 0,01 dan menggunakan fungsi aktivasi sigmoid bipolar. Model VAR-NN (2-14-1) memberikan nilai MSE sebesar 0,0165 dan MAPE sebesar 21% pada hasil pengujian. Oleh karena itu, arsitektur NN terbaik untuk data residual VAR jumlah penumpang kereta api wilayah Non Jabotabek (Jawa) adalah VAR-NN (2-14-1).

### Pemodelan ERNN wilayah Jabotabek



Gambar 7. Plot PACF data jumlah penumpang kereta api wilayah Jabotabek

Gambar 7 menunjukkan plot PACF untuk data jumlah penumpang kereta api di wilayah Jabotabek. Berdasarkan plot PACF diperoleh lag-lag yang signifikan, yaitu lag 1, lag 13, lag 14, lag 15 dan lag 16. Sehingga jaringan akan dibangun memiliki input sebanyak 5 variabel, yaitu  $x_{t-1}$ ,  $x_{t-13}$ ,  $x_{t-14}$ ,  $x_{t-15}$ ,  $x_{t-16}$  dan target  $x_t$ . Karena data input berasal dari

$x_{t-1}, x_{t-13}, x_{t-14}, x_{t-15}$  dan  $x_{t-16}$ , maka tidak mungkin untuk menggunakan data dari data ke-1 hingga data ke-16. Selain itu, penelitian ini akan mencakup 104 titik data, mulai dari data ke-17 hingga data ke-120.

Dalam membangun jaringan ERNN ini, 20% dari data ditetapkan sebagai data uji, dan 80% sisanya ditetapkan sebagai data pelatihan. Hasilnya, dari 104 data untuk wilayah Jabotabek, 83 data digunakan untuk pelatihan dan 21 data untuk pengujian. Selanjutnya dilakukan normalisasi data pada data input dan data target dengan bantuan software Matlab R2018a. Setelah data dinormalisasi, dilakukan perancangan model untuk mendapatkan model jaringan terbaik.

Perintah untuk membangun jaringan ERNN yaitu:

```
net = newelm(minmax(in), [15 1],
{'tansig','purelin'}, 'traingdx');
```

Perintah `newelm` digunakan untuk membangun jaringan ERNN dengan  $n$  neuron pada lapisan tersembunyi dan satu neuron pada lapisan output. Perintah `{'tansig' 'purelin'}` menunjukkan fungsi aktivasi yang digunakan dengan `tansig` pada lapisan tersembunyi dan `purelin` pada lapisan output. Perintah `traingdx` menunjukkan algoritma pelatihan yang digunakan.

Berikut adalah langkah-langkah untuk membangun model terbaik dalam jaringan ERNN.

a. Penentuan jaringan optimum

Dalam jaringan ERNN yang akan digunakan, terdapat satu lapisan tersembunyi. Jumlah neuron pada lapisan tersembunyi diperoleh melalui metode *trial and error* dengan mencoba berbagai jumlah neuron, yaitu 5, 10 dan 15. Fungsi aktivasi sigmoid bipolar, atau `tansig` di Matlab, digunakan di lapisan tersembunyi. Fungsi linier atau identitas, disebut sebagai `purelin` di Matlab, digunakan pada lapisan output.

b. Memilih algoritma pelatihan

*Gradient Descent with Momentum and Adaptive Learning Rate*, yang juga dikenal sebagai `traingdx` di Matlab, adalah metode pelatihan yang digunakan untuk membangun jaringan ERNN.

c. Penentuan inisialisasi bobot awal

Algoritma Nguyen-Widrow digunakan untuk menginisialisasi bobot awal. Metode ini

bertujuan untuk memperpendek periode pelatihan jaringan dan untuk meningkatkan kinerja.

d. Menentukan parameter pelatihan

Algoritma pelatihan adalah dasar untuk parameter yang dipilih. Tabel 4 memberikan parameter algoritma *Gradient Descent with Momentum and Adaptive Learning Rate* (`Traingdx`).

