

BAB II

LANDASAN TEORI

2.1 Inflasi

Inflasi merupakan kenaikan harga-harga secara umum dan terus menerus, namun kenaikan harga yang terjadi pada satu atau dua barang tidak dapat dikatakan sebagai inflasi kecuali kenaikan barang tersebut mempengaruhi kenaikan harga barang lainnya. Berdasarkan international best practice, indikator inflasi antara lain:

- 1) Indeks Harga Konsumen(IHK) adalah suatu indeks yang menghitung rata-rata perubahan harga dalam satu periode, dari suatu kumpulan barang dan jasa yang dikonsumsi oleh masyarakat dalam rentang waktu tertentu.
- 2) Indeks Harga Perdagangan Besar(IHPB). Harga Perdagangan Besar dari suatu komoditi barang ialah harga transaksi yang terjadi antara penjual/pedagang besar pertama dengan pembeli/pedagang besar berikutnya/pedagang lainnya dalam jumlah besar padasar pertama atas suatu komoditas.
- 3) Deflator Produk Domestik Bruto (DPDB) menggambarkan pengukuran level harga barang akhir dan jasa yang diproduksi dalam suatu ekonomi(negeri)

Terdapat pengelompokan yang dipublikasikan BPS saat ini yaitu disagregasi inflasi. Disagregasi inflasi IHK dikelompokkan menjadi :

- 1) Inflasi Inti, yaitu komponen inflasi yang sifatnya cenderung tetap di dalam

laju inflasi. Komponen ini dipengaruhi oleh faktor fundamental seperti permintaan-penawaran, lingkungan eksternal dan ekspektasi inflasi dari pedagang dan konsumen

- 2) Inflasi non Inti, yaitu komponen inflasi yang memiliki tingkat volatilitas yang tinggi. Komponen dari inflasi non inti terdiri dari : Inflasi Komponen Bergejolak dan Inflasi Komponen Harga yang diatur Pemerintah.

Berdasarkan tingkatannya, inflasi dibagi menjadi 4 diantaranya :

1. Inflasi Ringan yakni suatu inflasi yang mudah untuk dikendalikan dan belum begitu mengganggu perekonomian suatu negara. Terjadi kenaikan harga suatu barang atau jasa secara umum, yaitu di bawah 10% per tahun dan dapat dikendalikan.
2. Inflasi Sedang yakni suatu inflasi yang dapat menurunkan tingkat kesejahteraan masyarakat berpenghasilan tetap, namun belum membahayakan kegiatan perekonomian suatu negara. Inflasi berada di kisaran 10% – 30% per tahun.
3. Inflasi Berat adalah suatu inflasi yang mengakibatkan kekacauan perekonomian di suatu negara. Pada kondisi tersebut masyarakat lebih memilih untuk menyimpan barang dan tidak mau menabung karena bunganya jauh lebih rendah ketimbang nilai inflasi. Inflasi ini berada pada kisaran 30% – 100% per tahun.
4. Inflasi Sangat Berat (Hyperinflation) merupakan inflasi yang telah mengacaukan perekonomian suatu negara dan sangat sulit untuk dikendalikan meskipun dapat dilakukan kebijakan moneter dan fiskal.

Inflasi ini juga berada di kisaran 100% ke atas per tahun.

Inflasi juga dapat disebabkan dari sisi permintaan, sisi penawaran dan ekspektasi, ataupun gabungan dari ketiga faktor tersebut. Adapun faktor-faktor tersebut dijelaskan dalam buku Kebanksentralan seri inflasi (Suseno dan Siti Astiyah,2009:11-17) yaitu sebagai berikut :

1. Inflasi yang disebabkan faktor permintaan (*Demand Pull Inflation*)

Inflasi yang disebabkan oleh permintaan timbul karena adanya pertambahan jumlah uang beredar dalam jangka pendek. Bertambahnya jumlah uang beredar mengakibatkan suku bunga mengalami penurunan sehingga jumlah konsumsi dan investasi meningkat secara keseluruhan. Dengan adanya peningkatan permintaan maka secara otomatis mendorong peningkatan harga-harga secara keseluruhan. Pengertian inflasi permintaan dalam buku kebankentralan seri inflasi (Suseno dan Siti Astiyah,2009:13) Inflasi permintaan atau demand pull inflation adalah inflasi yang timbul sebagai hasil interaksi antara permintaan dan penawaran terhadap barang dan jasa domestik dalam jangka panjang.

2. Inflasi Penawaran atau *cost push inflation/ supply shock inflation*.

Inflasi penawaran adalah inflasi yang disebabkan faktor penawaran yang memicu kenaikan harga penawaran atas suatu barang, termasuk barang-barang yang harus diimpor, serta harga barang-barang yang dikendalikan oleh pemerintah seperti kenaikan harga minyak dunia, kenaikan harga bahan bakar minyak (BBM) dan kenaikan tarif dasar

listrik (TDL). Inflasi penawaran disebabkan oleh adanya kenaikan biaya produksi secara terus-menerus dalam jangka waktu tertentu.

3. Inflasi Campuran (*Mixed Inflation*)

Inflasi campuran merupakan inflasi yang disebabkan oleh kenaikan permintaan dan kenaikan penawaran, perilaku permintaan dan penawaran tidak seimbang ataupun permintaan terhadap barang dan jasa bertambah.

