



Analisis Dinamika Ekonomi Sumatera Barat dan Implikasinya terhadap Perencanaan Karier menggunakan *Feed-Forward Neural Networks*

Mutia Yollanda^{✉1}, Ghea Weisha², Lidya Pratiwi³, Mawanda Almuhayar⁴, Dahlia Misrika⁵, Ade Herdian Putra⁶

Program Studi Statistika dan Sains Data, Departemen Matematika dan Sains Data,
Universitas Andalas, Indonesia^{1,2,3,4,5}

Departemen Bimbingan dan Konseling, Universitas Negeri Padang, Indonesia⁶

email: mutia.yollanda@sci.unand.ac.id¹, ghea_weisha@sci.unand.ac.id²,
lidya_pratiwi@sci.unand.ac.id³, mawandaalmuhayar@sci.unand.ac.id⁴,
dahlia.misrika@sci.unand.ac.id⁵, adeherdian@unp.ac.id⁶

Received 14 May 2025,

Accepted 17 September 2025,

Published 30 September 2025

Abstrak

Penelitian ini menganalisis dinamika ekonomi di Sumatera Barat serta implikasinya terhadap perencanaan karier, dengan memanfaatkan model *Feed-Forward Neural Networks* (FFNN). Model dikembangkan untuk memprediksi Tingkat Pengangguran Terbuka (TPT) berdasarkan data tahunan 2010–2024, menggunakan lima variabel ekonomi: Produk Domestik Regional Bruto (PDRB), inflasi, Upah Minimum Provinsi (UMP), Tingkat Partisipasi Angkatan Kerja (TPAK), dan lama sekolah. Arsitektur jaringan terdiri dari dua lapisan tersembunyi, dengan hasil prediksi menunjukkan nilai *Sum of Squared Errors* (SSE) sebesar 0.145 pada data pelatihan dan 0.023 pada data pengujian, yang mencerminkan tingkat akurasi tinggi. Hasil estimasi menunjukkan bahwa PDRB, UMP, dan lama sekolah memiliki pengaruh negatif signifikan terhadap TPT, sedangkan pengaruh inflasi dan TPAK relatif kecil. Temuan ini memberikan dasar empiris untuk perumusan kebijakan ketenagakerjaan yang lebih adaptif dan tepat sasaran. Selain itu, hasil model ini dapat dimanfaatkan dalam layanan konseling karier berbasis data guna membantu masyarakat memahami tren pasar kerja serta merancang jalur karier yang sesuai dengan dinamika ekonomi daerah. Pendekatan FFNN terbukti efektif dalam mendukung perencanaan karier yang lebih responsif, sekaligus memperkuat strategi pembangunan sumber daya manusia di Sumatera Barat.

Kata Kunci: *Tingkat Pengangguran Terbuka; Produk Domestik Regional Bruto; Upah Minimum Provinsi; Lama Sekolah; Feed-Forward Neural Networks.*

Abstract

This study analyzes the economic dynamics of West Sumatra and their implications for career planning using a Feed-Forward Neural Networks (FFNN) model. The model was developed to predict the Open Unemployment Rate (OUR; denoted as TPT) based on annual data from 2010–2024, incorporating five economic variables: Gross Regional Domestic Product (GRDP; denoted as PDRB), inflation, Provincial Minimum Wage, Labor Force Participation Rate, and average years of schooling. The network architecture consists of two hidden layers, with prediction results showing a Sum of Squared Errors (SSE) of 0.145 for training data and 0.023 for testing

data, indicating high predictive accuracy. The estimation results reveal that GRDP, PMW, and average years of schooling have a significantly negative effect on OUR, while inflation and LFPR show relatively minor effects. These findings provide an empirical basis for formulating more adaptive and targeted employment policies. Additionally, the model's outcomes can be used in data-driven career counseling services to help individuals understand labor market trends and design career paths aligned with regional economic developments. The FFNN approach proves effective in supporting more responsive career planning while strengthening strategies for human resource development in West Sumatra.

Keywords: *Open Unemployment Rate; Gross Regional Domestic Product; Provincial Minimum Wage; Years of Schooling; Feed-Forward Neural Networks.*

✉ Corresponding author

PENDAHULUAN

Tingkat Pengangguran Terbuka (TPT) merupakan isu besar yang dihadapi banyak wilayah di Indonesia, termasuk Provinsi Sumatera Barat. Pengangguran tidak hanya mencerminkan ketidakseimbangan pasar tenaga kerja, tetapi juga berdampak pada stabilitas sosial dan ekonomi suatu daerah. Faktor-faktor yang memengaruhi TPT sangat kompleks, mencakup berbagai aspek makroekonomi seperti Pertumbuhan Produk Domestik Regional Bruto (PDRB), Inflasi, Upah Minimum Provinsi (UMP), Tingkat Partisipasi Angkatan Kerja (TPAK), dan Lama Sekolah. Oleh karena itu, analisis mendalam terhadap faktor-faktor ini menjadi sangat penting untuk merancang kebijakan yang efektif dalam mengurangi tingkat pengangguran.

Berbagai penelitian telah dilakukan untuk mengkaji hubungan antara variabel ekonomi dan pengangguran. Hasil kajian menunjukkan bahwa inflasi, Indeks Pembangunan Manusia (IPM), dan Upah Minimum Provinsi (UMP) memiliki pengaruh terhadap pengangguran di Indonesia [1]. Selain itu, Produk Domestik Regional Bruto (PDRB) dan Tingkat Partisipasi Angkatan Kerja (TPAK) terbukti berdampak signifikan terhadap pengangguran melalui pendekatan regresi spasial [2]. Di Provinsi Riau, PDRB, Pengeluaran Perkapita (PPK), dan Rata-rata Lama Sekolah (RLS) juga berkontribusi terhadap variasi Tingkat Pengangguran Terbuka (TPT) [3]. Pada tingkat regional, nilai tukar ditemukan memiliki dampak signifikan terhadap Produk Domestik Bruto (PDB) di negara-negara ASEAN, sementara inflasi tidak menunjukkan pengaruh yang signifikan [4]. Secara global, variabel seperti GDP, produktivitas tenaga kerja, pertumbuhan populasi, dan inovasi kecerdasan buatan atau *Artificial Intelligence* (AI) berperan dalam menurunkan tingkat pengangguran, sedangkan pengaruh inflasi cenderung lebih kecil [5]. Hal ini menunjukkan bahwa pengangguran merupakan fenomena yang kompleks sehingga upaya penanggulangannya perlu mempertimbangkan interaksi antara faktor ekonomi, sosial, dan perkembangan teknologi.