Tabel 4. Parameter Pelatihan untuk Algoritma `Traingdx`

Maksimum epoch	:	5000
Target error	:	0,001
Learning rate (LR)	:	0,01, 0,02, 0,03, 0,1, 0,2, 0,3
Momentum	:	0,1, 0,2, 0,8, 0,9
Epoch show	:	500

e. Denormalisasi

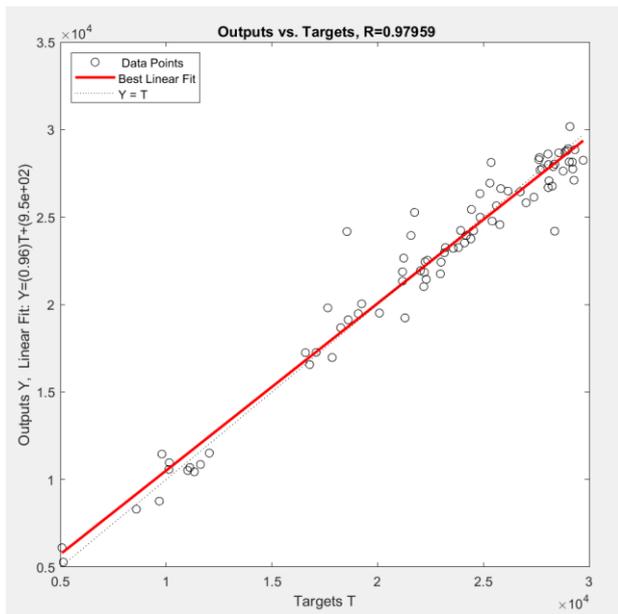
Merupakan transformasi data dari hasil peramalan dengan jaringan saraf tiruan ke nilai aslinya dilakukan setelah pelatihan selesai. Output jaringan yang sudah dinormalisasi dikembalikan ke bentuk aslinya.

Model terbaik terbentuk berdasarkan *trial and error* terhadap arsitektur jaringan pada ERNN. Model terbaik adalah model dengan MSE dan MAPE pengujian terkecil dengan jaringan paling sederhana.

Berdasarkan hasil pelatihan jaringan pada Tabel 5 diperoleh bahwa model ERNN terbaik dengan algoritma pelatihan *gradient descent* dengan *momentum* dan *adaptive learning rate* pada arsitektur jaringan 5-15-1 dengan momentum = 0,1 dan LR = 0,3 pada fungsi aktivasi `tansig`. Model ERNN (5-15-1) memperoleh hasil pada epoch ke 5000 yang memberikan nilai MSE dan MAPE pengujian masing-masing sebesar  $3,4983e+07$  dan 38,7995%. Iterasi berhenti pada epoch ke 5000 meskipun target error yang diinginkan (Goal = 0,001) belum tercapai. Model ini pada epoch ke 5000 telah mencapai konvergen dengan performance = 0,0400.

Selanjutnya, melakukan uji kesesuaian model pada model terbaik. Uji kesesuaian model dilakukan untuk melihat apakah model terbaik yang telah diperoleh layak atau tidak untuk digunakan sebagai model peramalan. Pengujian ini dilihat dari plot regression pada data latih. Uji kesesuaian model

ERNN dengan arsitektur jaringan 5-15-1 dapat dilihat dari plot regression pada Gambar 8.

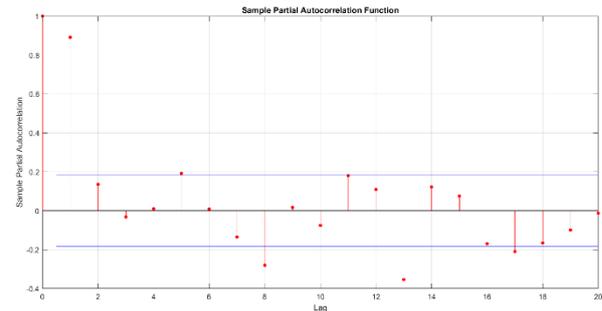


Gambar 8. Plot Regression ERNN Wilayah Jabotabek pada Arsitektur 5-15-1

Uji kesesuaian model ERNN dengan arsitektur jaringan 5-15-1 dapat dilihat dari plot regresi pada Gambar 6. Titik-titik pada plot mendekati garis diagonal, dan koefisien korelasi sebesar 0,97959 (mendekati 1) menunjukkan hasil yang baik dalam membandingkan output jaringan dengan target. Oleh karena itu, dapat disimpulkan bahwa model ERNN dengan arsitektur jaringan 5-15-1 layak

digunakan sebagai model peramalan penumpang kereta api wilayah Jabotabek.