4. Inflasi Ekspektasi (*Expected Inflation*)

Inflasi tidak hanya disebabkan oleh faktor permintaan dan penawaran, namun inflasi dapat disebabkan oleh adanya ekspektasi para pelaku ekonomi atau disebut inflasi ekspektasi (Gordon,2007:15). Inflasi ekspektasi adalah inflasi yang terjadi akibat adanya perilaku masyarakat secara umum yang bersifat adatif atau foward looking.

2.2 Peramalan

Peramalan (Bahasa Inggris = *Forecasting*) merupakan suatu teknik analisa perhitungan yang dilakukan dengan pendekatan kualitatif maupun dengan pendekatan kuantitatif untuk memperkirakan kejadian dimasa depan dengan menggunakan referensi data-data di masa lalu. Peramalan bertujuan untuk memperkirakan prospek ekonomi dan kegiatan usaha serta pengaruh lingkungan terhadap prospek ekonomi dan kegiatan usaha tersebut. Peramalan atau Forecasting adalah bagian terpenting bagi setiap perusahaan ataupun organisasi bisnis dalam setiap pengambilan keputusan manajemen. Peramalan itu sendiri bisa menjadi dasar bagi perencanaan jangka pendek, menengah maupun jangka

panjang suatu perusahaan. Di dalam sebuah peramalan (*forecasting*) dibutuhkan sedikit mungkin kesalahan (*error*) di dalamnya. Agar dapat meminimalisir tingkat kesalahan tersebut, maka akan lebih baik jika peramalan tersebut dilakukan dalam satuan angka atau kuantitatif. Peramalan merupakan prediksi nilai-nilai sebuah variable berdasarkan pada nilai dari variable yang diketahui atau pada data historis dan pengalaman variable tersebut (Makridakis, 1999: Lampiran 24), peramalan juga merupakan proses menganalisis data masa lalu, dan data saat ini untuk menentukan data dimasa mendatang (Santoso, 2009:7). Berdasarkan pendapat para ahli peramalan merupakan kegiatan memperkirakan hal yang akan datang menggunakan data masa lalu.

2.3 Time Series

Data time series merupakan sekumpulan data berdasarkan interval tertentu, seperti: harian, mingguan, bulanan, dan tahunan. Peramalan merupakan upaya untuk memprediksi kejadian yang akan datang. Peramalan mempunyai dua sifat yaitu berdasarkan pada data yang sudah ada yaitu kuantitatif dan berdasarkan pendapat para pakar yaitu kualitatif. Peramalan data time series adalah meramalkan nilai yang akan datang berdasarkan data masa lalu pada periode tertentu. Tujuan dari peramalan adalah untuk mengurangi tingkat ketidakpastian di mana penilaian manajemen harus dilakukan. Peramalan sendiri bertumbuh karena kompleksitas lingkungan organisasi yang terus meningkat sehingga dibutuhkan pengambilan keputusan yang semakin sistematis, selain itu pengembangan metode peramalan dan pengetahuan telah memungkinkan adanya

penerapan langsung oleh praktisi. Tahapan dalam melakukan peramalan dimulai dengan mendefinisikan permasalahan yang terjadi kemudian dilakukan pengumpulan informasi untuk mendukung penyelesaian masalah setelah itu dilakukan analisa terhadap data tersebut untuk menentukan metode peramalan yang cocok digunakan. Tahap selanjutnya adalah membangun model yang akan digunakan dalam tahap peramalan dan menguji model tersebut untuk mengetahui tingkat akurasi dari model yang dibangun. Apabila model sudah diuji, model dapat diterapkan dengan memasukan data input untuk menghasilkan nilai ramalan yang diinginkan. Dalam melakukan peramalan didapatkan dua metode yang dapat digunakan yaitu metode kuantitatif dan kualitatif. Perbedaan dari kedua metode tersebut adalah pada metode kualitatif lebih subjektif karena hanya berdasarkan pengetahuan dan pengamatan penulis sedangkan metode kuantitatif bersifat objektif karena berdasarkan histori data pada periode sebelumnya. Peramalan dengan menggunakan metode kuantitatif dapat dilakukan ketika terdapat tiga kondisi sebagai berikut :

- 1) Terdapat informasi yang cukup mengenai masa lalu
- 2) Informasi tersebut kemudian dapat dikuantitatifkan menjadi data numerik
- 3) Dapat diasumsikan bahwa beberapa aspek pola masa lalu akan berlanjut di masa mendatang.

Dalam metode time series sendiri ada beberapa metode, yaitu metode *moving average*, *exponential smoothing*, dekomposisi, dan ARIMA, untuk penjelasan lebih lanjut, akan dijelaskan sebagai berikut :

1. *Moving average*

Moving average adalah metode peramalan dengan mengambil sekelompok nilai pengamatan, mengambil rata-ratanya, lalu menggunakan rata-rata tersebut untuk meramalkan masa depan (Subagyo, 1984:7). Metode *moving average* merupakan metode yang digunakan untuk menghilangkan fluktuasi yang terjadi, apabila terdapat data yang ireguler, maka untuk menghilangkannya menggunakan proses mencari mean, metode ini berasumsi bahwa data masa lalu relative sama dengan data saat ini, dan untuk meramalkan saat masa depan. Dengan demikian proses rata-rata ini dilakukan secara kontinyu dari data masa lalu sampai ke data saat ini. (Santoso, 2009:76). Jadi bisa disimpulkan bahwa moving average adalah metode yang mengambil nilai rata-rata dari data masa lalu hingga data saat ini untuk meramalkan keadaan masa depan.