Beberapa studi internasional memberikan perspektif tambahan terhadap strategi intervensi pengangguran. Kebijakan pasar tenaga kerja aktif, seperti subsidi upah, terbukti efektif dalam mengurangi pengangguran jangka panjang dan ketergantungan terhadap bantuan sosial, seperti yang tercermin dari pengalaman di negara maju [6]. Namun, dalam konteks kualitas pekerjaan, durasi tunjangan pengangguran yang terlalu panjang dapat berdampak negatif terhadap pencocokan

kerja akibat lemahnya jaringan sosial dalam proses pencarian kerja [7]. Evaluasi terhadap kebijakan redistributif, seperti upah minimum dan subsidi pajak penghasilan, juga perlu mempertimbangkan dinamika jangka panjang karena efek jangka pendek dan jangka panjangnya dapat berbeda secara signifikan [8]. Dengan demikian, perumusan kebijakan ketenagakerjaan sebaiknya tidak hanya berfokus pada penciptaan lapangan kerja, tetapi juga pada keberlanjutan kualitas pekerjaan dan efektivitas intervensi dalam jangka panjang.

Selain intervensi ekonomi, dukungan non-ekonomi juga dianggap penting dalam mengatasi pengangguran. Intervensi berbasis konseling karier dapat meningkatkan kesiapan kerja, terutama bila dilakukan secara personal maupun dalam kelompok [9], [10]. Strategi belajar yang baik dan keterlibatan eksploratif dalam proses pendidikan juga berkontribusi terhadap hasil keputusan karier yang lebih positif [11]. Pendekatan holistik dinilai relevan dalam merespons tantangan pengangguran struktural dan psikososial, terutama dalam konteks pasca pandemi COVID-19 [12].

Dalam konteks prediksi tren pengangguran, sejumlah studi di Indonesia menunjukkan pendekatan yang beragam. Proyeksi menggunakan model ARIMA non-musiman memperkirakan penurunan Tingkat Pengangguran Terbuka (TPT) hingga tahun 2050 dengan tingkat akurasi yang cukup tinggi [13]. Di wilayah Bengkulu, analisis terhadap faktor-faktor determinan menunjukkan bahwa Indeks Pembangunan Manusia (IPM) memiliki pengaruh paling dominan terhadap TPT, disusul oleh variabel jumlah penduduk, tingkat kemiskinan, dan PDRB [14]. Di sisi lain, kebijakan upah minimum di negara lain, seperti Rusia, dikaitkan dengan peningkatan pengangguran di kalangan pekerja muda serta peningkatan tingkat informalitas kerja [15]. Sementara itu, urbanisasi di Rumania diketahui berkontribusi terhadap peningkatan pengangguran, tetapi peran kebijakan pemerintah dan inflasi justru berpotensi menurunkannya [16].

Dalam ranah kecerdasan buatan, berbagai studi menyoroti dampaknya terhadap pengangguran dan struktur ekonomi. Teknologi AI diketahui memperburuk ketimpangan kekayaan dalam jangka pendek, dengan dampak jangka panjang yang sangat tergantung pada sektor teknologi yang terdampak [17]. Di Afrika Selatan, investasi dalam AI berkorelasi negatif terhadap pekerjaan terampil dan berkontribusi pada penurunannya dalam jangka panjang [18]. Meski demikian, AI juga dapat memberikan kontribusi positif, seperti membantu meredam dampak penuaan populasi terhadap pertumbuhan inklusif global dan menurunkan pengangguran di kalangan penyandang disabilitas, terutama di negara berpendapatan tinggi [19], [20]. Beberapa penelitian juga menegaskan bahwa hubungan antara AI dan pengangguran bersifat non-linier, dengan efek yang bergantung pada kondisi makroekonomi seperti tingkat inflasi [21], [22].

Sejumlah penelitian juga membahas peran kebijakan ekonomi dalam mengurangi pengangguran. Faktor-faktor seperti harga minyak, investasi asing, Produk Domestik Bruto (PDB) riil, dan keterbukaan perdagangan diketahui berkontribusi dalam menurunkan pengangguran, dengan pengaruh harga minyak yang lebih besar ketika berada di atas ambang tertentu [23]. Ketahanan ekonomi suatu negara juga berperan penting dalam menjaga stabilitas pasar tenaga kerja; negara dengan efisiensi ekonomi tinggi justru dapat menjadi lebih rentan terhadap guncangan eksternal [24]. Dalam ranah kebijakan moneter, pendekatan ekspansioner terbukti memiliki dampak yang bervariasi antar kelompok demografis, dengan

manfaat lebih besar dirasakan oleh sebagian kelompok pekerja, sementara bagi kelompok lainnya dampaknya tidak signifikan [25].


Dalam ranah bimbingan karier, informasi ekonomi yang bersifat prediktif menjadi penting dalam membantu individu membuat keputusan yang rasional dan adaptif. Dalam ranah bimbingan karier, informasi ekonomi yang bersifat prediktif memainkan peran penting dalam membantu individu membuat keputusan secara rasional dan adaptif. Pendekatan tatap muka dalam konseling karier terbukti lebih efektif dibandingkan dengan alternatif daring, sebagaimana tercermin dari peningkatan durasi pengangguran ketika layanan tersebut dialihkan secara digital [26]. Pemodelan *Feed-Forward Neural Networks* (FFNN) juga dapat memberikan wawasan dinamis tentang bagaimana perubahan kebijakan fiskal atau fluktuasi ekonomi tertentu berdampak terhadap sektor-sektor yang berpotensi menyerap tenaga kerja. Dengan pendekatan ini, strategi bimbingan karier dapat diarahkan pada bidang yang menunjukkan tren pertumbuhan positif berdasarkan simulasi ekonomi jangka pendek dan menengah. Dengan demikian, peran bimbingan karier tidak hanya bersifat responsif terhadap kondisi pasar kerja, tetapi juga proaktif dalam memanfaatkan data ekonomi untuk mendukung pengambilan keputusan yang lebih terukur dan berkelanjutan.

Berdasarkan hasil penelitian sebelumnya, variabel-variabel yang memengaruhi TPT di Provinsi Sumatera Barat, seperti PDRB, Inflasi, UMP, TPAK, dan Lama Sekolah, memiliki dampak yang signifikan terhadap dinamika pasar kerja di wilayah ini. Dengan menggunakan pendekatan FFNN, penelitian lebih lanjut dapat memberikan pemahaman yang lebih mendalam tentang faktor-faktor ekonomi yang memengaruhi TPT, sekaligus menghasilkan prediksi yang lebih akurat untuk mendukung perencanaan karier berbasis data. Penelitian ini diharapkan dapat berkontribusi dalam pengembangan layanan bimbingan karier yang lebih relevan dan adaptif terhadap kondisi pasar tenaga kerja yang terus berubah. Selain itu, penelitian ini juga dapat menjadi masukan bagi pembuat kebijakan dan lembaga pendidikan untuk merancang strategi yang lebih efektif dalam merespons tantangan ekonomi dan mengoptimalkan kesiapan tenaga kerja. Dengan pendekatan berbasis data, pencari kerja dapat mengambil keputusan yang lebih terinformasi dan berkelanjutan dalam menghadapi perubahan dinamika pasar kerja di Sumatera Barat.

