

---

## **Analisis Faktor-Faktor Penyebab Inflasi di Indonesia Menggunakan Regresi Ridge, LASSO, dan Elastic-Net**

---

**Husna Afanyn Khoirunissa\***, **Andreas Rony Wijaya**, **Bayutama Isnaini**, **Kiki Ferawati**  
Program Studi Statistika, Universitas Sebelas Maret, Surakarta, Indonesia

\*Corresponding author: [husnafanynk@staff.uns.ac.id](mailto:husnafanynk@staff.uns.ac.id)

Submitted: 24-Dec-2024

Revised: 16-Jan-2025

Accepted: 19-Jan-2025

---

**Abstract.** *The economic condition of a country can be measured using one of the indicators, the inflation rate. Therefore, the inflation needs to be maintained so that its rate can be controlled. To support this, it is necessary to pay attention to several factors that influence the inflation rate. These factors include the amount of exports, imports, narrow money (M1), broad money (M2), the rupiah exchange rate against the USD, interest rates, rice prices in wholesale trade, farmer exchange rates (NTP), world crude oil prices, bank investment credit, GDP, and foreign exchange reserves. In this study, we analyze the significant factors influencing the inflation rate in Indonesia using the best model of the Ridge regression, LASSO regression, and Elastic-Net methods. In this modeling, the  $\gamma$  and  $\lambda$  values from the three methods are optimized first. The data used in this study consist of inflation data in Indonesia and its factors for 2020-2024, sourced from the BPS. Among the three high-dimensional data methods, the LASSO regression is the best method with the smallest MSE for modeling inflation data in Indonesia. The LASSO regression model produces 8 predictor variables that significantly influence inflation data, i.e., imports, M1, interest rates, and world crude oil prices with positive coefficient signs, as well as rice price variables in wholesale trade, NTP, GDP, and foreign exchange reserves with negative coefficient signs.*

**Keywords:** *inflation, ridge regression, lasso regression, elastic-net.*

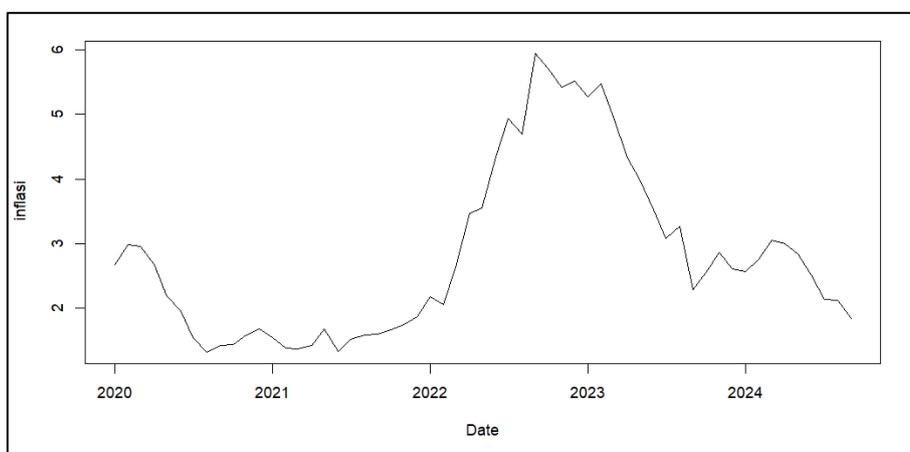
---

### **1. PENDAHULUAN**

Inflasi merupakan salah satu indikator ekonomi makro yang sangat penting dalam menentukan stabilitas dan pertumbuhan ekonomi suatu negara. Inflasi merupakan proses meningkatnya harga-harga barang dan jasa secara umum dan terus-menerus dalam suatu periode waktu tertentu dengan laju yang tidak kecil. Laju pertumbuhan inflasi selalu diupayakan stabil dan rendah agar tidak menimbulkan ketidakstabilan perekonomian [1]. Tingkat inflasi yang tidak terkendali dapat menyebabkan ketidakstabilan ekonomi yang menyebabkan meningkatnya harga-harga barang dan jasa secara umum dan terus menerus sehingga mengurangi daya beli masyarakat. Daya beli masyarakat yang menurun menyebabkan penurunan permintaan barang dan jasa, penurunan produksi, peningkatan beban operasional, dan ketidakstabilan keuangan perusahaan yang berimbas pada terjadinya pemutusan hubungan kerja (PHK) dan peningkatan angka pengangguran serta kemiskinan. Oleh karena itu, inflasi dapat menimbulkan efek domino dan dampak yang sangat luas terhadap ekonomi makro [2].

Persentase inflasi di Indonesia sangat fluktuatif yang disebabkan oleh berbagai hal baik dari faktor ekonomi maupun non ekonomi. Gambar 1 memberikan gambaran fluktuasi dari inflasi

di Indonesia sepanjang tahun 2020 hingga 2024. Pada pertengahan tahun 2020, Indonesia mengalami deflasi mencapai 21,43% dengan titik inflasi terendah pada Agustus 2020 sebesar 1,32% sedangkan pada pertengahan tahun 2022 hingga awal tahun 2023, Indonesia mengalami peningkatan inflasi sebesar 31,43% dengan titik inflasi tertinggi pada September 2022 sebesar 5,95%. Pemerintah melalui Bank Indonesia telah memberikan kebijakan moneter berupa pengendalian suku bunga dan uang beredar di Indonesia. Namun, masih banyak faktor lain yang menyebabkan fluktuasi inflasi di Indonesia sehingga penelitian ini sangat menarik untuk dibahas.