2. *Exponential Smoothing*

Metode *exponential smoothing* merupakan perkembangan dari metode *moving average*, dimana metodenya sama seperti *moving average*, metode *exponential smoothing* pun ada beberapa macam, yaitu tunggal, ganda dan yang lebih rumit lagi. Semuanya mempunyai karakteristik sama, yaitu nilai yang lebih baru akan mendapatkan beban yang lebih besar dari pada nilai-nilai pada sebelumnya (Makridakis, 1999:101). Metode *exponential smoothing* adalah metode yang hampir sama dengan metode *moving average*, perbedaannya dimana untuk metode *exponential smoothing*, data pada tahun sebelumnya mempunyai bobot yang lebih besar dari data saat ini (Santoso, 2009:86). Jadi dapat disimpulkan bahwa

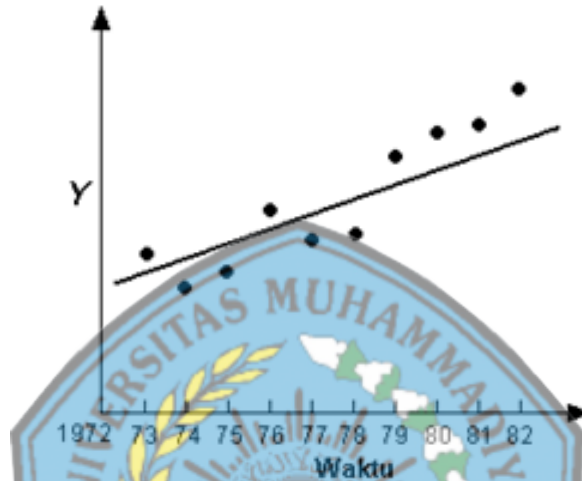
metode ini hampir sama dengan metode *moving average*, yang berbeda pada metode ini adalah data masa lalu yang mempunyai bobot lebih besar dari pada data sekarang. Metode *exponential smoothing* ini dibagi lagi menjadi 3, yaitu *single exponential smoothing*, *double exponential smoothing* dan *triple exponential smoothing*.

3. Dekomposisi

Metode dekomposisi merupakan metode yang memecah data menjadi beberapa pola, dan mengidentifikasi pola-pola tersebut secara terpisah, sehingga didapatkan tingkat keakuratan yang tinggi (Makridakis, 1999:150). Metode dekomposisi merupakan metode yang digunakan apabila data mempunyai 4 pola, yaitu trend, siklis, musiman, dan irregular, ketika pola-pola tersebut didapatkan, maka data tersebut di pisah-pisahkan, dan dilakukan peramalan, sehingga mendapatkan hasil yang lebih akurat (Santoso, 2009:132). Jadi menurut pendapat dua ahli diatas dapat disimpulkan bahwa dekomposisi merupakan peramalan yang menggunakan data yang mengandung 4 unsur pola data yaitu, trend, siklis, musiman dan irregular, yang berguna untuk mendapatkan tingkat keakuratan peramalan yang tinggi. Pola data dalam peramalan time series dibagi menjadi 4 jenis (Makridakis, et.al.,1995) yaitu :

1. *Trend* (Tren)


Pola data trend menunjukkan pergerakan data yang cenderung meningkat atau menurun dalam jangka waktu tertentu. Pola data *trend* dapat dilihat pada gambar 2.1.



Gambar 2.1. Pola Data Tren

2. *Seasonal* (musiman)

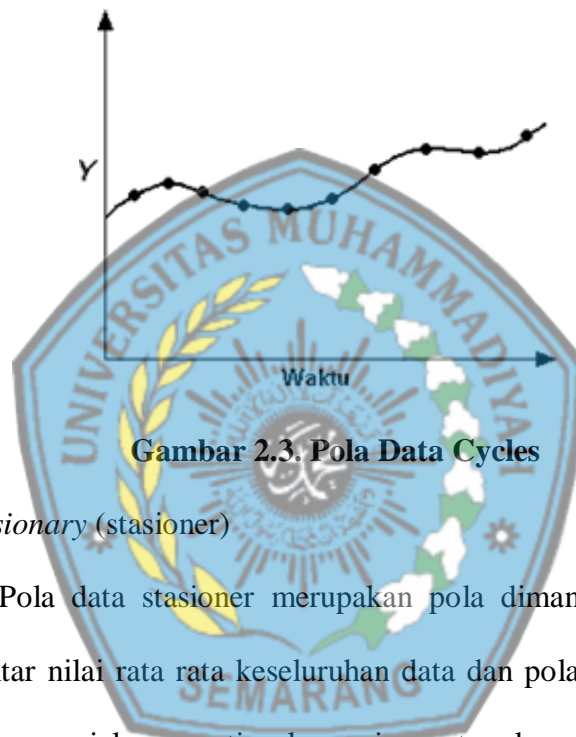
Pola data musiman merupakan pola data yang berhubungan dengan faktor yang bersifat eventual, seperti libur sekolah atau hari raya. Pola data musiman dapat dilihat pada gambar 2.2



Gambar 2.2. Pola Data Seasonal

3. *Cycles* (siklus)

Pola data siklus merupakan pola dimana variasi data bergelombang pada durasi yang lebih panjang dan bervariasi dari satu siklus ke siklus yang lain. Pola data Siklus dapat dilihat pada gambar 2.3



Gambar 2.3. Pola Data Cycles

4. *Stasionary* (stasioner)

Pola data stasioner merupakan pola dimana data befluktuasi di sekitar nilai rata rata keseluruhan data dan pola ini tidak membentuk pola yang jelas seperti pola musiman, trend maupun pola siklus. Pola data stasioner dapat dilihat pada gambar 2.4



Gambar 2.4. Pola Data Stasionary

3 *Box-Jenkins* (ARIMA)

ARIMA adalah suatu metode yang mengintegrasikan antara dua metode yaitu metode *autoregressif* dan metode *moving average* metode ini menggunakan data masalah dan sekarang dan memiliki tingkat keakuratan tinggi untuk peramalan jangka pendek, ARIMA sendiri bisa dikembangkan menjadi model musiman dan menjadi SARIMA (Makridakis, 1999:466). Metode ARIMA adalah metode peramalan yang murni menggunakan data masalah saja, dan pada metode ini tidak perlu menentukan mana variable dependen dan independennya, pada ARIMA data yang diperoleh tidak perlu di pecah-pecah menjadi pola-pola data seperti pada dekomposisi (Santoso, 2009:152).

