

BAB II

LANDASAN TEORI

Pada bab II dijelaskan pengertian-pengertian dasar yang digunakan sebagai landasan pembahasan pada bab selanjutnya yaitu Konsep Dasar *Time Series*, Wisatawan Mancanegara, dan Jaringan saraf tiruan (*Neural Network*),

A. Konsep Dasar *Time Series*

Time series merupakan serangkaian pengamatan terhadap suatu peristiwa, kejadian, gejala atau perubahan yang terjadi dari waktu ke waktu. (Hanke & Winchern, 2005:58). Sebagai contoh yaitu data yang dikumpulkan terkait dengan satuan waktu yaitu jam, hari, minggu, bulan, tahun maupun semester dan data yang diamati sepanjang waktu. Pola gerakan data dapat diketahui dengan adanya data *time series*. Pola data *time series* digunakan untuk menganalisis data masa lalu yang akan digunakan untuk meramalkan suatu nilai atau kejadian pada masa yang akan datang.

Data *time series* dapat dikategorikan menjadi data yang stasioner atau non stasioner. Data *time series* dikatakan stasioner jika rata-rata dan variansinya konstan. Stasioner terjadi apabila tidak terjadi kenaikan atau penurunan secara tajam pada data. Kestasioneran juga dapat dilihat dengan plot PACF dan ACF. Jika nilai koefisien korelasi menurun secara cepat seiring meningkatnya *lag* maka data dapat dikatakan stasioner.

Stasioner dibagi menjadi dua yaitu stasioner dalam *mean* (rata-rata) dan stasioner dalam variansi. Jika data stasioner dalam *mean* maka terjadi fluktuasi data

berada di sekitar suatu nilai rata-rata yang konstan. Apabila dilihat dari plot ACF maka nilai autokorelasi dari data stasioner akan turun menuju nol sesudah *time lag* (selisih waktu) kedua, ketiga dan seterusnya. Sedangkan data stasioner dalam varian adalah data yang dari waktu ke waktu mempunyai fluktuasi yang tetap atau konstan dan tidak berubah-ubah. Secara visual dapat dilihat dengan menggunakan plot *time series* yaitu dengan melihat fluktuasi data dari waktu ke waktu. Jika data tidak stasioner dalam *mean* untuk menstasionerkan dilakukan pembedaan (*differencing*). Proses *differencing* dapat dilakukan dengan mengurangi suatu data dengan data sebelumnya untuk beberapa periode sampai data stasioner. Sedangkan jika data nonstasioner dalam varian maka perlu dilakukan transformasi agar data stasioner. (Wei ,2006:68-71)

1. Autokorelasi (*Autocorrelation Function/ACF*)

Autokorelasi didefinisikan korelasi yang terjadi antar observasi satu atau lebih variabel (Hanke & Winchern, 2005:327). Autokorelasi merupakan korelasi dari sebuah data *time series* untuk selang waktu (*lag*) yang berlainan. Autokorelasi dapat digunakan untuk menentukan ada tidaknya faktor musiman (*seasonality*). Selain itu, autokorelasi dapat digunakan untuk menentukan kestasioneran suatu data.

Dalam suatu proses stasioner Z_t , didefinisikan suatu deret $\{Z_t\} = Z_1, Z_2, Z_3 \dots, Z_n$ dan $\{Z_{t+k}\} = Z_{t+1}, Z_{t+2}, \dots, Z_{t+k-1}$ terhadap waktu t sampai pada waktu $t + k$ dimana rata-rata $E(Z_t) = \mu$, dan $Var(Z_t) = E(Z_t - \mu)^2 = \sigma^2$

adalah konstan, dan kovarian antara Z_t dan nilainya pada periode waktu Z_{t+k} $cov(Z_t, Z_{t+k})$, disebut autokovarian pada *lag* k , dan didefinisikan sebagai

