

Metode *Backpropagation* untuk Memprediksi Tingkat Pengangguran Terbuka (TPT) di Provinsi Jawa Barat dengan Optimasi Adam

Maya Setiana¹, Bayu Rahayudi², Lailil Muflikhah³

Program Studi Teknologi Informasi, Fakultas Ilmu Komputer, Universitas Brawijaya
Email: ¹mayasetiana@student.ub.ac.id, ²ubay1@ub.ac.id, ³lailil@ub.ac.id

Abstrak

Pengangguran termasuk salah satu tantangan yang dihadapi negara berkembang, termasuk Indonesia. Faktor penyebab utama yang mempengaruhi tingkat pengangguran adalah kesenjangan antara lapangan pekerjaan yang tersedia dibandingkan angka angkatan kerja yang tersedia. Di samping itu, rendahnya kebutuhan tenaga kerja di sejumlah sektor di Indonesia juga berkontribusi pada peningkatan jumlah pengangguran. Jawa Barat menjadi provinsi yang menempati urutan pertama dengan populasi sekaligus Tingkat Pengangguran Terbuka (TPT) tertinggi di Indonesia. Prediksi yang akurat tentang Tingkat Pengangguran Terbuka (TPT) akan menjadi alat penting dalam perencanaan dan kebijakan ekonomi yang berorientasi pada tindakan untuk memperbaiki kesejahteraan masyarakat serta menciptakan peluang pekerjaan yang lebih luas. Dalam penelitian ini, metode *backpropagation* dengan optimasi Adam diimplementasikan untuk memprediksi TPT Provinsi Jawa Barat. *Backpropagation* merujuk pada metode yang efektif digunakan untuk melakukan prediksi, sedangkan optimasi Adam akan digunakan sebagai solusi untuk mengatasi masalah *learning speed* yang lambat dalam metode *backpropagation*. Hasil penelitian menunjukkan bahwa metode *backpropagation* dengan optimasi Adam dapat diimplementasikan untuk memprediksi TPT di Provinsi Jawa Barat dengan *error* yang cukup rendah. Nilai MSE terendah diperoleh pada penerapan parameter jumlah neuron *hidden layer* sebanyak 2, nilai *learning rate* 0.001, jumlah *epoch* 1000, proporsi data *training* 70%, dan nilai *batch size* 8 dengan rata-rata nilai MSE sebesar 2.9072.

Kata kunci: jaringan saraf tiruan, *backpropagation*, optimasi adam, prediksi, *time series*.

Abstract

Unemployment is a major problem faced by developing countries, including Indonesia. The main factors that influence the unemployment rate are the imbalance between the available jobs and the existing workforce. In addition, the low absorption of labor in some industrial sectors in Indonesia also contributes to the increasing number of unemployed people. West Java Province is the province with the highest population and Tingkat Pengangguran Terbuka (TPT) in Indonesia. Accurate prediction of TPT in West Java Province will be an important tool in planning and economic policies that are oriented towards improving the welfare of the people and creating more jobs. Backpropagation is one of the effective methods used for prediction. Adam optimization will be used as a solution to address the slow learning speed problem in the backpropagation method. The results of the study showed that the backpropagation method with Adam optimization can be implemented to predict TPT in the West Java Province with a relatively low error. The lowest MSE value was obtained using the parameters of the number of hidden layer neurons of 2, the learning rate of 0.001, the number of epochs of 1000, the proportion of training data of 70%, and the batch size of 8 with an average MSE value of 2.9072.

Keywords: artificial neural network, *backpropagation*, adam optimizer, prediction, *time series*

1. PENDAHULUAN

Pengangguran merujuk pada keadaan dimana seseorang yang merupakan bagian dari angkatan bekerja dan ingin bekerja namun tidak memperoleh pekerjaan (Sukirno, 2006).

Berdasarkan taraf kesejahteraan masyarakat, pengangguran menjadi salah satu permasalahan yang dihadapi negara berkembang seperti Indonesia. Faktor utama yang mempengaruhi tingkat pengangguran di antaranya adalah kondisi timpang dan tidak seimbang antara

lapangan kerja yang tersedia dengan kuantitas tenaga kerja yang tersedia serta rendahnya penerimaan tenaga kerja pada sejumlah sektor di Indonesia (Adwandha, Ratnawati, & Adikara, 2017). Adapun provinsi di Indonesia yang memiliki tingkat pengangguran yang tinggi adalah Provinsi Jawa Barat.

Jawa Barat, provinsi yang memiliki jumlah penduduk sekaligus Tingkat Pengangguran Terbuka (TPT) paling tinggi di Indonesia. Tingkat Pengangguran Terbuka (TPT) dapat diartikan sebagai persentase antara pencari kerja dibandingkan dengan total angkatan kerja dengan tujuan memberikan gambaran proporsi penduduk dengan usia kerja yang tergolong ke dalam kelompok pengangguran di suatu wilayah tertentu. Pada tahun 2020, BPS mencatat TPT di Provinsi Jawa Barat mencapai 9.085%, namun peningkatan terjadi di tahun berikutnya menjadi 9.37%, dan mengalami penurunan pada 2022 menjadi 8.33 persen. Hal ini menunjukkan bahwa TPT di Provinsi Jawa Barat memiliki angka yang relatif tinggi dibandingkan dengan provinsi lain di Indonesia.

