

# Pemodelan Prediksi Alokasi Pagu Belanja Pegawai dengan Metode *Neural Network* dan *Linear Regression*

Rudi Hartono<sup>1\*</sup>, Hendra Adi Saputra<sup>1</sup>, Gandung Triyono<sup>1</sup>

<sup>1</sup>Program Studi Magister Ilmu Komputer, Universitas Budi Luhur, Indonesia.

---

## Artikel Info

### Kata Kunci:

Belanja Pegawai;  
Linear Regression;  
Neural Network;  
Pemodelan;  
Prediksi.

### Keywords:

*Employee Spending;*  
*Linear Regression;*  
*Neural Network;*  
*Modelling;*  
*Prediction.*

---

### Riwayat Artikel:

Submitted: 4 Agustus 2024  
Accepted: 14 Oktober 2024  
Published: 22 Oktober 2024

**Abstrak:** Belanja Pegawai merupakan belanja rutin yang diterima Aparatur Sipil Negara (ASN) yang merupakan hak pegawai sebagai wujud penghargaan atau kompensasi atas tugas yang telah dilaksanakan untuk mendukung fungsi dan tugas unit organisasi pemerintah. Penelitian ini bertujuan untuk memprediksi alokasi pagu belanja pegawai tersebut dengan mengimplementasikan dan membandingkan kinerja algoritma *Neural Network* dan *Linear Regression*. Penelitian ini menggunakan rasio data pelatihan dan pengujian 90:10, 80:20 dan 70:30 dengan hasil pengujian menggunakan algoritma *neural network* mendapatkan nilai RMSE sebesar 1.528.548.203,391, 1.574.970.259,712, dan 1.502.955.371,784, sedangkan *Linear Regression* mendapatkan nilai RMSE sebesar 1.525.213.978,925, 1.612.945.104,455, dan 1.540.826.342,006. Berdasarkan hasil perbandingan pada rasio ideal data uji dan latih 80:20, dapat disimpulkan bahwa algoritma *Neural Network* dengan nilai RMSE 1.574.970.259,712 menunjukkan nilai kinerja yang lebih baik dari pada *Linear Regression* dengan nilai RMSE 1.612.945.104,455, diharapkan hasil tersebut dapat digunakan untuk membantu prediksi penyediaan alokasi pagu belanja pegawai dimasa yang akan datang.

**Abstract:** *Employee Expenditures are routine expenditures received by the State Civil Apparatus (ASN) which are employees' rights as a form of appreciation or compensation for tasks that have been carried out to support the functions and duties of government organizational units. This research aims to predict the allocation of employee spending ceilings by implementing and comparing the performance of Neural Network and Linear Regression algorithms. This research uses training and testing data ratios of 90:10, 80:20 and 70:30 with test results using a neural network algorithm getting RMSE values of 1,528,548,203.391, 1,574,970,259.712, and 1,502,955,371.784, while Linear Regression gets RMSE values of 1,525,213,978.925, 1,612,945,104.455, and 1,540,826,342.006. Based on the comparison results on the ideal ratio of test and training data of 80:20, it can be concluded that the Neural Network algorithm with an RMSE value of 1,574,970,259.712 shows a better performance value than Linear Regression with an RMSE value of 1,612,945,104.455, it is hoped that it can be used for help predict the provision of employee spending ceiling allocations in the future.*

---

### Corresponding Author:

Rudi Hartono  
Email: [2211601998@student.budiluhur.ac.id](mailto:2211601998@student.budiluhur.ac.id)

---

## PENDAHULUAN

Kementerian Agama Republik Indonesia merupakan salah satu lembaga pemerintah pusat yang berada di bawah kendali langsung Presiden Republik Indonesia, berdasarkan perintah Keputusan Presiden Nomor 12 Tahun 2023. Kementerian Agama Republik Indonesia bertugas menangani urusan pemerintahan di bidang keagamaan di seluruh wilayah Indonesia dari Sabang sampai Merauke. Dengan cakupan urusan daerah yang begitu luas, maka diperlukan pengelolaan sumber daya manusia yang handal, terutama untuk melindungi hak-hak pegawai yang bekerja di unit vertikal, baik di pusat maupun daerah. Oleh karena itu, pengelolaan anggaran belanja pegawai, termasuk alokasi batas atas belanja pegawai, merupakan persoalan administratif yang penting. Perkiraan alokasi anggaran yang akurat sangat penting untuk memastikan tersedianya dana yang cukup untuk memenuhi kebutuhan operasional dan pengembangan karyawan. Di lingkungan Kementerian Agama Republik Indonesia (Sekretaris Jenderal Kementerian Agama Republik Indonesia), perkiraan dan prakiraan yang akurat mengenai alokasi batasan belanja kepada pegawai dapat meningkatkan efisiensi dan efektivitas pengelolaan anggaran.

Berdasarkan Laporan Keuangan (LKK) Kementerian Agama RI Tahun 2018 sampai dengan 2020, didapatkan pagu awal belanja pegawai (biasanya bulan Januari) yang kemudian dilakukan revisi perubahan pagu diakhir periode, hal ini menandakan ada perencanaan alokasi pagu awal belanja pegawai yang kurang akurat. Perubahan/revisi alokasi pagu dan realisasinya seperti pada tabel 1 (Kementerian Agama RI, 2018) (Kementerian Agama RI, 2019) (Kementerian Agama RI, 2020).

Tabel 1. Alokasi Pagu dan Realisasi Belanja Pegawai Tahun 2018 – 2020.