Gambar 1. Inflasi di Indonesia

Penelitian terkait faktor-faktor penyebab inflasi di Indonesia telah banyak dilakukan dan dikembangkan untuk mengetahui faktor apa saja yang mempengaruhi inflasi di Indonesia. Beberapa penelitian terkait adalah penelitian oleh Djambak [3] yang mengkaji faktor dominan yang mempengaruhi inflasi di Indonesia pada tahun 1981-2007. Penelitian memberikan hasil bahwa jumlah uang beredar, pertumbuhan depresiasi nilai rupiah, ekspektasi masyarakat terhadap inflasi, PDB, dan defisit APBN berpengaruh secara signifikan terhadap inflasi di Indonesia. Penelitian lain oleh Beureukat [4] yang mengkaji inflasi pada tahun 2007-2017 memberikan kesimpulan bahwa suku bunga berpengaruh positif secara signifikan terhadap inflasi. Penelitian oleh Kalalo, dkk [5] memberikan hasil bahwa variabel suku bunga berpengaruh secara signifikan terhadap inflasi di tahun 2000-2014 sedangkan sisanya, yaitu variabel jumlah uang beredar, harga minyak dunia, kurs terhadap dollar Amerika tidak berpengaruh secara signifikan terhadap inflasi. Hasil dari penelitian-penelitian yang telah disebutkan tersebut dikaji menggunakan metode *ordinary least square* (OLS).

Metode OLS merupakan metode yang populer dan banyak digunakan untuk menemukan hasil estimasi model regresi dengan meminimumkan *residual sum of squares* (RSS). Dalam proses estimasinya, metode OLS memiliki asumsi yang harus dipenuhi, salah satunya asumsi tidak terjadi pelanggaran multikolinearitas. Padahal dalam implementasi metode OLS sering digunakan banyak variabel prediktor sehingga model rentan melanggar asumsi multikolinearitas dan mengakibatkan varians koefisien yang tidak terkendali. Metode regresi Ridge yang dikenalkan oleh Hoerl & Kennard [6], regresi LASSO oleh Tibshirani [7], dan Elastic-Net oleh Zou & Hastie [8] memberikan solusi dari masalah tersebut dengan menyusutkan koefisien, menyeleksi variabel, dan mengoptimasi parameter melalui penambahan parameter penalti  $L_1$ -norm (pada regresi LASSO),  $L_2$ -norm (pada regresi Ridge), serta gabungan  $L_1$ -norm dan  $L_2$ -norm (pada Elastic-Net).

Berdasarkan uraian di atas, pada penelitian ini dikaji terkait faktor-faktor apa saja yang mempengaruhi inflasi di Indonesia melalui 12 variabel prediktor yang mewakili variabel-variabel makro ekonomi menggunakan model terbaik dengan metode regresi Ridge, LASSO, dan Elastic-Net pada data inflasi di Indonesia pada tahun 2020-2024.

## 2. DATA DAN METODOLOGI

Data yang digunakan pada penelitian ini terdiri dari data variabel dependen dan independen yang merupakan data sekunder dari *website* Badan Pusat Statistik (BPS), Bank Indonesia (BI), dan Kementerian Perdagangan. Data inflasi bulanan menjadi variabel respon yang diambil dari Januari 2020 sampai dengan September 2024 sebanyak 56 observasi. Variabel prediktor yang digunakan merupakan variabel-variabel makro ekonomi yang diduga menjadi faktor-faktor penyebab inflasi di Indonesia, diantaranya variabel ekspor, impor, M1, M2, nilai tukar rupiah terhadap USD, suku bunga, harga beras di perdagangan besar, nilai tukar petani (NTP), harga minyak mentah dunia, kredit investasi perbankan, PDB, dan cadangan devisa. Deskripsi variabel disajikan pada Tabel 1.

Tabel 1. Variabel penelitian

Variabel	Deskripsi	Satuan
$y$	Inflasi	Persen
$x_1$	Total impor	Juta US Dollar
$x_2$	Total ekspor	Juta US Dollar
$x_3$	Jumlah uang beredar sempit (M1)	Miliar Rupiah
$x_4$	Jumlah uang beredar luas (M2)	Miliar Rupiah
$x_5$	Nilai tukar (kurs) rupiah terhadap USD	Rupiah
$x_6$	Suku bunga	Persen
$x_7$	Harga beras di perdagangan besar	Rupiah per Kilogram
$x_8$	Nilai Tukar Petani (NTP)	Persen
$x_9$	Harga minyak mentah dunia	US Dollar
$x_{10}$	Kredit investasi perbankan	Miliar Rupiah
$x_{11}$	Produk Domestik Bruto (PDB)	Miliar Rupiah
$x_{12}$	Cadangan devisa	Juta US Dollar

Sebelum dilakukan analisis, data dilakukan *pre-processing* terlebih dahulu. Setiap variabel memiliki satuan yang berbeda sehingga perlu dilakukan standarisasi yang bertujuan agar seluruh variabel yang akan digunakan dalam penelitian ini memiliki format tunggal dan terpadu sehingga kualitas data terjaga. Pada tahap akhir, untuk mendapatkan nilai estimasi koefisiennya, data akan dikembalikan pada satuan asli.

