

Prediksi Alokasi Pagu Belanja Modal Terhadap Realisasi di Kementerian Pertanian Dengan Metode *Neural Network* dan *Generalized Linear Model*

Wahyu Ragil Saputro^{*1}, Moh Himam Iqbal², Samidi³

^{1,2,3}Fakultas Teknologi Informasi, Magister Ilmu Komputer, Universitas Budi Luhur, Indonesia
Email: ¹2311601955@student.budiluhur.ac.id, ²2311601799@student.budiluhur.ac.id,
³samidi@budiluhur.ac.id

Abstrak

Belanja Modal adalah pengeluaran anggaran untuk perolehan aset tetap dan aset lainnya yang memberi manfaat lebih dari satu periode akuntansi. Belanja modal meliputi antara lain belanja modal untuk perolehan tanah, gedung dan bangunan, peralatan, aset tak berwujud. Penelitian ini bertujuan untuk memprediksi alokasi pagu belanja modal di Kementerian Pertanian dari tahun 2021 sampai dengan 2023 dengan mengimplementasikan dan membandingkan kinerja algoritma *Neural Network* dan *Generalized Linear Model*. Penelitian ini menggunakan rasio data pelatihan dan pengujian 90:10, 80:20, dan 70:30. Hasil pengujian menggunakan algoritma *neural network* mendapatkan nilai RMSE sebesar 47.627.183.477,290, 49.167.088.101,340, dan 33.270.553.845,293, sedangkan *Generalized Linear Model* mendapatkan nilai RMSE sebesar 211.888.285.568,081, 222.669.954.080,210, dan 223.385.799.402,206. Berdasarkan hasil perbandingan pada rasio ideal data uji dan latih 70:30, dapat disimpulkan bahwa model *Neural Network* menghasilkan RSME lebih rendah (33.270.553.845) dibanding *Generalized Linear Model* (223.385.799.402) menjadikannya pilihan yang lebih akurat untuk prediksi anggaran. Hasil tersebut diharapkan dapat digunakan untuk membantu prediksi penyediaan alokasi pagu belanja pegawai dimasa yang akan datang.

Kata kunci: *belanja modal, generalized linear model, neural network, pemodelan, prediksi.*

Modeling of Capital Expenditure Ceiling Allocation to Realization in the Ministry of Agriculture Using Neural Network and Generalized Linear Model Methods

Abstract

Capital Expenditures are budget expenditures for the acquisition of fixed assets and other assets that provide benefits for more than one accounting period. Capital expenditure includes, among other things, capital expenditure for the acquisition of land, buildings and structures, equipment, intangible assets. This research aims to predict the capital expenditure ceiling allocation in the Ministry of Agriculture from 2021 to 2023 by implementing and comparing the performance of the Neural Network and Generalized Linear Model algorithms. This research uses training and testing data ratios of 90:10, 80:20, and 70:30. The test results using the neural network algorithm obtained RMSE values of 47,627,183,477.290, 49,167,088,101.340, and 33,270,553,845.293, while the Generalized Linear Model obtained an RMSE value of 211,888,285,568.081, 222,669,954,080.210, and 223,385,799,402.206. Based on the comparison results on the ideal ratio of test and training data of 70:30, it can be concluded that the Neural Network model produces a lower RSME (33,270,553,845) than the Generalized Linear Model (223,385,799,402) making it a more accurate choice for budget predictions. It is hoped that these results can be used to help predict the allocation of employee spending ceilings in the future.

Keywords: *capital expenditure, generalized linear model, neural network, modelling, prediction*

1. PENDAHULUAN

Kementerian Pertanian merupakan kementerian negara di lingkungan Pemerintah Indonesia yang membidangi urusan pertanian. Berdasarkan Peraturan Presiden Nomor 47 Tahun 2009 tentang Pembentukan dan Organisasi Kementerian Negara, Kementerian Pertanian dibentuk dibawah Kementerian Koordinator Perekonomian. Kementerian Pertanian mempunyai tugas menyelenggarakan urusan di bidang pertanian dalam pemerintahan untuk membantu Presiden dalam menyelenggarakan pemerintahan negara. Dalam melaksanakan tugas, Kementerian Pertanian menjalankan fungsi perumusan, penetapan, dan pelaksanaan kebijakan di bidang pertanian, pengelolaan barang milik/kekayaan negara yang menjadi tanggung jawab Kementerian Pertanian,

pengawasan atas pelaksanaan tugas di lingkungan Kementerian Pertanian, pelaksanaan bimbingan teknis dan supervisi atas pelaksanaan urusan Kementerian Pertanian di daerah, dan pelaksanaan kegiatan teknis yang berskala nasional. Dengan cakupan urusan daerah yang begitu luas, maka diperlukan pengelolaan sarana dan prasarana aset dan atau aset lainnya untuk mendukung kegiatan Kementerian Pertanian. Oleh karena itu, pengelolaan anggaran belanja modal, termasuk pengelolaan aset dan aset lainnya merupakan persoalan yang sangat penting[1]. Perkiraan alokasi anggaran yang akurat sangat penting untuk memastikan tersedianya dana yang cukup untuk memenuhi kebutuhan operasional dan pengelolaan aset dan dapat meningkatkan efisiensi dan efektivitas pengelolaan anggaran dan belanja modal.

Berdasarkan Laporan Keuangan Kementerian Pertanian Republik Indonesia Tahun 2021 sampai dengan 2023[2][3][4], didapatkan pagu awal belanja modal yang kemudian dilakukan revisi perubahan pagu diakhir periode, hal ini menandakan ada perencanaan alokasi pagu awal belanja pegawai yang kurang akurat[5]. Perubahan/revisi alokasi pagu dan realisasinya seperti pada tabel 1.

Tabel 1. Alokasi Pagu dan Realisasi Belanja Modal Tahun 2021-2023

Tahun	Pagu Awal	Pagu Revisi	Realisasi Belanja	%Realisasi (Awal)	%Realisasi (Revisi)
2021	1.012.910.943.000	857.057.562.000	845.841.925.172	83,51%	98,69%
2022	606.594.574.000	689.326.665.000	645.942.308.969	106,49%	93,71%
2023	544.048.624.000	563.846.730.000	493.275.255.634	90,67%	87,48%

Berdasarkan data alokasi pagu dan realisasi belanja modal tahun 2021-2023 pada tabel 1 khususnya pada prosentase %Realisasi Awal, diperlukan peramalan/prediksi penyediaan alokasi pagu belanja modal yang akurat, sehingga revisi alokasi pagu belanja modal pada akhir periode anggaran tidak perlu dilakukan dan realisasi anggaran melebihi 100% seperti yang terjadi di tahun 2022 dimana realisasi awal mencapai 106,49%. Untuk mencapai hasil prediksi yang akurat, penelitian ini mempertimbangkan penggunaan algoritma *Neural Network* dan *Generalized Linear Model*. Algoritma *Neural Network* mampu menangkap pola-pola kompleks dan non-linear dalam data historis, yang sering kali muncul dalam perencanaan dan realisasi anggaran. *Neural Network* memiliki kemampuan adaptasi yang tinggi terhadap data beragam dan mampu mempelajari keterkaitan yang tidak eksplisit, sehingga lebih cocok untuk kasus-kasus di mana hubungan antara variabel input dan output tidak linier. Sementara itu, *Generalized Linear Model* dipilih karena fleksibilitas dalam distribusi variabel respon dengan berbagai jenis distribusi, seperti normal, *binomial*, *poisson*, *gamma*, dan *inverse gaussian*. Ini memungkinkan pengguna untuk melakukan pemodelan pada data yang tidak berdistribusi normal, yang seringkali merupakan gambaran pada regresi linear sederhana. Penggunaan kedua algoritma ini secara paralel dapat memberikan alternatif prediksi yang beragam, baik dari segi kompleksitas maupun kesederhanaan, sehingga memberikan gambaran lebih menyeluruh untuk pengambilan keputusan[6] [7].