Prediksi dapat diartikan sebagai suatu proses sistematis dengan tujuan memperkirakan suatu peristiwa yang memiliki peluang berlangsung pada masa mendatang mengacu pada data historis dari masa lampau dan data saat ini dengan maksud mendapatkan hasil perkiraan yang mendekati realitas yang akan terjadi. Dengan adanya data prediksi TPT, diharapkan dapat memberikan informasi bagi pemerintah dan entitas terkait untuk menentukan suatu solusi. Salah satu metode prediksi yang efektif adalah *backpropagation*, seperti penelitian yang dilakukan oleh Adwandha, Ratnawati, & Adikara (2017) yang mencapai nilai AFER terendah sebesar 4.715198444% untuk memprediksi jumlah pengangguran.

Dalam banyak aplikasi pengenalan pola, *backpropagation* ditujukan untuk mengetahui bobot optimal yang terdapat pada jaringan saraf tiruan dengan arsitektur *multilayer network* dengan menyesuaikan bobot berdasarkan nilai kesalahan yang didapatkan selama *training*. Akan tetapi, kelemahan utama dari metode *backpropagation* adalah *learning rate* yang lambat menuju minimum lokal sehingga kurang optimal selama proses *training*. Hal ini terjadi karena jumlah *hidden node* yang kurang memadai dan pengaturan awal bobot yang tidak sesuai. Laju konvergensi yang lambat juga menjadi permasalahan yang umum dalam metode *gradient descent*, termasuk metode

backpropagation.

Optimasi Adam dianggap sebagai solusi yang potensial untuk mengatasi masalah *learning speed* yang lambat dalam metode *backpropagation* karena lebih efisien secara komputasi, terutama karena kebutuhan memorinya yang kecil (Indolia, et al., 2018). Dalam penerapannya, Adam lebih menguntungkan dibandingkan metode pembelajaran adaptif lainnya karena konvergensinya yang cepat dan kemampuannya dalam melatih model sehingga proses *training* menjadi lebih efisien. Selain itu, Adam mampu memperbaiki beberapa kekurangan dalam teknik optimasi lainnya, seperti masalah *learning rate* yang menghilang dan variasi tinggi dalam pembaruan parameter sehingga menyebabkan fluktuasi dalam *loss function* yang membuat proses *training* tidak stabil (Kumar & Ningombam, 2018).

Berdasarkan uraian permasalahan yang telah dijelaskan, pada penelitian berikut ini akan memanfaatkan jaringan saraf tiruan *backpropagation* dengan optimasi bobot menggunakan Adam untuk memprediksi Tingkat Pengangguran Terbuka (TPT) di Provinsi Jawa Barat. Prediksi TPT yang akurat akan menjadi alat penting dalam perencanaan dan kebijakan ekonomi yang berorientasi pada peningkatan kesejahteraan masyarakat serta menciptakan lapangan kerja yang lebih luas.

2. LANDASAN KEPUSTAKAAN

2.1 Normalisasi

Normalisasi data merupakan proses mengubah atau menyesuaikan nilai data agar berada dalam rentang tertentu untuk nantinya dapat diolah dengan lebih baik. Normalisasi *min-max* ialah suatu teknik normalisasi menggunakan transformasi linier pada data primer menjadi skala yang ditentukan sebelumnya atau skala baru dengan mempertahankan relatif data asli. Berikut merupakan rumus dari normalisasi *min-max* atau *MinMax Scaler* (Han, Kamber, & Pei, 2011) :

$$v'_i = \frac{v_i - \min_A}{\max_A - \min_A} (\text{new_max}_A - \text{new_min}_A) + \text{new_min}_A \quad (1)$$

Keterangan:

- v_i = nilai asli dari suatu atribut
- v_i = nilai baru suatu atribut setelah dinormalisasi
- \min_A = nilai minimum dari suatu atribut sebelum dinormalisasi

max_A = nilai maksimum dari suatu atribut sebelum dinormalisasi
 new_min_A = nilai minimum baru yang diharapkan setelah dinormalisasi
 new_max_A = nilai maksimum baru yang diharapkan setelah dinormalisasi

2.2 Prediksi

Prediksi adalah upaya untuk menaksir secara sistematis tentang suatu peristiwa yang berpeluang terjadi di masa depan dengan memanfaatkan beragam data yang sesuai dari periode waktu yang lalu (data historis) melalui suatu pendekatan ilmiah untuk memperkecil kesalahan (Kafil, 2019). Prediksi (peramalan) memiliki peran yang signifikan terhadap perencanaan dan pengambilan keputusan terkait suatu kebijakan dan strategi (Wanto, et al., 2017). Secara prinsip, menurut Makridakis, Wheelwright, & McGee (1995) pendekatan peramalan pada dasarnya dikategorikan menjadi dua jenis, pendekatan kualitatif dan pendekatan kuantitatif.


2.2 Jaringan Saraf Tiruan

Jaringan saraf tiruan dapat diartikan sebagai suatu metode prediksi dengan tingkat *error* data yang cukup rendah serta mampu melakukan generalisasi dengan baik karena didukung proses data *training* yang memadai dan proses learning yang disesuaikan dengan bobot sehingga mampu memprediksi data deret waktu untuk beberapa waktu yang akan datang (Nugraha & SN, 2014). Perlu diperhatikan bahwa jaringan saraf tiruan tidak diatur secara khusus untuk menghasilkan *output* tertentu karena *output* yang dihasilkan oleh jaringan didasarkan pada pengalaman yang diperoleh selama proses *training* (Jaya, et al., 2018).