Tahap awal dalam analisis, data dimodelkan menggunakan metode OLS yang meminimumkan RSS dengan fungsi tujuan pada persamaan (1).

$$\min_{\beta \in \mathbb{R}^p} \sum_{t=1}^T (y_t - \mathbf{X}'_t \beta)^2 \tag{1}$$

Selanjutnya, model OLS dilakukan pengujian asumsi klasik multikolinearitas. Hasil pengujian yang mengindikasikan adanya pelanggaran multikolinearitas menjadi alasan utama bahwa data dalam penelitian ini selanjutnya dilakukan pemodelan *high dimensional data*, yaitu regresi Ridge, LASSO, dan Elastic-Net.

### 2.1. Regresi Ridge

Regresi Ridge pertama kali diperkenalkan oleh Hoerl & Kennard [6] sebagai metode yang sangat berguna untuk mengatasi masalah multikolinearitas. Metode dalam regresi Ridge merupakan pengembangan dari metode OLS dengan menambahkan kendala pada koefisien  $\beta_i$  sehingga besarnya koefisien menyusut dan tidak mengakibatkan varians yang tinggi [9]. Oleh karena itu, untuk mengendalikan varians, diberikan suatu kendala sehingga terdapat batasan untuk besarnya koefisien pada regresi. Pada regresi Ridge, diberikan kendala dengan parameter penalti  $L_2$ -norm, yaitu  $\|\boldsymbol{\beta}\|_2 \leq s$  atau  $\sum_{i=1}^p \beta_i^2 \leq s$  untuk setiap  $s$  bernilai positif. Oleh karena itu, fungsi tujuan pada regresi Ridge dikembangkan dengan menambahkan kendala tersebut pada fungsi tujuan OLS persamaan (1). Fungsi tujuan regresi Ridge yang meminimumkan *penalized residual sum of square* (PRSS) dituliskan pada persamaan (2).

$$\min_{\boldsymbol{\beta} \in \mathbb{R}^p} \sum_{t=1}^T (y_t - \mathbf{X}'_t \boldsymbol{\beta})^2 + \lambda \sum_{i=1}^p \beta_i^2 \quad (2)$$

Parameter  $\lambda$  merupakan parameter penalti yang bernilai positif,  $\lambda > 0$ . Seiring meningkatnya nilai  $\lambda$ , estimasi parameter pada regresi Ridge akan terus menyusut menuju 0. Kemudian, jika  $\lambda$  cukup besar, beberapa koefisien akan tepat sama dengan 0.

### 2.2. Regresi Least Absolute Shrinkage and Selection Operator (LASSO)

Regresi LASSO dikembangkan oleh Tibshirani [7] sebagai metode dalam seleksi variabel dan sekaligus menghasilkan optimasi parameter. Sama halnya pada regresi Ridge, metode dalam regresi LASSO merupakan pengembangan dari metode OLS dengan mengecilkan (*shrinkage*) beberapa koefisien dan menetapkan koefisien lain menjadi 0 sehingga diperoleh variabel-variabel yang baik (*selection operator*) dari kedua pemilihan subset. Oleh karena itu, metode LASSO secara otomatis memilih variabel yang relevan dan signifikan [10]. Pada regresi LASSO, diberikan kendala dengan parameter penalti  $L_1$ -norm, yaitu  $\|\boldsymbol{\beta}\|_1 \leq s$  atau  $\sum_{i=1}^p |\beta_i| \leq s$  untuk setiap  $s$  bernilai positif. Oleh karena itu, fungsi tujuan pada regresi LASSO dikembangkan dengan menambahkan kendala tersebut pada fungsi tujuan OLS persamaan (1). Fungsi tujuan regresi Ridge yang meminimumkan PRSS dituliskan pada persamaan (3).

$$\min_{\boldsymbol{\beta} \in \mathbb{R}^p} \sum_{t=1}^T (y_t - \mathbf{X}'_t \boldsymbol{\beta})^2 + \lambda \sum_{i=1}^p |\beta_i| \quad (3)$$

Parameter  $\lambda$  merupakan parameter penalti yang bernilai positif,  $\lambda > 0$ . Seiring meningkatnya nilai  $\lambda$ , estimasi parameter pada regresi LASSO akan terus menyusut menuju 0. Kemudian, jika  $\lambda$  cukup besar, beberapa koefisien akan tepat sama dengan 0.