**Pemodelan ERNN wilayah Non Jabotabek (Jawa)**



Gambar 9. Plot PACF data jumlah penumpang kereta api wilayah Non Jabotabek (Jawa)

Gambar 9 menunjukkan plot PACF untuk data jumlah penumpang kereta api di wilayah Non Jabotabek (Jawa). Berdasarkan plot PACF diperoleh lag-lag yang signifikan, yaitu lag 1, lag 5, lag 8, lag 11, lag 13 dan lag 17. Sehingga jaringan akan dibangun memiliki input sebanyak 6 variabel, yaitu  $x_{t-1}, x_{t-5}, x_{t-8}, x_{t-11}, x_{t-13}, x_{t-17}$  dan target  $x_t$ . Karena data input berasal dari  $x_{t-1}, x_{t-5}, x_{t-8}, x_{t-11}, x_{t-13}$  dan  $x_{t-17}$ , maka tidak mungkin untuk menggunakan data dari data ke-1 hingga data ke-17. Selain itu, penelitian ini akan mencakup 103 titik data, mulai dari data ke-18 hingga data ke-120.

Tabel 5. Hasil Pelatihan ERNN Data Wilayah Jabotabek dengan Momentum = 0,1 dan LR = 0,3

Arsitektur Jaringan	Epoch	Perf	Pelatihan			Pengujian		
			MSE	MAPE (%)	R	MSE	MAPE (%)	R
5-15-1	5000	0,0400	1,6198e+06	4,4048	0,9796	3,4983e+07	38,7995	0,2840

Dalam membangun jaringan ERNN ini, 20% dari data ditetapkan sebagai data uji, dan 80% sisanya ditetapkan sebagai data pelatihan. Hasilnya, dari 103 data untuk wilayah Non Jabotabek (Jawa), 82 data digunakan untuk pelatihan dan 21 data untuk pengujian. Selanjutnya dilakukan normalisasi data pada data input dan data target dengan bantuan software Matlab R2018a. Setelah data dinormalisasi,

dilakukan perancangan model untuk mendapatkan model jaringan terbaik.

Perintah untuk membangun jaringan ERNN yaitu:

```
net = newelm(minmax(in), [15 1], {'tansig','purelin'}, 'traingdx');
```

Perintah newelm digunakan untuk membangun jaringan ERNN dengan n neuron pada lapisan tersembunyi dan satu neuron pada lapisan output.

Perintah {'tansig' 'purelin'} menunjukkan fungsi aktivasi yang digunakan dengan tansig pada lapisan tersembunyi dan purelin pada lapisan output. Perintah traingdx menunjukkan algoritma pelatihan yang digunakan.

Berikut adalah langkah-langkah untuk membangun model terbaik dalam jaringan ERNN.

f. Penentuan jaringan optimum

Dalam jaringan ERNN yang akan digunakan, terdapat satu lapisan tersembunyi. Jumlah neuron pada lapisan tersembunyi diperoleh melalui metode *trial and error* dengan mencoba berbagai jumlah neuron, yaitu 5, 10 dan 15. Fungsi aktivasi sigmoid bipolar, atau tansig di Matlab, digunakan di lapisan tersembunyi. Fungsi linier atau identitas, disebut sebagai purelin di Matlab, digunakan pada lapisan output.

g. Memilih algoritma pelatihan

*Gradien Descent with Momentum and Adaptive Learning Rate*, yang juga dikenal sebagai traingdx di Matlab, adalah metode pelatihan yang digunakan untuk membangun jaringan ERNN.

h. Penentuan inisialisasi bobot awal

Algoritma Nguyen-Widrow digunakan untuk menginisialisasi bobot awal. Metode ini bertujuan untuk memperpendek periode pelatihan jaringan dan untuk meningkatkan kinerja.

i. Menentukan parameter pelatihan

Algoritma pelatihan adalah dasar untuk parameter yang dipilih. Tabel 4 memberikan parameter algoritma *Gradient Descent with Momentum and Adaptive Learning Rate* (Traingdx).

j. Denormalisasi

Merupakan transformasi data dari hasil peramalan dengan jaringan saraf tiruan ke nilai aslinya dilakukan setelah pelatihan selesai. Output jaringan yang sudah dinormalisasi dikembalikan ke bentuk aslinya.