$$\gamma_k = cov(Z_t, Z_{t+k}) = E(Z_t - \mu)(Z_{t+k} - \mu) \quad (2.1)$$

Sedangkan nilai ρ_k pada saat $k = 1, 2, 3 \dots$ disebut fungsi autokorelasi (*Autocorrelation Function/ ACF*). (Wei, 2006:10-11)

$$\rho_k = \frac{\gamma_k}{\gamma_0} = \frac{cov(Z_t, Z_{t+k})}{\sqrt{Var(Z_t)} \sqrt{Var(Z_{t+k})}} \quad (2.2)$$

dengan

- ρ_k = fungsi autokorelasi pada *lag* k
- γ_k = autokovariansi dari Z_t dan Z_{t+k}
- t = waktu
- $Var(Z_t)$ = variansi konstan

Nilai autokorelasi berkisar antar -1 sampai 1 . Jika nilai autokorelasi tepat ± 1 atau mendekati, dapat disimpulkan terdapat hubungan yang tinggi antara data *time series* tersebut dalam *lag* yang berlainan. Jika nilai autokorelasi adalah 0 , maka tidak terdapat hubungan dari data *time series* tersebut. Pengujian signifikansi autokorelasi bertujuan untuk mengetahui apakah ada autokorelasi yang berbeda signifikan dari nol. Hipotesis yang digunakan untuk menguji autokorelasi adalah

$$H_0: \rho_k = 0 \text{ (autokorelasi pada lag } k \text{ signifikan dari nol)}$$

$$H_1: \rho_k \neq 0 \text{ (autokorelasi pada lag } k \text{ tidak signifikan dari nol)}$$

dengan statistik uji

$$t = \frac{r_k}{SE(r_k)} \text{ dengan } df = n - 1 \quad (2.3)$$

Standar *error* autokorelasi $SE(r_k)$ dapat diperoleh dengan rumus

$$SE(r_k) = \sqrt{\frac{1 + 2 \sum_{i=1}^{k-1} r_i^2}{n}} \text{ dan } SE(r_1) = \sqrt{\frac{1}{n}} \text{ jika } k = 1 \quad (2.4)$$

dengan

$SE(r_k)$ = Standar *error* autokorelasi pada *lag* k

r_k = autokorelasi sampel pada *lag* k

n = banyaknya pengamatan


Kriteria keputusan dari pengujian ini adalah H_0 ditolak jika $t_{hitung} > t_{n-1}(\frac{\alpha}{2})$ atau

$$t_{hitung} < -t_{n-1}(\frac{\alpha}{2})$$

Autokorelasi juga dapat ditentukan dengan melihat *correlogram*.

Correlogram adalah plot antara *lag* k dengan r_k dengan selang kepercayaan dapat diperoleh dengan menggunakan rumus sebagai berikut

$$0 \pm t_{n-1} \left(\frac{\alpha}{2} \right) \times SE(r_k) \quad (2.5)$$



Gambar 2.1. Plot Autokorelasi Pada Data Wisatawan Mancanegara

Gambar di atas menunjukkan plot autokorelasi pada data wisatawan mancanegara dengan menggunakan aplikasi minitab. Pada *lag 1*, *lag 2*, *lag 3*, *lag 4* dan *lag 5* terdapat autokorelasi yang berbeda signifikan dari nol karena melewati selang kepercayaan. Autokorelasi yang tidak sama dengan nol menunjukkan bahwa terdapat hubungan antar pengamatan.