### 2.3. Elastic-Net

Metode Elastic-Net pertama kali diperkenalkan oleh Zou & Hastie [8] sebagai metode yang mengkombinasikan parameter penalti pada regresi Ridge dan LASSO. Elastic-Net memberikan penyusutan koefisien dan melakukan seleksi variabel sehingga dapat mengatasi kekurangan dari metode regresi Ridge dan LASSO. Pada Elastic-Net, diberikan kendala dengan parameter penalti  $L_1$ -norm dan  $L_2$ -norm yang besarnya dikontrol oleh parameter yang elastis, yaitu parameter  $\gamma$ . Oleh karena itu, fungsi tujuan pada regresi LASSO dikembangkan dengan menambahkan kendala tersebut pada fungsi tujuan OLS persamaan (1). Fungsi tujuan Elastic-Net yang meminimumkan PRSS dituliskan pada persamaan (4) dan dijabarkan pada persamaan (5).

$$\min_{\boldsymbol{\beta} \in \mathbb{R}^p} \sum_{t=1}^T (y_t - \mathbf{X}'_t \boldsymbol{\beta})^2 + \lambda [(1 - \gamma) \|\boldsymbol{\beta}\|_2 + \gamma \|\boldsymbol{\beta}\|_1] \quad (4)$$

$$\min_{\boldsymbol{\beta} \in \mathbb{R}^p} \sum_{t=1}^T (y_t - \mathbf{X}'_t \boldsymbol{\beta})^2 + \lambda [(1 - \gamma) \sum_{i=1}^p \beta_i^2 + \gamma \sum_{i=1}^p |\beta_i|] \quad (5)$$

Parameter  $0 < \gamma < 1$  merupakan parameter elastis yang mengontrol besarnya parameter penalti  $\lambda$  dan menjembatani perbedaan antara regresi Ridge dan LASSO. Nilai parameter  $\gamma = 0$  pada regresi Ridge sesuai dengan fungsi tujuan pada persamaan (2) dan nilai  $\gamma = 1$  pada regresi LASSO sesuai dengan fungsi tujuan pada persamaan (3).

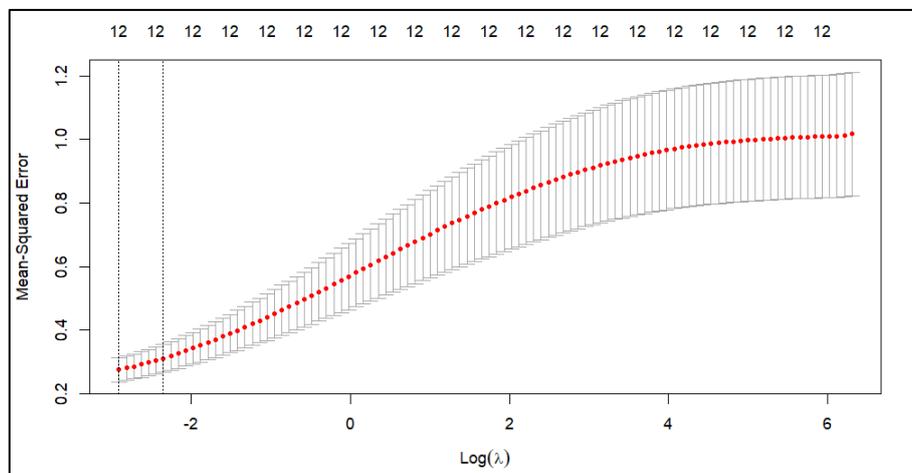
### 3. HASIL DAN PEMBAHASAN

Inflasi merupakan masalah yang bersifat multidimensi dan dipengaruhi oleh berbagai variabel. Hal ini dapat menimbulkan masalah multikolinearitas pada model OLS. Hasil dari uji multikolinearitas menggunakan statistik uji *Variance Inflation Factor* (VIF) menunjukkan bahwa hanya terdapat 5 variabel saja yang memiliki nilai VIF  $< 10$ , yaitu variabel  $x_2, x_5, x_6, x_9,$  dan  $x_{12}$  sedangkan 7 variabel lainnya memiliki nilai VIF  $> 10$  yang artinya terjadi multikolinearitas pada model regresi OLS. Oleh karena itu, perlu dilakukan pemodelan *high dimensional data* yang mencakup pada penyeleksian variabel menggunakan metode *embedded*.

Metode yang akan digunakan pada penelitian ini adalah regresi Ridge, LASSO, dan Elastic-Net. Pada pemodelan ini,  $\gamma$  dan  $\lambda$  dilakukan optimalisasi sebagai berikut: ketika  $\gamma$  dibuat tetap (untuk regresi Ridge  $\gamma = 0$  sehingga sesuai dengan fungsi tujuan regresi Ridge pada persamaan (2) dan untuk LASSO  $\gamma = 1$  sehingga sesuai dengan fungsi tujuan regresi LASSO pada persamaan (3)), parameter penyusutan  $\lambda$  dilakukan optimalisasi berdasarkan nilai minimum *Mean Square Error* (MSE). Selanjutnya, dalam metode Elastic-Net, nilai  $\gamma$  ditingkatkan sebesar 0,1 untuk setiap tahapannya sehingga diperoleh pasangan  $\gamma$  dan  $\lambda$  yang optimum berdasarkan nilai MSE terkecil.

#### 3.1. Pemodelan Regresi Ridge

Pemodelan regresi Ridge dilakukan dengan mengoptimal parameter penyusutan  $\lambda$  pada  $\gamma = 0$ . Proses optimalisasi menggunakan metode *10-fold Cross Validation* (CV) dan vektor random integer pada R dengan `set.seed(123)`. Parameter  $\lambda$  yang optimal dihitung berdasarkan nilai MSE yang terkecil.