METODOLOGI

Dalam analisis makroekonomi, diperlukan pendekatan yang mampu memahami perubahan dan perkembangan ekonomi secara menyeluruh. Untuk itu, penelitian ini menggunakan metode *Feed-Forward Neural Network* (FFNN), yaitu salah satu jenis jaringan saraf tiruan yang digunakan untuk memprediksi data berdasarkan pola-pola yang terbentuk dari data sebelumnya. FFNN dapat mengenali hubungan yang rumit antar variabel ekonomi yang mungkin sulit dijelaskan dengan metode biasa.

Adapun arsitektur dari model FFNN ini dapat ditampilkan pada Gambar 1 berikut [27]:



Gambar 1. Arsitektur Feed-Forward Neural Networks.

Gambar 1 merupakan model arsitektur FFNN secara umum. Model FFNN yang digunakan terdiri dari beberapa lapisan, yaitu lapisan input yang menerima data ekonomi (*input layer*), lapisan tersembunyi yang memproses data (*hidden layer*), dan lapisan output yang menghasilkan prediksi (*output layer*). Adapun proses dari model FFNN ini terbagi atas dua tahap, yaitu dari lapisan input ke lapisan tersembunyi dan kemudian dari lapisan tersembunyi ke lapisan keluaran. Misalkan unit masukan yang berada pada sebuah lapisan masukan $x_t = (x_{t1}, x_{t2}, \dots, x_{tn})$ ditransmisikan ke setiap unit tersembunyi dalam lapisan tersembunyi yang hubungannya dapat dinyatakan sebagai berikut [28]:

$$i_{tp} = f_p^h(\sum_{i=1}^n w_{pi}^h x_{ti} + w_{p0}^h) \quad (1)$$

di mana w_{pi}^h adalah bobot penghubung unit masukan i ke unit tersembunyi p , w_{p0}^h adalah bias, dan f_p^h adalah fungsi aktivasi ke lapisan tersembunyi. Kemudian, unit tersembunyi ini ditransmisikan ke setiap unit keluaran pada lapisan keluaran yang dapat dinyatakan sebagai berikut:

$$y_{tj} = f_j^o(\sum_{p=1}^M w_{pj}^o i_{tp} + w_{j0}^o) \quad (2)$$

di mana " h " dan " o " menunjukkan lapisan tersembunyi dan lapisan keluaran secara berturut - turut.

Model ini dilatih dengan data sebelumnya agar dapat menghasilkan prediksi ekonomi ke depan. Setelah itu, hasil prediksi dianalisis untuk melihat bagaimana kemungkinan arah perkembangan ekonomi Sumatera Barat di masa mendatang. Oleh karena itu, nilai residual yang paling minimum dibutuhkan dari penjumlahan kuadrat residual untuk memperbaiki bobot dari masing-masing unit yang terkait sehingga model FFNN akan memperoleh nilai optimal parameter bobot dari lapisan keluaran ke lapisan tersembunyi dan kemudian dari lapisan tersembunyi ke lapisan masukan yang dapat dinyatakan secara berturut -turut sebagai berikut:

$$\frac{\partial E(W)}{\partial w_{jp}^o} = -(z_{tj} - y_{tj}) f_j^{o'}(\sum_{p=1}^M w_{pj}^o i_{tp} + w_{j0}^o) i_{tp} \quad (3)$$

$$\frac{\partial E(W)}{\partial w_{pi}^h} = -\sum_{j=1}^Q (z_{tj} - y_{tj}) f_j^{o'}(\sum_{p=1}^M w_{pj}^o i_{tp} + w_{j0}^o) w_{jp}^o f_p^h(\sum_{i=1}^n w_{pi}^h x_{ti} + w_{p0}^h) x_{ti} \quad (4)$$

di mana $E(W) = \frac{1}{2} \sum_{i=1}^n (z_{tj} - y_{tj})^2$, $\Delta w_{jt} = -\eta \frac{\partial E(W)}{\partial w_{jt}}$, z_{tj} merupakan keluaran yang ingin dicapai dari data pengamatan ke j untuk data ke- k atau target, dan y_{tj} adalah nilai keluaran dari lapisan keluaran ke j untuk data ke- k .

Adapun penyesuaian bobot dengan menggunakan metode FFNN untuk data ke- k dapat dinyatakan sebagai berikut:

$$w_{jp}^o(k+1) = w_{jp}^o(k) + \Delta w_{jp}^o(k) \quad (5)$$

$$w_{pi}^h(k+1) = w_{pi}^h(k) + \Delta w_{pi}^h(k). \quad (6)$$

Dari hasil prediksi tersebut, dibuatlah beberapa kesimpulan tentang dampak perkembangan ekonomi terhadap perencanaan karier. Misalnya, jika data menunjukkan bahwa sektor tertentu akan tumbuh pesat, maka masyarakat dan generasi muda bisa mulai mempersiapkan diri untuk mengembangkan karier di bidang tersebut. Dengan demikian, metode ini tidak hanya memprediksi ekonomi, tetapi juga membantu merancang strategi karier yang sesuai dengan kondisi daerah.

Untuk mengukur performa model FFNN secara kuantitatif, digunakan dua metrik evaluasi yaitu *Mean Absolute Percentage Error* (MAPE) dan *Mean Squared Error* (MSE). MAPE memberikan gambaran tingkat kesalahan relatif rata-rata, sedangkan MSE mengukur besarnya error kuadrat antara data aktual dan hasil estimasi. Kedua metrik ini dinyatakan sebagai berikut [28]:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - t_i|}{y_i} \times 100\% \quad (10)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - t_i)^2. \quad (11)$$

Dalam hal ini, y_i merupakan nilai aktual pada observasi ke- i , t_i merupakan nilai hasil prediksi pada observasi ke- i , dan n menyatakan jumlah total observasi yang digunakan dalam evaluasi model.

Jika nilai MAPE berada pada rentang 0%-10%, maka tingkat keakurasian model dikategorikan sangat akurat. Rentang 10%-20% menunjukkan model berakurat baik, sedangkan 20%-50% mengindikasikan model memiliki akurasi sedang. Apabila MAPE melebihi 50%, maka model dianggap memiliki akurasi rendah. Dengan demikian, nilai MAPE dapat digunakan sebagai tolok ukur efektivitas model FFNN dalam memprediksi Tingkat Pengangguran Terbuka (TPT). Di sisi lain, semakin kecil nilai MSE, semakin kecil pula penyimpangan antara nilai aktual dan hasil prediksi. Kombinasi MAPE dan MSE memberikan gambaran menyeluruh tentang presisi dan kestabilan model dalam menangkap pola data, serta mendukung validitas hasil prediksi untuk digunakan dalam pengambilan keputusan kebijakan ketenagakerjaan dan perencanaan karier di Sumatera Barat.

HASIL DAN PEMBAHASAN

Bab ini menyajikan hasil pemodelan dan peramalan Tingkat Pengangguran Terbuka (TPT) menggunakan pendekatan *Feed-Forward Neural Networks* (FFNN).