2.3 Backpropagation

Backpropagation dapat didefinisikan sebagai salah satu *training* method yang dimanfaatkan dalam jaringan saraf tiruan (Amrin, 2016). Metode ini dinamakan *backpropagation* dikarenakan ketika proses *training* berlangsung, *error* yang dicapai saat proses akan dipropagasikan kembali pada unit-unit yang lebih rendah dalam struktur hierarki (Maharani, 2009). Arsitektur jaringan pada algoritma *backpropagation* terangkai atas *input layer*, *hidden layer*, dan *output layer* (Fausett,

1994). Setiap unit yang terdapat pada *input layer* jaringan saraf tiruan akan selalu terkoneksi dengan setiap unit pada *hidden layer*, hal serupa juga terjadi pada setiap unit yang terdapat pada *hidden layer* yang terkoneksi dengan unit yang terdapat pada *output layer*. Arsitektur jaringan pada algoritma *backpropagation* diilustrasikan pada Gambar 1.



Gambar 1. Arsitektur Jaringan Backpropagation

Proses *training* yang terdapat di jaringan *backpropagation* melibatkan tiga langkah, yaitu feedforward pola *input training*, *backpropagation* terhadap *error*, dan penyesuaian bobot (Fausett, 1994). Algoritma pelatihan yang digunakan untuk *training* jaringan *backpropagation* dengan fungsi aktivasi sigmoid biner dijelaskan seperti berikut ini (Siang, 2005):

- Langkah 1 : Inisialisasi seluruh nilai bobot menggunakan nilai *random* yang bernilai rendah.
- Langkah 2 : Apabila kriteria penghentian belum tercapai, jalankan tahapan 2-9.
- Langkah 3 : Untuk setiap set *training* data, ikuti tahapan-tahapan 3-8.
- Fase I: Feedforward**
- Langkah 4 : Untuk masing-masing *input* unit akan mendapatkan sinyal dan melajutkannya ke hidden unit yang berada di atasnya.
- Langkah 5 : Hitung keseluruhan *output* di *hidden layer* $Z_j = (j = 1, 2, 3, \dots, p)$ yang hasilnya akan digunakan pada fungsi aktivasi.
- Langkah 6 : Hitung seluruh *output* jaringan yang terdapat pada unit $y_k (k = 1, 2, 3, \dots, m)$ yang hasilnya akan digunakan pada fungsi aktivasi.

Fase II: Backpropagation

- Langkah 7 : Hitung faktor δ *output unit* sesuai

error pada masing-masing *output unit* $y_k (k = 1, 2, 3, \dots, m)$. Kemudian hitung selisih pembaruan bobot w_{kj} yang akan digunakan untuk melakukan pembaruan bobot pada w_{kj} dengan laju percepatan α .

Langkah 8 : Hitung faktor δ pada *hidden unit* sesuai *error* pada masing-masing setiap *hidden unit* $z_j (j = 1, 2, 3, \dots, p)$. Selanjutnya lakukan perhitungan untuk suku perubahan bobot v_{ji} yang nantinya dimanfaatkan untuk melakukan perubahan bobot pada v_{ji} .

Fase III: Perubahan Bobot

Langkah 9 : Hitung seluruh pembaruan bobot untuk w_{kj} dan V_{ji} .

2.4 Optimasi Adam

Adam merupakan suatu metode untuk optimasi *stochastic* yang lebih efisien, dimana metode ini hanya membutuhkan *first-order gradient* dengan kebutuhan memori yang kecil. Metode ini akan melakukan perhitungan terhadap *individual adaptive learning rates* pada parameter yang berbeda. Adam diambil dari istilah “*Adaptive Momentum*” (Kingma & Ba, 2015). Secara struktural, Adam merupakan hasil kombinasi dari RMSProp dan *Stochastic Gradient Descent* (SGD) menggunakan momentum yang dikenalkan oleh Diederik Kingma dari OpenAI dan Jimmy Ba dari University of Toronto dalam *paper ICLR 2015* yang berjudul “Adam: A Method for Stochastic Optimization”. Berikut merupakan tahap-tahap yang dilakukan oleh Adam *optimizer* (Soydaner, 2020)

$$m_t \leftarrow \beta_1 m_{t-1} + (1 - \beta_1) g_t \tag{2}$$

$$v_t \leftarrow \beta_2 v_{t-1} + (1 - \beta_2) g \odot g \tag{3}$$

Bias pada momen pertama dan kedua dikoreksi untuk memperbaiki estimasi momen, yang kemudian digunakan dalam perhitungan dan penerapan pembaruan parameter.

$$\hat{m} \leftarrow \frac{m_t}{1 - \beta_1^t} \tag{4}$$

$$\hat{v} \leftarrow \frac{v_t}{1 - \beta_2^t} \tag{5}$$

$$\theta_t \leftarrow \theta_{t-1} + \alpha \frac{\hat{m}_t}{\sqrt{\hat{v}_t + \epsilon}} \tag{6}$$

Keterangan:

- g = Gradient
- m_t = Bobot rata-rata momentum
- m_{t-1} = Bobot rata-rata momentum sebelumnya
- v_t = Bobot rata-rata momentum
- v_{t-1} = Bobot rata-rata turunan parsial sebelumnya
- β_1 = Nilai beta terhadap momentum
- β_2 = Nilai beta terhadap turunan parsial
- ϵ = Epsilon
- α = Learning rate
- θ = Parameter yang akan diperbaiki (bobot)