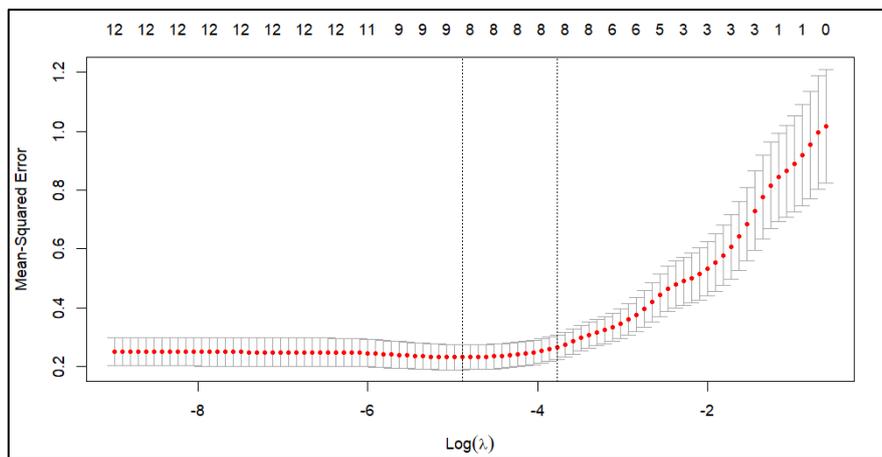
Gambar 2. *Cross Validation* parameter  $\lambda$  pada regresi Ridge

Gambar 2 menunjukkan proses *cross validation* parameter  $\lambda$  pada regresi Ridge. Garis vertikal dari kiri ke kanan masing-masing menunjukkan nilai  $\log \lambda_{min}$  dan nilai  $\log \lambda_{1se}$ . Pada penelitian ini, digunakan nilai  $\lambda_{1se}$  (disebut dengan pendekatan “*one-standard-error*”) sebagai

parameter  $\lambda$  optimum yang memberikan nilai  $\lambda$  pada satu *standard error* minimum sehingga nilai  $\lambda_{1se}$  lebih *robust* terhadap *overfitting*. Hasil perhitungan diperoleh parameter  $\lambda$  optimum untuk regresi Ridge sebesar 0,095 dengan MSE sebesar 0,311.

### 3.2. Pemodelan Regresi LASSO

Pemodelan regresi LASSO dilakukan dengan mengoptimal parameter penyusutan  $\lambda$  pada  $\gamma = 1$ . Sama halnya pada metode regresi Ridge, proses optimalisasi menggunakan metode *10-fold cross validation* (CV) dan vektor random integer pada R dengan `set.seed(123)`. Parameter  $\lambda$  yang optimal dihitung berdasarkan nilai MSE yang terkecil.



Gambar 3. *Cross Validation* parameter  $\lambda$  pada regresi LASSO

Gambar 3 menunjukkan proses *cross validation* parameter  $\lambda$  pada regresi LASSO. Garis vertikal dari kiri ke kanan masing-masing menunjukkan nilai  $\log \lambda_{min}$  dan nilai  $\log \lambda_{1se}$ . Hasil perhitungan diperoleh parameter  $\lambda$  optimum untuk regresi LASSO sebesar 0,023 dengan MSE sebesar 0,265 dan variabel prediktor yang masuk dalam model sebanyak 8 variabel.

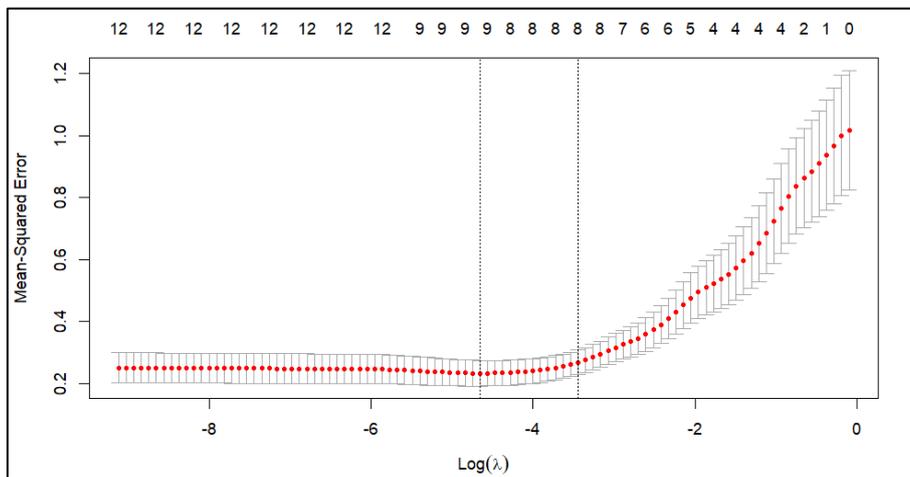
### 3.3. Pemodelan Elastic-Net

Pemodelan Elastic-Net dilakukan dengan mengoptimal pasangan  $\gamma$  dan  $\lambda$  yang optimum untuk setiap peningkatan parameter *tuning*  $\gamma$  sebesar 0,1 berdasarkan nilai MSE yang terkecil. Sama halnya pada metode regresi Ridge dan LASSO, proses optimalisasi menggunakan metode *10-fold Cross Validation* (CV) dan vektor random integer pada R dengan `set.seed(123)`.