2. Autokorelasi Parsial (*Partial Autocorrelation Function/PACF*)

Autokorelasi parsial merupakan pengembangan dari autokorelasi, yaitu dengan cara menghilangkan dependensi linear pada variabel $Z_{t+1}, Z_{t+2}, \dots$, dan Z_{t+k-1} , sehingga diperoleh bentuk korelasi baru yang dinyatakan sebagai

$$\text{corr}(Z_t, Z_{t+k} | Z_{t+1}, Z_{t+2}, \dots, Z_{t+k-1})$$

Autokorelasi parsial antara Z_t dan Z_{t+k} akan sama dengan autokorelasi antara $(Z_t - \hat{Z}_t)$ dan $(Z_{t+k} - \hat{Z}_{t+k})$ sehingga (Wei ,2006:13)

$$\rho_k = \frac{\gamma_k}{\gamma_0} = \frac{\text{cov}[(Z_t - \hat{Z}_t), (Z_{t+k} - \hat{Z}_{t+k})]}{\sqrt{\text{Var}(Z_t - \hat{Z}_t)} \sqrt{\text{Var}(Z_{t+k} - \hat{Z}_{t+k})}} \quad (2.6)$$

$$Z_{t+k} = \phi_{k1}Z_{t+k-1} + \phi_{k2}Z_{t+k-2} + \dots + \phi_{kk}Z_t + e_{t+k}$$

$$E(Z_{t+k-j}, Z_{t+k}) = \phi_{k1}E(Z_{t+k-j}, Z_{t+k-1}) + \phi_{k2}E(Z_{t+k-j}, Z_{t+k-2})$$

$$+ \dots + \phi_{kk}E(Z_{t+k-j}, Z_t) + E(Z_{t+k-j}, e_{t+k})$$

$$\gamma_j = \phi_{k1}\gamma_{j-1} + \phi_{k2}\gamma_{j-2} + \dots + \phi_{kk}\gamma_{j-k} \quad (2.7)$$

$$E(Z_{t+k-j}, Z_{t+k-1}) = \gamma_{j-1}, E(Z_{t+k-j}, Z_{t+k}) = \gamma_0 \quad \text{dan} \quad E(Z_{t+k-j}, e_{t+k}) = 0$$

berdasarkan definisi. Z_{t+k} merupakan proses stasioner dengan *mean* nol yang diregresikan dengan k lag variabel $Z_{t+k-1}, Z_{t+k-2}, \dots, Z_t$ dimana ϕ_{ki} merupakan parameter regresi ke- i dan e_{t+k} menyatakan *error* yang tidak berkorelasi dengan Z_{t+k-j} untuk $j \geq 1$. Jika kedua ruas dibagi dengan γ_0 diperoleh (Wei ,2006:14)

$$\rho_j = \phi_{k1}\rho_{j-1} + \phi_{k2}\rho_{j-2} + \dots + \phi_{kk}\rho_{j-k} \text{ untuk } j = 1, 2, 3, \dots, k \quad (2.8)$$

dimana,

$$\rho_{-1} = \rho_1$$

$$\rho_{-(k-1)} = \rho_{(k-1)}$$

Sehingga,

$$\rho_1 = \phi_{k1}\rho_0 + \phi_{k2}\rho_1 + \dots + \phi_{kk}\rho_{k-1}$$

$$\rho_2 = \phi_{k1}\rho_1 + \phi_{k2}\rho_0 + \dots + \phi_{kk}\rho_{k-2}$$

$\vdots$

$$\rho_k = \phi_{k1}\rho_{k-1} + \phi_{k2}\rho_{k-2} + \dots + \phi_{kk}\rho_0$$

$\rho_1 = \frac{\gamma_1}{\gamma_0}$ merupakan korelasi pertama sehingga diperoleh $\phi_{11} = \rho_1$. Sehingga autokorelasi parsial yang pertama sama dengan autokorelasi pertama. Menurut aturan Crammer untuk $k = 1, 2, 3, \dots$ diperoleh (Wei, 2006:15)

$$\phi_{11} = \rho_1$$

$$\phi_{22} = \frac{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & \rho_2 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & 1 \end{vmatrix}}$$

$\vdots$

$$\phi_{kk} = \frac{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \dots & \rho_{k-2} & \rho_1 \\ \rho_1 & 1 & \rho_1 & \dots & \rho_{k-3} & \rho_2 \\ \vdots & \vdots & \vdots & \dots & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \dots & \rho_1 & \rho_k \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \dots & \rho_{k-2} & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & \dots & \rho_{k-3} & \rho_{k-2} \\ \vdots & \vdots & \vdots & \dots & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \dots & \rho_1 & 1 \end{vmatrix}}$$

ϕ_{kk} merupakan fungsi dari k yang disebut dengan fungsi autokorelasi parsial.