2.4 Autocorrelation Function (ACF) dan Partial Autocorrelation Function (PACF)

Autokorelasi digunakan untuk menentukan koefisien korelasi pada deret berkala dan untuk mempelajari pola data termasuk trend atau musiman. Fungsi autokorelasi merupakan semua himpunan autokorelasi untuk semua lag k.

$$\rho_k = \frac{\text{cov}(X_t X_{t-k})}{\sqrt{\text{Var}(X_t) \text{Var}(X_{t-k})}} = \frac{y_k}{y_0} \quad (2.1)$$

Keterangan :

ρ_k = autokorelasi pada lag k

t = waktu pengamatan

Estimasi ρ_k atau $\hat{\rho}_k$ dilakukan dengan menggunakan autokorelasi dari

pengamatan pada waktu t sampai pengamatan pada waktu $t + k$, rumus yang digunakan adalah sebagai berikut (Tsay, 2010: 31):

$$\hat{\rho}_k = \frac{\sum_{t=k+1}^n (X_t - \bar{X})(X_{t-k} - \bar{X})}{\sum_{t=1}^n (X_t - \bar{X})^2} \quad (2.2)$$

Keterangan :

r_k = autokorelasi pada lag k

\bar{X} = rata – rata dari pengamatan

X_t = pengamatan pada waktu ke – t

Signifikansi autokorelasi juga dapat ditentukan dengan melihat correlogram. Correlogram adalah plot antara lag k dengan $r_k = 0$ yang direpresentasikan dengan garis putus-putus berwarna merah, sedangkan lag data direpresentasikan dengan garis tegak berwarna biru. Selanjutnya Partial Autocorrelation Function (PACF) atau autokorelasi parsial digunakan untuk mengukur korelasi antara X_t dengan $X_t - k$ setelah $X_t - 1, X_t - 2, \dots, X_t - k$ dihilangkan. Autokorelasi parsial diformulasikan seperti berikut. Autokorelasi parsial diformulasikan seperti berikut (Montgomery, Jennings & Kulachi, 2008) :

$$\Phi_{kk} = \frac{|\rho_k|}{|P_k|} \quad (2.3)$$

Keterangan :

Φ_{kk} = nilai PACF ke k

ρ_k = nilai PACF pada lag k

P_k = nilai persamaan PACF pada aturan Cramer.

Rumus ini didasari dari persamaan Yule-Walker,

$$P_k \Phi_{kk} = \rho_k \quad (2.4)$$

Dengan,

$$\rho_k = \begin{bmatrix} \rho_1 \\ \rho_2 \\ \vdots \\ \rho_k \end{bmatrix} \text{ dan } \phi_{kk} = \begin{bmatrix} \phi_{k1} \\ \phi_{k2} \\ \vdots \\ \phi_{kk} \end{bmatrix} \quad (2.5)$$

Dan

$$\rho_k = \begin{bmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_{k-1} \\ \rho_1 & 1 & \rho_2 & \cdots & \rho_{k-2} \\ \rho_2 & \rho_1 & 1 & \cdots & \rho_{k-3} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \cdots & 1 \end{bmatrix} \quad (2.6)$$


2.5 Jaringan Syaraf Tiruan Dalam Peramalan

Jaringan syaraf tiruan (JST) atau biasa dikenal dengan istilah neural network merupakan suatu metode komputasi yang meniru sistem jaringan syaraf biologis. Metode ini menggunakan elemen perhitungan nonlinier dasar disebut neuron yang diorganisasikan sebagai jaringan yang saling berhubungan, sehingga mirip dengan jaringan syaraf manusia. Jaringan syaraf tiruan dibentuk untuk memecahkan suatu masalah tertentu seperti pengenalan pola atau klasifikasi karena untuk proses pembelajaran. Hal yang ingin dicapai dengan melatih JST adalah untuk mencapai keseimbangan antara kemampuan mengingat dan generalisasi. Yang dimaksud kemampuan mengingat merupakan kemampuan JST untuk mengambil kembali secara sempurna sebuah pola yang telah dipelajari. Kemampuan generalisasi merupakan kemampuan JST untuk menghasilkan respons yang bisa diterima terhadap pola-pola masukan yang serupa (namun tidak identik) dengan pola-pola yang sebelumnya telah dipelajari. Menurut Fausett

(1994:3), jaringan syaraf tiruan dibentuk sebagai generalisasi model matematika dari jaringan syaraf biologi dengan asumsi sebagai berikut:

- 1) Pemrosesan informasi terjadi pada banyak elemen sederhana (neurons).
- 2) Sinyal dikirimkan diantara neuron-neuron melalui penghubung-penghubung.
- 3) Penghubung antar neuron memiliki bobot yang akan memperkuat atau memperlemah sinyal.
- 4) Untuk menentukan keluaran, setiap neuron menggunakan fungsi aktivasi yang dikenakan pada penjumlahan masukan yang diterima.