Data dan Sumber Data

Data yang digunakan dalam penelitian ini mencakup data tahunan Tingkat Pengangguran Terbuka (TPT) di Provinsi Sumatera Barat dari tahun 2010 hingga 2024. Selain TPT, data yang juga digunakan adalah Produk Domestik Regional Bruto (PDRB) dalam juta rupiah, tingkat inflasi tahunan dalam persentase, Upah Minimum Provinsi (UMP) dalam rupiah, Tingkat Partisipasi Angkatan Kerja (TPAK) dalam persentase, serta Rata-Rata Lama Sekolah dalam tahun. Seluruh data tersebut diperoleh dari website resmi Badan Pusat Statistik (BPS) di <https://www.bps.go.id/id>.

Data ini akan digunakan untuk membangun model prediksi menggunakan pendekatan FFNN, yang memungkinkan analisis hubungan dinamis antar variabel serta menghasilkan proyeksi TPT di masa mendatang untuk Provinsi Sumatera Barat. Gambar 1 menunjukkan pergerakan data TPT, PDRB, Inflasi, UMP, TPAK, dan Lama Sekolah secara berturut-turut selama periode yang dianalisis.



Gambar 2. Grafik Perkembangan TPT, PDRB, Inflasi, UMP, TPAK, dan Rata- Rata Lama Sekolah di Provinsi Sumatera Barat (2010-2024)

Berdasarkan Gambar 2, grafik ini menggambarkan perkembangan indikator ekonomi dan sosial di Provinsi Sumatera Barat antara tahun 2010 hingga 2024. Dari data yang disajikan, terlihat beberapa tren utama yang mencerminkan dinamika ekonomi dan kesejahteraan masyarakat dalam kurun waktu tersebut. TPT menunjukkan fluktuasi signifikan, dengan lonjakan tertinggi sekitar tahun 2011 dan tren penurunan setelahnya. PDRB memperlihatkan pertumbuhan yang konsisten, mengindikasikan perkembangan ekonomi daerah yang stabil. Inflasi mengalami perubahan dari tahun ke tahun, dengan puncak tertinggi sekitar 2013 sebelum


mengalami stabilisasi. UMP terus meningkat setiap tahun, menunjukkan adanya perbaikan dalam kesejahteraan pekerja. TPAK mengalami variasi, dengan tren peningkatan secara umum. Rata-rata lama sekolah terus meningkat, mencerminkan perbaikan dalam akses pendidikan. Gambar ini memberikan wawasan penting tentang bagaimana berbagai faktor ekonomi dan sosial saling berkaitan serta mempengaruhi kesejahteraan masyarakat di Sumatera Barat. Analisis lebih lanjut dapat membantu dalam merumuskan kebijakan yang lebih efektif.

Estimasi Model *Feed-Forward Neural Networks* (FFNN)

Dalam membangun model FFNN, langkah awal yang dilakukan adalah menentukan sampel data yang digunakan dalam proses pelatihan dan pengujian. Berdasarkan Case Processing Summary, data yang digunakan dalam model terdiri dari 15 observasi, di mana 80% (12 observasi) dialokasikan untuk pelatihan (*training*) dan 20% (3 observasi) digunakan untuk pengujian (*testing*). Tidak ada data yang dikecualikan, sehingga seluruh sampel digunakan secara optimal dalam pemodelan. Pembagian sampel ini penting untuk memastikan bahwa model memiliki cukup data untuk belajar pola hubungan antar variabel dalam fase pelatihan, sekaligus memungkinkan evaluasi akurasi prediksi pada tahap pengujian. Dengan proporsi ini, model FFNN dapat meminimalkan risiko overfitting serta meningkatkan kemampuan generalisasi terhadap data baru.

Struktur jaringan saraf tiruan dalam model FFNN terdiri dari tiga lapisan utama, yaitu lapisan input, lapisan tersembunyi, dan lapisan output. Lapisan input mencakup lima variabel ekonomi dan sosial yang telah dinormalisasi, yaitu PDRB, Inflasi, UMP, TPAK, dan Lama Sekolah, sehingga setiap variabel memiliki skala yang seragam untuk meningkatkan stabilitas pelatihan model. Lapisan tersembunyi terdiri dari dua lapisan, masing-masing memiliki satu unit neuron, yang berfungsi untuk menangkap pola non-linear antar variabel melalui fungsi aktivasi sigmoid. Sementara itu, lapisan output memiliki satu unit neuron yang bertugas memprediksi variabel dependen TPT (%), dengan metode normalisasi yang konsisten dengan lapisan input dan fungsi aktivasi sigmoid untuk memperoleh estimasi probabilistik. Model ini menggunakan fungsi error Sum of Squares untuk meminimalkan perbedaan antara nilai prediksi dan nilai aktual dalam tahap pelatihan.

Struktur ini menunjukkan bagaimana model FFNN mengolah variabel ekonomi dan sosial untuk memprediksi tingkat pengangguran terbuka. Dengan adanya dua hidden layers, model memiliki fleksibilitas dalam menangkap hubungan yang lebih kompleks dibandingkan metode regresi linear konvensional. Struktur jaringan dalam Gambar 3 menunjukkan arsitektur model FFNN. Berdasarkan Gambar 3, arsitektur FFNN dalam model ini terdiri atas lima unit input, dua lapisan tersembunyi masing-masing dengan satu neuron, dan satu unit output. Lima unit input merepresentasikan variabel-variabel independen yang berpengaruh terhadap TPT, PDRB, Inflasi, UMP, TPAK, dan Lama Sekolah. Setiap input terhubung ke neuron pada lapisan tersembunyi pertama melalui bobot sinaptik (*synaptic weights*) yang berbeda, sebagaimana ditunjukkan oleh garis-garis berwarna abu - abu muda (berbobot positif) dan biru tua (berbobot negatif).



Gambar 3. Arsitektur Feed-Forward Neural Networks dengan struktur 5-1-1-1.

Kehadiran bias di setiap lapisan (termasuk di lapisan input, tersembunyi, dan keluaran) berfungsi untuk menyesuaikan ambang aktivasi, sehingga meningkatkan fleksibilitas model dalam menangkap variasi data. Aktivasi pada neuron di lapisan tersembunyi dihitung menggunakan fungsi aktivasi sigmoid, yang menghasilkan output dalam rentang 0 hingga 1, memungkinkan interpretasi dalam bentuk probabilitas. Proses aktivasi ini berlanjut ke lapisan tersembunyi kedua yang juga menggunakan fungsi sigmoid sebelum akhirnya diteruskan ke lapisan output untuk menghasilkan estimasi nilai TPT.

Model ini memperlihatkan bahwa FFNN mampu mengintegrasikan pengaruh variabel ekonomi dan sosial secara non-linear. Jalur-pengaruh yang ditunjukkan pada gambar memberikan gambaran hubungan sinaptik dan arah kontribusi masing-masing variabel terhadap hasil akhir. Dengan struktur jaringan yang sederhana namun efisien, model ini mampu memetakan kompleksitas hubungan antara faktor makroekonomi dengan tingkat pengangguran terbuka secara lebih akurat dibandingkan pendekatan regresi tradisional.