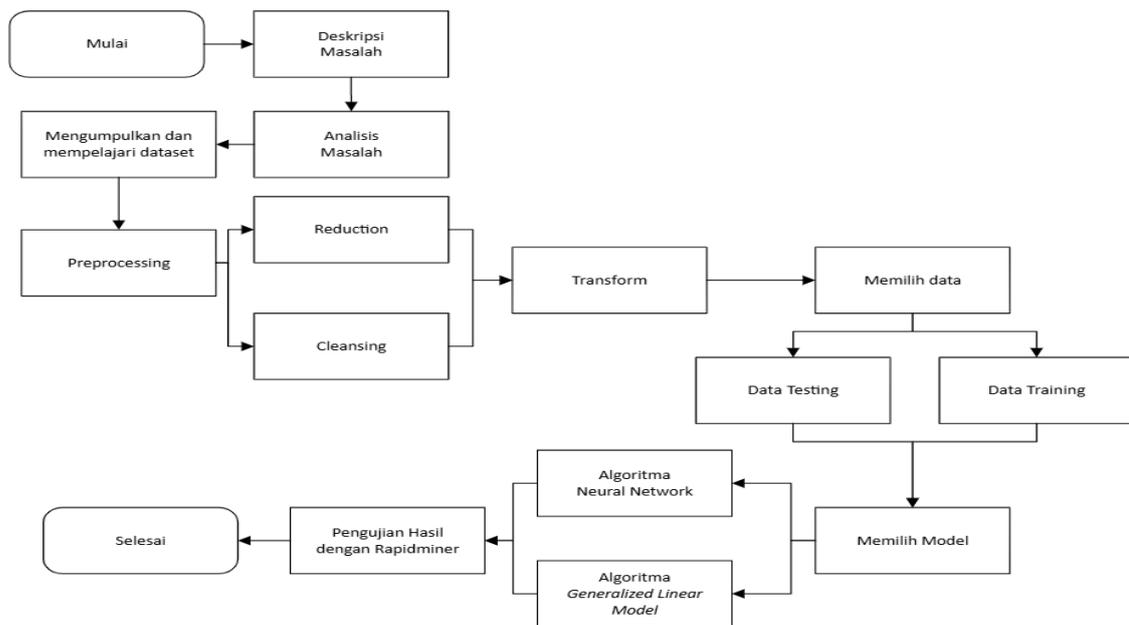
Beberapa penelitian sebelumnya dengan data serupa diantaranya adalah penelitian “Analisis Anggaran dan Realisasi Belanja Modal pada Kominfo Balai Besar Pengkajian dan Pengembangan Komunikasi dan Informatika Makassar” dengan metode deskriptif kualitatif oleh Hasan Hamzah berupa data anggaran dan belanja modal yang berdampak pada penyerapan anggaran [8]. Berikutnya penelitian Iskandar “Revolusi Industri 4.0 Dalam Pengelolaan Kas Negara: Pemodelan Prakiraan Kas Negara Menggunakan Jaringan Saraf Tiruan” dengan metode *Neural Network* menghasilkan MSE sebesar 1,21 [9]. Kemudian penelitian Purwati “Data Mining Menggunakan Algoritma *Neural Network* dan Visualisasi Data untuk Memprediksi Kelulusan Siswa” menghasilkan nilai akurasi sebesar 92,83% [10]. Pada penelitian lebih lanjut oleh Kusumodestoni dan Suyatno dengan menggunakan algoritma jaringan syaraf tiruan “*Exchange Forecasting Menggunakan Neural Network Models*”, hasil penelitian menunjukkan nilai prediksi sebesar 0,431 +/- 0,096 [11]. Penelitian selanjutnya oleh Rudi Hartono dengan “Pemodelan Prediksi Alokasi Pagu Belanja Pegawai dengan Metode *Neural Network* dan *Linear Regression*” menghasilkan nilai RMSE sebesar 1.574.970.259,712 untuk *Neural Network* dan sebesar 1.612.945.104,455 untuk *Linear Regression* [12].

Penelitian ini bertujuan untuk mengimplementasikan dan membandingkan dua algoritma, yaitu *Neural Network* dan *Generalized Linear Model*, untuk memprediksi alokasi batas belanja modal di lingkungan Kementerian Pertanian Republik Indonesia. Berbeda dari penelitian sebelumnya yang hanya menggunakan model linier, penelitian ini menggabungkan *Neural Network* untuk menangkap pola non-linear yang kompleks. Dengan membandingkan kinerja kedua model ini, penelitian ini bertujuan untuk memberikan wawasan yang lebih mendalam tentang metode peramalan yang lebih efektif dan efisien serta membantu mengambil gambaran pengelolaan anggaran yang lebih baik. Melalui analisis data yang komprehensif dan penggunaan metrik evaluasi yang sesuai seperti *Mean Absolute Error* (MAE) atau *Root Mean Square Error* (RMSE)[13][14], penelitian ini mengidentifikasi kekuatan dan kelemahan masing-masing algoritma dari perspektif peramalan anggaran. Hasil

penelitian ini diharapkan dapat membantu pejabat pemerintah, khususnya Kementerian Pertanian Republik Indonesia, untuk meningkatkan akurasi perkiraan anggaran belanja modalnya.

2. METODE PENELITIAN

Metode yang digunakan dalam penelitian ini adalah metode kualitatif dengan pendekatan deskriptif. Tujuan penelitian adalah untuk memberikan gambaran yang jelas tentang fenomena yang diteliti dengan mengkomunikasikan tujuan yang jelas, merencanakan pendekatan pelaksanaan, dan mengumpulkan berbagai jenis data yang akan digunakan untuk membuat laporan penelitian [15]. Metode penelitian yang digunakan untuk membuat model *data mining* didasarkan pada jaringan saraf tiruan dan regresi linier. Gambar 1 menunjukkan tahapan penelitian ini.



Gambar 1. Tahapan Penelitian Algoritma *Neural Network* dan *Generalized Linear Model*

Tahapan penelitian pada Gambar 1 dapat dijelaskan sebagai berikut:

2.1. Deskripsi Masalah

Pada tahap ini, batas-batas masalah yang ingin diatasi sudah didefinisikan dengan jelas. Langkah ini dimaksudkan untuk membantu menemukan solusi terbaik terhadap permasalahan yang ada. Tahapan ini sangat penting sebagai langkah awal dalam memulai suatu penelitian [16]. Penetapan batasan suatu masalah secara tepat memungkinkan peneliti untuk fokus pada aspek-aspek yang relevan dan menghindari penyimpangan dari tujuan utama penelitian.

2.2. Analisis Masalah

Dengan meninjau hasil Laporan Realisasi Anggaran (*Face*) tahun 2021 sampai dengan 2023 di Kementerian Pertanian Republik Indonesia, ditemukan bahwa persentase realisasi belanja modal melebihi pagu anggaran awal. Untuk mengatasi permasalahan ini, dilakukan pencarian solusi dengan mempelajari berbagai literatur terkait. Pendekatan ini memungkinkan identifikasi langkah-langkah strategis yang dapat diambil untuk menyeimbangkan anggaran dan mengoptimalkan pengelolaan keuangan di masa mendatang.

2.3. Mengumpulkan dan Mempelajari dataset

Pada tahap ini dilakukan pendataan berdasarkan data realisasi belanja pegawai yang diperoleh dari sistem informasi yang dikelola Direktorat Teknologi Sistem Informasi Keuangan (SITP) Direktorat Jenderal Perbendaharaan Kementerian Keuangan. Memperoleh data aktual belanja pegawai multi tahun selama tiga tahun dari 2021 hingga 2023 untuk tujuan memprediksi alokasi belanja modal. Data ini terdiri dari 12 atribut.

2.4. Data Pre-processing

Level ini penting dalam analisis data dan pembelajaran mesin, yang tujuannya adalah menyiapkan data mentah agar dapat digunakan secara efektif dalam model analitik. Langkah-langkah utamanya adalah:

2.4.1. Data Cleansing

Fase ini termasuk menghapus duplikat. Penghapusan data yang terjadi lebih dari satu kali, penanganan nilai yang hilang, validasi data, yaitu memastikan bahwa data sesuai dengan aturan atau batasan yang ditentukan.

2.4.2. Data Reduction

Tahap ini mengurangi jumlah data yang harus dianalisis sambil mempertahankan informasi penting. Teknik-teknik dalam *data reduction* meliputi:

2.4.2.1. PCA (Principal Component Analysis)

Teknik ini mengurangi dimensi data dengan mengidentifikasi dan memproyeksikan data ke arah komponen utama yang menjelaskan variabilitas terbesar. Teknik PCA dapat meningkatkan kualitas data dengan mengurangi dimensi data, menghilangkan redundansi, meningkatkan performa model, efisiensi komputasi, dan visualisasi data.

