

BAB II

TINJAUAN PUSTAKA

2.1 Inflasi

Inflasi adalah suatu keadaan yang mengakibatkan naiknya harga secara umum atau proses meningkatnya harga-harga secara umum dan terus menerus (berkesinambungan) [5]. Inflasi dengan kata lain merupakan proses menurunnya nilai mata uang secara kontinu. Inflasi merupakan proses suatu kejadian dan bukan tinggi rendahnya tingkat harga. Sehingga, jangan menganggap kalau tingkat harga tinggi itu berarti inflasi tinggi. Inflasi terjadi kalau proses kenaikan harga yang terus menerus dan saling pengaruh mempengaruhi. Dalam pengertian inflasi tersebut terdapat 3 poin penting yaitu:

1. Dalam inflasi, terjadi kecenderungan peningkatan harga
2. Peningkatan harga dalam inflasi terjadi terus menerus (kontinu) bukan hanya sekali atau dua kali saja dalam suatu waktu saja.
3. Berhubungan dengan pengertian tingkat harga umum, tidak terbatas pada beberapa komoditas saja ataupun pada satu waktu saja.

Indikator yang sering digunakan untuk mengukur tingkat inflasi adalah Indeks Harga Konsumen (IHK) [6]. Indeks harga konsumen adalah ukuran rata-rata perubahan harga dari suatu paket komoditas dalam suatu kurun waktu tertentu.

2.2 Kebutuhan Hidup Layak (KHL)

Berdasarkan Peraturan Menteri Tenaga Kerja dan Transmigrasi RI No. 17 tahun 2005 tentang Komponen dan Pelaksanaan Tahapan Pencapaian Kebutuhan Hidup Layak, menyatakan bahwa Kebutuhan Hidup Layak adalah standar kebutuhan yang harus dipenuhi oleh seorang pekerja lajang untuk dapat hidup layak baik secara fisik, nonfisik dan sosial untuk kebutuhan satu bulan. Peraturan mengenai KHL, diatur dalam UU No.13 tahun 2003 tentang Ketenagakerjaan. Pembahasan lebih dalam mengenai ketentuan KHL, diatur dalam Keputusan Menteri Tenaga Kerja No. 17 tahun 2005 tentang Komponen dan Tahapan Pencapaian Kebutuhan Hidup Layak. Namun, Keputusan Menteri Tenaga Kerja No. 17 tahun 2005 direvisi oleh Keputusan Menteri Tenaga Kerja No. 13 tahun 2012 tentang Perubahan Penghitungan Kebutuhan Hidup Layak. Berdasarkan Peraturan Menteri Tenaga Kerja dan Transmigrasi RI No. 17 tahun 2005 komponen kebutuhan hidup layak untuk pekerja lajang dalam sebulan dengan 3000 kilo kalori perhari.

Jumlah jenis kebutuhan yang semula 46 jenis dalam Keputusan Menteri Tenaga Kerja No. 17 tahun 2005 menjadi 60 jenis KHL dalam Keputusan Menteri Tenaga Kerja No. 13 tahun 2012. Selain penambahan 14 jenis baru KHL tersebut, juga terdapat penyesuaian/penambahan jenis kualitas dan kuantitas KHL serta perubahan jenis kebutuhan. Berikut komponen komponen makanan dan minuman standar Kebutuhan Hidup Layak berdasarkan Keputusan Menteri Tenaga Kerja No. 13 tahun 2012 :

Tabel 2.1 Standar KHL (Komponen Makanan dan Minuman)

No	Komponen	Kualitas/Kriteria	Jumlah Kebutuhan
I. MAKANAN DAN MINUMAN			
1	Beras Sedang	Sedang	10 kg
2	Sumber Protein :		
	a. Daging	Sedang	0.75 kg
	b. Ikan Segar	Baik	1.2 kg
	c. Telur Ayam	Telur ayam ras	1 kg
3	Kacang-kacangan : tempe/tahu	Baik	4.5 kg
4	Susu bubuk	Sedang	0.9 kg
5	Gula pasir	Sedang	3 kg
6	Minyak goreng	Curah	2 kg
7	Sayuran	Baik	7.2 kg
8	Buah-buahan (setara pisang/pepaya)	Baik	7.5 kg
9	Karbohidrat lain (setara tepung terigu)	Sedang	3 kg
10	Teh atau Kopi	Celup/Sachet	2 Dus isi 25
11	Bumbu-bumbuan	Nilai 1 s/d 10	15%