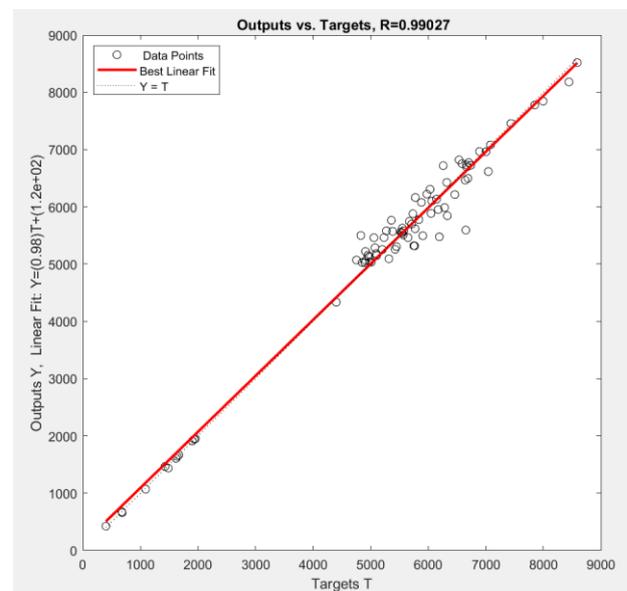
Model terbaik terbentuk berdasarkan *trial and error* terhadap arsitektur jaringan pada ERNN. Model terbaik adalah model dengan MSE dan MAPE pengujian terkecil dengan jaringan paling sederhana.

Berdasarkan hasil pelatihan jaringan pada Tabel 6 diperoleh bahwa model ERNN terbaik dengan algoritma pelatihan *gradient descent* dengan

*momentum* dan *adaptive learning rate* pada arsitektur jaringan 6-15-1 dengan momentum = 0,8 dan LR = 0,01 pada fungsi aktivasi tansig. Model ERNN (5-15-1) memperoleh hasil pada epoch ke 5000 yang memberikan nilai MSE dan MAPE pengujian masing-masing sebesar  $3,4591e+06$  dan 50,8854%. Iterasi berhenti pada epoch ke 5000 meskipun target error yang diinginkan (Goal = 0,001) belum tercapai. Model ini pada epoch ke 5000 telah mencapai konvergen dengan performance = 0,0191.

Selanjutnya, melakukan uji kesesuaian model pada model terbaik. Uji kesesuaian model dilakukan untuk melihat apakah model terbaik yang telah diperoleh layak atau tidak untuk digunakan sebagai model peramalan. Pengujian ini dilihat dari plot regression pada data latih. Uji kesesuaian model ERNN dengan arsitektur jaringan 6-15-1 dapat dilihat dari plot regression pada Gambar 7.

Uji kesesuaian model ERNN dengan arsitektur jaringan 6-15-1 dapat dilihat dari plot regresi pada Gambar 10. Titik-titik pada plot mendekati garis diagonal, dan koefisien korelasi sebesar 0,99027 (mendekati 1) menunjukkan hasil yang baik dalam membandingkan output jaringan dengan target. Oleh karena itu, dapat disimpulkan bahwa model ERNN dengan arsitektur jaringan 6-15-1 layak digunakan sebagai model peramalan penumpang kereta api Non wilayah Jabotabek (Jawa).