2.4.2.2. Feature Selection

Teknik ini memilih fitur yang paling relevan untuk analisis dengan menggunakan metode statistik atau algoritma *machine learning*.

2.4.2.3. Sampling

Teknik ini mengambil subset data yang representatif dari populasi data asli untuk mengurangi volume data yang perlu diproses.

2.4.2.4. Aggregation

Teknik ini menggabungkan data pada level yang lebih tinggi untuk mengurangi granularitas.

2.4.3. Data Transformation

Tahap ini mengubah format, struktur, atau nilai data agar sesuai dengan kebutuhan analisis. Langkah-langkah dalam data transformation meliputi Normalisasi dan Standarisasi yaitu menyesuaikan skala data agar memiliki distribusi yang konsisten, seperti normalisasi (0 hingga 1) atau standarisasi (nilai rata-rata dan deviasi standar), Pengkodean kategorikal yaitu mengubah data kategorikal menjadi format numerik, seperti menggunakan *one-hot encoding*, Agregasi Data yaitu menggabungkan data dari beberapa sumber atau merangkum data menjadi bentuk yang lebih ringkas dan Pembuatan Fitur Baru yaitu membuat fitur baru dari data yang ada untuk memperkaya informasi yang digunakan dalam model.

2.5. Memilih Data

Tahapan memilih data dibagi menjadi memilih data training dan data testing sebagai berikut.

2.5.1. Data Training

Bagian dari kumpulan data yang digunakan untuk melatih model atau algoritma. Ini adalah data yang dimasukkan ke model sehingga model dapat mempelajari pola dan hubungan antar variabel. Selama proses pelatihan, parameter model dioptimalkan sehingga model dapat membuat prediksi yang akurat ketika dihadapkan pada data baru yang belum pernah dilihat sebelumnya.

2.5.2. Data Testing

Bagian dari kumpulan data terpisah yang tidak digunakan saat melatih model. Setelah model dilatih menggunakan data pelatihan, data pengujian digunakan untuk menguji bagaimana model dapat menerapkan pengetahuan yang dipelajari ke data baru yang belum pernah dilihat sebelumnya. Tes ini membantu mengevaluasi kemampuan model dalam membuat prediksi yang akurat.

Data *training* dan data *testing* ditentukan dengan melakukan split data dengan 3 rasio pengujian yaitu 90:10, 80:20, dan 70:30 terhadap data testing. Rasio ini ini menentukan proporsi data yang dialokasikan untuk mengevaluasi performa model dalam skenario data terbatas.

2.6. Memilih Model

2.6.1. Algoritma Neural Network

Algoritma jaringan syaraf tiruan (jaringan syaraf tiruan) merupakan teknik komputasi yang terinspirasi dari cara otak manusia memproses informasi [17]. Algoritma ini terdiri dari banyak unit pemrosesan sederhana yang saling berhubungan yang bekerja secara paralel untuk memecahkan masalah kompleks seperti prediksi, pengenalan pola, dan klasifikasi[18], [19].

2.6.1.1. Struktur Dasar Neural Network

- a) Lapisan masukan: Lapisan ini menerima data mentah atau fitur dari kumpulan data.
- b) Lapisan Tersembunyi: Lapisan ini melakukan perhitungan dan transformasi pada data menggunakan bobot dan fungsi aktivasi.
- c) Lapisan keluaran: Lapisan ini memberikan hasil akhir dari jaringan saraf.

2.6.1.2. Perhitungan pada Neural Network

Nilai *net input* (net input) ke *neuron j* di lapisan tersembunyi atau *output* dihitung sebagai:

- Nilai net Input

$$Z_j = \sum_{i=1}^n w_{ij} x_i + b_i \quad (1)$$

Dimana:

x_i = adalah input dari *neuron* ke- i (dari lapisan sebelumnya).

w_{ij} = adalah bobot yang menghubungkan *neuron i* ke *neuron j*.

b_i = adalah bias *neuron j*

- Fungsi Aktivasi

Fungsi aktivasi mengubah nilai net input menjadi output yang akan digunakan sebagai input ke neuron di lapisan berikutnya. Beberapa fungsi aktivasi yang umum digunakan adalah:

- a) Sigmoid : $\sigma(z) = \frac{1}{1+e^{-z}}$
- b) ReLU (Rectified Linear Unit): $ReLU(z) = \max(0,z)$
- c) Tanh (Hyperbolic Tangent): $\tanh(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$

- Nilai Output

Output dari *neuron j* setelah diterapkan fungsi aktivasi adalah:

$\alpha_j = f(z_j)$ di mana f adalah fungsi aktivasi yang digunakan.

2.6.1.3. Proses Training Neural Network

- a) Forward Propagation

Input data disalurkan melalui jaringan dari lapisan input ke lapisan output, menghasilkan prediksi output.

- b) Loss Function

Fungsi loss mengukur seberapa baik prediksi neural network dibandingkan dengan nilai target yang sebenarnya. Contoh fungsi *loss* yang sering digunakan adalah Mean Squared Error (MSE):

$$\mathcal{L} = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2 \quad (2)$$

Dimana:

y_i adalah nilai target sebenarnya.

\hat{y}_i adalah nilai prediksi dari *neural network*.

m adalah jumlah contoh data.

2.6.1.4. Backpropagation

Proses *backpropagation* menghitung gradien dari fungsi *loss* terhadap bobot dan bias dengan menggunakan aturan rantai (*chain rule*). Gradien ini kemudian digunakan untuk memperbarui bobot dan bias agar mengurangi nilai *loss*. Pembaharuan bobot dilakukan menggunakan algoritma optimisasi seperti *Gradient Descent*:

$$w_{ij} \leftarrow w_{ij} - \eta \frac{\partial \mathcal{L}}{\partial w_{ij}} \tag{3}$$

Dimana:

η adalah learning rate.

$\eta \frac{\partial \mathcal{L}}{\partial w_{ij}}$ adalah gradien dari fungsi *loss* terhadap bobot.

2.6.1.5. Iterasi dan Konvergensi

Proses *forward* propagation dan *backpropagation* diulangi untuk sejumlah iterasi atau sampai nilai *loss* mencapai ambang batas tertentu (konvergensi).

2.6.2. Algoritma Generalized Linear Model

Analisis regresi linier merupakan pemodelan dengan pendekatan secara statistik untuk menentukan hubungan linier antara variabel satu dengan variabel lainnya, yaitu variabel respon (variabel yang dipengaruhi) dengan variabel penjelas (variabel penyebab)[20]. Pendekatan regresi secara teori mendapatkan hasil yang baik ketika variabel respon berdistribusi normal dan varians data (keragaman data) bernilai konstan. *Generalized Linear Models* dapat mengatasi ketika variabel respon tidak berdistribusi normal dan keragaman data bernilai konstan. *Generalized Linear Models* di definisikan sebagai perluasan dari regresi linier dengan menggunakan distribusi keluarga eksponensial. Tujuan dari model *Generalized Linear Models* ini adalah untuk mengestimasi variabel respon (*Y*) yang bergantung pada penjelasan dari variabel-variabel penjelas (*X*)[21], [22]. Variabel pengamatan *Y* yang berdistribusi keluarga eksponensial memiliki fungsi peluang sebagai berikut:

$$f(y|\theta, \phi) = \exp\left(\frac{y\theta - b(\theta)}{\phi} + c(y, \phi)\right), y \in S \tag{4}$$

dengan *y* adalah variabel respon, θ adalah parameter kanonik, ϕ adalah parameter skala, dan *S* adalah himpunan bagian dari himpunan bilangan asli (\mathbb{N}) atau bilangan real (\mathbb{R}). Sedangkan *b*(θ) dan *c*(*y*, ϕ) adalah suatu fungsi yang diketahui. Pada distribusi keluarga eksponensial berlaku: $E(y)=b'(\theta)$ dan $Var(y)=\phi b''(\theta)$.