Setelah proses pelatihan dan pengujian selesai dilakukan, kinerja model FFNN dievaluasi melalui nilai error dan tingkat kesalahan relatif. Nilai-nilai ini menjadi indikator utama dalam menilai sejauh mana model mampu mempelajari pola dari data pelatihan serta menggeneralisasikan pola tersebut ke data pengujian. Ringkasan hasil evaluasi model ditampilkan pada Tabel 1.

Tabel 1. Validasi Model FFNN.		
Validasi Model FFNN		
Pelatihan	Sum of Squares Error	0.145
Pengujian	Sum of Squares Error	0.023
Variabel Terikat: TPT (%)		

Hasil yang ditunjukkan pada Tabel 1 mempertegas bahwa arsitektur FFNN mampu melakukan pemodelan yang efektif terhadap hubungan antar variabel ekonomi dan sosial yang mempengaruhi TPT Sumatera Barat. Rendahnya nilai *Sum of Squares Error* pada tahap pengujian (0.023) dibandingkan tahap pelatihan (0.145) menunjukkan bahwa model memiliki kemampuan generalisasi yang baik. Hal ini menjadi indikator bahwa model tidak mengalami overfitting, yaitu kondisi ketika model hanya menghafal data pelatihan tetapi gagal memprediksi data baru secara akurat. Keberhasilan model ini juga dipengaruhi oleh penggunaan fungsi aktivasi sigmoid pada lapisan tersembunyi dan lapisan output. Fungsi sigmoid berperan penting dalam menangkap pola non-linear yang kompleks di antara variabel input seperti PDRB, Inflasi, UMP, TPAK, dan Lama Sekolah, serta meneruskannya melalui bobot yang telah disesuaikan ke unit pada lapisan output.

Jika dibandingkan dengan pendekatan statistik konvensional seperti regresi linear berganda, model FFNN memiliki keunggulan dalam memetakan hubungan yang tidak bersifat linier dan tidak memerlukan asumsi ketat mengenai distribusi data. Regresi linear, misalnya, memiliki keterbatasan dalam menangkap interaksi non-linier antar variabel, sedangkan FFNN dapat secara otomatis menyesuaikan bobot dan bias untuk memodelkan relasi kompleks. Oleh karena itu, hasil dari FFNN yang diperoleh ini menegaskan bahwa pendekatan jaringan saraf tiruan lebih fleksibel dan adaptif dalam konteks dinamika ekonomi yang tidak selalu mengikuti pola linier.

Untuk memahami bagaimana model FFNN membentuk hubungan antara variabel input dan output, analisis terhadap estimasi bobot antar lapisan jaringan sangat penting. Tabel 2 menunjukkan hasil estimasi parameter bobot jaringan yang menghubungkan lapisan masukan dengan lapisan tersembunyi, serta lapisan tersembunyi dengan lapisan keluaran. Setiap bobot mencerminkan kontribusi masing-masing variabel terhadap aktivasi neuron pada lapisan berikutnya. Tanda dan besarnya bobot memberikan indikasi awal mengenai arah dan kekuatan pengaruh variabel terhadap prediksi TPT (%).

Tabel 2. Estimasi Parameter Bobot Model FFNN

Estimasi Parameter Bobot Jaringan			
Prediktor	Hasil Prediksi		
	Lapisan Tersembunyi 1	Lapisan Tersembunyi 2	Lapisan keluaran
	$H(1:1)$	$H(2:1)$	TPT
Lapisan Masukan	(Bias)	0.496	
	PDRB	-2.458	
	Inflasi	0.060	
	UMP	-2.736	
	TPAK	-0.628	
	LamaSekolah	-2.244	
Lapisan Tersembunyi 1	(Bias)	0.821	
	$H(1:1)$	-4.413	
Lapisan - Tersembunyi 2	(Bias)		1.668
	$H(2:1)$		4.348


Berdasarkan Tabel 2, dapat dilihat bahwa setiap variabel input dalam model FFNN memiliki bobot tersendiri yang menghubungkannya ke lapisan tersembunyi

pertama, kemudian diteruskan ke lapisan tersembunyi kedua, hingga akhirnya ke lapisan output yang memprediksi TPT. Nilai bobot ini menggambarkan arah dan kekuatan pengaruh masing-masing variabel terhadap output model.

- a. Variabel PDRB memiliki bobot negatif yang cukup besar (-2.458), yang mengindikasikan bahwa peningkatan PDRB cenderung menurunkan TPT. Secara ekonomi, hal ini sesuai dengan logika bahwa pertumbuhan ekonomi pada PDRB menciptakan lebih banyak lapangan pekerjaan sehingga mengurangi pengangguran.
- b. Variabel Inflasi memiliki bobot positif (0.060), meskipun kecil. Ini menunjukkan bahwa peningkatan inflasi sedikit banyak dikaitkan dengan kenaikan TPT. Hal ini dapat dipahami karena inflasi yang tinggi dapat menurunkan daya beli dan meningkatkan biaya produksi, yang pada gilirannya berdampak pada berkurangnya kapasitas perusahaan untuk mempertahankan atau merekrut tenaga kerja baru.
- c. Variabel UMP memiliki bobot negatif besar (-2.736), yang menunjukkan bahwa semakin tinggi UMP, semakin besar kemungkinan TPT meningkat. Hal ini mencerminkan bahwa upah minimum yang terlalu tinggi bisa menjadi beban bagi dunia usaha, sehingga mengurangi jumlah pekerja yang bisa direkrut.
- d. Variabel TPAK juga memiliki bobot negatif (-0.628). Ini menandakan bahwa peningkatan partisipasi angkatan kerja secara umum berkorelasi dengan penurunan TPT, dengan asumsi bahwa pasar tenaga kerja mampu menyerap tenaga kerja yang tersedia. Dalam konteks data ini, peningkatan TPAK lebih sering terjadi bersamaan dengan penurunan pengangguran.
- e. Variabel Lama Sekolah memiliki bobot negatif yang cukup besar (-2.244). Hal ini menunjukkan bahwa semakin tinggi rata-rata lama sekolah, semakin kecil kemungkinan seseorang menganggur. Ini mencerminkan pentingnya pendidikan dalam meningkatkan daya saing dan kemampuan individu untuk memperoleh pekerjaan yang layak.


Oleh karena itu, bobot-bobot ini menunjukkan bahwa variabel ekonomi dan sosial yang digunakan dalam model FFNN memainkan peran penting dan berbeda dalam memengaruhi tingkat pengangguran terbuka di Sumatera Barat. Hubungan non-linear antar variabel ini diolah oleh jaringan saraf untuk menghasilkan prediksi yang lebih akurat dibandingkan pendekatan linier sederhana.