2.5 Perhitungan Error

2.5.1 MSE

Mean square error (MSE) adalah satu di antara metode yang dimanfaatkan dengan tujuan menghitung selisih antara nilai prediksi dan nilai aktual. Jika nilai MSE yang dihasilkan semakin rendah dapat disimpulkan bahwa tingkat kesalahan yang diberikan juga semakin rendah (Deborah & Prathap, 2021). MSE dapat memberikan Informasi yang lebih akurat daripada *mean absolute deviation* (MAD) sehingga lebih sering digunakan untuk optimasi bobot (Robial, 2018). Berikut ini merupakan rumus MSE (Deborah & Prathap, 2021) :

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{Y}_i - Y_i)^2 \tag{7}$$

Keterangan:

- \hat{Y}_i = vektor dari nilai yang sebenarnya
- Y_i = vektor dari prediksi n
- n = jumlah periode prediksi yang terlibat

3. METODOLOGI

3.1 Data Penelitian

Data informasi yang dimanfaatkan pada riset ini ialah data tentang Tingkat Pengangguran Terbuka (TPT) di Provinsi Jawa Barat dimulai tahun 1986 sampai 2022 beserta variabel-variabel lain yang berpengaruh terhadap nilai TPT. Pada tahun 1995, Survei Angkatan Tenaga Kerja Nasional (SAKERNAS) tidak dilaksanakan sama sekali sehingga tidak dilibatkan dalam data penelitian ini.

Terdapat beberapa *missing value* pada data penelitian sehingga diperlukan metode untuk mengisi data tersebut. Pada Python, interpolasi merupakan suatu teknik yang digunakan untuk mengisi nilai yang hilang dengan estimasi berdasarkan pola data yang ada. Metode *Spline* merupakan teknik yang digunakan untuk mengestimasi nilai data dengan

memanfaatkan fungsi matematika yang meminimalisir total kelengkungan permukaan (Quoc Tran & Nguyen Thanh, 2008). Penelitian ini menggunakan metode Spline dengan parameter k (derajat) untuk mengontrol tingkat akurasi penyesuaian pola data, di mana nilai k yang digunakan merepresentasikan spline linear, yaitu 1.

Data penelitian yang digunakan mulanya terdiri dari 36 data dengan 13 atribut. Untuk meningkatkan jumlah sampel guna meningkatkan akurasi prediksi dan menciptakan representasi data yang lebih halus, teknik interpolasi linier akan dilakukan pada data tersebut. Dengan asumsi bahwa data bersifat kontinu dalam ruang, interpolasi linier membuat perkiraan tentang bagaimana nilai di antara dua titik data dikaitkan berdasarkan garis lurus yang menghubungkan titik-titik tersebut (Afani, Yuwono, & Nurhadi, 2019). Data yang mulanya berjumlah 36 akan digandakan menjadi 12 untuk menyamakan dengan jumlah bulan setiap tahun sehingga jumlah data yang akan dimanfaatkan dalam penelitian mencapai 421. Adapun data *inputan* yang akan dimanfaatkan diilustrasikan pada Tabel 1.

Tabel 1. Informasi Data *Inputan*

Data <i>Inputan</i>	Informasi tentang Data <i>Inputan</i>
X1	TPAK Jawa Barat
X2	Jumlah angkatan kerja Jabar
X3	Pendaftaran pencari kerja Jabar
X4	Lowongan kerja terdaftar Jabar
X5	Pemenuhan tenaga kerja Jabar
X6	Laju pertumbuhan ekonomi Indonesia
X7	Laju pertumbuhan PDRB (non-migas)
X8	Laju pertumbuhan penduduk Jabar
X9	Laju inflasi Indonesia
X10	Laju inflasi Bandung
X11	APM Indonesia
X12	IPM Jabar

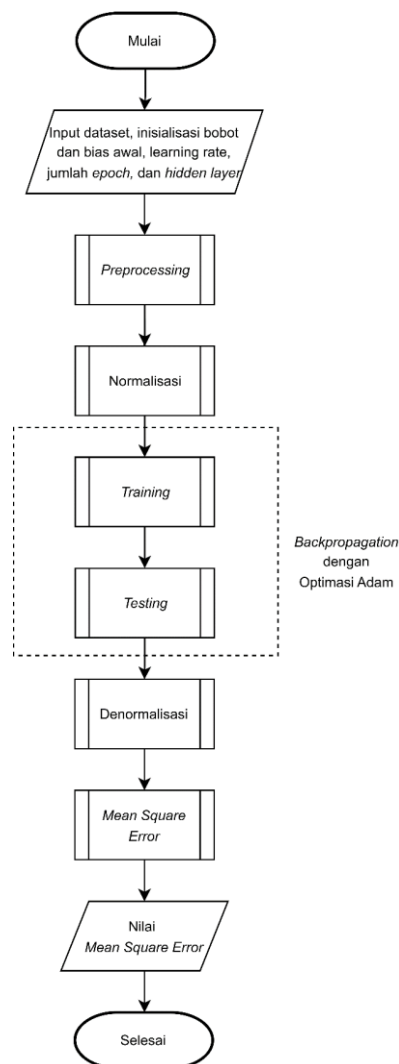
Arsitektur *backpropagation* pada penelitian ini digunakan untuk memprediksi Tingkat Pengangguran Terbuka (TPT) di Provinsi Jawa Barat yang terdiri atas 12 *inputan*, 1 *hidden layer*, dan 1 *output*.