Tabel 2. Performa model berdasarkan parameter *tuning* yang berbeda

$\gamma$	$\lambda_{1se}$	MSE	$p$
0,1	0,05212	0,2753	11
0,2	0,04998	0,2763	8
0,3	0,04404	0,2725	8
0,4	0,03979	0,2709	8
0,5	0,03493	0,2677	8
<b>0,6</b>	0,03195	<b>0,2673</b>	8
0,7	0,03005	0,2690	8
0,8	0,02886	0,2723	8
0,9	0,02565	0,2687	8

Tabel 2 meringkas performa model untuk parameter *tuning*  $\gamma$  yang berbeda dengan peningkatan  $\gamma$  sebesar 0,1 untuk setiap *tuning* sehingga menghasilkan 10 pasang  $(\gamma, \lambda)$ . Hasil diperoleh pasangan terbaik  $(\gamma, \lambda)$  untuk model Elastic-Net, yaitu  $(\gamma = 0,6, \lambda = 0,03195)$  dengan nilai MSE terkecil sebesar 0,2673 dan  $p$  menunjukkan banyak variabel prediktor yang tidak tereliminasi sebesar 8 variabel. Parameter  $\gamma = 0,6$  terpilih meskipun nilai MSE untuk setiap  $\gamma$  memiliki perbedaan yang sangat kecil, bahkan untuk nilai  $\gamma = 0,2$  sampai dengan  $\gamma = 0,9$  memiliki jumlah prediktor tidak nol yang sama.

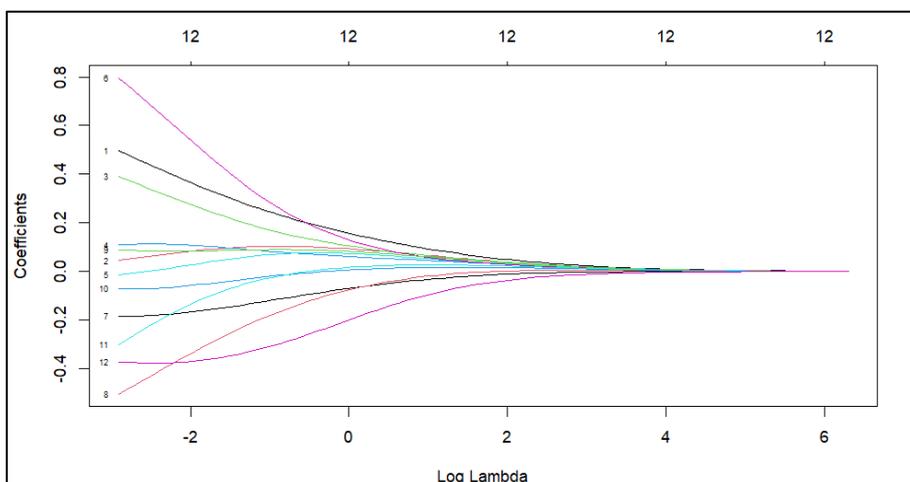


Gambar 4. *Cross validation* parameter  $\lambda$  pada regresi Elastic-Net

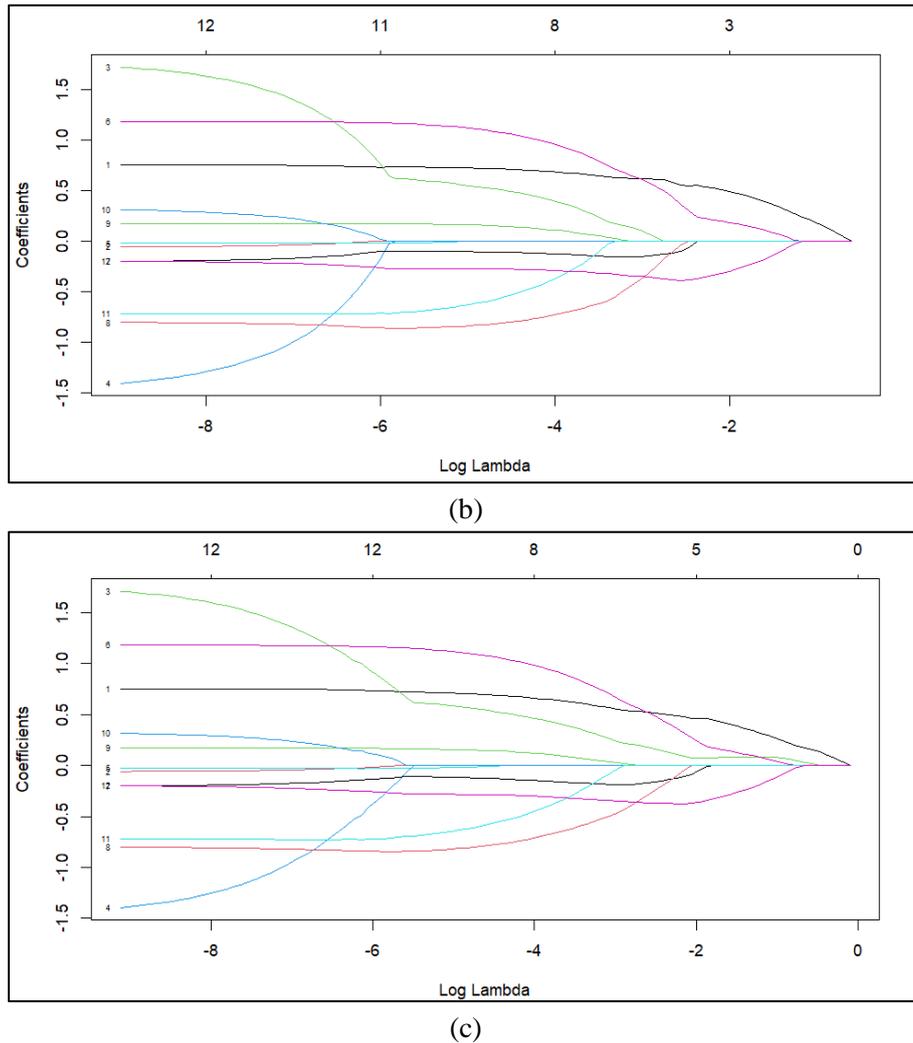
Gambar 4 menunjukkan proses *cross validation* parameter  $\lambda$  pada Elastic-Net dengan parameter *tuning*  $\gamma = 0,6$ . Garis vertikal dari kiri ke kanan masing-masing menunjukkan nilai  $\log \lambda_{min}$  dan nilai  $\log \lambda_{1se}$ . Hasil perhitungan diperoleh parameter  $\lambda$  optimum untuk Elastic-Net sebesar 0,03195 dengan MSE sebesar 0,267.