GLM memiliki tujuan yang sama dengan regresi linier pada umumnya, yaitu menentukan nilai harapan bersyarat dari variabel respon dengan menggunakan data pengamatan yang sudah ada. Dalam hal ini, akan ditentukan parameter $\beta_1, \beta_2, \dots, \beta_n$ melalui fungsi hubung dari nilai rata-rata variabel penjelas (μ_i), yang dapat dituliskan sebagai kombinasi linier dari variabel penjelas *x_i* seperti berikut:

$$g(\mu_i) = \beta_0 + \sum_{j=1}^n \beta_j x_{ij} = x_i^T \beta = \eta_i, i = 1, 2, \dots, m \tag{5}$$

$$\beta = \begin{pmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_n \end{pmatrix} \tag{6}$$

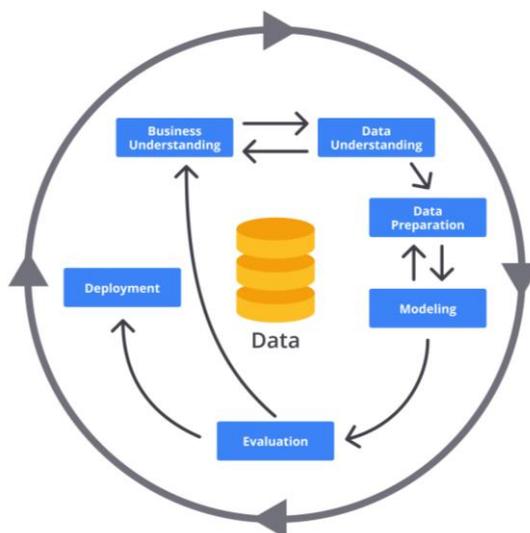
dengan $\beta = \begin{pmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_n \end{pmatrix}$ adalah vektor kolom yang berukuran $((n+1) \times 1)$, $x_i = \begin{pmatrix} 1 \\ x_{i1} \\ \vdots \\ x_{in} \end{pmatrix}$ adalah vektor kolom yang berukuran $((n+1) \times 1)$, *n* adalah banyaknya variabel penjelas, *m* adalah banyaknya amatan. Fungsi yang menghubungkan prediktor linier η_i dengan nilai μ_i adalah fungsi *g*, dengan *g* adalah fungsi yang monoton dan terturunkan. Pada GLM (*g*) disebut sebagai fungsi hubung. Pada penelitian ini, fungsi hubung yang digunakan adalah fungsi hubung kanonik *g*, yaitu fungsi yang memenuhi persamaan $g(\mu_i)=\theta_i$ [17].

2.7. Pengujian

Hasil pengujian penelitian ini menggunakan *software* Rapidminer. Pemilihan Rapidminer sebagai perangkat lunak analisis data karena mempunyai berbagai keunggulan kemampuan integrasi data yang luas,

kompatibilitas dengan berbagai algoritma *machine learning*, kemampuan pengolahan data yang besar, dan mempunyai fitur evaluasi model yang lengkap.

Dalam mengolah data, Teknik analisis pengolahan data menggunakan metode CRISP-DM. Model teknik analisis data dengan metodologi CRISP-DM mempunyai enam tahapan, yaitu *business understanding*, *data understanding*, *data preparation*, *modeling*, *evaluation*, dan *deployment* [23]. Berikut pada Gambar 2 adalah tahapan dengan CRISP-DM.



Gambar 2. Data Mining dalam CRIPS-DM

Berikut adalah penjelasan dari enam tahapan dalam CRIPS-DM, yaitu:

2.7.1. Pemahaman Bisnis (*Business Understanding*)

Tahap pertama ini sangat penting karena melibatkan pemahaman mendalam tentang bisnis, cara data dihasilkan atau dikumpulkan, dan bagaimana tujuan model bisa diselaraskan dengan tujuan bisnis. Aktivitas yang dilakukan termasuk mendefinisikan tujuan dan kebutuhan bisnis, menerjemahkannya ke dalam permasalahan data mining, serta menyusun strategi awal untuk memperoleh tujuan dimaksud.

2.7.2. Pemahaman Data (*Data Understanding*)

Proses ini dimulai yaitu dengan mengumpulkan data, kemudian menganalisisnya untuk memahami lebih dalam. Ini mencakup identifikasi masalah kualitas data dan menemukan hal menarik dari data yang dapat digunakan untuk mendapatkan informasi tersembunyi.

2.7.3. Persiapan Data (*Data Preparation*)

Kemudian pada langkah ini mencakup seluruh aktivitas untuk membangun dataset akhir yang akan digunakan dalam pemodelan. Data asli yang telah dibersihkan dari nilai kosong, inkonsistensi, dan noise akan digunakan. Proses ini meliputi pemilihan tabel, rekaman, dan atribut data, dan sering kali perlu diulang beberapa kali.

2.7.4. Pemodelan (*Modelling*)

Pada tahap ini, berbagai teknik pemodelan diterapkan dan disesuaikan untuk mendapatkan hasil terbaik. Ini melibatkan penyesuaian parameter untuk memaksimalkan kinerja model.

2.7.5. Evaluasi (*Evaluation*)

Pemodelan Prediksi Alokasi Pagu Belanja Modal dengan Metode *Neural Network* dan *Generalized Linear Model*. Setelah model dilatih, tahap ini bertujuan untuk mengevaluasi kualitas dan efektivitas model. Evaluasi dilakukan untuk memastikan model telah memenuhi tujuan yang telah ditetapkan.

2.7.6. Penyebaran (Deployment)

Sebagai tahap akhir, informasi yang diperoleh disebarakan dalam bentuk atau prototipe yang dapat digunakan, seperti laporan atau sistem informasi proses penambangan data secara berulang pada institusi.

3. HASIL DAN PEMBAHASAN

Pada tahap ini dilakukan proses pengolahan data berdasarkan pada tahapan CRIPS-DM yang sudah dijelaskan sebelumnya.

3.1. Pemahaman Bisnis (Business Understanding)

Analisis data realiasi belanja pegawai menggunakan algoritma *Neural Network* dan *Generalized Linear Model* bertujuan dalam memudahkan untuk prediksi/perencanaan anggaran modal tahun-tahun yang akan datang. Dengan titik fokus pada variabel seperti tahun, bulan dan nilai realisasi, tujuan utama adalah harapan untk mendapatkan nilai akurasi yang baik ketika penyusunan anggaran dilakukan.

3.2. Pemahaman Data (Data Understanding)

Data yang digunakan untuk proses data mining merupakan data kuantitatif, berupa atribut data berbentuk numerik. Adapun atribut data tersebut berisi tahun, bulan, realisasi, data ini merupakan hasil pengelompokan berdasarkan transaksi harian belanja modal yang kemudian dijumlahkan dan dikelompokan menurut tahun dan bulan. Adapun sumber data didapatkan berdasarkan hasil observasi pada Sistem Informasi yang dikelola oleh Direktorat Sistem Informasi dan Teknologi Perbendaharaan terkait belanja modal. Data penelitian berasal dari Laporan Realisasi Anggaran Audited selama periode waktu 3 tahun, bulan Januari 2021 sampai dengan Desember 2023.

3.3. Persiapan Data

3.3.1. Data Awal

Data awal ini berupa *file excel* hasil ekstrak dari *database*, dengan jumlah baris sebanyak 456 data dengan 12 atribut. Data awal tersebut seperti pada Tabel 2.

Tabel 2. Dataset Awal Pagu dan Realisasi Belanja Modal Tahun 2021-2023

No	Kode Dept	Kode Unit	Kode Satker	...	Kode Akun	Tahun	Bulan	Realisasi
1	018	01	418328	...	532111	2021	01	96.483.000
2	018	01	418328	...	532111	2021	02	96.483.000
3	018	01	418328	...	532111	2021	03	123.283.000
4	018	01	418328	...	532111	2021	04	123.283.000
5	018	01	418328	...	532111	2021	05	123.283.000
...
16.614	018	12	649458	...	533111	2023	14	179.327.000
16.615	018	12	649458	...	533121	2023	14	1.675.225.000
16.616	018	12	649458	...	534131	2023	14	126.649.000

3.3.2. Pemilihan Atribut

Setelah data awal diperoleh, proses selanjutnya adalah seleksi atribut. Tujuan seleksi atribut (*feature selection*) adalah untuk memilih subset atribut yang paling relevan atau signifikan untuk digunakan dalam model. Proses seleksi atribut terdiri dari menghapus dan menambahkan kolom *sequence* untuk keperluan pengolahan data dengan menggunakan *tools* Rapidminer. Atribut setelah seleksi terdiri dari *sequence*, tahun, bulan, dan realisasi yang kemudian dilakukan penggabungan realisasi *grouping* berdasarkan tahun dan bulan. Hasil seleksi atribut terdapat pada tabel 3.