Tahun	Pagu Awal	Pagu Revisi	Realisasi Belanja	%Realisasi/ Awal	%Realisasi/ Revisi
2018	37.898.487.715.000	37.955.143.615.000	35.784.419.494.584	94,42	94,28
2019	36.096.212.351.000	38.483.409764.000	38.209.387.897.940	105,85	99,29
2020	38.614.505.567.000	39.178.058.994.000	39.227.039.908.222	101,59	100,13

Berdasarkan data alokasi pagu awal, revisi, realisasi dan prosentase pada tabel 1 khususnya pada prosentase %Realisasi/Awal, diperlukan peramalan/prediksi penyediaan alokasi pagu belanja pegawai yang akurat, sehingga revisi alokasi pagu belanja pegawai pada akhir periode anggaran tidak perlu dilakukan dan realisasi anggaran tidak minus/melebihi 100%. Untuk mencapai hasil prediksi yang akurat ini, penggunaan algoritma *neural network* dan *linear regression* dapat dipertimbangkan. 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, *linear regression* dipilih karena kesederhanaannya dan kemampuannya memberikan interpretasi yang mudah terhadap hubungan linear antar variabel. Dalam kasus di mana hubungan antar variabel lebih sederhana dan dapat dijelaskan secara linear, *linear regression* dapat menghasilkan prediksi yang cepat dan efektif. 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.

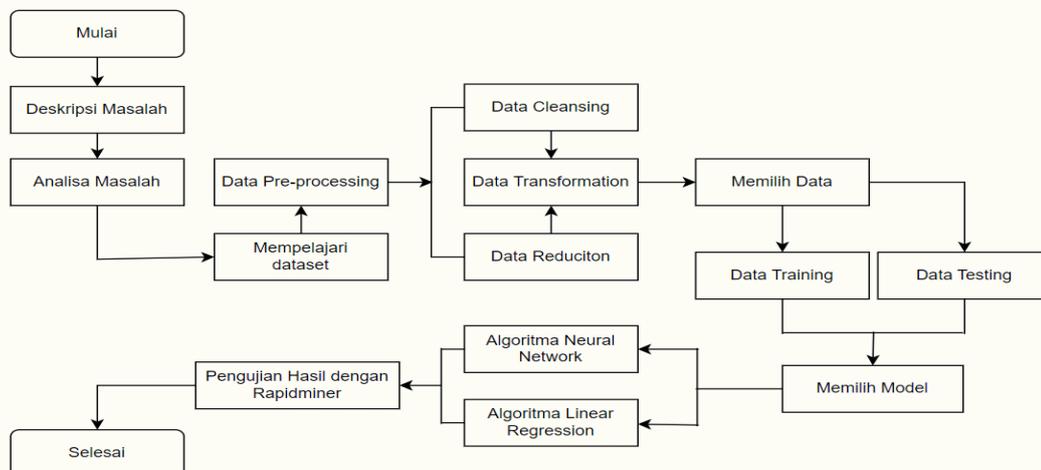
Beberapa penelitian sebelumnya dengan data serupa diantaranya adalah penelitian “Analisis Pagu Minus Belanja Pegawai Pada Pengadilan Negeri Semarang Kelas IA Khusus” dengan metode deskriptif kualitatif oleh (Pratiwi dkk., 2024) berupa data belanja pegawai dengan hasil berdampak pada IKPA. Berikutnya “Analisis Realisasi Anggaran Belanja Pegawai Pada Satker Lingkup Kantor Kementerian Agama Kabupaten Bima dan Kota Bima” dengan metode pendekatan kualitatif terhadap belanja pegawai dengan hasil penelitian Periode 2019-2021 selalu minus (Syahrudin, 2022). Penelitian lain dengan judul “Politik Fiskal Serapan Anggaran Belanja Pegawai Dan Belanja Barang” dengan metode deskriptif kualitatif oleh (Karbilai, 2023) berupa data belanja pegawai dengan hasil Periode 2020-2021 melebihi 100%. Sederangkan penelitian lain yang menggunakan algoritma sama berupa “Jaringan Syaraf Tiruan untuk Memprediksi Beban Listrik Menggunakan Metode Backpropagation (Studi Kasus

PT. PLN Wilayah Sumatera Barat)” yang sedang dibahas. Hasil penelitian menunjukkan nilai MSE = 0,00095761 dan nilai akurasi 96,48% (Hadi Wijaya, 2019). Selain itu, penelitian “Metode Jaringan Syaraf Tiruan untuk Menentukan Akurasi Peramalan Harga Rumah” dari Hasil Penelitian menemukan nilai MAE = 0,28 dan nilai akurasi 74% (Ridho et al., 2022). Kemudian penelitian “Data Mining Menggunakan Algoritma Neural Network dan Visualisasi Data untuk Memprediksi Kelulusan Siswa” menghasilkan nilai akurasi sebesar 92,83% (Purwati et al., 2020). Pada penelitian lebih lanjut dengan menggunakan algoritma jaringan syaraf tiruan “Exchange Forecasting Menggunakan Neural Network Models”, hasil penelitian menunjukkan nilai prediksi sebesar 0,431 +/- 0,096 (Kusumodestoni & Suyatno, 2015). Penelitian selanjutnya dengan menggunakan algoritma regresi linier adalah “Data mining prediksi harga saham perusahaan pelayaran menggunakan regresi linier” (Akhmad, 2020) berdasarkan hasil penelitian diperoleh nilai RMSE sebesar 7,522. Dan yang lain penelitian “Penerapan Algoritma Regresi Linier pada Data Harga Cabai Rawit di Pasar India” memperoleh nilai RMSE = 14975.095 dari hasil penelitian (Fahrudin et al., 2024).

Penelitian ini bertujuan untuk mengimplementasikan dan membandingkan dua algoritma, yaitu *neural network* dan *linear regression*, untuk memprediksi alokasi batas belanja pegawai di lingkungan Sekjen Kementerian Agama RI. 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 keputusan 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), penelitian ini mengidentifikasi kekuatan dan kelemahan masing-masing algoritma dari perspektif peramalan anggaran. Hasil penelitian ini diharapkan dapat membantu pejabat pemerintah, khususnya Sekretaris Jenderal Kementerian Agama RI, untuk meningkatkan akurasi perkiraan anggarannya.