4. PERANCANGAN

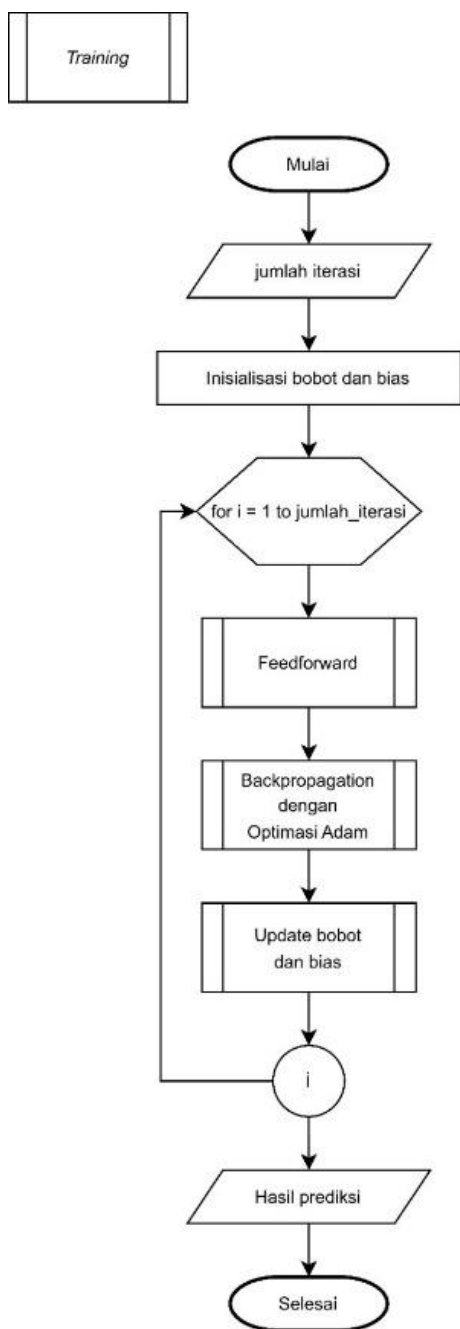
Penelitian ini akan menggunakan metode

backpropagation dengan optimasi Adam untuk mengoptimalkan bobot pada jaringan *backpropagation*. Diagram alir jaringan saraf tiruan diilustrasikan pada Gambar 2 yang berisi penjelasan alur proses algoritma *backpropagation* secara ringkas.

Dataset yang akan digunakan merupakan data mengenai Tingkat Pengangguran Terbuka (TPT) di Provinsi Jawa Barat beserta variabel-variabel lain yang mempengaruhi nilai TPT yang merupakan data sekunder dari laman BPS. Sebelum melangkah ke tahap berikutnya, data akan menjalani proses *preprocessing* terlebih dahulu dengan melakukan imputasi dan *resampling*. Normalisasi akan dilakukan dengan *minmax*. Proses *training* dan *testing* pada penelitian ini akan menggunakan metode *backpropagation* dengan optimasi Adam. Selanjutnya denormalisasi akan dilakukan pada target. Untuk nantinya digunakan untuk menghitung nilai MSE.



Gambar 2. Diagram Alir Jaringan Saraf Tiruan




Gambar 3. Diagram Alir *Training* Metode *Backpropagation* dengan Optimasi Adam

5. PENGUJIAN DAN HASIL

Terdapat beberapa skenario pengujian di antaranya pengujian variasi jumlah neuron *hidden layer*, *learning rate*, *epoch*, variasi jumlah data *training* dan data *testing*, *batch size*, serta pengujian validasi. Setelah dilakukan pengujian untuk seluruh parameter, sehingga didapatkan kesimpulan hasil pengujian yang akan dimanfaatkan untuk evaluasi akhir.

5.1 Pengujian Jumlah Neuron *Hidden Layer*

Jumlah neuron *hidden layer* yang akan diterapkan pada pengujian penelitian ini ialah 1, 2, 4, 6, 8, dan 16. Selanjutnya, setiap jumlah neuron akan diuji sebanyak 5 kali menggunakan bobot awal berupa nilai acak yang bervariasi. Dengan konfigurasi awal untuk *learning rate* sebesar 0.001, jumlah *epoch* 1000, dan data *testing* sebesar 0.3 dari seluruh data. Detail hasil pengujian pengaruh variasi jumlah neuron *hidden layer* ditunjukkan pada Gambar 4.




Gambar 4. Grafik Pengujian Jumlah Neuron *Hidden Layer*

Mengacu pada *output* yang diperoleh saat pengujian, jumlah neuron *hidden layer* berpotensi memiliki dampak yang signifikan pada nilai MSE. Hasil MSE terbaik ditunjukkan pada rata-rata nilai MSE terendah, yaitu 3.3654 pada jumlah neuron *hidden layer* 2. Sebaliknya, rata-rata nilai MSE tertinggi diperoleh pada jumlah neuron *hidden layer* sebesar 16 dengan nilai MSE 50.5904.

Jumlah neuron *hidden layer* juga dapat mempengaruhi kecepatan waktu pelatihan algoritma *backpropagation*. Kinerja pelatihan algoritma akan semakin lambat seiring dengan bertambahnya jumlah neuron *hidden layer*. Agar hasil yang didapatkan lebih presis maka jumlah neuron *hidden layer* yang besar adalah solusi yang paling tepat karena algoritma dapat mempelajari pola yang lebih kompleks dalam data meskipun akan memperlambat waktu pelatihan algoritma (Uzair & Jamil, 2020). Meskipun jumlah neuron *hidden layer* yang besar berpotensi meningkatkan akurasi, hal ini tidak selalu menghasilkan akurasi yang paling baik. Mengacu pada evaluasi yang telah dijalankan dapat ditraik kesimpulan yakni jumlah neuron *hidden layer* 2 adalah nilai yang optimal guna menghasilkan model yang akurat.