Jaringan syaraf tiruan terdiri dari 3 lapisan, yaitu Input Layer, Hidden Layer dan Output Layer, seperti ditunjukkan pada gambar 2.5. Pada tiap lapisan bertanggung jawab untuk melakukan fungsi yang sama yaitu melengkapi sistem. Struktur ini berdasarkan pada modifikasi dari model tiga lapisan arsitektur perangkat lunak, yaitu Data lapisan, lapisan layanan (Web, sensor) dan lapisan presentasi (Web, Windows dan Agen).



Gambar 2.5. Skema Dasar Neural Network

Menurut Murphy, J.J, 1986 Jaringan Syaraf Tiruan ditentukan oleh 3 hal, yaitu :

- 1) Pola hubungan antara neurons yang disebut arsitektur jaringan.
- 2) Metode untuk menentukan bobot penghubung yang disebut dengan metode

pembelajaran atau learning.

- 3) Fungsi aktivasi, yaitu fungsi yang digunakan.

Neuron merupakan suatu unit pemroses informasi yang menjadi dasar dalam pengoperasian jaringan syaraf tiruan (Siang, 2005:23). *Neuron* terdiri dari tiga elemen pembentuk yaitu:

- 1) Himpunan unit-unit yang dihubungkan dengan jalur koneksi.
- 2) Suatu unit penjumlah yang akan menjumlahkan masukan-masukan sinyal yang sudah dikalikan dengan bobotnya.
- 3) Fungsi aktivasi yang akan menentukan apakah sinyal dari unit masukan akan diteruskan ke unit lain ataukah tidak.

Para peneliti telah membuat banyak penelitian menggunakan Jaringan Syarat Tiruan untuk diimplementasikan di berbagai bidang seperti rekayasa, ilmu komputer, biokimia, dan fisika. Adanya keberhasilan implementasi Jaringan Syarat Tiruan di bidang-bidang tersebut menjadi dorongan untuk menerapkan di bidang keuangan, ekonomi, dan industri. Karena didukung oleh karakteristik-karakteristik dari Jaringan Syarat Tiruan itu sendiri. Jaringan Syarat Tiruan memiliki beberapa keunggulan jika dibandingkan dengan metode tradisional. Jaringan Syarat Tiruan adalah sebuah metode yang mampu secara mandiri menyelesaikan data-driven dimana hanya terdapat sedikit pengetahuan berkaitan dengan persoalan yang ingin diselesaikan. Semua jenis Jaringan Syarat Tiruan memiliki kinerja yang baik untuk peramalan. Jaringan Syarat Tiruan melibatkan berbagai derajat kebebasan, konsekuensinya diperlukan banyak percobaan melalui uji coba untuk menentukan nilai parameter yang sesuai sehingga dihasilkan

arsitektur jaringan terbaik. Jaringan Syarat Tiruan terdiri dari berbagai macam jenis, menurut Theodosiou Jaringan Syarat Tiruan mampu belajar dari contoh-contoh yang diberikan dan menangkap relasi fungsional diantara data bahkan jika relasi tersebut belum diketahui atau sulit di deskripsikan, sehingga dapat dibilang bahwa Jaringan Syarat Tiruan bersifat menyamaratakan.


Jaringan Syarat Tiruan ini adalah pembelajar yang cepat dan selalu menghasilkan permukaan regresi optimal yang konvergen sehingga mampu mengatasi persoalan yang sering dialami oleh metode Jaringan Syarat Tiruan lainnya yaitu solusi dengan nilai galat yang bersifat lokal Minimum. Jaringan syaraf tiruan biasanya mempunyai 3 kelompok lapisan unit-unit, yaitu lapisan masukan yang terhubung dengan lapisan tersembunyi selanjutnya terhubung dengan lapisan keluaran. Aktifitas dari lapisan-lapisan ini yaitu:

- 1) Aktifitas unit-unit lapisan masukan menunjukkan informasi dasar yang kemudian digunakan dalam jaringan syaraf tiruan.
- 2) Aktifitas setiap unit-unit lapisan tersembunyi ditentukan oleh aktifitas dari unit-unit masukan dan bobot dari koneksi antara unit-unit masukan dan unitunit dari lapisan tersembunyi.
- 3) Karakteristik dari unit-unit keluaran tergantung pada aktifitas unit-unit lapisan tersembunyi dan bobot antara unit-unit lapisan tersembunyi dan unit-unit keluaran. Daftar hubungan istilah yang banyak digunakan adalah sebagai berikut :

Tabel 2.1. Istilah Jaringan Syaraf Tiruan dan Statistik

Istilah Jaringan Syaraf Tiruan	Istilah Statistik
Arsitektur	Model
Training	Estimasi
Learning	Model fitting
Kelompok training	Sampel
Masukan	Variabel independen
Keluaran	Nilai prediksi dari variabel depende
Nilai pelatihan (training) atau target	Nilai sebenarnya dari variabel dependen
Nilai target	Nilai observasi
Error	Residual
Generalisasi	Prediksi
Prediksi	Peramalan
Bobot Parameter jaringan	Parameter jaringan

Model-model jaringan syaraf tiruan ditentukan oleh arsitektur jaringan serta algoritma pelatihan. Arsitektur akan menjelaskan kemana arah perjalanan sinyal atau data di dalam jaringan, sedangkan algoritma belajar menjelaskan bagaimana bobot koneksi harus diubah agar pasangan masukan-keluaran yang diinginkan dapat tercapai.