**METODE**

Metode yang digunakan dalam penelitian ini adalah metode kualitatif dengan pendekatan deskriptif (Septyani Juanda et al., 2024). 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 (Jayusman et al., 2020). 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 *Linear Regression*

Tahapan penelitian pada Gambar 1 dapat dijelaskan sebagai berikut:

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 (Pirman et al., 2024). Penetapan batasan suatu masalah secara tepat memungkinkan peneliti untuk fokus pada aspek-aspek yang relevan dan menghindari penyimpangan dari tujuan utama penelitian.
2. **Analisa Masalah**

Dengan meninjau hasil laporan realisasi anggaran di Sekretariat Jenderal Kementerian Agama RI, ditemukan bahwa persentase realisasi belanja pegawai 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.
3. **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). Memperoleh data aktual belanja pegawai multi tahun fiskal selama tiga tahun dari 2018 hingga 2020 untuk tujuan memprediksi alokasi belanja pegawai. Data ini terdiri dari 12 atribut.
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:

  - a. **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.
  - b. **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.
  - c. **Data Reduction**

Tahap ini mengurangi jumlah data yang harus dianalisis sambil mempertahankan informasi penting. Teknik-teknik dalam *data reduction* meliputi PCA (*Principal Component Analysis*) yaitu mengurangi dimensi data dengan mengidentifikasi dan memproyeksikan data ke arah komponen utama yang menjelaskan variabilitas terbesar, Feature Selection yaitu memilih fitur yang paling relevan untuk analisis dengan menggunakan metode statistik atau algoritma *machine learning*, Sampling yaitu mengambil subset data yang representatif dari populasi data asli untuk mengurangi volume data yang perlu diproses dan Aggregation yaitu menggabungkan data pada level yang lebih tinggi untuk mengurangi granularitas.

5. Memilih Data

a. 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.

b. 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.

6. Memilih Model

a. Algoritma *Neural Network*

Algoritma jaringan syaraf tiruan (jaringan syaraf tiruan) merupakan teknik komputasi yang terinspirasi dari cara otak manusia memproses informasi (H. Putra & Ulfa Walmi, 2020). 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.

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) Perhitungan pada *Neural Network*

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

**Nilai Net Input**

$$Z_j = \sum_{i=1}^n w_{ij}x_i + b_j$$

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.

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):

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

Dimana:

$y_i$  adalah nilai target sebenarnya.

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

$m$  adalah jumlah contoh data.

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:

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

Dimana:

$\eta$  adalah learning rate.

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

5) Iterasi dan Konvergensi

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

b. Algoritma *Linear Regression*

Regresi linier adalah model prediktif yang umum digunakan dalam penambangan data. Analisis regresi digunakan untuk menguji pengaruh antara variabel bebas (independen) dan variabel terikat (Wulansari & Novandi, 2023). Jenis regresi linier dibedakan menjadi dua jenis yaitu model regresi linier sederhana dan model regresi linier berganda, seperti yang dijelaskan di bawah ini:

1) Model Regresi Linear Sederhana

Regresi linear sederhana adalah metode statistik yang digunakan untuk memahami dan memodelkan hubungan antara dua variabel: satu variabel independen (prediktor) dan satu variabel dependen (respon). Tujuannya untuk menemukan persamaan garis lurus yang paling baik menggambarkan hubungan antara kedua variabel tersebut.

a) Persamaan

$$y = \beta_0 + \beta_1 x + \epsilon$$

Dimana:

$y$  = Variabel dependen (respon)

$x$  = Variabel independen (prediktor)

$\beta_0$  = Intercept, yaitu nilai  $y$  ketika  $x=0$

$\beta_1$  = slope atau kemiringan garis regresi, menunjukkan nilai perubahan  $y$  untuk setiap perubahan pada  $x$ .

$\epsilon$  = error atau residu, yaitu selisih nilai yang diamati kemudian nilai yang diprediksi oleh model.

*Intercept* adalah titik di mana garis regresi memotong sumbu y. Ini merupakan nilai prediksi y ketika x bernilai nol.

*Slope* adalah kemiringan garis regresi dan menunjukkan hubungan antara variabel bebas dan tidak bebas. Slope positif menunjukkan bahwa peningkatan x berhubungan dengan peningkatan y, sedangkan slope negatif menunjukkan bahwa peningkatan x berhubungan dengan penurunan y.

b) Proses Estimasi

Metode *Ordinary Least Squares* (OLS) digunakan untuk mengestimasi parameter  $\beta_0$  dan  $\beta_1$  dengan cara meminimalkan jumlah kuadrat dari residual (selisih nilai yang diamati dan diprediksi oleh model).

Persamaan untuk mencari koefisien regresi  $\beta_1$  yaitu :

$$\beta_1 = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sum(x_i - \bar{x})^2}$$

Dan untuk  $\beta_0$  yaitu:

$$\beta_0 = \bar{y} - \beta_1\bar{x}$$

Dimana:

$x_1$  dan  $y_1$  = nilai rata-rata

$\bar{x}$  dan  $\bar{y}$  = nilai rata-rata dari x dan y

c) Evaluasi Model

Koefisien Determinasi ( $R^2$ ) mengukur proporsi variabilitas dalam data tidak bebas dijelaskan oleh model regresi. Nilai  $R^2$  berkisar antara 0 dan 1. Semakin mendekati 1, semakin baik model dalam menjelaskan variabilitas data.