### 3.4. Koefisien Regresi dan Perbandingan Model

Nilai penyusutan  $\lambda$  yang berbeda memberikan nilai koefisien dan banyaknya variabel prediktor yang berbeda pula untuk setiap modelnya.



(a)



Gambar 5. Pergerakan koefisien untuk setiap parameter penyusutan  $\lambda$  pada (a) regresi Ridge, (b) LASSO, dan (c) Elastic-Net

Gambar 5 menunjukkan jalur pergerakan dari estimasi koefisien terhadap nilai  $\log(\lambda)$ . Jalur pergerakan koefisien sesuai dengan tanda positif dan negatif dari koefisien. Semakin besar parameter  $\lambda$  menunjukkan semakin banyak estimasi yang menyusut menjadi nol. Pada pergerakan estimasi regresi Ridge (a), jumlah parameter tidak mengalami penyusutan akibat  $\gamma = 0$ . Hal ini berbanding terbalik pada estimasi LASSO (b) dan Elastic-Net (c) dengan nilai  $\gamma$  tidak nol sehingga mengalami penyusutan banyaknya variabel prediktor.

Tabel 3. Nilai estimasi untuk setiap variabel prediktor yang terpilih

Variabel	Regresi Ridge $\gamma = 0$	LASSO $\gamma = 1$	Elastic-Net $\gamma = 0,6$
Intercept	$1,87 \times 10^{-16}$	$-1,01 \times 10^{-17}$	$7,00 \times 10^{-17}$
$x_1$	0,41531	0,66785	0,61279
$x_2$	0,06898	-	-
$x_3$	0,31809	0,33812	0,35623
$x_4$	0,11092	-	-
$x_5$	0,00823	-	-

Variabel	Regresi Ridge $\gamma = 0$	LASSO $\gamma = 1$	Elastic-Net $\gamma = 0,6$
$x_6$	0,64053	0,88997	0,84042
$x_7$	-0,17957	-0,12973	-0,17164
$x_8$	-0,40283	-0,68704	-0,59686
$x_9$	0,08259	0,08714	0,07689
$x_{10}$	-0,06581	-	-
$x_{11}$	-0,19147	-0,26746	-0,25309
$x_{12}$	-0,37697	-0,29810	-0,32479

Tabel 3 menunjukkan secara detail hasil estimasi koefisien untuk setiap metode yang digunakan. Variabel prediktor yang terpilih pada model LASSO sama halnya dengan variabel prediktor yang terpilih pada model Elastic-Net dengan tanda koefisien yang sama juga. Variabel ekspor, M2, kurs, dan kredit investasi perbankan tereliminasi pada seleksi variabel metode LASSO dan Elastic-Net sehingga tersisa 8 variabel yang masuk ke dalam persamaan model. Berdasarkan koefisien variabel, metode regresi Ridge, LASSO, dan Elastic-Net memiliki hasil dengan tanda koefisien yang sama. Variabel harga beras di perdagangan besar, NTP, PDB, dan cadangan devisa memiliki tanda negatif di ketiga model. Hal ini menandakan bahwa seluruh variabel yang masuk ke dalam model secara konsisten berpengaruh pada variabel respon di ketiga model.

Tabel 4. Perbandingan metode pada ketiga model inflasi

Metode	MSE
Regresi Ridge	0,311
Regresi LASSO	<b>0,265</b>
Elastic-Net	0,267

Pada penelitian ini, model terbaik ditentukan berdasarkan nilai MSE terkecil. Pada Tabel 4 disajikan nilai MSE dari ketiga model yang dibangun dengan metode regresi Ridge, LASSO, dan Elastic-Net. Nilai MSE pada model regresi LASSO dan Elastic-Net memiliki perbedaan yang sangat kecil. Berdasarkan variabel prediktor terpilih pada Tabel 3, model regresi LASSO dan Elastic-Net juga memiliki variabel prediktor yang sama. Meskipun memiliki perbedaan yang sangat kecil, model regresi LASSO terpilih sebagai model terbaik dengan MSE terkecil dan metode estimasi yang lebih sederhana daripada metode Elastic-Net untuk memodelkan data inflasi pada penelitian ini.