Selengkapnya mengenai komponen komponen Kebutuhan Hidup Layak berdasarkan Keputusan Menteri Tenaga Kerja No. 13 tahun 2012 ada pada lampiran.

2.3 Peramalan

Peramalan adalah kegiatan untuk memperkirakan apa yang akan terjadi pada masa yang akan datang [7]. Peramalan merupakan bagian vital bagi setiap organisasi bisnis dan untuk setiap pengambilan keputusan manajemen yang sangat signifikan.

Peramalan runtun waktu adalah serangkaian pengamatan terhadap suatu variabel yang diambil dari waktu ke waktu dan dicatat secara berurutan menurut urutan waktu [8].

2.4 Model Runtun Waktu

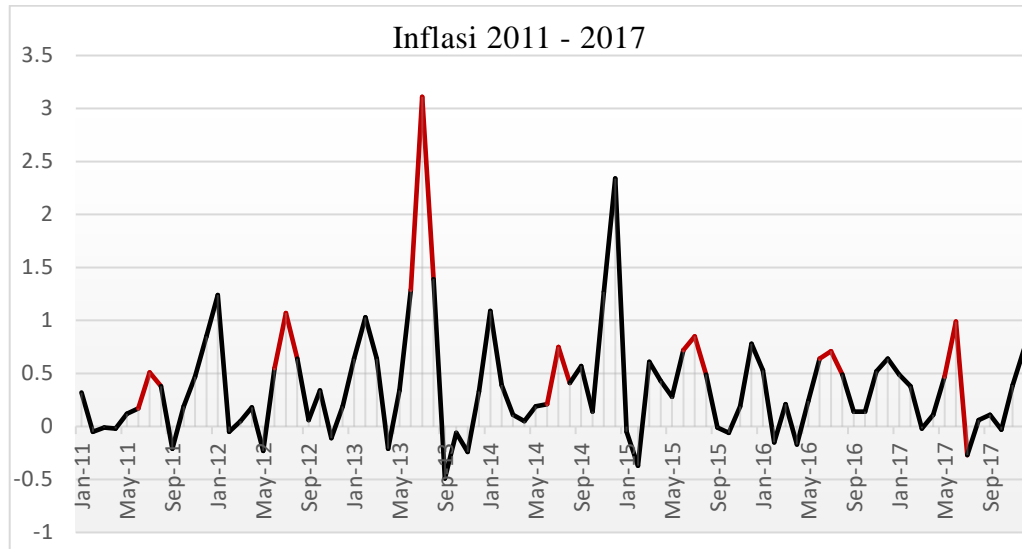
Peramalan merupakan alat bantu yang penting dalam perencanaan yang efektif dan efisien [9]. Teknik peramalan terbagi menjadi dua bagian, yang pertama metode peramalan subjektif dan metode peramalan objektif [10]. Metode peramalan subjektif mempunyai model kualitatif dan metode peramalan objektif mempunyai dua model, yaitu model runtun waktu dan model kausal. Model kualitatif berupaya memasukkan faktor-faktor subyektif dalam model peramalan, model ini akan sangat bermanfaat jika data kuantitatif yang akurat sulit diperoleh. Contoh dari metode ini ialah metode *delphi*, opini juri eksekutif, komposit kekuatan dan survey pasar konsumen.

Model runtun waktu merupakan model yang digunakan untuk memprediksi masa depan dengan menggunakan data historis. Dengan kata lain, model runtun waktu mencoba melihat apa yang terjadi pada suatu kurun waktu tertentu dan menggunakan data masa lalu untuk memprediksi. Contoh dari model runtun waktu ini antara lain Moving Average, ARIMA, Naive dan proyeksi *trend*.