2) Model Regresi Linear Berganda

Model regresi linier berganda adalah teknik statistik untuk memodelkan hubungan antara variabel terikat (respon) dan dua atau lebih variabel bebas (prediktor). Model ini memperluas konsep regresi linier sederhana dengan mempertimbangkan beberapa prediktor untuk menjelaskan variabilitas variabel terikat.

a. Persamaan

$$y = \beta_0 + \beta_1x_1 + \beta_2x_2 + \dots + \beta_nx_n + \epsilon$$

Dimana:

y = Variabel dependen (respon)

$x_1, x_2, \dots, x_n$  = Variabel independen (prediktor)

$\beta_0$  = Intercept, yaitu nilai y ketika  $x_1=0$

$\beta_1, \beta_2, \dots, \beta_n$  = koefisien regresi yang menunjukkan perubahan pada y untuk setiap perubahan pada  $x_i$ , dengan asumsi variabel lain tetap konstan.

$\epsilon$  = error atau residu, yaitu selisih nilai yang diamati dan diprediksi oleh model.

*Intercept* adalah titik di mana garis regresi memotong sumbu y. Ini merupakan nilai prediksi y ketika x bernilai nol.

*Slope* adalah kemiringan garis regresi dan menunjukkan hubungan antara variabel independen dan dependen. Slope positif menunjukkan bahwa peningkatan x berhubungan dengan peningkatan y, sedangkan slope negatif menunjukkan bahwa peningkatan x berhubungan dengan penurunan y.

b. Proses Estimasi

Metode *Ordinary Least Squares* (OLS) digunakan untuk mengestimasi parameter  $\beta_1, \beta_2, \dots, \beta_n$  dengan meminimalkan jumlah kuadrat dari residual (selisih antara nilai yang diamati dan nilai yang diprediksi oleh model).

Persamaan untuk mencari koefisien regresi  $\beta_1$  yaitu:

$$\hat{\beta} = (X^T X)^{-1} X^T y$$

Dimana:

$X$  = Matriks data variabel independen.

$y$  = Vektor data variabel dependen.

$\hat{\beta}$  = Vektor koefisien regresi yang diestimasi.

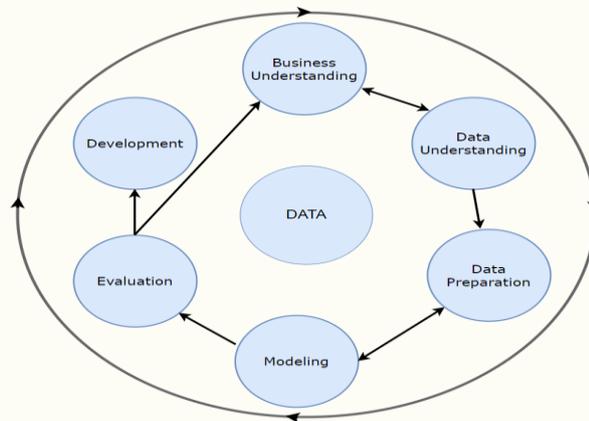
c. Evaluasi Model

Koefisien Determinasi ( $\mathcal{R}^2$ ) pengukuran ini sama halnya seperti yang dilakukan pada model Linear Regression.

7. Pengujian

Hasil pengujian penelitian ini menggunakan software Rapidminer dengan teknik analisis pengolahan data menggunakan metode CRISP-DM.

Dalam mengolah data, model teknik analisis data dengan metodologi CRISP-DM dengan enam tahapan, yaitu *business understanding*, *data understanding*, *data preparation*, *modeling*, *evaluation*, dan *deployment* (Mumu et al., 2023). Berikut pada Gambar 2 adalah tapan dnegan CRISP-DM.



Gambar 2. Data Mining dalam CRIPS-DM

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

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. 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.
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.
4. Pemodelan (*Modelling*)  
Pada tahap ini, berbagai teknik pemodelan diterapkan dan disesuaikan untuk mendapatkan hasil terbaik. Ini melibatkan penyesuaian parameter untuk memaksimalkan kinerja model.
5. Evaluasi (*Evaluation*)

Setelah model dilatih, tahap ini bertujuan untuk mengevaluasi kualitas dan efektivitas model. Evaluasi dilakukan untuk memastikan model telah memenuhi tujuan yang telah ditetapkan.

#### 6. Penyebaran (*Deployment*)

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

## HASIL DAN PEMBAHASAN

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

### 1. Pemahaman Bisnis (*Business Understanding*)

Analisa data realiasi belanja pegawai menggunakan algoritma *Neural Network* dan *Linear Regression* bertujuan dalam memudahkan untuk prediksi/perencanaan anggaran tahun-tahun mendatang. Dengan titik fokus pada variabel seperti tahun, bulan dan nilai realisasi, tujuan utama adalah harapan untuk mendapatkan nilai akursi yang baik ketika penyusunan anggaran dilakukan, terutama anggaran tahun-tahun mendatang.

### 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 pegawai yang kemudian dijumlahkan dan dikelompokkan 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 pegawai. Data penelitian berasal dari data pembayaran selama periode waktu 3 tahun, bulan Januari 2018 sampai dengan Desember 2020.

### 3. Persiapan Data (*Data Preparation*)

#### 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. Data Awal/Dataset.

No	Kdba	Kdesl	Kdsatker	...	Kdakun	Tahun	Bulan	Realisasi
1	025	01	416289	...	511111	2018	01	2.295.634.400
2	025	01	416289	...	511119	2018	01	41.363
3	025	01	416289	...	511121	2018	01	178.267.160
4	025	01	416289	...	511122	2018	01	51.075.294
5	025	01	416289	...	511123	2018	01	140.405.000
...	...	...	...	...	...	...	...	...
455	025	01	416289	...	512111	2020	12	82.428.000
456	025	01	416289	...	512411	2020	12	4.542.843.049

#### Pemilihan Atribut

Berdasarkan tabel 2, telah dilakukan seleksi atribut, menghapus dan penambahan kolom *sequence* untuk keperluan pengolahan data pada Rapidminer, sehingga atribut yang digunakan terdiri dari seq (sebagai ID), tahun, bulan dan realisasi, seperti pada tabel 3. Selanjutnya dilakukan penjumlahan realisasi (*grouping by* tahun, bulan).