Hipotesis yang digunakan untuk menguji autokorelasi parsial adalah

$$H_0: \phi_{kk} = 0 \text{ (autokorelasi parsial pada lag } k \text{ signifikan dari nol)}$$

$$H_1: \phi_{kk} \neq 0 \text{ (autokorelasi parsial pada lag } k \text{ tidak signifikan dari nol)}$$

Statistik uji yang digunakan adalah

$$t = \frac{\phi_{kk}}{SE(\phi_{kk})} \text{ dengan } df = n - 1 \quad (2.9)$$

Standar *error* autokorelasi parsial $SE(\phi_{kk})$ dapat diperoleh dengan rumus

$$SE(\hat{\phi}_{kk}) = \sqrt{\frac{1}{n}} \quad (2.10)$$

dengan

$SE(\hat{\phi}_{kk})$ = Standar *error* autokorelasi parsial pada *lag* k

ϕ_{kk} = autokorelasi parsial pada *lag* k


n = banyak pengamatan

Kriteria keputusan dari pengujian ini adalah H_0 ditolak jika $t_{hitung} > t_{n-1}(\frac{\alpha}{2})$ atau

$$t_{hitung} < -t_{n-1}(\frac{\alpha}{2})$$

Signifikansi autokorelasi parsial dapat juga diketahui dengan melihat *correlogram*. Gambar 2.2 adalah plot PACF data wisatawan yang menunjukkan bahwa *lag* 1, *lag* 2, dan *lag* 14 memiliki autokorelasi parsial tidak berbeda signifikan dengan nol. Selang kepercayaan yang berpusat di $\hat{\phi}_{kk} = 0$ adalah :

$$0 \pm t_{n-1} \left(\frac{\alpha}{2} \right) \times SE(\hat{\phi}_{kk}) \quad (2.11)$$



Gambar 2.2. Plot Partial Autokorelasi pada Data Wisatawan Mancanegara

3. Pemilihan Model

Pemodelan dilakukan untuk mendapatkan output atau prediksi yang optimum. Output dikatakan optimum jika nilai prediksi $\hat{y}_n$ mendekati y_n dimana menghasilkan *error* (e_n) yang minimal. Nilai e_n didefinisikan sebagai berikut

$$e_n = y_n - \hat{y}_n \quad (2.12)$$

dimana

y_n = nilai target ke- n

$\hat{y}_n$ = nilai prediksi ke- n

e_n = *error* data ke- n

Ada beberapa kriteria pemilihan model yang dapat digunakan untuk membandingkan beberapa model dan memilih model yang terbaik yang didasarkan pada *error*nya. Apabila *error* semakin besar maka peramalan yang akan dilakukan

kurang akurat. Kriteria yang digunakan untuk memperoleh akurasi peramalan yang tinggi adalah dengan mengukur *Mean Square Error* (MSE) dan *Mean Absolute Percentage Error* (MAPE) : (Hanke & Winchern, 2005 : 80)

a. *Mean Square Error* (MSE)

MSE menyatakan besarnya kesalahan rata-rata kuadrat dari suatu metode peramalan.

$$MSE = \frac{\sum_{n=1}^m (y_n - \hat{y}_n)^2}{m} \quad (2.13)$$

Dengan m menyatakan banyak data, y_n adalah nilai data aktual dan $\hat{y}_n$ merupakan nilai prediksi.

b. *Mean Absolute Percentage Error* (MAPE)

MAPE menyatakan besar rata-rata kesalahan mutlak peramalan dibandingkan dengan nilai sebenarnya.

$$MAPE = \frac{\sum_{n=1}^m \frac{|y_n - \hat{y}_n|}{y_n}}{m} \times 100 \% \quad (2.14)$$

Pemodelan akan memiliki akurasi yang tinggi apabila nilai MSE dan MAPE kecil.