2.5 Pola Data Musiman (*Seasonal*)

Pola data musiman adalah salah satu dari 4 bentuk pola data deret waktu yang menunjukkan perulangan indeks pada kurun waktu tertentu seperti hari, minggu, bulan atau kuartal. Variasi musiman adalah fluktuasi yang muncul secara reguler setiap tahun yang biasanya disebabkan oleh iklim, kebiasaan (mempunyai pola tetap dari waktu ke waktu). Contoh yang menunjukkan variasi musiman

seperti nilai inflasi akan meningkat pada saat hari raya, penjualan barang pokok akan meningkat pada kurun waktu tertentu.



Gambar 2.1 Contoh Pola Data Musiman

Gambar 2.1 adalah data runtun waktu inflasi kota Bandung menunjukkan pola data musiman, pola data berulang pada kurun waktu tertentu, seperti hari, minggu, bulan atau kuartal.

2.6 Metode Seasonal Autoregressive Integrated Moving Average (SARIMA)

Metode *Seasonal Autoregressive Integrated Moving Average* atau lebih dikenal dengan metode SARIMA adalah metode peramalan runtun waktu untuk data model stokastik dengan pola data musiman. Metode SARIMA dapat dipakai untuk data yang bersifat musiman yang dapat memberikan hasil peramalan yang tidak jauh beda dengan data aktual.

Langkah-langkah pemodelan *Seasonal Autoregressive Integrated Moving*

Average (SARIMA) adalah [11]:

1. Proses identifikasi model.
2. Pendugaan parameter model.
3. Pemeriksaan residual(sisaan).
4. Menggunakan model untuk peramalan jika model memenuhi syarat.

Secara umum, notasi SARIMA adalah :

$$\text{SARIMA } (p,d,q) (P,D,Q)^s \quad (1)$$

Dimana :

p,d,q : Bagian tidak musiman dari model

$(P,D,Q)^s$: Bagian musiman dari model

s : Jumlah periode per musim

Rumus umum dari SARIMA $(p,d,q)(P,D,Q)^s$ adalah sebagai berikut :

$$\Phi_p B^s \phi_p(B) (1-B)^d (1-B^s)^D Z_t = \theta_q(B) \Theta_q(B^s) a_t \quad (2)$$

dengan :

$\phi_p(B)$: AR *Non Seasonal*

$\Phi_p B^s$: AR *Seasonal*

$(1-B)^d$: *differencing non seasonal*

$(1-B^s)^D$: *differencing seasonal*

$\theta_q(B)$: MA *non seasonal*

$\Theta_q(B^s)$: MA *seasonal*

Tahap differencing adalah olah data dengan menghitung nilai perbedaan antara Z_t dengan Z_{t-1} . Data dihitung selisihnya dengan data periode sebelumnya. Hal ini dilakukan untuk menghilangkan unsur tren pada data.

Dalam menetapkan nilai p dan q dapat dibantu dengan mengamati pola *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF) dengan acuan pada tabel berikut [12].

Tabel 2.2 Pola ACF dan PACF untuk Identifikasi Parameter Tentatif

Model	Pola ACF	Pola PACF
AR (p)	Menurun secara cepat (<i>dies down</i>)	Muncul <i>spike</i> yang signifikan hingga <i>lag</i> ke- p dan <i>cut off</i> setelah <i>lag</i> ke- p
MA (q)	muncul <i>spike</i> yang signifikan hingga <i>lag</i> ke- q dan <i>cut off</i> setelah <i>lag</i> ke- q	menurun secara cepat (<i>dies down</i>)
ARMA (p,q)	menurun secara cepat (<i>dies down</i>)	menurun secara cepat (<i>dies down</i>)
AR (p) atau MA (q)	muncul <i>spike</i> yang signifikan hingga <i>lag</i> ke- q dan <i>cut off</i> setelah <i>lag</i> ke- q	muncul <i>spike</i> yang signifikan hingga <i>lag</i> ke- p dan <i>cut off</i> setelah <i>lag</i> ke- p