5.2 Pengujian Nilai Learning Rate

Nilai *learning rate* yang akan diterapkan pada pengujian penelitian ini di antaranya ialah 0.0001, 0.0005, 0.001, 0.005, 0.01, 0.005, 0.1, dan 0.5. Selanjutnya, setiap *learning rate* akan diuji sebanyak 5 kali menggunakan bobot awal berupa nilai acak yang bervariasi. Dengan konfigurasi awal menggunakan jumlah neuron yang telah didapatkan pada pengujian terdahulu, jumlah *epoch* 1000, dan data *testing* sebesar 0.3 dari seluruh data. Detail hasil pengujian pengaruh variasi nilai *learning rate* ditunjukkan pada Gambar 5.



Gambar 5. Grafik Pengujian Nilai Learning Rate


Mengacu pada *output* dari evaluasi, nilai *learning rate* dapat memberikan pengaruh yang signifikan pada nilai MSE. Hasil MSE yang paling rendah diperoleh pada penggunaan *learning rate* 0.5. dengan nilai MSE 1.0611. Sebaliknya, nilai MSE tertinggi diperoleh pada penggunaan nilai *learning rate* sebesar 0.0001 dengan nilai MSE 34.5345.

Ilustrasi Gambar 5 menunjukkan bahwa nilai MSE cenderung semakin kecil sejalan dengan peningkatan nilai *learning rate*. Kondisi ini dapat terjadi ketika nilai *learning rate* meningkat, model akan belajar lebih cepat karena penyesuaian bobot dan bias yang lebih besar. Namun, nilai *learning rate* yang terlalu besar juga dapat menyebabkan model kurang akurat karena jaringan saraf akan melewati pola yang kompleks dalam data saat proses *training* dan proses *training* menjadi tidak konsisten. Mengacu pada evaluasi yang telah dilaksanakan dapat ditarik kesimpulan yakni nilai *learning rate* yang optimal untuk menghasilkan model yang akurat adalah 0.001 dengan nilai MSE 2.4631.

5.3 Pengujian Jumlah Epoch

Jumlah *epoch* yang akan diterapkan pada pengujian penelitian ini di antaranya adalah 100, 500, 1000, 2000, 3000, 5000, dan 10000.

Selanjutnya, setiap jumlah *epoch* akan diuji sebanyak 5 kali menggunakan bobot awal berupa nilai acak yang bervariasi. Dengan konfigurasi awal menggunakan jumlah neuron dan *learning rate* yang sudah diperoleh pada pengujian sebelumnya, dan data *testing* sebesar 0.3 dari seluruh data. Detail hasil pengujian pengaruh variasi jumlah *epoch* ditampilkan pada Gambar 6.



Gambar 6. Grafik Pengujian Jumlah Epoch

Berdasarkan *output* dari pengujian jumlah *epoch*, jumlah *epoch* dapat memberikan pengaruh yang signifikan terhadap nilai MSE. Dari hasil evaluasi yang dilaksanakan, hasil MSE optimal ditunjukkan pada rata-rata nilai MSE terendah, yaitu 3.1600 pada jumlah *epoch* 1000. Sebaliknya, rata-rata nilai MSE optimal diperoleh pada jumlah *epoch* 100 dengan nilai MSE 20.9942.


Jumlah *epoch* nilai MSE cenderung semakin menurun sejalan dengan peningkatan jumlah *epoch*. Menambah jumlah *epoch* akan menyebabkan proses *training* menjadi lebih lambat, namun model yang dihasilkan akan lebih akurat karena *epoch* yang besar memungkinkan untuk mempelajari pola yang kompleks pada data dengan waktu yang lebih lama.

Data yang memiliki pola yang kompleks, seperti data gambar atau suara mungkin memerlukan jumlah *epoch* yang lebih besar untuk mencapai akurasi yang optimal. Sebaliknya, data yang memiliki pola yang sederhana, seperti data numerik memiliki kemungkinan untuk dapat mencapai akurasi yang optimal dengan jumlah *epoch* yang lebih kecil. Pada penelitian ini, jumlah *epoch* 1000 adalah jumlah *epoch* yang optimal untuk menghasilkan model yang akurat.

5.4 Pengujian Variasi Jumlah Data Training dan Data Testing

Variasi jumlah data *training* yang akan diterapkan dalam pengujian penelitian ini di antaranya ialah 80%, 70%, dan 30%. Sedangkan

untuk data *testing* adalah 20%, 30%, dan 70%. Selanjutnya, setiap perbandingan akan diuji sebanyak 5 kali menggunakan bobot awal berupa nilai acak yang bervariasi. Pengujian ini akan dilakukan dengan mengimplementasikan arsitektur dan parameter optimal yang telah diperoleh pada pengujian sebelumnya. Detail hasil evaluasi pengaruh variasi jumlah data *training* dan data *testing* ditampilkan pada Gambar 7.



Gambar 7. Grafik Pengujian Jumlah Data *Training* dan Data *Testing*


Mengacu pada *output* dari evaluasi variasi jumlah data *training* dan data *testing*, perbedaan dalam jumlah data *training* dan data *testing* yang dimanfaatkan berpotensi mempengaruhi nilai MSE. Berdasarkan *output* dari pengujian, hasil MSE terbaik ditunjukkan pada rata-rata nilai MSE terendah, yaitu 3.809 pada jumlah data *training* 70% dan data *testing* 30%. Semakin rendah nilai MSE maka semakin optimal kinerja algoritma terhadap data. Sebaliknya, rata-rata nilai MSE tertinggi diperoleh pada jumlah data *training* 30% dan data *testing* 70% dengan nilai MSE 22.815.