Untuk mengevaluasi sejauh mana residua tersebar terhadap nilai prediksi yang dihasilkan oleh model, pola residual pada Gambar 4 menunjukkan distribusi residual yang tersebar di sekitar garis nol, yang dapat memberikan gambaran mengenai kecocokan model dalam melakukan prediksi. Berdasarkan Gambar 4, dapat dilihat bahwa residual tersebar secara acak di sekitar garis nol, tanpa menunjukkan pola tertentu yang terstruktur. Hal ini mengindikasikan bahwa model FFNN telah melakukan prediksi dengan cukup baik. Dengan demikian, model dianggap memenuhi asumsi residual yang ideal, yaitu distribusi acak dan tidak berpola. Penyebaran ini juga menunjukkan bahwa tidak ada hubungan sistematis antara nilai prediksi dan residual, yang berarti model tidak mengalami masalah underfitting atau overfitting yang signifikan.



Gambar 4. Grafik Residual Model FFNN


Untuk memahami kontribusi masing-masing variabel input terhadap kinerja model FFNN, dilakukan analisis terhadap tingkat kepentingan (*importance*) variabel-variabel tersebut. Analisis ini bertujuan untuk mengidentifikasi variabel mana yang paling berpengaruh dalam pembentukan pola yang dipelajari oleh model. Hasil dari analisis ini ditampilkan pada Gambar 5. Berdasarkan Gambar 5, terlihat bahwa variabel UMP dan PDRB memiliki pengaruh paling besar terhadap hasil estimasi model FFNN, diikuti oleh variabel LamaSekolah dan TPAK. Sementara itu, variabel Inflasi menunjukkan tingkat pengaruh yang paling rendah. Informasi ini dapat digunakan sebagai acuan dalam penyusunan kebijakan, karena menunjukkan faktor-faktor yang paling relevan terhadap prediksi TPT di wilayah tersebut.



Gambar 5. Variabel Berpengaruh pada Model FFNN

Setelah mengetahui pengaruh variabel input terhadap model, langkah selanjutnya adalah membandingkan hasil estimasi model dengan data aktual untuk

menilai sejauh mana prediksi model mencerminkan kondisi nyata. Perbandingan ini divisualisasikan dalam bentuk grafik yang memperlihatkan TPT aktual dan hasil prediksi model FFNN dari tahun 2010 hingga 2024. Gambar 6 menyajikan hasil visualisasi perbandingan data asli dan data prediksi dengan model FFNN.



Gambar 6. Grafik Perbandingan Model FFNN dan Data Asli TPT Provinsi Sumatera Barat

Gambar 6 menunjukkan bahwa estimasi yang dihasilkan oleh model FFNN memiliki pola yang cukup mendekati data aktual, terutama pada tahun-tahun setelah 2014. Meski terdapat sedikit deviasi pada beberapa titik, secara umum tren yang dipelajari oleh model berhasil merepresentasikan fluktuasi TPT di Provinsi Sumatera Barat. Hal ini menunjukkan potensi model FFNN dalam memodelkan data time-series dengan cukup akurat.

Untuk mengukur performa model FFNN secara kuantitatif, digunakan dua metrik evaluasi yaitu *Mean Absolute Percentage Error* (MAPE) dan *Mean Squared Error* (MSE). MAPE memberikan gambaran tingkat kesalahan relatif rata-rata, sedangkan MSE mengukur besarnya error kuadrat antara data aktual dan hasil estimasi. Nilai dari kedua metrik ini disajikan pada Tabel 3.

Tabel 3. Estimasi Parameter Model FFNN

MAPE	MSE
4.698	13.202

Hasil evaluasi model berdasarkan Tabel 3 menunjukkan bahwa nilai MAPE sebesar 4.698 dan MSE sebesar 13.202 menandakan bahwa model FFNN mampu memberikan estimasi yang cukup akurat terhadap nilai TPT. Nilai MAPE yang relatif rendah menunjukkan tingkat kesalahan relatif yang kecil, sehingga model dapat dianggap handal dalam melakukan prediksi untuk keperluan analisis dan pengambilan kebijakan di masa depan.

Proyeksi Indikator Ekonomi dan Dampaknya terhadap Karier

Berdasarkan hasil estimasi parameter bobot model FFNN pada Tabel 2, model prediksi TPT dengan fungsi aktivasi f^{h1} pada lapisan tersembunyi pertama, f^{h2} pada lapisan tersembunyi kedua, dan f^o pada lapisan keluaran dapat dinyatakan dalam bentuk matematis sebagai berikut:

$$H(1:1) = f^{h1}(0.496 - 2.458PDRB + 0.060Inflasi - 2.736UMP - 0.628TPAK - 2.244LamaSekolah) \quad (9)$$

$$H(2:1) = f^{h2}(0.821 - 4.413H(1:1)) \quad (10)$$

$$TPT = f^o(1.668 - 4.348H(2:1)) \quad (11)$$

Persamaan (9) hingga (11) menggambarkan hubungan matematis antara variabel-variabel ekonomi dan output prediksi Tingkat Pengangguran Terbuka (TPT) melalui jaringan saraf FFNN dengan menggunakan fungsi sigmoid. Persamaan (9) menunjukkan bahwa input seperti PDRB, inflasi, UMP, TPAK, dan lama sekolah diolah melalui fungsi aktivasi f^{h1} pada lapisan tersembunyi pertama, kemudian diteruskan ke lapisan tersembunyi kedua melalui fungsi f^{h2} sebagaimana terlihat dalam Persamaan (10). Akhirnya, output dari lapisan tersembunyi kedua digunakan untuk memprediksi nilai TPT melalui fungsi aktivasi keluaran (*output*) yaitu f^o , seperti ditunjukkan dalam Persamaan (11). Nilai koefisien pada masing-masing variabel memberikan wawasan penting terhadap arah dan kekuatan pengaruhnya. Misalnya, nilai negatif yang besar pada variabel PDRB, UMP, dan lama sekolah menunjukkan bahwa peningkatan ketiga indikator ini cenderung menurunkan TPT. Artinya, wilayah dengan pertumbuhan ekonomi yang baik, upah layak, dan tingkat pendidikan tinggi cenderung memiliki tingkat pengangguran yang lebih rendah. Sebaliknya, inflasi memiliki dampak positif meskipun kecil, menunjukkan bahwa tekanan harga dapat meningkatkan risiko pengangguran.

Dalam konteks proyeksi indikator ekonomi, model ini memberikan alat prediktif yang berguna untuk mengantisipasi tren ketenagakerjaan. Jika suatu wilayah menunjukkan tren peningkatan PDRB dan lama sekolah, maka TPT diprediksi akan menurun. Sebaliknya, jika UMP meningkat tajam tanpa diimbangi produktivitas, maka risiko kenaikan pengangguran tetap ada. Informasi ini sangat penting dalam merancang kebijakan ketenagakerjaan dan pendidikan yang lebih sinkron dengan kebutuhan pasar.