Gambar 2.6. Sel Jaringan Syaraf

Pada gambar 2.6 terlihat sebuah sel syaraf tiruan sebagai elemen penghitung. Simpul Y menerima masukan dari unit 1 (bias), x_1 , x_2 , dan x_3 dengan bobot masing-masing adalah w_0 , w_1 , w_2 , dan w_3 . Argumen fungsi aktivasi merupakan net masukan (kombinasi linear masukan dan bobotnya). Keempat sinyal unit yang ada dijumlahkan sehingga diperoleh persamaan $net = 1w_0 + x_1w_1 + x_2w_2 + x_3w_3$. Besarnya sinyal yang diterima oleh Y mengikuti fungsi aktivasi $y = f(net)$. Apabila nilai fungsi aktivasi ini cukup kuat, maka sinyal akan diteruskan. Nilai fungsi aktivasi (keluaran model jaringan) juga dapat digunakan sebagai dasar untuk merubah bobot.

2.6 Generalized Regression Neural Network

Generalized Regression Neural Network merupakan suatu metode dalam Jaringan Syaraf Tiruan yang memiliki kemiripan dengan jaringan berbasis radial (Radial Basis Function) yang cukup sering digunakan untuk mendapatkan suatu

fungsi aproksimasi dari data-data nonlinear. Dasar dari operasi *Generalized Regression Neural Network* secara esensial didasarkan pada regresi nonlinear (kernel) dimana estimasi dari nilai harapan output ditentukan oleh himpunan input-inputnya (Leung et.al, 2000). Walaupun *Generalized Regression Neural Network* menghasilkan output berupa vektor multivariate, dengan tidak mengurangi keumuman deskripsi dari logika operasi *Generalized Regression Neural Network* pada bagian ini disederhanakan untuk kasus output univariat. Persamaan (2.1) meringkas logika *Generalized Regression Neural Network* dalam formula regresi nonlinier:

$$E[y|x] = \frac{\int_{-\infty}^{\infty} y f(x,y) dy}{\int_{-\infty}^{\infty} f(x,y) dy} \quad (2.7)$$

Dalam hal ini y merupakan output yang diprediksi oleh *Generalized Regression Neural Network*, sedangkan x merupakan vektor input (x_1, x_2, \dots, x_p) yang terdiri dari p variabel prediktor dari output y diberikan vektor input x dan $f(x,y)$ merupakan fungsi densitas probabilitas bersama dari x dan y . Teori General Regression Neural Network diperoleh dari estimasi densitas kernel multivariate (Sprecht,1991). Tujuan dari estimasi multivariate nonparametrik ini yaitu mengestimasi fungsi densitas probabilitas $F(Z_1^*, \dots, Z_m^*)$ dari m variabel acak $z = (Z_1, \dots, Z_m)^T$ dengan menggunakan n ukuran dari tiap variabel. Estimator densitas kernel multivariate pada kasus m dimensi didefinisikan sebagai berikut.

$$F(z^*) = \frac{1}{n} \sum_{i=1}^n \frac{1}{h_1 \dots h_m} k\left(\frac{z_{i1} - z_1^*}{h_1}, \dots, \frac{z_{im} - z_m^*}{h_m}\right) \quad (2.8)$$

Dimana K merupakan fungsi kernel multivariate dan bandwidth (parameter penghalusan) vektor $h = (h_1, \dots, h_m)^T$. Data asli $Z(X_i, Y_i)$; $i = 1, \dots, n$

akan dibagi menjadi himpunan data training dan digunakan untuk pengembangan model, sedangkan himpunan data training berasal dari suatu proses sampling yang mengukur nilai output dengan additive random noise:

$$Z_i = E[Z|x, y] + \varepsilon_i \quad (2.9)$$

Dimana :

$$\varepsilon_i \sim NID(0, \sigma^2) \quad (2.10)$$

Mean bersyarat dari Z jika diberikan ke (x, y) yang dikenal sebagai suatu regresi Z pada (x, y) merupakan suatu solusi yang meminimalkan MAPE. Jika $f(x, y, Z)$ merupakan fungsi densitas probabilitas kontinu bersama maka mean bersyarat tersebut adalah :

$$E[Z|x, y] = \frac{\int_{-\infty}^{\infty} Z f(x, y, Z) dZ}{\int_{-\infty}^{\infty} f(x, y, Z) dZ} \quad (2.11)$$

Fungsi densitas $f(x, y, Z)$ dapat diestimasi dari data dengan menggunakan estimator konsisten nonparametrik sebagai berikut :

$$f(x, y, z) = \frac{1}{[(2\pi)^{\frac{(p+1)}{2}} \sigma^p]} \frac{1}{n} \sum_{i=1}^n \exp\left(-\frac{(X-X_i)^T}{2\sigma^2}\right) \exp\left[\frac{-(Y-Y_i)}{2\sigma^2}\right] \quad (2.12)$$

Dengan p banyaknya lag input dan n adalah banyaknya pengukuran dalam himpunan data Training, h merupakan suatu panjang bidang, serta jarak metrik (D_i^2) adalah :

$$D_i^2 = (X - X_i)^T (X - X_i) \quad (2.13)$$

Dengan mensubstitusi estimasi probabilitas bersama (2.11) ke dalam mean (2.12) bersyarat diperoleh estimator *kernel Nadaraya-Watson* sebagai berikut:

$$\hat{y}_m(X, Y) = \frac{\sum_{i=1}^n y_i \exp\left(\frac{D_i^2}{\sigma}\right)}{\sum_{i=1}^n \exp\left(\frac{D_i^2}{\sigma}\right)} \quad (2.14)$$

2.7 Struktur dan Arsitektur GRNN

Pada dasarnya struktur jaringan *Generalized Regression Neural Network* sama dengan jaringan neural network pada umumnya, namun karena *Generalized Regression Neural Network* didasarkan pada teori regresi Kernel maka dari itu output layer untuk *Generalized Regression Neural Network* ini juga berasal dari estimasi fungsi $m(x)$ pada model regresi Kernel.