Dari hasil pengujian dapat diamati bahwa nilai MSE semakin rendah sejalan dengan peningkatan jumlah data *training* yang signifikan. Namun, nilai MSE mengalami peningkatan yang signifikan pada jumlah data *training* yang lebih besar, yaitu 80%. Hal ini disebabkan oleh adanya anomali data pada data *training* 80%. Anomali data adalah data yang tidak sesuai dengan pola data lainnya. Anomali data dapat menyebabkan model *overfitting*.

Berdasarkan pada pengujian yang telah diaplikasikan, dapat ditarik kesimpulan bahwa proporsi jumlah data *training* 70% dan data *testing* 30% adalah proporsi yang optimal untuk menghasilkan model yang akurat. Dengan proporsi ini, jaringan saraf akan memiliki cukup data untuk mempelajari pola dalam data dan mengevaluasi kinerja model.

5.5 Pengujian Variasi *Batch Size*

Variasi variasi *batch size* yang akan diterapkan pada pengujian penelitian ini di antaranya adalah 4, 8, 16, 32, dan 48. Selanjutnya, setiap jumlah *batch size* akan diuji sebanyak 5 kali menggunakan bobot awal berupa nilai acak yang bervariasi. Pengujian ini akan dilakukan dengan mengimplementasikan arsitektur dan parameter optimal yang telah diperoleh pada pengujian sebelumnya. Hasil pengujian pengaruh nilai *batch size* diilustrasikan pada Gambar 8.




Gambar 8. Grafik Pengujian Variasi Nilai *Batch Size*

Berdasarkan pada pengujian yang telah dilakukan, hasil MSE terbaik ditunjukkan pada rata-rata nilai MSE terendah, yaitu 2.9776 *batch size* 8. Nilai MSE yang rendah menunjukkan algoritma yang mampu memprediksi data dengan akurat. Sebaliknya, rata-rata nilai MSE tertinggi diperoleh pada *batch size* 48 dengan nilai MSE 18.1564.

Nilai MSE cenderung semakin meningkat sejalan dengan peningkatan nilai *batch size*. Pada pengujian ini, nilai MSE yang lebih kecil dan konvergensi yang lebih cepat dapat diperoleh pada penggunaan nilai *batch size* yang lebih kecil. Sedangkan nilai *batch size* yang lebih besar juga cenderung menghasilkan proses *training* yang lebih stabil, artinya nilai *loss* dan akurasi model cenderung berubah secara halus dari satu iterasi ke iterasi berikutnya. Hal ini karena setiap iterasi yang dilakukan akan menggunakan lebih banyak data sehingga fluktuasi akibat *outlier* berkurang. Berdasarkan pada pengujian yang telah diaplikasikan, dapat ditarik kesimpulan bahwa nilai *batch size* 8 adalah nilai *batch size* yang optimal untuk menghasilkan model yang akurat.

5.6 Pengujian Validasi

Pengujian validasi merujuk pada pengujian yang menerapkan setiap arsitektur dan parameter yang memberikan hasil optimal pada perancangan pengujian yang sudah diperoleh pada pengujian terdahulu. Pengujian validasi akan diterapkan dengan menjalankan model sebanyak 10 kali menggunakan bobot awal berupa nilai acak yang bervariasi. Pengujian validasi akan digunakan untuk memvalidasi model dari semua parameter optimal. Detail hasil pengujian validasi diilustrasikan pada Gambar 9.



Gambar 9. Grafik Pengujian Validasi

Berdasarkan *output* dari seluruh pengujian validasi yang sudah diterapkan dengan parameter optimal, yakni jumlah neuron *hidden layer* sebanyak 2, nilai *learning rate* 0.001, jumlah *epoch* 1000, proporsi data *training* 70%, dan nilai *batch size* 8 diperoleh rata-rata nilai MSE yang cukup konsisten. Nilai MSE tersebut berada pada rentang 1.2353-4.6599 dengan rata-rata nilai MSE sebesar 2.90717. Nilai MSE yang konsisten menunjukkan bahwa metode tersebut tidak terlalu sensitif terhadap perubahan data. Hal ini penting karena data TPT berpotensi mengalami perubahan dari waktu ke waktu. Lebih dari itu, nilai rata-rata yang rendah menunjukkan bahwa model dapat memprediksi nilai TPT dengan cukup akurat. Hal ini dibuktikan dengan rentang nilai prediksi yang cukup dekat dengan nilai aktual.

5.7 Analisis Pengujian

Pada pengujian metode *backpropagation* dengan optimasi Adam, nilai MSE optimal didapatkan pada pengujian dengan parameter jumlah neuron *hidden layer* sebanyak 2, nilai *learning rate* 0.001, jumlah *epoch* 1000, proporsi data *training* 70%, dan nilai *batch size* 8. Dari parameter tersebut didapatkan rata-rata nilai MSE sebesar 2.90717. Pada penelitian oleh Pohan, Warsito, & Suryono (2020) dihasilkan Nilai MSE sebesar 0.0112 yang menunjukkan bahwa nilai prediksi

yang dihasilkan mendekati data sebenarnya. Adapun penelitian ini memiliki rentang data yang mirip dengan penelitian tersebut, itu sebabnya dapat ditarik kesimpulan yakni model yang diperoleh pada penelitian ini dengan nilai MSE 2.9072 mampu melakukan prediksi dengan hasil nilai prediksi yang cukup dekat dengan nilai aktual, tetapi tidak sebaik penelitian sebelumnya.