Tabel 3. Dataset setelah seleksi atribut

Sequence	Realisasi	Bulan	Tahun
01	23.759.430.219	1	2021
02	42.230.522.995	2	2021

03	80.957.729.186	3	2021
04	114.287.672.970	4	2021
05	145.223.943.057	5	2021
06	193.807.489.831	6	2021
...
30	57.885.014.926	4	2023
31	70.351.951.047	5	2023
32	82.762.896.254	6	2023
33	105.073.226.484	7	2023
34	142.909.702.326	8	2023
35	168.533.106.474	9	2023
36	210.204.678.775	10	2023
37	272.923.592.434	11	2023
38	493.275.255.634	12	2023
39	493.275.255.634	13	2023
40	493.275.255.634	14	2023

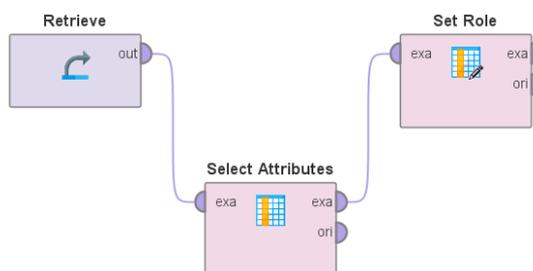
Dataset tersebut merupakan jumlah realisasi per bulan dari tahun 2021 sampai dengan tahun 2023. Periode pelaporan tahun 2021 hanya sampai periode 12, sedangkan tahun 2022 dan 2023 sampai dengan periode 14, sehingga didapatkan 40 baris data.

3.4. Pemodelan Data (*Modelling*)

3.4.1. Menentukan atribut *label* dan *role*

Tujuan menentukan atribut label adalah menentukan target prediksi dan memastikan algoritma fokus pada target, sedangkan atribut role untuk mengklasifikasikan fungsi atribut, menyediakan informasi tambahan untuk pemodelan, dan membatasi atribut yang digunakan sebagai input.

Operator *Select Attributes* dan *Set Roles* digunakan untuk menentukan atribut pada dataset. Tampilan operator tersebut seperti pada gambar 3.



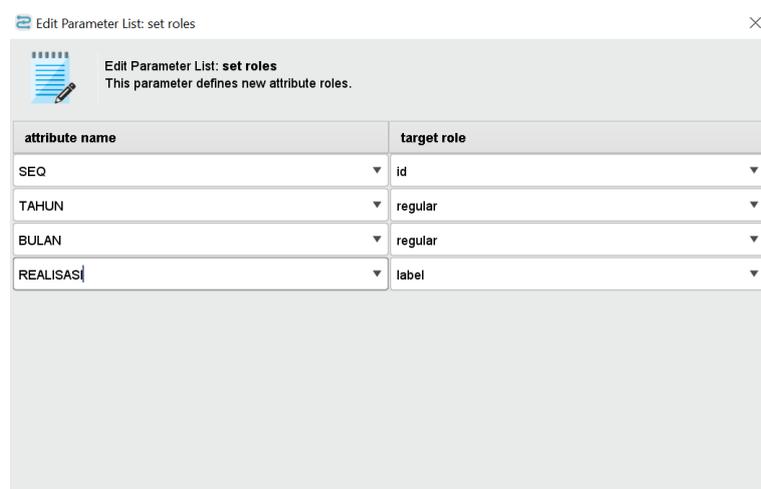
Gambar 3. Operator *Select Attributes* dan *Set Roles*

Penentuan *Set Role* dengan memilih identitas dari setiap atribut yang digunakan. Atribut *Sequence* menggunakan *role id*, sedangkan atribut bulan dan tahun menggunakan *role regular*. Atribut Realisasi sebagai atribut utama menggunakan *role label*.

Setiap *role* memiliki fungsi khusus yang membantu mengarahkan bagaimana setiap atribut digunakan dalam proses pemodelan. Fungsi dari beberapa *role* adalah sebagai berikut:

- 1) *Id*, atribut dengan *role* sebagai *ID* berfungsi sebagai pengenalan unik untuk setiap entri atau baris data, mirip dengan kunci primer dalam database.
- 2) *Regular*, atribut yang digunakan sebagai fitur atau prediktor dalam model. Atribut ini berisi variabel independen yang memiliki pengaruh terhadap target atau *label* yang ingin diprediksi.
- 3) *Label*, merupakan target prediksi model. Dalam masalah klasifikasi, *label* adalah kategori atau kelas yang ingin diprediksi, sementara dalam regresi, *label* adalah variabel numerik yang diprediksi.

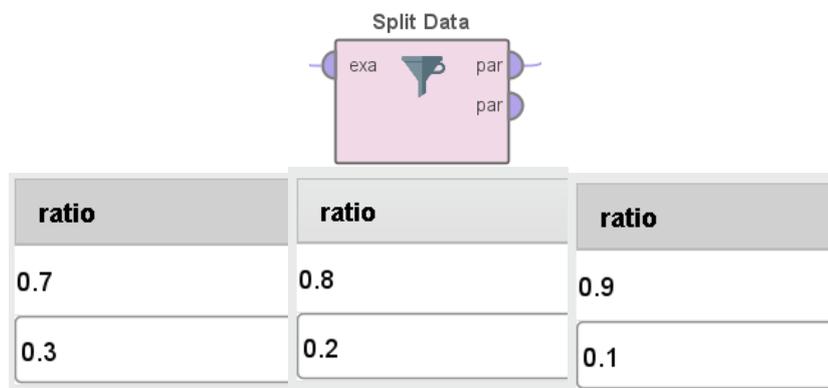
Tampilan penentuan *role* terdapat pada gambar 4.



Gambar 4. Penentuan *role* terhadap atribut

3.4.2. Menentukan Data *Training* dan Data *Testing*

Data training adalah bagian dari dataset yang digunakan untuk melatih model. Data ini terdiri dari atribut dan label yang sudah diketahui nilainya. Sedangkan Data testing adalah bagian dari dataset yang digunakan untuk mengevaluasi kinerja model setelah dilatih. Data training dan data testing ditentukan dengan melakukan Split Data dengan 3 pengujian yaitu 90:10, 80:20, dan 70:30 terhadap data testing. Penentuan data di Split Data dengan melakukan pemilihan ratio berdasarkan persentase seperti pada gambar 5.



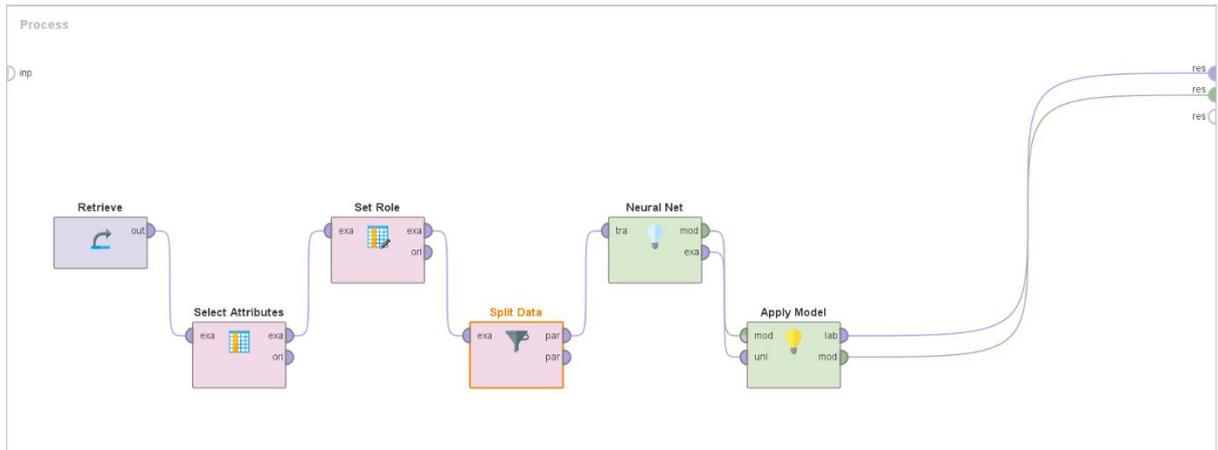
Gambar 5. Menentukan split data *training* dan *testing*

3.4.3. Implementasi Algoritma *Neural Network* dan *Generalized Linear Model*

Setelah melakukan tahapan menentukan atribut dataset, set role, dan split data training dan pengujian, berikutnya adalah melakukan implementasi menggunakan algoritma *Neural Network* dan *Generalized Linear Model*.