Kemudian nilai \hat{y} yang diterapkan pada basis *neural network* dengan komputasi yang disederhanakan (Specht, 1991).

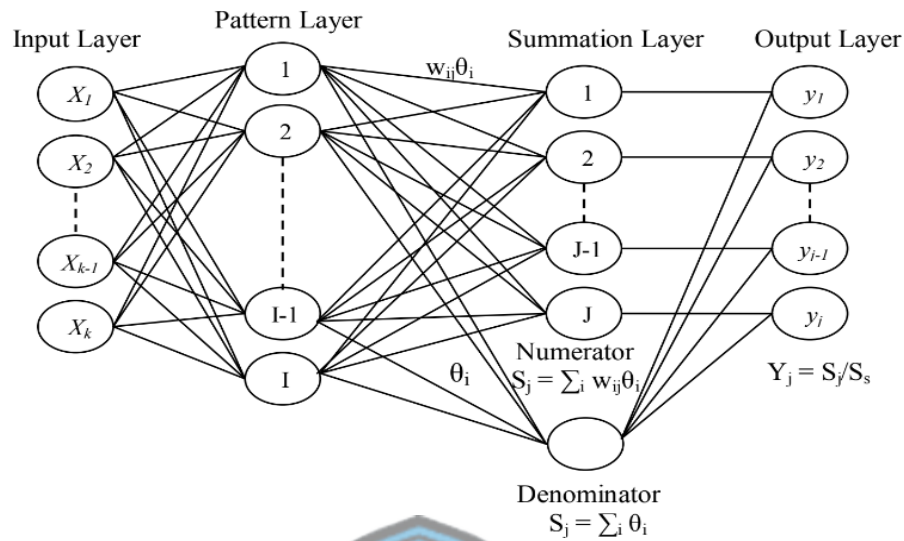
$$\hat{y}_m(x, y) = \frac{\sum_{i=1}^n z_i \exp\left(\frac{D_i^2}{\sigma}\right)}{\sum_{i=1}^n \exp\left(\frac{D_i^2}{\sigma}\right)} \quad (2.15)$$

Dimana D_i^2 akan dapat didekati dengan menggunakan jarak Euclidian antara vektor *input* dan vektor bobot *input* pada data pelatihan (Wasserman, 1993).

$$D_i^2 = \sum_{j=1}^p (x_j - v_{ij})^2 \quad (2.16)$$

$$D_i = \sqrt{\sum_{j=1}^p (x_j - v_{ij})^2}, (i = 1, 2, \dots, n) \text{ dan } (j = 1, 2, \dots, p) \quad (2.17)$$

Seperti yang terlihat pada Gambar 2.7, GRNN terdiri atas empat lapisan, yaitu lapisan masukan, lapisan basis radial atau lapisan pola (*pattern*) atau lapisan tersembunyi (*hidden*), lapisan penggabungan (*summation*), dan lapisan keluaran. Lapisan pola dan lapisan penggabungan memiliki koneksi penuh, sedangkan lapisan keluaran hanya terhubung ke beberapa *neuron* pada lapisan penggabungan. Lapisan penggabungan terdiri dari dua tipe *neuron* yaitu simpul penggabungan dan simpul pembagian.



Gambar 2.7. Arsitektur GRNN Secara Umum

Lapisan masukan menerima informasi yang kemudian menyajikan ke lapisan pola untuk diproses. Semua data dari lapisan masukan akan disalin sebagai bobot menjadi lapisan pola. Pada lapisan pola di *Generalized Regression Neural Network* , Pada jaringan *Generalized Regression Neural Network* fungsi aktivasi yang digunakan yaitu aktivasi radial basis.

$$\theta_i = e^{-n^2} \quad (2.18)$$

Dengan,

$$n = b \cdot D_i \quad (2.19)$$

b merupakan bobot bias lapisan *input*, khusus pada *Generalized Regression Neural Network* bobot bias lapisan *input* ini bernilai $0,8326/spread$ untuk semua neuron. Kemudian akan dapat didekati dengan menggunakan jarak Euclidian.

Jarak yang telah ditemukan kemudian akan digunakan untuk menemukan nilai fungsi aktivasi pada masing-masing neuron pada input layer ke hidden layer. Kemudian setelah fungsi aktivasi terbentuk, maka selanjutnya masuk pada layer

atau lapisan selanjutnya yaitu summation layer, pada layer ini terdapat dua pemrosesan jaringan yang pertama merupakan penjumlahan aritmatik terhadap fungsi aktivasi (S_s) dan penjumlahan terboboti (S_w), dimana bobot pada layer ini sama dengan nilai vektor target.

$$S_s = \sum_{i=1}^n \theta_i \quad (2.20)$$

Dan,

$$S_w = \sum_{i=1}^n \theta_i w_i \quad (2.21)$$

Setelah didapatkan nilai penjumlahan nilai aktivasi dan nilai terboboti, kemudian masuk pada *output layer*, dimana *output* akan didapatkan dari nilai pembagian antara penjumlahan terboboti dan nilai penjumlahan fungsi aktivasi.