Tahapan pemeriksaan residual terbagi menjadi pemeriksaan L-jung Box (*white noise*), dan kenormalan residual. Pengujian untuk memenuhi asumsi *white noise* dilakukan pengujian L-jung Box dengan hipotesa :

$$H_0 : \rho_1 = \rho_2 = \rho_{\dots} = \rho_k = 0 \quad (3)$$

$$H_1 : \text{minimal ada satu nilai } \rho_k \neq 0, \text{ dimana } k = 1, 2, \dots, K$$

dengan statistik uji :

$$Q = n(n + 2) \sum_{k=1}^K (n - k)^{-1} \hat{\rho}_k \quad (4)$$

Dimana n adalah banyak pengamatan dan $\hat{\rho}_k$ adalah sampel ACF residual pada lag ke- k , dan K adalah lag maksimum. Daerah kritis $= Q > \chi^2_{(\alpha, K-m)}$ atau $P\text{-value} < \alpha = 5\%$.

Pengujian kenormalan distribusi dapat dilakukan uji Kolmogorov-Smirnov dengan hipotesa:

H_0 : residual berdistribusi normal

H_1 : residual tidak berdistribusi normal

Dengan statistik uji :

$$D = \sup_x [|F_n(x) - F_0(x)|] \quad (5)$$

Dimana D adalah nilai deviasi absolut maksimum antara $F(x)_n$ dan $F_0(x)$, \sup masing-masing merupakan fungsi *Kolmogorov* peluang kumulatif yang dihitung dari data sampel, fungsi peluang kumulatif distribusi normal, dan nilai supremum untuk semua α_t . Daerah Kritis: Tolak H_0 jika $D \geq D_{(1-\alpha, n)}$ atau $P\text{-value} < \alpha$, dengan $\alpha = 5\%$. Model terbaik ditentukan berdasarkan nilai galat, semakin kecil nilai galat yang dihasilkan maka semakin baik model tersebut sekaligus menentukan model tersebut layak untuk digunakan pada peramalan.

2.7 Single Exponential Smoothing

Metode ini juga sering disebut perataan eksponensial tunggal yang biasa dipakai trader untuk peramalan jangka pendek. Model mengansumsikan jika data berfluktuasi di sekitar nilai mean yang tetap, dan juga tanpa trend atau pola pertumbuhan konsisten [13]. Tidak seperti Moving Average, Single Exponential Smoothing akan menawarkan penekanan yang lebih besar pada

runtun waktu melalui penggunaan sebuah konstanta smoothing. Rumus dasarnya adalah:

$$S_{t+1} = (\alpha * X_t) + (1 - \alpha) S_{t-1} \quad (6)$$

Dimana :

α = konstanta pemulusan, nilai dari 0 sampai 1. Bila α mendekati nol, smoothing terjadi lebih lambat. Nilai terbaik untuk α adalah yang menghasilkan kesalahan kuadrat rata-rata terkecil (MSE) . Ada berbagai cara untuk melakukan ini, namun metode yang populer adalah algoritma Levenberg-Marquardt .

t = periode waktu

Ada formula alternatif. Sebagai contoh, Roberts (1959) menggantikan y_{t-1} dengan pengamatan saat ini, y_t . Rumus lain menggunakan ramalan untuk periode sebelumnya dan periode berjalan:

$$F_t = F_{t-1} + \alpha(A_{t-1} - F_{t-1}) \quad (7)$$

Dimana :