$$\hat{y} = -1,01 \times 10^{-17} + 0,66785x_1 + 0,33812x_3 + 0,88997x_6 - 0,12973x_7 - 0,68704x_8 + 0,08714x_9 - 0,26746x_{11} - 0,29810x_{12} \tag{6}$$

Pada persamaan 6 disajikan model terbaik menggunakan metode regresi LASSO. Terdapat 4 dari 12 variabel yang mengalami penyusutan dan terseleksi dari model. Variabel-variabel yang terseleksi dari model tersebut merupakan variabel prediktor yang tidak berpengaruh secara signifikan terhadap variabel respon inflasi sehingga koefisiennya disusutkan menjadi nol. Selanjutnya, terdapat 8 variabel prediktor yang berpengaruh secara signifikan terhadap variabel respon inflasi, diantaranya variabel total impor, jumlah uang beredar sempit (M1), suku bunga, harga minyak mentah dunia, harga beras di perdagangan besar, NTP, PDB, dan cadangan devisa. Variabel impor, M1, suku bunga, dan harga minyak mentah dunia memiliki tanda koefisien yang positif berarti bahwa peningkatan setiap variabel, meningkatkan persentase inflasi. Sebaliknya, variabel harga beras di perdagangan besar, NTP, PDB, dan cadangan devisa memiliki tanda koefisien yang negatif berarti bahwa peningkatan variabel, menurunkan persentase inflasi.

#### 4. KESIMPULAN

Diantara ketiga metode *high dimensional data*, yaitu metode regresi Ridge, LASSO, dan Elastic-Net, metode LASSO merupakan metode terbaik dengan MSE terkecil untuk memodelkan data inflasi di Indonesia pada tahun 2020-2024. Model regresi LASSO menghasilkan 8 variabel prediktor yang berpengaruh secara signifikan terhadap data inflasi, yaitu variabel impor, M1, suku bunga, dan harga minyak mentah dunia dengan tanda koefisien positif serta variabel harga beras di perdagangan besar, NTP, PDB, dan cadangan devisa dengan tanda koefisien negatif.

#### DAFTAR PUSTAKA

- [1] M. H. Meiditambua, S. A. Centauri, and M. R. Fahlevi, "Pengaruh inflasi terhadap pertumbuhan ekonomi: perspektif Indonesia," *J. ACITYA ARDANA*, vol. 3, no. 1, pp. 17–26, Nov. 2023, doi: 10.31092/jaa.v3i1.2045.
- [2] A. Rizani, R. A. Norrahman, I. Harsono, A. S. Yahya, and D. M. Syifa, "Efek inflasi terhadap daya beli masyarakat pada tinjauan ekonomi makro," *J. Int. Multidiscip. Res.*, vol. 1, no. 2, pp. 344–358, 2023, doi: <https://doi.org/10.62504/4w0gee05>.
- [3] S. Djambak, "Faktor dominan mempengaruhi inflasi di Indonesia," *J. Ekon. Pembang.*, vol. 6, no. 1, pp. 23–38, Jun. 2008, doi: 10.29259/jep.v6i1.4844.
- [4] B. Beureukat, "Pengaruh suku bunga terhadap inflasi di Indonesia," *Oikonomia J. Manaj.*, vol. 18, no. 1, p. 39, Jan. 2022, doi: 10.47313/oikonomia.v18i1.1546.
- [5] H. Y. T. Kalalo, T. O. Rotinsulu, and M. T. B. Maramis, "Analisis faktor-faktor yang mempengaruhi inflasi di Indonesia periode 2000-2014," *J. Berk. Ilm. Efisiensi*, vol. 16, no. 01, pp. 706–717, 2016, [Online]. Available: <https://ejournal.unsrat.ac.id/index.php/jbie/article/view/11653>
- [6] A. E. Hoerl and R. W. Kennard, "Ridge regression: biased estimation for nonorthogonal problems," *Technometrics*, vol. 12, no. 1, pp. 55–67, 1970, doi: 10.1080/00401706.1970.10488634.
- [7] R. Tibshirani, "Regression shrinkage and selection via the Lasso," *J. R. Stat. Soc. Ser. B*, vol. 58, no. 1, pp. 267–288, 1996, [Online]. Available: [jstor.org/stable/2346178](http://www.jstor.org/stable/2346178)
- [8] H. Zou and T. Hastie, "Regularization and variable selection via the elastic net," *J. R. Stat. Soc. Ser. B Stat. Methodol.*, vol. 67, no. 2, pp. 301–320, Apr. 2005, doi: 10.1111/j.1467-9868.2005.00503.x.
- [9] A. K. M. E. Saleh, M. Arashi, and B. M. G. Kibria, *Theory of Ridge Regression Estimation with Applications*, vol. 5, no. 1. John Wiley & Sons, Inc, 2019.
- [10] W. K. Hardle and D. D. Prastyo, "Embedded predictor selection for default risk calculation: a southeast asian industry study," in *Handbook of Asian Finance*, vol. 1, Elsevier, 2014, pp. 131–148. [Online]. Available: <http://dx.doi.org/10.1016/B978-0-12-800982-6.00007-X>