$$\hat{y}_t = \frac{S_s}{S_w} \quad (2.22)$$

2.8 Normalisasi Data

Pada metode *Generalized Regression Neural Network* memang tidak dibutuhkan asumsi normalitas, namun normalisasi data tetap dilakukan, hal ini bertujuan untuk meningkatkan performa peramalan atau dalam arti lain jaringan tidak mengalami kegagalan pada saat peramalan. Data pelatihan maupun pengujian dinormalisasikan pada interval 0 sampai dengan 1, hal ini disesuaikan dengan fungsi aktivasi yang digunakan pada metode *Generalized Regression Neural Network* ini yaitu fungsi aktivasi radial basis. Namun mengingat fungsi sigmoid merupakan fungsi asimtotik yang nilainya tidak pernah mencapai 0 ataupun 1, akan lebih baik jika ditransformasikan ke interval yang lebih kecil yaitu pada interval [0.1, 0.9]. Normalisasi data tersebut dilakukan dengan menggunakan

formulasi berikut :

$$X' = \frac{0,8(X-b)}{(a-b)} + 0,1 \quad (2.23)$$

Keterangan :

a = data maksimum

b = data minimum

x = data aktual/asli

X' = data normalisasi

Setelah jaringan terbentuk dan output dari masing-masing metode didapatkan, dibutuhkan data dalam bentuk seperti semula agar dapat dibandingkan dengan hasil data aktual yang dianalisis, hal ini dapat dilakukan dengan langkah denormalisasi.


$$X = \frac{(\hat{y}-0,1)(a-b)}{0,8} + b \quad (2.24)$$

Keterangan :

a = data maksimum

b = data minimum

\hat{y} = output (data keluaran)

X = data aktual

2.9 Kriteria Pemilihan Model Peramalan

Parameter yang akan digunakan untuk pemilihan model peramalan yang paling optimal yaitu nilai *spread* (σ). Lapisan masukan dan lapisan pola berkaitan erat dengan penentuan sigma yang merupakan parameter bebas yang biasa disebut

dengan parameter penghalusan (*smoothing parameter*). Seperti konsep bandwidth pada regresi Kernel, nilai *spread* (σ) adalah parameter penyebaran atau juga parameter smoothing, Bandwidth disini merupakan pengontrol kemulusan pada regresi kernel. Pemilihan nilai bandwidth menjadi sangat penting karena apabila nilai bandwidth terlalu kecil maka akan mengakibatkan data terlalu fluktuatif atau data jauh dari pola, namun apabila terlalu besar maka akan mengakibatkan data terlalu halus sehingga tidak nampak polanya. Maka dari itu pemilihan σ harus dilakukan dengan beberapa kali percobaan dengan tolak ukur nilai error untuk menentukan nilai σ yang paling baik.

Pada jaringan *Generalized Regression Neural Network* parameter smoothing (σ), ditentukan melalui proses pelatihan jaringan. Pada kasus ini, σ memberikan pengaruh yang cukup besar pada nilai error yang terbentuk pada jaringan. Untuk itu, pada penerapannya pemilihan σ menghasilkan nilai minimum MAPE dengan menggunakan metode trial and error, yang akan menghasilkan kurva parabola (Zaknich dan Attikiouzel, 1993).

2.10 Perhitungan Tingkat Akurasi

Untuk menghasilkan peramalan yang akurat dilakukan evaluasi dengan menggunakan metode *Mean Absolute Percentage Error* (MAPE). *Mean Absolute Percentage Error* (MAPE) dihitung dengan menggunakan kesalahan absolut pada tiap periode dibagi dengan nilai observasi yang nyata untuk periode itu. Kemudian, merata-rata kesalahan persentase absolut tersebut. Pendekatan ini berguna ketika ukuran atau besar variabel ramalan itu penting dalam

mengevaluasi ketepatan ramalan. *Mean Absolute Percentage Error* (MAPE) mengindikasikan seberapa besar kesalahan dalam meramal yang dibandingkan dengan nilai nyata. *Mean Absolute Percentage Error* (MAPE) merupakan parameter untuk mengukur kriteria pada peramalan. Kriteria *Mean Absolute Percentage Error* (MAPE) berdasarkan presentase dari 5%, jika nilai *Mean Absolute Percentage Error* (MAPE) kurang dari 5% maka kinerja model hasil nilai peramalan akan semakin baik. Nilai *Mean Absolute Percentage Error* (MAPE) semakin kecil maka data akan semakin akurat dalam hasil peramalan. Persamaan *Mean Absolute Percentage Error* (MAPE) sebagai berikut :

$$MAPE = \frac{100 \times \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right|}{n} \quad (2.25)$$

Keterangan :

A_t = Permintaan Aktual Periode ke – t

F_t = Nilai peramalan periode ke – t

n = Jumlah periode t

t = Periode

Semakin kecil nilai MAPE menunjukkan bahwa persentase kesalahan yang dihasilkan oleh model juga semakin kecil. Menurut Chang et al (2007) dalam Halimi et al (2013) nilai evaluasi yang dihasilkan mempunyai kriteria MAPE seperti berikut:

- a. $MAPE < 10\%$: Kemampuan peramalan sangat baik
- b. $10\% \leq MAPE < 20\%$: Kemampuan peramalan baik
- c. $20\% \leq MAPE < 50\%$: Kemampuan peramalan cukup
- d. $MAPE \geq 50\%$: Kemampuan peramalan buruk