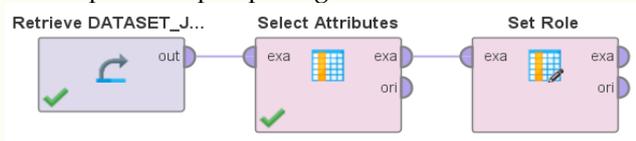
Tabel 3. Dataset Akhir.

Seq	Tahun	Bulan	Realisasi
01	2018	01	5.350.562.945
02	2018	02	4.537.893.877
03	2018	03	5.776.854.576
04	2018	04	5.144.413.876
05	2018	05	4.687.072.996
06	2018	06	10.143.165.781
07	2018	07	9.615.709.568
...	...	...	...
25	2020	01	5.808.245.459
26	2020	02	3.199.776.502
27	2020	03	2.969.754.776
28	2020	04	5.096.567.851
29	2020	05	4.927.907.232
30	2020	06	5.045.835.404
31	2020	07	4.952.681.994
32	2020	08	4.967.608.994
33	2020	09	5.051.492.215
34	2020	10	4.927.247.104
35	2020	11	4.724.729.324
36	2020	12	4.960.478.324

#### 4. Pemodelan (Modelling)

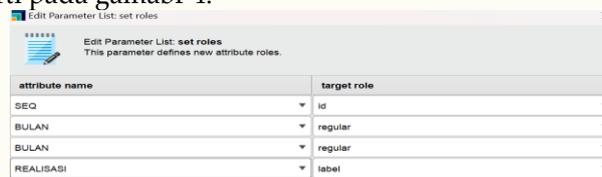
##### Menentukan Atribut Label dan Role

Dalam menentukan atribut dan role pada dataset, digunakan operator *Select Attributes* kemudian lanjutkan dengan Set Role seperti tampak pada gambar 3.



Gambar 3. Menentukan Atribut dan Role

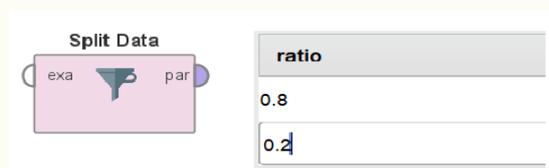
Untuk menentukan role, klik pada gambar Set Role, sehingga dapat kita tentukan role pada dataset yang ditentukan, seperti pada gambar 4.



Gambar 4. Menentukan Role.

##### Menentukan Split Data Training dan Testing

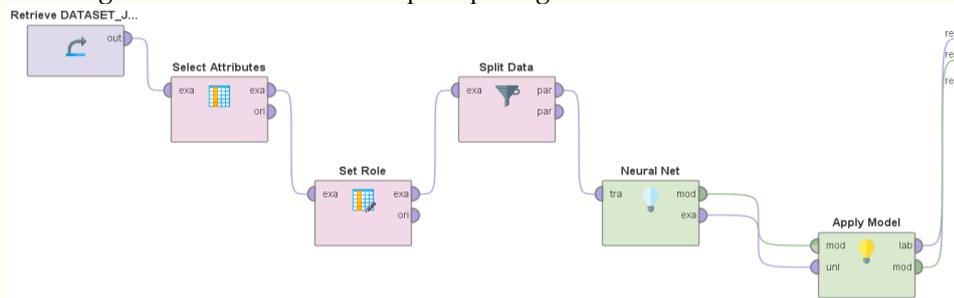
Pada tahap ini, cari dan pilih Split Data dan tentukan nilai ratio, pertama untuk data training 80% dengan isian 0.8 dan data testing 20% dengan isian 0.2, seperti pada gambar 5.



Gambar 5. Menentukan Split Data

#### Implementasi Algoritma Neural Network dan Linear Regression

Setelah menentukan atribut dataset, Set Role dan Split Data, berikutnya adalah melakukan implementasi menggunakan algoritma *Neural Network* dan *Linear Regression*. Cari dan pilih algoritma tersebut dan tambahkan function *Apply Model* untuk melihat hasilnya. Implementasi algoritma *Neural Network* seperti pada gambar 6.



Gambar 6. Implementasi Algoritma *Neural Network*

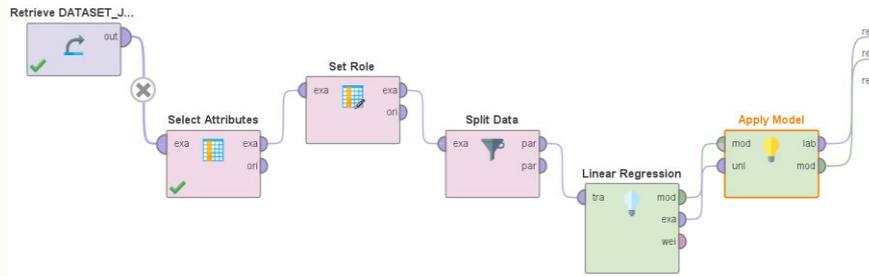
Hasil dari prediksi dengan perbandingan data *training/testing* 90:10, 80:20 dan 70:30 sebagaimana pada tabel 4.

Tabel 4. Hasil Implementasi Algoritma *Neural Network*.