3.4.3.1. *Neural Network*

Pemilihan algoritma ini dengan menambahkan *function apply model* dengan memilih model *Neural Network* seperti pada gambar 6.



Gambar 6. Algoritma *Neural Network*

Setelah menjalankan model tersebut, maka hasil dari prediksi dapat dihasilkan dengan perbandingan data *training* dan *testing* sebesar 90:10, 80:20, dan 70:30.

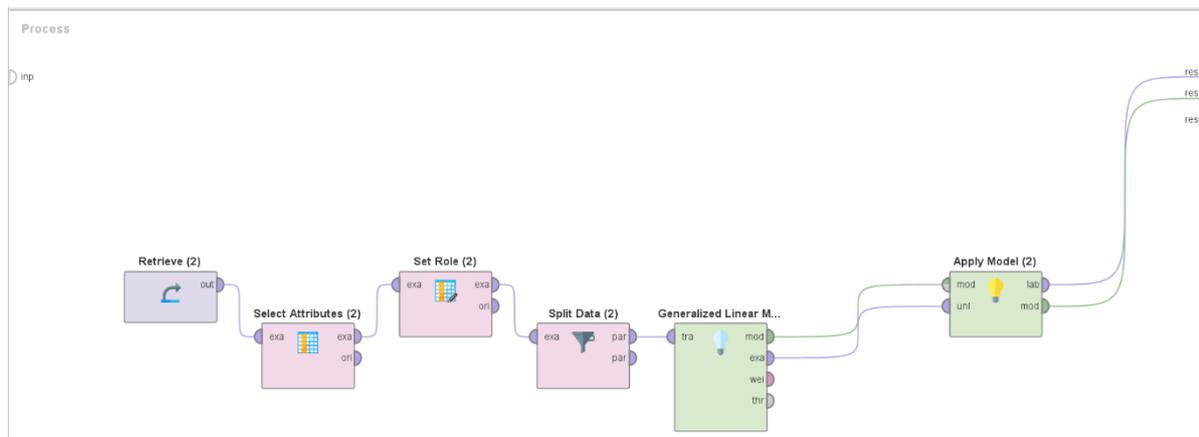
Tabel 4. Hasil Implementasi Algoritma *Neural Network*

Seq	Tahun	Bulan	Realisasi	Prediksi (90:10)	Prediksi (80:20)	Prediksi (70:30)
1	2021	01	23.759.430.219	35,629,972,748
2	2021	02	42.230.522.995	55,951,443,763	56,541,917,716	57,738,997,119
3	2021	03	80.957.729.186	82,075,523,150	83,732,264,181	82,705,412,823
4	2021	04	114.287.672.970	115,153,388,546	117,964,970,005	114,237,622,222
5	2021	05	145.223.943.057	156,285,748,649	160,259,635,032	153,224,124,364
6	2021	06	193.807.489.831	206,323,616,712	211,338,745,157	200,198,508,565
...
30	2023	04	57.885.014.926	40,815,175,995	339,631,291,133	316,920,057,803
31	2023	05	70.351.951.047	61,544,352,085
32	2023	06	82.762.896.254	87,874,755,105	493,097,747,081	453,114,623,996
33	2023	07	105.073.226.484	...	572,233,679,410	...
34	2023	08	142.909.702.326	...	648,393,851,615	...
35	2023	09	168.533.106.474	210,513,467,466	15,132,479,915	19,349,294,405
36	2023	10	210.204.678.775	...	29,468,784,868	33,187,522,639
37	2023	11	272.923.592.434	334,642,724,549	48,028,109,675	51,285,473,751
38	2023	12	493.275.255.634	408,096,303,490	71,756,138,483	74,628,388,726
39	2023	13	493.275.255.634	486,409,241,477	101,676,527,123	104,243,010,777
40	2023	14	493.275.255.634	566,428,378,597	138,808,579,760	141,068,986,956

Berdasarkan tabel 4, hasil prediksi belanja modal dengan split 90:01 bulan 01 tahun 2021 menghasilkan nilai sebesar 35,629,972,748, pada bulan 02 tahun 2021 sebesar 55,951,443,763, kemudian untuk split 80:20 bulan 02 tahun 2021 sebesar 56,541,917,716, pada bulan 03 sebesar 83,732,264,181, sedangkan untuk split 70:30 bulan 02 tahun 2021 sebesar 57,738,997,119 dan bulan 03 tahun 2021 sebesar 82,705,412,823 dan seterusnya sampai dengan bulan 14 tahun 2023. Hasil prediksi kosong pada tabel di atas merupakan data *testing*.

3.4.3.2. Generalized Linear Model

Pemilihan algoritma ini dengan menambahkan *function apply model* dengan memilih model *Generalized Linear Model* seperti pada gambar 7.



Gambar 7. Algoritma *Generalized Linear Model*

Setelah menjalankan model tersebut, maka hasil dari prediksi dapat dihasilkan dengan perbandingan data *training* dan *testing* sebesar 90:10, 80:20, dan 70:30.

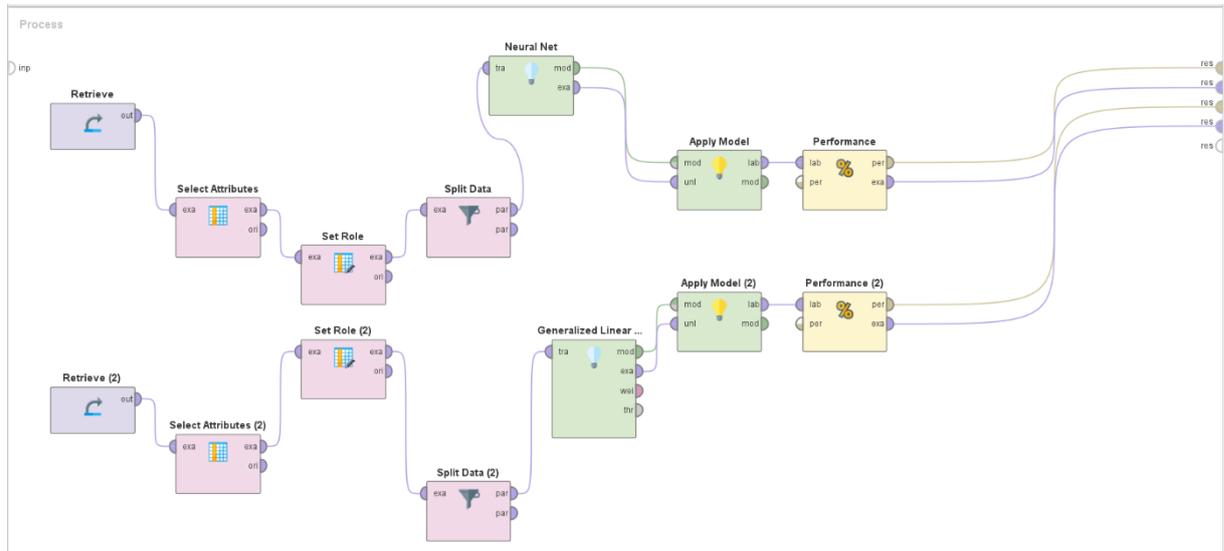
Tabel 5. Hasil Implementasi Algoritma *Generalized Linear Model*