Perbedaan nilai MSE yang cukup besar antara penelitian ini dan penelitian sebelumnya disebabkan oleh adanya anomali data. Anomali dalam dataset adalah data yang tidak sesuai dengan pola umum data lainnya. Data ini dapat berupa kejadian atau nilai yang tidak biasa atau berbeda secara signifikan dari data lainnya. Pada penelitian ini, data anomali ditemukan pada periode 2019-2021, yang mana pada periode tersebut sedang terjadi pandemi COVID-19. Variabel-variabel dalam data penelitian ini yang mengalami anomali data adalah Pendaftaran Pencari Kerja Jabar, Lowongan Kerja Terdaftar Jabar, Penempatan/Pemenuhan Tenaga Kerja Jabar, dan Laju Pertumbuhan Ekonomi Indonesia.

6. PENUTUP

Metode *backpropagation* dengan optimasi Adam dapat diterapkan untuk melakukan prediksi Tingkat Pengangguran Terbuka (TPT) di Provinsi Jawa Barat dengan optimasi Adam melalui beberapa proses, yaitu pada tahap pertama merupakan inisialisasi bobot dimana bobot awal diinisialisasi secara acak. Selanjutnya pada tahap *training*, bobot dioptimalkan dengan menggunakan optimasi Adam. Pada tahap pembaruan bobot, bobot optimum yang diperoleh dari tahap *training* digunakan untuk memprediksi nilai TPT.

Hasil akurasi yang optimal pada penggunaan metode *backpropagation* dengan optimasi Adam didapatkan dengan memanfaatkan parameter jumlah neuron *hidden layer* sebanyak 2, nilai *learning rate* 0.001, jumlah *epoch* 1000, proporsi data *training* 70% dan data *testing* 30%, serta nilai *batch size* 8 didapatkan hasil rata-rata nilai MSE sebesar 2.9072. Nilai MSE yang tersebut dipengaruhi oleh adanya anomali data sebagai dampak pandemi COVID-19 pada sejumlah variabel yang dimanfaatkan pada penelitian ini.

7. DAFTAR PUSTAKA

- Adwandha, D.P., Ratnawati, D.E., & Adikara, P.P. (2017) 'Prediksi Jumlah Pengangguran Terbuka di Indonesia menggunakan Metode Genetic-Based *Backpropagation*', *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 1(4), pp. 341–351.
- Han, J., Kamber, M., & Pei, J. (2011) *Data Mining: Concepts and Techniques, Data Mining: Concepts and Techniques*. Available at: <https://doi.org/10.1016/C2009-0-61819-5>.
- Indolia, S. *Et al.* (2018) 'Conceptual Understanding of Convolutional Neural Network- A Deep Learning Approach', *International Conference on Computational Intelligence and Data Science (ICCIDS 2018)*, 132, pp. 679–688. Available at: <https://doi.org/10.1016/j.procs.2018.05.069>.
- Jaya, H. *Et al.* (2018) *Kecerdasan Buatan, Journal of Chemical Information and Modeling*.
- Kingma, D.P. & Ba, J.L. (2015) 'Adam: A Method For Stochastic Optimization', in *ICLR 2015*, pp. 1–15.
- Kumar, S. & Ningombam, D. (2018) 'Short-Term Forecasting of Stock Prices Using Long Short Term Memory', *Proceedings - 2018 International Conference on Information Technology, ICIT 2018*, pp. 182–186. Available at: <https://doi.org/10.1109/ICIT.2018.00046>.
- Maharani, W. (2009) 'Klasifikasi Data Menggunakan Jst *Backpropagation* Momentum Dengan Adaptive *Learning Rate*', *Jurnal Fisika Unand*, 1(4), pp. 46–58. Available at: <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/7237>.
- Nugraha, H.G. & Sn, A. (2014) 'Optimasi Bobot Jaringan Syaraf Tiruan Menggunakan Particle Swarm Optimization', *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*, 8(1), p. 25. Available at: <https://doi.org/10.22146/ijccs.3492>.
- Pohan, S., Warsito, B., & Suryono, S. (2020) '*Backpropagation* artificial neural network for prediction plant seedling growth', *Journal of Physics: Conference Series*, 1524(1). Available at: <https://doi.org/10.1088/1742-6596/1524/1/012147>.
- Robial, S.M. (2018) 'Perbandingan Model Statistik pada Analisis Metode Peramalan *Time Series* (Studi Kasus: PT. Telekomunikasi Indonesia, Tbk Kandatel Sukabumi)', *Jurnal Ilmiah SANTIKA*, 8(2), pp. 1–17.
- Soydaner, D. (2020) 'A Comparison of Optimization Algorithms for Deep Learning', *International Journal of Pattern Recognition and Artificial Intelligence*, 34(13). Available at: <https://doi.org/10.1142/S0218001420520138>.
- Uzair, M. & Jamil, N. (2020) 'Effects of *Hidden Layers* on the Efficiency of Neural networks', *Proceedings - 2020 23rd IEEE International Multi-Topic Conference, INMIC 2020*, pp. 1–6. Available at: <https://doi.org/10.1109/INMIC50486.2020.9318195>.
- Wanto, A. *Et al.* (2017) 'Analysis of Artificial Neural Network *Backpropagation* Using Conjugate Gradient Fletcher Reeves in the Predicting Process', in *International Conference on Information and Communication Technology (iconict)*. Available at: <https://doi.org/10.1088/1742-6596/930/1/012018>.