Seq	Tahun	Bulan	Realisasi	Prediksi %(90:10)	Prediksi %(80:20)	Prediksi %(70:30)
01	2018	01	5.350.562.945	5.666.011.387,361	5.990.314.641,650	6.012.832.474,763
02	2018	02	4.537.893.877	5.809.336.425,895	6.097.861.483,408	6.117.693.425,052
03	2018	03	5.776.854.576	5.952.322.157,876	6.204.733.110,529	6.222.561.783,859
04	2018	04	5.144.413.876	6.094.381.944,194	...	...
05	2018	05	4.687.072.996	6.234.944.271,372	6.415.209.683,483	6.430.705.176,910
06	2018	06	10.143.165.781	6.373.461.937,260	6.518.226.560,233	6.533.192.299,099
07	2018	07	9.615.709.568	6.509.420.399,866	6.619.398.353,109	...
...	...	...	...	...	...	4.675.288.053,238
25	2020	01	5.808.245.459	4.001.418.706,788	4.415.095.676,006	...
26	2020	02	3.199.776.502	4.104.857.689,104	4.577.532.119,828	...
27	2020	03	2.969.754.776	4.213.191.932,806	4.663.390.087,969	4.895.216.280,421
28	2020	04	5.096.567.851	4.326.306.877,238	4.843.882.227,778	...
29	2020	05	4.927.907.232	...	...	5.058.861.200,290
30	2020	06	5.045.835.404	4.566.157.239,924	5.035.106.114,092	...
31	2020	07	4.952.681.994	...	...	...
32	2020	08	4.967.608.994	4.822.418.083,794	5.134.282.747,862	5.235.316.965,657
33	2020	09	5.051.492.215	4.955.841.657,981	...	5.327.956.593,355
34	2020	10	4.927.247.104	...	5.338.632.807,343	...
35	2020	11	4.724.729.324	5.231.107.870,973	5.443.287.384,132	5.520.955.040,516
36	2020	12	4.960.478.324	5.371.952.059,134	5.990.314.641,650	5.620.766.205,497

Berdasarkan tabel 4, maka dapat disampaikan hasil prediksi belanja pegawai untuk bulan Januari 2020 dengan perbandingan split data sebagaimana pada tabel 4, menghasilkan prediksi 4.001.418.706,788, dan 4.415.095.676,006. Berikut nya Bulan Februari 2020 menghasilkan prediksi 4.104.857.689,104 dan 4.577.532.119,828. Berikutnya bulan Maret 2020 menghasilkan prediksi 4.213.191.932,806, 4.663.390.087,969 dan 4.895.216.280,421 dan seterusnya pada bulan Desember 2020 menghasilkan prediksi 5.371.952.059,134, 5.990.314.641,650 dan 5.620.766.205,497 (prediksi ini dapat digunakan sebagai acuan untuk periode sama pada tahun berikut yaitu 2023), sedangkan data hasil prediksi kosong merupakan data testing.

Implementasi algoritma *Linear Regression* seperti pada gambar 7.



Gambar 7. Implementasi Algoritma *Linear Regression*.

Hasil dari prediksi dengan perbandingan data *training/testing* 90:10, 80:20 dan 70:30 sebagaimana pada tabel 5.

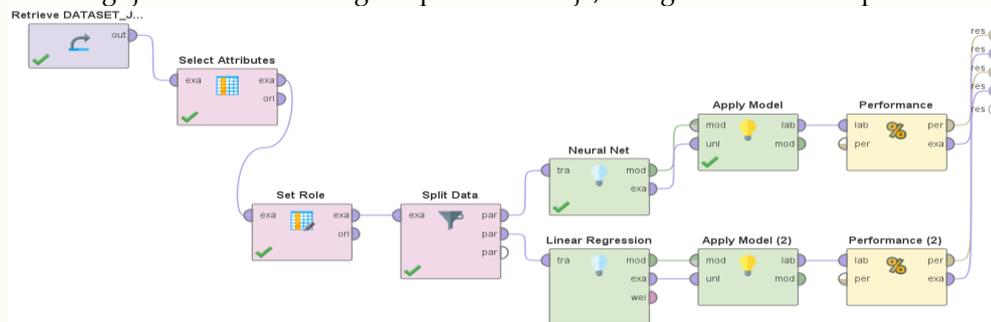
Seq	Tahun	Bulan	Realisasi	Prediksi %(90:10)	Prediksi %(80:20)	Prediksi %(70:30)
01	2018	01	5.350.562.945	5.782.780.521,182	6.612.787.365,232	6.444.462.659,555
02	2018	02	4.537.893.877	5.912.679.261,764	6.612.787.365,232	6.444.462.659,555
03	2018	03	5.776.854.576	6.042.578.002,346	6.612.787.365,232	6.444.462.659,555
04	2018	04	5.144.413.876	6.172.476.742,927	6.612.787.365,232	6.444.462.659,555
05	2018	05	4.687.072.996	6.302.375.483,509	6.612.787.365,232	6.444.462.659,555
06	2018	06	10.143.165.781	6.432.274.224,091	6.612.787.365,232	6.444.462.659,555
07	2018	07	9.615.709.568	6.562.172.964,673	6.612.787.365,232	6.444.462.659,555
...	...	...	...	...	...	...
25	2020	01	5.808.245.459	4.004.068.352,459	4.857.558.904,792	5.099.449.288,958
26	2020	02	3.199.776.502	4.133.967.093,041	4.857.558.904,792	5.099.449.288,958
27	2020	03	2.969.754.776	4.263.865.833,623	4.857.558.904,792	5.099.449.288,958
28	2020	04	5.096.567.851	4.393.764.574,205	4.857.558.904,792	5.099.449.288,958
29	2020	05	4.927.907.232	...	...	...
30	2020	06	5.045.835.404	4.653.562.055,368	4.857.558.904,792	5.099.449.288,958
31	2020	07	4.952.681.994	...	...	...