Gambar 10. Plot Regression ERNN Wilayah Non Jabotabek (Jawa) pada Arsitektur 6-15-1

Tabel 6. Hasil Pelatihan ERNN Data Wilayah Non Jabotabek (Jawa) dengan Momentum = 0,8 dan LR = 0,01

Arsitektur Jaringan	Epoch	Perf	Pelatihan			Pengujian		
			MSE	MAPE (%)	R	MSE	MAPE (%)	R
6-15-1	5000	0,0191	6,3960e+04	3,1462	0,9903	3,4591e+06	50,8854	0,7701

### Model Terbaik VAR-NN dan ERNN untuk Peramalan Jumlah Penumpang Kereta Api Wilayah Jabotabek

Tabel 7 membandingkan hasil uji coba dengan menggunakan kedua pendekatan tersebut. Dibandingkan dengan model ERNN, teknik VAR-NN menghasilkan nilai uji MSE dan MAPE yang lebih rendah, sehingga menjadikannya sebagai model yang paling sesuai untuk memprediksi jumlah penumpang kereta api di wilayah Jabotabek, berdasarkan Tabel 7 berikut.

Tabel 7. Hasil MSE dan MAPE model peramalan terbaik jumlah penumpang kereta api wilayah Jabotabek

Metode	Model Optimal	MSE	MAPE (%)
VAR-NN	1-7-1	0,0137	11,7
ERNN	5-15-1	3,4983e+07	38,7995

### Model Terbaik VAR-NN dan ERNN untuk Peramalan Jumlah Penumpang Kereta Api Wilayah Non Jabotabek (Jawa)

Tabel 8 membandingkan hasil uji coba dengan menggunakan kedua pendekatan tersebut. Dibandingkan dengan model ERNN, teknik VAR-NN menghasilkan nilai uji MSE dan MAPE yang lebih rendah, sehingga menjadikannya sebagai model yang paling sesuai untuk memprediksi jumlah penumpang kereta api di wilayah Non Jabotabek (Jawa), berdasarkan Tabel 7 berikut.

Tabel 8. Hasil MSE dan MAPE model peramalan terbaik jumlah penumpang kereta api wilayah Non Jabotabek (Jawa)

Metode	Model Optimal	MSE	MAPE (%)
VAR-NN	2-14-1	0,0165	21
ERNN	6-15-1	3,4591e+06	50,8854

## PENUTUP

### SIMPULAN

Berdasarkan hasil pembahasan yang telah dilakukan dapat diambil kesimpulan bahwa Model optimal VAR-NN (1-7-1) dengan 1 neuron pada lapisan input, 7 neuron pada lapisan tersembunyi, dan 1 neuron pada lapisan output diperoleh dengan pemodelan VAR-NN untuk memprediksi jumlah penumpang kereta api di wilayah Jabotabek dengan menggunakan metode Backpropagation, fungsi aktivasi sigmoid bipolar, dan nilai MSE dan MAPE sebesar 0,0137 dan 11,7%. Model terbaik VAR-NN (2-14-1) dengan 2 neuron pada lapisan input, 14 neuron pada lapisan tersembunyi, dan 1 neuron pada lapisan output diperoleh dengan menggunakan pendekatan VAR-NN untuk memprediksi jumlah penumpang kereta api di wilayah Non Jabotabek (Jawa). Algoritma Backpropagation, dengan fungsi aktivasi sigmoid bipolar, menghasilkan nilai MSE dan MAPE masing-masing sebesar 0,0165 dan 21%.

Model optimal ERNN (5-15-1) dengan 5 neuron pada lapisan input, 15 neuron pada lapisan tersembunyi, dan 1 neuron pada lapisan output, ditemukan dengan pemodelan ERNN untuk memprediksi jumlah penumpang kereta api di wilayah Jabotabek. Pelatihan jaringan menggunakan *Gradient Descent with Momentum and Adaptive Learning Rate* (traingdx) dengan momentum 0.1 dan *learning rate* 0.3, dengan menggunakan fungsi aktivasi sigmoid bipolar. Hasilnya menghasilkan nilai MSE dan MAPE masing-masing sebesar 3.4983e+07 dan 38.7995%. Model optimal ERNN (6-15-1) dengan 6 neuron pada lapisan input, 15 neuron pada lapisan tersembunyi, dan 1 neuron pada lapisan output, diperoleh dengan menggunakan pendekatan ERNN untuk memprediksi jumlah penumpang kereta api di wilayah Non-Jabotabek (Jawa). Pelatihan jaringan menggunakan *Gradient Descent with Momentum and Adaptive Learning Rate* (traingdx) dengan momentum

0.8, *learning rate* 0.01 dan menghasilkan nilai MSE dan MAPE sebesar  $3.4591e+06$  dan 50.8854% dengan menggunakan fungsi aktivasi sigmoid bipolar.