Seq	Tahun	Bulan	Realisasi	Prediksi (90:10)	Prediksi (80:20)	Prediksi (70:30)
1	2021	01	23.759.430.219	245,808,376,589
2	2021	02	42.230.522.995	245,808,376,591	257,235,263,028	236,022,210,717
3	2021	03	80.957.729.186	245,808,376,593	257,235,263,030	236,022,210,720
4	2021	04	114.287.672.970	245,808,376,596	257,235,263,032	236,022,210,722
5	2021	05	145.223.943.057	245,808,376,598	257,235,263,035	236,022,210,724
6	2021	06	193.807.489.831	245,808,376,600	257,235,263,037	236,022,210,726
...	245,808,376,602
30	2023	04	57.885.014.926	245,808,376,605	257,235,263,041	236,022,210,731
31	2023	05	70.351.951.047	245,808,376,607
32	2023	06	82.762.896.254	245,808,376,609	257,235,263,046	236,022,210,735
33	2023	07	105.073.226.484	245,808,376,611	257,235,263,048	...
34	2023	08	142.909.702.326	245,808,376,613	257,235,263,050	...
35	2023	09	168.533.106.474	245,808,376,588	257,235,263,025	236,022,210,715
36	2023	10	210.204.678.775	245,808,376,591	257,235,263,027	236,022,210,717
37	2023	11	272.923.592.434	245,808,376,593	257,235,263,029	236,022,210,720
38	2023	12	493.275.255.634	245,808,376,595	257,235,263,032	236,022,210,722
39	2023	13	493.275.255.634	245,808,376,597	257,235,263,034	236,022,210,724
40	2023	14	493.275.255.634	245,808,376,599	257,235,263,036	236,022,210,726

Berdasarkan tabel 4, hasil prediksi belanja modal dengan split 90:01 bulan 01 tahun 2021 menghasilkan nilai sebesar 245,808,376,589, pada bulan 02 tahun 2021 sebesar 245,808,376,591, kemudian untuk split 80:20 bulan 02 tahun 2021 sebesar 257,235,263,028, pada bulan 03 sebesar 257,235,263,030, sedangkan untuk split 70:30 bulan 02 tahun 2021 sebesar 236,022,210,717 dan bulan 03 tahun 2021 sebesar 236,022,210,720 dan seterusnya sampai dengan bulan 14 tahun 2023. Hasil prediksi kosong pada tabel di atas merupakan data *testing*.

3.5. Evaluasi (*Evaluation*)

Jika tahap pemodelan selesai dilakukan, maka berikutnya adalah melakukan evaluasi terhadap kinerja model. Proses evaluasi ini dengan data uji yang telah ditentukan sebesar 10%, 20% dan 30% dari seluruh data. Pengujian dilakukan dengan operator *performance*, sebagaimana terlihat pada Gambar 8.



Gambar 8. Pengujian dengan menggunakan *Performance*

Pada tahap menggunakan algoritma *Neural Network* dan *Generalized Linear Model* Linear pengujian terhadap *Parameter feature selection* dan *Perfomance* untuk mendapatkan indikator statistik yang dipakai adalah nilai *Root Mean Squared Error* (RMSE). RMSE adalah ukuran seberapa besar kesalahan antara nilai prediksi dan nilai sebenarnya. Semakin kecil nilai RMSE, semakin tinggi akurasi model dalam memprediksi data. Nilai RMSE pada penelitian ini dapat dilihat pada tabel 6.

Tabel 6. Hasil percobaan dengan parameter *performance*

Jenis Algoritma	Data (90:10)	Data (80:20)	Data (70:30)
Algoritma <i>Neural Network</i>	47.627.183.477,290	49.167.088.101,340	33.270.553.845,293
RMSE	+/- 0.000	+/- 0.000	+/- 0.000
Algoritma <i>Generalized Linear Model</i>	211.888.285.568,081	222.669.954.080,210	223.385.799.402,206
RMSE	+/- 0.000	+/- 0.000	+/- 0.000

Hasil dari percobaan pada tabel 6, di atas menunjukkan bahwa atribut yang dapat memengaruhi nilai RMSE adalah bulan dan tahun terhadap nilai prediksi realisasi sebagai acuan alokasi pagu belanja modal. Berdasarkan jumlah komposisi data *training* dan *testing* pada table 6 tersebut, didapatkan hasil pemodelan algoritma *Neural Network* memberikan nilai *Root Mean Squared Error* (RMSE) dengan perbandingan data *training* dan *testing* 90:10, yakni sebesar 47.627.183.477,290, data *training* dan *testing* 80:20 sebesar 49.167.088.101,340 dan terakhir data *training* dan *testing* 70:30 adalah sebesar 33.270.553.845,293. Sedangkan untuk algoritma *Generalized Linear Model* memberikan nilai *Root Mean Squared Error* (RMSE) dengan perbandingan data *training* dan *testing* 90:10, yakni sebesar 211.888.285.568,081, data *training* dan *testing* 80:20 sebesar 222.669.954.080,210 dan terkahir data *training* dan *testing* 80:20 adalah sebesar 223.385.799.402,206.

3.6. Penyebaran (*Deployment*)

Jika sudah menyelesaikan tahap evaluasi, akhir dalam penelitian ini adalah melaksanakan *deployment* terhadap model yang telah dibangun. Langkah penerapan ini dapat diwujudkan dalam bentuk penyusunan laporan komprehensif yang merinci hasil-hasil penelitian, dengan mengikuti panduan metode *Cross-Industry Standard Process for Data Mining* (CRISP-DM). Laporan ini memuat nilai *Root Mean Squared Error* (RMSE) terbaik, mengidentifikasi atribut yang memiliki pengaruh signifikan terhadap nilai RMSE, serta menganalisis peran *parameter feature selection* dalam mempengaruhi nilai RMSE. Berikut adalah hasil dari percobaan yang disajikan dalam tabel dengan label yang telah ditentukan, yaitu realisasi, seperti pada tabel 7 dan tabel 8.

Tabel 7. Hasil Percobaan atribut Algoritma *Neural Network*

Atribut	Atribut	Label	RMSE Data (90:10)	Data (80:20)	Data (70:30)
Tahun	Bulan	Realisasi	47.627.183.477,290	49.167.088.101,340	33.270.553.845,293
			+/- 0.000	+/- 0.000	+/- 0.000

Tabel 8. Hasil Percobaan atribut Algoritma *Generalized Linear Model*

Atribut	Atribut	Label	RMSE Data (90:10)	Data (80:20)	Data (70:30)
Tahun	Bulan	Realisasi	211.888.285.568,081 +/- 0.000	222.669.954.080,210 +/- 0.000	223.385.799.402,206 +/- 0.000

Berdasarkan hasil penelitian ini, model *Neural Network* dan *Generalized Linear Model* memberikan hasil yang signifikan dalam memprediksi alokasi pagu belanja modal. Penggunaan kedua algoritma ini berhasil menangkap pola dalam data historis yang berkaitan dengan alokasi, revisi, dan realisasi belanja pegawai. Secara umum, model *Neural Network* menunjukkan kinerja yang lebih baik dalam situasi di mana pola hubungan antar variabel cenderung non-linear, sementara *Generalized Linear Model* lebih efektif pada data dengan pola hubungan yang linier dan lebih sederhana. Selain itu, model *Neural Network* lebih unggul dalam menangkap pola non-linear yang kompleks dibandingkan *Generalized Linear Model* karena kemampuannya memodelkan hubungan non-linear secara otomatis melalui *hidden layers* dan *activation functions*, fleksibilitas arsitektur yang dapat disesuaikan untuk data kompleks, dan kemampuan mengekstrak fitur dan interaksi variabel tanpa perlu eksplisit ditentukan.

Penelitian sebelumnya oleh Rudi Hartono menggunakan metode *Neural Network* dan *Linear Regression* dengan objek penelitian adalah belanja pegawai memperoleh hasil yang linear dengan penelitian ini [12]. Nilai RMSE sebesar 1.574.970.259,712 untuk *Neural Network* dan sebesar 1.612.945.104,455 untuk *Linear Regression* menunjukkan bahwa metode prediksi menggunakan *neural network* dan *linear regression* dapat memberikan hasil yang lebih terukur dibandingkan dengan metode kualitatif deskriptif yang telah digunakan dalam penelitian sebelum-sebelumnya. Penelitian ini memberikan solusi yang dapat digunakan sebagai alternatif untuk melakukan prediksi yang lebih akurat dalam pengelolaan alokasi anggaran belanja pegawai, khususnya di lingkungan Kementerian Pertanian Republik Indonesia.