Seq	Tahun	Bulan	Realisasi	Prediksi %(90:10)	Prediksi %(80:20)	Prediksi %(70:30)
32	2020	08				
			4.967.608.994	4.913.359.536,532	4.857.558.904,792	5.099.449.288,958
33	2020	09				
			5.051.492.215	5.043.258.277,114	4.857.558.904,792	5.099.449.288,958
34	2020	10	4.927.247.104	...	...	...
35	2020	11	4.724.729.324			
				5.303.055.758,278	4.857.558.904,792	5.099.449.288,958
36	2020	12	4.960.478.324			
				5.432.954.498,859	4.857.558.904,792	5.099.449.288,958

Berdasarkan tabel 5, maka dapat disampaikan hasil prediksi belanja pegawai untuk bulan Januari 2020 dengan perbandingan split data sebagaimana pada tabel 5, menghasilkan prediksi 4.004.068.352,459, 44.857.558.904,792 dan 5.099.449.288,958. Berikut nya Bulan Februari 2020 menghasilkan prediksi 4.133.967.093,041, 4.857.558.904,792 dan 5.099.449.288,958. Berikutnya bulan Maret 2020 menghasilkan prediksi 4.263.865.833,623, 4.857.558.904,792 dan 5.099.449.288,958 dan seterusnya pada bulan Desember 2020 menghasilkan prediksi 5.432.954.498,859, 4.857.558.904,792 dan 54.857.558.904,792 (prediksi ini dapat digunakan sebagai acuan untuk periode sama pada tahun berikut yaitu 2023), sedangkan data hasil prediksi kosong merupakan data testing.

5. Evaluasi (Evaluation)

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



Gambar 8. Proses pengujian dengan melihat performance.

Pada tahap menggunakan algoritma *Neural Network* dan *Linear Regression* Linear pengujian terhadap *Parameter feature selection* dan *Perfomance* untuk mendapatkan indikator statistik yang dipakai adalah nilai *Root Mean Squared Error (RMSE)* (Rahman, 2018), dapat dilihat pada tabel 6.

Tabel 6. Hasil percobaan *Parameter feature selection* dan *Perfomance*

Jenis Algoritma	Data %(90:10)	Data %(80:20)	Data %(70:30)
<i>Algoritma Neural Network</i>			
RMSE	1.528.548.203,391 +/- 0.000	1.574.970.259,712 +/- 0.000	1.502.955.371,784 +/- 0.000
<i>Algoritma Linear Regression</i>			
RMSE	1.525.213.978,925 +/- 0.000	1.612.945.104,455 +/- 0.000	1.540.826.342,006 +/- 0.000

Hasil dari percobaan pada tabel 8, di atas menunjukkan bahwa atribut yang dapat memengaruhi nilai RMSE adalah bulan dan tahun terhadap nilai prediksi realisasi sebagai acuan alokasi pagu belanja pegawai. Berdasarkan jumlah komposisi data training dan testing pada table 8 tersebut, didapatkan hasil pemodelan algoritma *Neural Network* memberikan nilai *Root Mean Squared Error* (RMSE) dengan perbandingan data training dan testing 90:10, yakni sebesar 1.528.548.203,391, data training dan testing 80:20 sebesar 1.574.970.259,712 dan terakhir data training dan testing 80:20 adalah sebesar 1.502.955.371,784. Sedangkan untuk algoritma *Linear Regression* memberikan nilai *Root Mean Squared Error* (RMSE) dengan perbandingan data training dan testing 90:10, yakni sebesar 1.525.213.978,925, data training dan testing 80:20 sebesar 1.612.945.104,455 dan terakhir data training dan testing 80:20 adalah sebesar 1.540.826.342,006.

## 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.

### Hasil atribut berpengaruh pada Root Mean Squared Error (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	Label	RMSE			
		Data %(90:10)	Data %(80:20)	Data %(70:30)	
Tahun	Bulan	Realisasi	1.528.548.203,391	1.574.970.259,712	1.502.955.371,784
			+/- 0.000	+/- 0.000	+/- 0.000

Tabel 8. Hasil percobaan atribut Algoritma *Linear Regression*

Atribut	Label	RMSE			
		Data %(90:10)	Data %(80:20)	Data %(70:30)	
Tahun	Bulan	Realisasi	1.525.213.978,925	1.612.945.104,455	1.540.826.342,006
			+/- 0.000	+/- 0.000	+/- 0.000

Berdasarkan hasil penelitian ini, model *neural network* dan *linear regression* memberikan hasil yang signifikan dalam memprediksi alokasi pagu belanja pegawai. 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 *linear regression* lebih efektif pada data dengan pola hubungan yang linier dan lebih sederhana. Hasil penelitian ini dapat dibandingkan dengan beberapa penelitian sebelumnya yang menggunakan pendekatan berbeda, namun dengan objek penelitian yang serupa:

Penelitian oleh (Pratiwi et al., 2024) menggunakan metode deskriptif kualitatif. Objek penelitian ini adalah data belanja pegawai pada Pengadilan Negeri Semarang Kelas IA Khusus. Temuan penelitian ini menunjukkan adanya dampak pada indikator Kinerja Pelaksanaan Anggaran (IKPA). Penelitian ini tidak memanfaatkan pendekatan kuantitatif seperti regresi atau *neural network*. Pendekatan kualitatif memberikan wawasan deskriptif mengenai dampak belanja pegawai terhadap kinerja, tetapi tidak menghasilkan model prediksi yang terukur seperti dalam penelitian ini. Metode prediktif yang digunakan dalam penelitian ini memberikan keunggulan dalam memproyeksikan permasalahan anggaran ke depan dengan lebih akurat. Penelitian yang dilakukan oleh (Syahrudin, 2022)

menggunakan metode kualitatif. Objek penelitiannya adalah realisasi anggaran belanja pegawai pada Satker Kantor Kementerian Agama Kabupaten Bima dan Kota Bima. Hasil penelitiannya menunjukkan periode 2019-2021 selalu mengalami defisit (minus). Penelitian ini juga menggunakan metode kualitatif yang menjelaskan kondisi anggaran yang selalu minus, namun tidak memberikan solusi berbasis prediktif. Dalam penelitian ini, dengan menggunakan model *neural network* dan linear regression, prediksi defisit dapat diidentifikasi lebih awal sehingga solusi proaktif bisa diterapkan. Model yang dibangun dalam penelitian ini menawarkan kelebihan berupa kemampuan meramal defisit sebelum terjadi. Penelitian oleh (Karbilai (2023) menggunakan pendekatan kualitatif menggambarkan kondisi di mana anggaran melebihi target. Namun, penelitian ini tidak memberikan prediksi atau mekanisme pencegahan. Model dalam penelitian ini memungkinkan pengambil kebijakan untuk memproyeksikan kondisi serupa sebelum akhir periode, sehingga melebihi anggaran bisa dicegah.