Nilai MSE dan MAPE terkecil menjadi dasar pemilihan pemodelan terbaik. Model VAR-NN (1-7-1) yang terdiri dari 1 neuron pada lapisan input, 7 neuron pada lapisan tersembunyi, dan 1 neuron pada lapisan output merupakan model yang paling efektif untuk menduga jumlah penumpang kereta api di wilayah Jabotabek. Model VAR-NN (2-14-1) yang terdiri dari 2 neuron pada lapisan input, 14 neuron pada lapisan tersembunyi, dan 1 neuron pada lapisan output merupakan model yang paling efektif untuk meramalkan jumlah penumpang kereta api di wilayah Non Jabotabek (Jawa).

#### SARAN

Penelitian selanjutnya disarankan untuk menggunakan variasi tambahan dalam jumlah hidden neuron, hidden layer, fungsi aktivasi, teknik pelatihan, dan parameter lainnya untuk mendapatkan arsitektur model yang lebih baik.

#### DAFTAR PUSTAKA

- Butarbutar, P., Midyanti, D. M., & Rismawan, T. (2022). Implementasi Jaringan Syaraf Tiruan Menggunakan Metode Elman Recurrent Neural Network untuk Prediksi Penyakit Jantung Koroner. *Coding Jurnal Komputer dan Aplikasi*, 10(1), 103-113. doi:<http://dx.doi.org/10.26418/coding.v10i01.52723>
- Caraka, R. E., Chen, R. C., Yasin, H., Suhartono, S., Lee, Y., & Pardamean, B. (2021). Hybrid Vector Autoregression Feedforward Neural Network with Genetic Algorithm Model for Forecasting Space-Time Pollution Data. *Indonesian Journal of Science and Technology*, 6(1), 243-266. doi:<https://ejournal.kjpupi.id/index.php/ijost/article/view/67>
- Cynthia, E. P., Yanti, N., Yusra, Fitriani, Y., & Yusuf, M. (2019). Penerapan Metode Elman Recurrent Neural Network (ERNN) untuk Peramalan Penjualan. *Journal of Education Informatic Technology and Science (JeITS)*, 1(2), 49-61. doi:<https://ejournal.umri.ac.id/index.php/JeITS/article/view/1431>
- Dalimunthe, S. B., Sinulingga, S., & Ginting, R. (2023). Implementation Of Machine Learning in Demand Forecasting: A Review of Method Used in Demand Forecasting with Machine Learning. *Jurnal Sistem Teknik Industri (JSTI)*, 25(1), 41-49.
- Diani, K. A., Setiawan, & Suhartono. (2013). Pemodelan VAR-NN dan GSTAR-NN untuk Peramalan Curah Hujan di Kabupaten Malang. *Jurnal Sains dan Seni ITS*, 2(1), D31-D36. doi:10.12962/j23373520.v2i1.3137
- Giusti, A., Widodo, A. W., & Adinugroho, S. (2017). Prediksi Penjualan Mi Menggunakan Metode Extreme Learning Machine (ELM) di Kober Mie Setan Cabang Soekarno Hatta. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 2(9), 2972-2978.
- Kristianto, A. (2004). *Kecerdasan Buatan*. Yogyakarta: Graha Ilmu.
- Makridakis, S., Wheelwright, S. C., & McGee, V. E. (1995). *Metode dan Aplikasi Peramalan Edisi Kedua (Jilid 1)*. Jakarta: Erlangga.
- Nurjanah, I. S., Ruhiat, D., & Andiani, D. (2018). Implementasi Model Autoregressive Integrated Moving Average (ARIMA) Untuk Peramalan Jumlah Penumpang Kereta Api di Pulau Sumatra. *Jurnal Teorema: Teori dan Riset Matematika*, 3(2), 145-156.
- Nurvianti, I., Setiawan, B. D., & Bachtiar, F. A. (2019). Perbandingan Peramalan Jumlah Penumpang Keberangkatan Kereta Api di DKI Jakarta Menggunakan Metode Double Exponential Smoothing dan Triple Exponential Smoothing. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 3(6), 5257-5263.
- Pattah, S. Y., Santoso, L. W., & Santoso, M. (2017). Pembuatan Aplikasi Perdagangan Valas Dengan Metode Elman Neural Network. *Jurnal Infra*, 5(1).
- Pratama, R. I., & Saputro, D. R. (2018). Model Runtun Waktu Vector Autoregressive Moving Average With Exogenous Variable (VARMAX). *Konferensi Nasional Matematika dan Pembelajarannya (KNPMP)*.
- Radjabaycolle, J., & Pulungan, R. (2016). Predikssi Penggunaan Bandwidth menggunakan Elman Recurrent Neural Network. *BAREKENG: Jurnal Ilmu Matematika dan Terapan*, 10(2), 127-135. doi:<https://doi.org/10.30598/barekengvol10iss2pp127-135>
- Salim, L. L., Budhi, G. S., & Pasila, F. (2017). Kontrol Diskrit Hexapod dengan Metode Elman Neural Network dengan Studi Kasus Driving Simulator Game Sederhana. *Jurnal Infra*, 5(1), 128-133.
- Shanmuganathan, S. (2016). Artificial Neural Network Modelling: An Introduction. In S. Shanmuganathan, & S. Samarasinghe, *Artificial Neural Network Modelling. Studies in Computational Intelligence* (pp. 1-14). Cham: Springer. doi:[https://doi.org/10.1007/978-3-319-28495-8\\_1](https://doi.org/10.1007/978-3-319-28495-8_1)
- Sugiarti, L. (2018). *Implementasi Jaringan Syaraf Tiruan (JST) Elman Recurrent Neural Network (ERNN) Untuk Peramalan Permintaan Koran (Studi Kasus: PT. Media Haluan Mandiri Riau Pekanbaru)*. Pekanbaru: Fakultas Sains dan Teknologi. Universitas Islam Negeri Sultan Syarif Kasim Riau.