F_{t-1} = perkiraan untuk periode sebelumnya,

A_{t-1} = Permintaan nilai aktual untuk periode tersebut,

α = berat (harus antara 0 dan 1). Semakin dekat ke nol, semakin kecil bobotnya

2.8 Penggabungan Metode

Salah satu metode peramalan yang paling dikembangkan saat ini adalah runtun waktu, yakni menggunakan pendekatan kuantitatif dengan data masa

lampau dikumpulkan dan dijadikan acuan untuk peramalan masa depan. Teknik peramalan time series terbagi menjadi dua bagian. Pertama, model peramalan yang didasarkan pada model matematika statistik seperti moving average, exponential smoothing, regresi, dan ARIMA (Box Jenkins). Kedua, model peramalan yang didasarkan pada kecerdasan buatan seperti neural network, algoritma genetika, simulated annealing, genetic programming, klasifikasi, dan hybrid. Dengan demikian kita mengetahui bahwa dalam time series forecasting, ilmu statistik dan jaringan syaraf pun termasuk dalam bidang kajian penelitiannya.

Kombinasi yang pernah dicobakan untuk peramalan time series adalah model Neural Network dengan model ARIMA [14]. Ada tiga hal yang menjadi alasan penggunaan pengkombinasian model ARIMA dan Neural Network [15]. Pertama, sering kali terjadi kesulitan untuk menerapkan penggunaan model linier atau model non linier pada suatu permasalahan runtun waktu, sehingga model kombinasi ini menjadi alternatif yang lebih mudah. Kedua, dalam kenyataannya runtun waktu jarang yang linier atau nonlinier dan sering mengandung keduanya, dimana tidak hanya model ARIMA dan Neural Network masing-masing dapat memodelkan setiap kasusnya, sehingga pengkombinasian ini dapat digunakan untuk memodelkan runtun waktu yang mengandung linier dan non linier. Ketiga, dalam beberapa literatur peramalan menyatakan bahwa tidak ada model tunggal yang terbaik pada setiap situasi.

2.9 Evaluasi Hasil Peramalan

Evaluasi hasil peramalan digunakan untuk mengetahui keakuratan hasil peramalan yang telah dilakukan terhadap data yang sebenarnya. Terdapat banyak metode untuk melakukan perhitungan kesalahan peramalan. Beberapa metode yang digunakan adalah :

2.9.1 Mean Square Error (MSE)

Cara yang cukup sering digunakan dalam mengevaluasi hasil peramalan yaitu dengan menggunakan metode *Mean Squared Error* (MSE). Dengan menggunakan MSE, *error* yang ada menunjukkan seberapa besar perbedaan hasil estimasi dengan data aktual. MSE merupakan rata-rata selisih kuadrat antara nilai yang diramalkan dan yang diamati. Kekurangan penggunaan MSE adalah bahwa metode evaluasi ini cenderung menonjolkan nilai deviasi yang besar karena adanya pengkuadratan.

$$MSE = \frac{\sum(\text{kesalahan peramalan})^2}{n} \quad (8)$$

n = jumlah periode data

2.9.2 Mean Absolute Deviation (MAD)

Mean Absolute Deviation adalah ukuran kesalahan peramalan keseluruhan untuk sebuah model. Nilai MAD dihitung dengan mengambil jumlah nilai absolut dari kesalahan peramalan dibagi dengan jumlah periode data (n).

$$MAD = \frac{\sum|\text{data aktual}-\text{peramalan}|}{n} \quad (9)$$

n = jumlah periode data

2.9.3 Mean Absolute Percentage Error (MAPE)

Masalah yang sering muncul pada perhitungan akurasi dengan metode perhitungan MSE dan MAD adalah nilainya bergantung pada besarnya nilai dari *item* yang diramalkan. Apabila satuan dari item yang diramalkan adalah ribuan atau jutaan, nilai dari MAD dan atau MSE bisa jadi sangat besar. Untuk menghindari hal ini, dapat digunakan metode penghitungan akurasi dengan menghitung *Mean Absolute Percentage Error* (MAPE) [16]. MAPE adalah nilai rata-rata dari selisih absolut antara nilai hasil peramalan dan nilai aktual, nilai ditunjukkan dalam persentase.

$$\text{MAPE} = \sum_{t=1}^T \frac{|\text{peramalan} - \text{aktual}|}{\text{aktual}} * 100\% \quad (10)$$