4. KESIMPULAN

Berdasarkan hasil akhir penelitian dan pengujian terhadap dataset yang ada, penulis dapat menyimpulkan bahwa dari dua perbandingan algoritma *Neural Network* dan *Generalized Linear Model*, algoritma *Neural Network* menunjukkan hasil yang lebih baik dalam hal nilai *Root Mean Squared Error* (RMSE), sebagaimana terlihat pada tabel 6. Kinerja terbaik yang dihasilkan oleh *Neural Network* menunjukkan bahwa algoritma ini lebih mampu menangkap pola non-linear yang kompleks dalam data anggaran belanja modal, sehingga menghasilkan prediksi yang lebih akurat dibandingkan dengan *Generalized Linear Model* yang lebih efektif pada pola hubungan linear. Dengan demikian, penelitian ini memberikan solusi yang dapat digunakan sebagai alternatif untuk melakukan prediksi yang lebih akurat dalam pengelolaan alokasi anggaran belanja pegawai, khususnya di lingkungan Kementerian Pertanian Republik. Model prediksi ini juga relevan dan dapat diadaptasi oleh Kementerian atau Lembaga Negara lainnya pada masa yang akan datang, untuk mengurangi risiko revisi anggaran di akhir periode dan menghindari kondisi di mana realisasi anggaran melebihi 100%. Penelitian ini memberikan panduan praktis bagi pembuat kebijakan dalam merancang anggaran berbasis data prediktif. Rekomendasi untuk penelitian selanjutnya adalah dapat menggunakan kombinasi algoritma yang dapat berupa penelitian di masa mendatang dapat mempertimbangkan kombinasi metode yang berbeda (*ensemble methods*) untuk meningkatkan akurasi model prediksi, misalnya menggabungkan algoritma *Neural Network* dengan teknik lain seperti *Deep Learning* atau *Random Forest*.

DAFTAR PUSTAKA

- [1] A. P. Pambudy and M. I. Syairozi, "Analisis Peran Belanja Modal Dan Investasi Swasta Terhadap Pertumbuhan Ekonomi Serta Dampaknya Pada Kesejahteraan Masyarakat," *EKOBIS*, vol. 20, pp. 26–39, Jan. 2019.
- [2] Kementerian Pertanian RI, "Laporan Realisasi Anggaran (Face) Kementerian Pertanian Tahun 2021 Audited," 2021.
- [3] Kementerian Pertanian RI, "Laporan Realisasi Anggaran (Face) Kementerian Pertanian Tahun 2022 Audited," 2022.
- [4] Kementerian Pertanian RI, "Laporan Realisasi Anggaran (Face) Kementerian Pertanian Tahun 2023 Audited," 2023.
- [5] A.S Pratiwi and S. Nawatmi, "Analisis Pagu Minus Belanja Pegawai Pada Pengadilan Negeri Semarang

- Kelas IA Khusus,” *Jurnal Ekonomi Manajemen Sistem Informasi (JEMSI)*, vol. 5(5), no. <https://doi.org/10.31933/jemsi.v5i5>, 2024.
- [6] E. P. A. Akhmad, “Data Mining Menggunakan Regresi Linear untuk Prediksi Harga Saham Perusahaan Pelayaran. *Jurnal Aplikasi Pelayaran Dan Kepelabuhanan*,” <https://doi.org/10.30649/japk.v10i2.83>, vol. 10(2), 2020.
- [7] W. Y. A. Kurniawan Fahrudin, “Penerapan Algoritma Regresi Linear Pada Data Harga Cabai Rawit Di Pasar Indihiang,” *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 8(2), no. <https://doi.org/10.36040/jati.v8i2.9053>, pp. 1614–1620, 2024.
- [8] H. Hamzah, “Analisis Anggaran dan Realisasi Belanja Modal pada Kominfo Balai Besar Pengkajian dan Pengembangan Komunikasi dan Informatika Makassar,” <https://repository.unifa.ac.id/id/eprint/371/>, 2017.
- [9] Iskandar, S. Xu, and G. O’Donovan, “Revolusi Industri 4.0 Dalam Pengelolaan Kas Negara: Pemodelan Prakiraan Kas Negara Menggunakan Jaringan Saraf Tiruan,” 2018.
- [10] N. Purwati, R. Nurlistiani, and O. Devinsen, “Data Mining Dengan Algoritma Neural Network Dan Visualisasi Data Untuk Prediksi Kelulusan Mahasiswa,” *Jurnal Informatika*, vol. 20, no. 2, pp. 156–163, Dec. 2020, doi: 10.30873/ji.v20i2.2273.
- [11] R. H. Kusumodestoni, “Prediksi Forex Menggunakan Model Neural Network,” *Jurnal SIMETRIS*, vol. 6, 2015.
- [12] R. Hartono, H. A. Saputra, G. Triyono, A. Info, K. Kunci, and B. Pegawai, “Pemodelan Prediksi Alokasi Pagu Belanja Pegawai dengan Metode Neural Network dan Linear Regression,” vol. 4, pp. 865–880, 2024, doi: 10.51454/decode.v4i3.708.
- [13] B. Kabra and C. Nagar, “SCIENCE& TECHNOLOGY Convolutional Neural Network based sentiment analysis with TF-IDF based vectorization.” [Online]. Available: <http://pubs.thesciencein.org/jist>
- [14] M. Yang and Y. Liu, “Research on the potential for China to achieve carbon neutrality: A hybrid prediction model integrated with elman neural network and sparrow search algorithm,” *J Environ Manage*, vol. 329, Mar. 2023, doi: 10.1016/j.jenvman.2022.117081.
- [15] I. Jayusman, O. Agus, and K. Shavab, “Studi Deskriptif Kuantitatif Tentang Aktivitas Belajar Mahasiswa Dengan Menggunakan Media Pembelajaran Edmodo Dalam Pembelajaran Sejarah,” 2020. [Online]. Available: <https://jurnal.unigal.ac.id/index.php/artefak>
- [16] W. J. Tarigan, “Metode Penelitian Kualitatif,” 2024. [Online]. Available: <https://www.researchgate.net/publication/380937054>
- [17] H. Putra and N. U. Walmi, “Penerapan Prediksi Produksi Padi Menggunakan Artificial Neural Network Algoritma Backpropagation,” <https://doi.org/10.25077/TEKNOSI.v6i2.2020.100-107>, vol. 6, Aug. 2020.
- [18] N. Nurlistiani, R. Nurlistiani, and O. Devinsen, “Data Mining Dengan Algoritma Neural Network Dan Visualisasi Data Untuk Prediksi Kelulusan Mahasiswa,” *Jurnal Informatika*, vol. 20(2), pp. 156–163, 2020.
- [19] A.H. Wijaya, “Artificial Neural Network Untuk Memprediksi Beban Listrik dengan Menggunakan metode Backpropagation (Studi Kasus PT. PLN Regional Sumatera Barat),” *Jurnal CoreIT*, vol. 5(2), pp. 61–70, 2019.
- [20] N. Pratiwi and M. J. Paput, “Pemodelan Jumlah Penduduk Miskin di Jawa Timur dengan Generalized Linier Model,” *INSOLOGI: Jurnal Sains dan Teknologi*, vol. 1, pp. 491–497, 2022.
- [21] T. A. J. Putra, “Penghitungan Premi Asuransi Kendaraan Bermotor Menggunakan Generalized Linear Models dengan Distribusi Tweedie,” *Jambura Journal of Mathematics*, vol. 3, pp. 115–127, 2021.
- [22] Y. Wilandari and S. H. Kartiko, “Estimasi Cadangan Klaim Menggunakan Generalized Linear Model (GLM) Dan Copula,” *JURNAL GAUSSIAN*, vol. 9, pp. 411–420, 2020.
- [23] R. G. R. Mumu, N. Nurchim, and S. Sumarlinda, “Forecasting Central Bank Digital Currency Terhadap Rupiah Digital,” *IDEALIS: InDonEsiA journal Information System*, vol. 6(2), no. <https://doi.org/10.36080/idealis.v6i2.3027>, pp. 65–74, 2023.