Dari sudut pandang layanan konseling karier, integrasi data dari Tabel 2 dan Gambar 5 memperkuat pendekatan berbasis bukti dalam membantu pencari kerja di Provinsi Sumatera Barat. Gambar 5 menunjukkan bahwa variabel yang paling berpengaruh terhadap model prediksi ketenagakerjaan adalah UMP dan PDRB, diikuti oleh Lama Sekolah, TPAK, dan Inflasi. Temuan ini memberikan dasar penting bagi konselor karier untuk merancang strategi yang lebih relevan dengan kondisi ekonomi wilayah Sumatera Barat. Dengan mengetahui bahwa UMP dan PDRB memiliki pengaruh besar terhadap ketenagakerjaan di Sumatera Barat, layanan konseling karier dapat diarahkan untuk meningkatkan pemahaman pencari kerja terhadap dinamika pasar kerja, nilai kompetensi, dan peluang kerja berdasarkan perkembangan ekonomi lokal. Pentingnya variabel Lama Sekolah, TPAK, dan Inflasi

juga menekankan perlunya peningkatan keterampilan, literasi keuangan, serta penguatan kesiapan kerja.

Informasi ekonomi yang akurat dan prediktif memungkinkan pendekatan konseling karier berbasis data menjadi lebih strategis dalam menyelaraskan kompetensi individu dengan kebutuhan pasar tenaga kerja. Hal ini memperkuat peran konselor dalam merancang jalur karier yang adaptif terhadap dinamika ekonomi, sekaligus mendorong pelatihan vokasional yang relevan dan kontekstual. Salah satu dinamika ekstrem yang menunjukkan pentingnya adaptasi ini adalah pandemi COVID-19, yang menyebabkan kontraksi tajam pada sektor padat karya seperti pariwisata, ritel, dan transportasi [29]. Dampaknya, terjadi lonjakan pengangguran yang diikuti oleh hambatan dalam pemulihan, terutama akibat ketidaksesuaian keterampilan serta pergeseran mendadak menuju model kerja jarak jauh yang menuntut kemampuan digital lebih tinggi. Kondisi ini turut memperpanjang durasi pengangguran, dengan proyeksi pengangguran jangka panjang yang signifikan selama masa pemulihan [30]. Dalam konteks kebijakan, pendekatan yang menitikberatkan pada penyerapan tenaga kerja dan pengurangan pengangguran sukarela terbukti lebih efektif dibanding sekadar penciptaan lapangan kerja baru, menandai perlunya intervensi yang lebih terarah dan berkelanjutan dalam pengelolaan pasar kerja [31].

Oleh karena itu, integrasi hasil analisis ini dalam layanan konseling karier menjadi langkah penting dalam mendukung strategi pembangunan sumber daya manusia di Sumatera Barat. Dengan memanfaatkan model prediktif berbasis data seperti FFNN, pendekatan perencanaan karier dapat disesuaikan secara lebih dinamis terhadap perubahan indikator ekonomi makro yang mempengaruhi pasar tenaga kerja di tingkat lokal.

SIMPULAN

Penelitian ini mengkaji dinamika ekonomi di Provinsi Sumatera Barat dan hubungannya dengan perencanaan karier menggunakan pendekatan prediktif FFNN. Model dibangun dengan lima variabel input, yaitu PDRB, inflasi, UMP, TPAK, dan lama sekolah, untuk memprediksi TPT. Arsitektur jaringan terdiri dari dua lapisan tersembunyi dengan masing-masing satu neuron dan menggunakan fungsi aktivasi sigmoid untuk menangkap pola nonlinier antar variabel.

Evaluasi model menunjukkan bahwa FFNN mampu menghasilkan estimasi TPT yang cukup akurat, dengan nilai MAPE sebesar 4.698 dan MSE sebesar 13.202. Pola estimasi model mengikuti tren data aktual dengan baik, yang mengindikasikan kemampuan generalisasi yang memadai dari model terhadap data yang tidak dilatih. Hasil analisis menunjukkan bahwa variabel UMP, PDRB, dan lama sekolah memiliki pengaruh paling besar dalam model dan cenderung menurunkan tingkat pengangguran. Hal ini tercermin dari nilai bobot yang tinggi dan bertanda negatif pada ketiga variabel tersebut. Sebaliknya, variabel inflasi dan TPAK menunjukkan kontribusi yang lebih kecil terhadap prediksi TPT.

Temuan ini memberikan dasar yang kuat bagi penyusunan kebijakan ketenagakerjaan yang lebih terarah dan berbasis data. Pendekatan FFNN terbukti mampu merepresentasikan keterkaitan antara indikator ekonomi dan kondisi pasar kerja, sehingga dapat dimanfaatkan untuk mendukung strategi pembangunan sumber daya manusia di Sumatera Barat melalui perencanaan karier yang lebih responsif terhadap perubahan ekonomi daerah.