- Suhartono, & Endharta, A. J. (2009). PERAMALAN KONSUMSI LISTRIK JANGKA PENDEK DENGAN ARIMA MUSIMAN GANDA DAN ELMAN-RECURRENT NEURAL NETWORK. *Jurnal Ilmiah Teknologi Informasi (JUTI)*, 7(4), 183-190.
- Susilawati, R., & Sunendiari, S. (2022). Peramalan Jumlah Penumpang Kereta Api Menggunakan Metode ARIMA dan Grey System Theory. *Jurnal Riset Statistika (JRS)*, 2(1), 1-12.
- Wang, J., & Wang, J. (2016). Forecasting energy market indices with recurrent neural networks: Case study of crude oil price fluctuations. *Energy*, 102, 365-374.  
doi:<https://doi.org/10.1016/j.energy.2016.02.098>
- Wu, W., An, S.-Y., Guan, P., Huang, D.-S., & Zhou, B.-S. (2019). Time series analysis of human brucellosis in mainland China by using Elman and Jordan recurrent neural networks. *BMC Infectious Diseases*, 19(1), 1-11.
- Wutsqa, D. U., Subanar, Guritno, S., & Soejoeti, Z. (2006). Forecasting Performance of VAR-NN and VARMA Models. *Proceedings of the 2nd IMT-GT Regional Conference on Mathematics* (p. 29). Statistics and Applications Universiti Sains Malaysia.
- Yasin, H., Warsito, B., Santoso, R., & Suparti. (2018). Soft Computation Vector Autoregressive Neural Network (VAR-NN) GUI-Based. *E3S Web of Conferences*. 73, p. 13008. EDP Sciences.  
doi:<https://doi.org/10.1051/e3sconf/20187313008>