Hasil penelitian ini membuktikan bahwa metode prediksi menggunakan *neural network* dan *linear regression* dapat memberikan hasil yang lebih terukur dan akurat dibandingkan metode kualitatif deskriptif yang telah digunakan dalam penelitian sebelumnya. Dengan memanfaatkan pendekatan prediktif, penelitian ini menawarkan solusi yang lebih tepat waktu dan efektif dalam mengatasi potensi defisit atau kelebihan anggaran belanja pegawai di masa depan.

## KESIMPULAN

Berdasarkan hasil akhir penelitian dan pengujian terhadap dataset yang ada, penulis dapat menyimpulkan bahwa dari dua perbandingan algoritma *Neural Network* dan *Linear Regression*, 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 pegawai, sehingga menghasilkan prediksi yang lebih akurat dibandingkan dengan *Linear Regression* 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 Sekretariat Jenderal Kementerian Agama RI. 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%. 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 prediksi, misalnya menggabungkan algoritma *Neural Network* dengan teknik lain seperti *Decision Trees* atau *Random Forest*.

## DAFTAR PUSTAKA

- Akhmad, E. P. A. (2020). Data Mining Menggunakan Regresi Linear untuk Prediksi Harga Saham Perusahaan Pelayaran. *Jurnal Aplikasi Pelayaran Dan Kepelabuhanan*, 10(2), 120. <https://doi.org/10.30649/japk.v10i2.83>
- Fahrudin, Y. I., Kurniawan, R., & Wijaya, Y. A. (2024). Penerapan Algoritma Regresi Linear Pada Data Harga Cabai Rawit Di Pasar Indihiang. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 8(2), 1614-1620. <https://doi.org/10.36040/jati.v8i2.9053>
- Karbilai, I. H. (2023). Politik Fiskal Serapan Anggaran Belanja Pegawai Dan Belanja Barang. *Jurnal Manajemen Indonesia*, 8(2), 83–97. <https://doi.org/10.29103/j-mind.v8i1.12801>
- Kementerian Agama RI. (2018). *Laporan Keuangan Kementerian Agama Tahun 2018 Audited*. [https://ppid.kemenag.go.id/v5/laporan\\_keuangan.php](https://ppid.kemenag.go.id/v5/laporan_keuangan.php)
- Kementerian Agama RI. (2019). *Laporan Keuangan Kementerian Agama Tahun 2019 Audited*. [https://ppid.kemenag.go.id/v5/laporan\\_keuangan.php](https://ppid.kemenag.go.id/v5/laporan_keuangan.php)

- Kementerian Agama RI. (2020). *Laporan Keuangan Kementerian Agama Tahun 2020 Audited*. [https://ppid.kemenag.go.id/v5/laporan\\_keuangan.php](https://ppid.kemenag.go.id/v5/laporan_keuangan.php)
- Kusumodestoni, R. H., & Suyatno, S. (2015). Prediksi Forex Menggunakan Model Neural Network. *Simetris: Jurnal Teknik Mesin, Elektro dan Ilmu Komputer*, 6(2), 205-210. <https://doi.org/10.24176/simet.v6i2.453>
- Mumu, R. G. R., Nurchim, N., & Sumarlinda, S. (2023). Forecasting Central Bank Digital Currency Terhadap Rupiah Digital. *IDEALIS: InDonEsiA journal Information System*, 6(2), 65-74. <https://doi.org/10.36080/idealism.v6i2.3027>
- Pratiwi, A. S., & Nawatmi, S. (2024). Analisis Pagu Minus Belanja Pegawai Pada Pengadilan Negeri Semarang Kelas IA Khusus. *Jurnal Ekonomi Manajemen Sistem Informasi (JEMSI)*, 5(5). <https://doi.org/10.31933/jemsi.v5i5>
- Purwati, N., Nurlistiani, R., & Devinsen, O. (2020). Data Mining Dengan Algoritma Neural Network Dan Visualisasi Data Untuk Prediksi Kelulusan Mahasiswa. *Jurnal Informatika*, 20(2), 156-163.
- Rahman, M. (2018). *Prediksi Pembayaran Tagihan Listrik Menggunakan Model Artificial Neural Network*.
- Ridho, I. I., Mahalisa, G., Sari, D. R., & Fikri, I. (2022). Metode Neural Network Untuk Penentuan Akurasi Prediksi Harga Rumah. *Technologia: Jurnal Ilmiah*, 13(1), 56-58. <http://dx.doi.org/10.31602/tji.v13i1.6252>
- Syahrudin, S. (2022). Analisis Realisasi Anggaran Belanja Pegawai Pada Satker Lingkup Kantor Kementerian Agama Kabupaten Bima Dan Kota Bima. *Jurnal Ilmiah Mandala Education*, 8(2), 1309-1323. <http://dx.doi.org/10.58258/jime.v8i2.2979>
- Wijaya, A. H. (2019). Artificial Neural Network Untuk Memprediksi Beban Listrik dengan Menggunakan metode Backpropagation (Studi Kasus PT. PLN Regional Sumatera Barat). *Jurnal CoreIT*, 5(2), 61-70.