DAFTAR PUSTAKA

- [1] S. Soekapdjo and M. R. Oktavia, "Pengaruh Inflasi, Indeks Pembangunan Manusia, Dan Upah Minimum Provinsi Terhadap Pengangguran Di Indonesia," *ECODEMICA*, vol. 5, no. 2, pp. 94–102, Aug. 2021, doi: 10.31294/eco.v5i2.10070.
- [2] M. Agustina, B. Abapihi, G. N. A. Wibawa, and I. Yahya, "Pemodelan Faktor-Faktor yang Mempengaruhi Tingkat Pengangguran Terbuka di Indonesia dengan Pendekatan Regresi Spasial," 2022.
- [3] F. Syaharani, "Analisis Pengaruh Rata Lama Sekolah, Laju Pertumbuhan PDRB, Dan Pengeluaran Perkapita Terhadap Tingkat Pengangguran Terbuka Di Provinsi Riau Menggunakan Model Data Panel Tahun 2021-2023," *EKOMA*, vol. 4, no. 3, pp. 4850–4859, Mar. 2025, doi: 10.56799/ekoma.v4i3.6565.
- [4] M. Yollanda and F. R. Ul Hasanah, "Analisis Pengaruh Variabel Moneter Terhadap Perkembangan Ekonomi Negara ASEAN," *JOSTECH*, vol. 3, no. 1, pp. 1–12, Mar. 2023, doi: 10.15548/jostech.v3i1.5741.
- [5] C. Magazzino, M. Mele, and M. Mutascu, "An artificial neural network experiment on the prediction of the unemployment rate," *Journal of Policy Modeling*, p. S0161893824001546, Dec. 2024, doi: 10.1016/j.jpolmod.2024.10.004.
- [6] U. Unterhofer and C. Wunsch, "Macroeconomic Effects of Active Labour Market Policies: A Novel Instrumental Variables Approach," Nov. 22, 2022, *arXiv*: arXiv:2211.12437. doi: 10.48550/arXiv.2211.12437.
- [7] J. Reale, F. Banning, and M. Roos, "Unemployment Benefits and Job Quality: Unveiling the Complexities of Labour Market Dynamics," Jul. 29, 2024, *arXiv*: arXiv:2407.20306. doi: 10.48550/arXiv.2407.20306.
- [8] E. Hurst, P. Kehoe, E. Pastorino, and T. Winberry, "The Macroeconomic Dynamics of Labor Market Policies," Mar. 28, 2025, *Staff Report*. doi: 10.21034/sr.668.
- [9] S. Sava and M. Crasovan, "Career Counseling and Validation of Competences as Keys for Facing Unemployment," *Procedia - Social and Behavioral Sciences*, vol. 76, pp. 734–738, Apr. 2013, doi: 10.1016/j.sbspro.2013.04.196.
- [10] C. L. D. Carvalho, J. Marôco, M. D. C. Taveira, and A. D. Silva, "Employability resources of unemployed adults: longitudinal effects of a group career intervention," *Front. Psychol.*, vol. 16, p. 1470611, Jan. 2025, doi: 10.3389/fpsyg.2025.1470611.
- [11] L. Demulder, K. Verschueren, M. Lacante, and V. Donche, "Identifying exploration profiles for higher education and their relationship with different student variables and outcomes," *Eur J Psychol Educ*, vol. 38, no. 3, pp. 1145–1163, Sep. 2023, doi: 10.1007/s10212-022-00641-w.
- [12] N. Drosos, M. Theodoroulakis, A. Antoniou, and I. C. Rajter, "Career Services in the Post-COVID-19 Era: A Paradigm for Career Counseling Unemployed Individuals," *Journal of Employment Couns*, vol. 58, no. 1, pp. 36–48, Mar. 2021, doi: 10.1002/joec.12156.
- [13] A. D. Huruta, "Predicting the unemployment rate using autoregressive integrated moving average," *Cogent Business & Management*, vol. 11, no. 1, p. 2293305, Dec. 2024, doi: 10.1080/23311975.2023.2293305.
- [14] C. Apriyanti and M. Yanuarti, "Analysis of the Determinants of Open Unemployment Rate: The Role of Human Development Index and Socioeconomic Factors," *jemaca*, vol. 1, no. 2, pp. 27–31, Dec. 2024, doi: 10.69693/jemaca.v1i2.13.
- [15] G. K. Ten and S. Wang, "Minimum wage and unemployment in Russia: A new look on an old construct," *Economic Modelling*, vol. 148, p. 107086, Jul. 2025, doi: 10.1016/j.econmod.2025.107086.
- [16] A. Moridian, M. Radulescu, M. Usman, S. M. R. Mahdavian, A. Hagi, and L. Serbanescu, "Unemployment rate and its relationship with government size, trade, inflation,

- urbanization, and economic growth in Romania," *Heliyon*, p. e41579, Dec. 2024, doi: 10.1016/j.heliyon.2024.e41579.
- [17] F. Liu and C. Liang, "Analyzing wealth distribution effects of artificial intelligence: A dynamic stochastic general equilibrium approach," *Heliyon*, vol. 11, no. 2, p. e41943, Jan. 2025, doi: 10.1016/j.heliyon.2025.e41943.
- [18] F. Giwa and N. Ngepah, "The relationship between artificial intelligence and low-skilled employment in South Africa," *Heliyon*, vol. 10, no. 23, p. e40640, Dec. 2024, doi: 10.1016/j.heliyon.2024.e40640.
- [19] H. Wen, J. Shang, and X.-H. Nghiem, "Does artificial intelligence matter for the population aging-inclusive growth nexus? International evidence," *Telecommunications Policy*, vol. 49, no. 4, p. 102932, May 2025, doi: 10.1016/j.telpol.2025.102932.
- [20] M. Abid, O. Ben-Salha, K. Gasmi, and N. H. A. Alnor, "Modelling for disability: How does artificial intelligence affect unemployment among people with disability? An empirical analysis of linear and nonlinear effects," *Research in Developmental Disabilities*, vol. 149, p. 104732, Jun. 2024, doi: 10.1016/j.ridd.2024.104732.
- [21] M. Mutascu, "Artificial intelligence and unemployment: New insights," *Economic Analysis and Policy*, vol. 69, pp. 653–667, Mar. 2021, doi: 10.1016/j.eap.2021.01.012.
- [22] Q. P. Nguyen and D. H. Vo, "Artificial intelligence and unemployment: An international evidence," *Structural Change and Economic Dynamics*, vol. 63, pp. 40–55, Dec. 2022, doi: 10.1016/j.strueco.2022.09.003.
- [23] A. A. Alfalih, "The impact of oil prices, foreign direct investment and trade openness on unemployment rates in an oil-exporting country: The case of Saudi Arabia," *Heliyon*, vol. 10, no. 3, p. e25094, Feb. 2024, doi: 10.1016/j.heliyon.2024.e25094.
- [24] T. Kiss, E. Braun, and T. Sebestyén, "Production network structure, specialization and unemployment: Measuring the structural resilience of national economies," *Structural Change and Economic Dynamics*, vol. 72, pp. 11–28, Mar. 2025, doi: 10.1016/j.strueco.2024.11.009.
- [25] H. Bennani, "Effect of monetary policy shocks on the racial unemployment rates in the US," *Economic Systems*, vol. 47, no. 1, p. 101058, Mar. 2023, doi: 10.1016/j.ecosys.2022.101058.
- [26] V. Vehkasalo, "Effects of face-to-face counselling on unemployment rate and duration: evidence from a Public Employment Service reform," *J Labour Market Res*, vol. 54, no. 1, p. 11, Dec. 2020, doi: 10.1186/s12651-020-00276-8.
- [27] D. Devianto, M. Yollanda, M. Maiyastri, and F. Yanuar, "The soft computing FFNN method for adjusting heteroscedasticity on the time series model of currency exchange rate," *Front. Appl. Math. Stat.*, vol. 9, p. 1045218, Apr. 2023, doi: 10.3389/fams.2023.1045218.
- [28] M. Yollanda, D. Devianto, and H. Yozza, "Nonlinear Modeling of IHSG with Artificial Intelligence," in *2018 International Conference on Applied Information Technology and Innovation (ICAITI)*, Padang, Indonesia: IEEE, Sep. 2018, pp. 85–90. doi: 10.1109/ICAITI.2018.8686702.
- [29] G. Caperna, M. Colagrossi, A. Geraci, and G. Mazzarella, "A babel of web-searches: Googling unemployment during the pandemic," *Labour Economics*, vol. 74, p. 102097, Jan. 2022, doi: 10.1016/j.labeco.2021.102097.
- [30] G. Chodorow-Reich and J. Coglianese, "Projecting unemployment durations: A factor-flows simulation approach with application to the COVID-19 recession," *Journal of Public Economics*, vol. 197, p. 104398, May 2021, doi: 10.1016/j.jpubeco.2021.104398.
- [31] C. Jo, D. H. Kim, and J. W. Lee, "Forecasting unemployment and employment: A system dynamics approach," *Technological Forecasting and Social Change*, vol. 194, p. 122715, Sep. 2023, doi: 10.1016/j.techfore.2023.122715.