4. Peramalan (*Forecasting*)

Peramalan (*forecasting*) secara umum didefinisikan sebagai salah satu cara memperkirakan apa yang akan terjadi di masa yang akan datang berdasarkan data historis yang ada. Hasil peramalan dipengaruhi oleh data, pola data, dan lain sebagainya. Teknik peramalan dibagi menjadi dua kategori utama yaitu peramalan didasarkan metode kualitatif dan kuantitatif (Hanke & Winchern, 2005 : 3). Metode

kualitatif adalah metode peramalan yang didasarkan pada intuisi, pengetahuan, pengalaman dan *judgment* dari orang yang melakukan peramalan, Metode kuantitatif adalah metode yang memiliki sifat yang obyektif karena didasarkan pada keadaan aktual data yang diolah dengan menggunakan metode-metode tertentu. Metode peramalan kuantitatif didefinisikan dengan peramalan deret waktu (*Time Series Method*) dan peramalan kausal. Menurut Hanke keakurasian yang tinggi terhadap peramalan dipengaruhi oleh metode yang digunakan dan peramalan yang akan datang terhadap waktu (Hanke & Winchern, 2005 : 4).

Peramalan berdasarkan periode waktunya, dikategorikan menjadi 3 macam yaitu : (Montgomery, Jennings & Kulahci, 2008: 1)

1. Jangka Pendek (*Short Term*)

Jangka pendek adalah peramalan berdasarkan kurun waktu yang singkat seperti hari, minggu dan bulan. Peramalan dengan jenis ini merupakan peramalan yang memiliki tingkat keakuransian yang masih tinggi.

2. Jangka Menengah (*Medium Term*)

Jangka Menengah adalah peramalan berdasarkan musim seperti triwulan, kuartal, semester dan lain sebagainya. Peramalan dengan jenis ini masih memiliki tingkat akurasi yang menengah.

3. Jangka Panjang (*Long Term*)

Jangka panjang merupakan peramalan dengan kurun waktu lebih dari dua tahun. Peramalan dengan jenis ini memiliki tingkat keakuratan yang rendah. Sehingga perlu digunakan pengamatan atau data yang cukup lama dan banyak untuk memperoleh keakuransian yang tinggi.

B. Wisatawan Mancanegara

Wisatawan merupakan salah satu pendukung di sektor pariwisata. Wisatawan adalah seseorang atau kelompok yang melakukan perjalanan wisata disebut dengan wisatawan (*tourist*) jika lama tinggalnya sekurang-kurangnya 24 jam di daerah atau negara yang dikunjungi. Sedangkan wisatawan yang tinggal di negara yang dikunjungi kurang dari 24 jam maka mereka disebut dengan pelancong (*excursionnist*) (Suswantoro, 2004:30). Pengertian wisatawan di Indonesia tercantum pada Instruksi Presiden RI No. 9 tahun 1969, yaitu setiap orang yang berpergian dari tempat tinggalnya untuk berkunjung ke tempat lain dengan menikmati perjalanan dan kunjungan itu.

Berdasarkan sifat perjalanan dan ruang lingkup dimana perjalanan wisata itu dilakukan, klasifikasi jenis dan macam wisatawan sebagai berikut (Yoeti,1996 :131):

1. Wisatawan mancanegara (*foreign tourist*)

Wisatawan mancanegara adalah seseorang atau kelompok orang asing yang melakukan perjalanan wisata yang datang memasuki suatu negara lain yang bukan merupakan negara dimana orang tersebut tinggal.

2. *Domestic foreign tourist*

Domestic foreign tourist adalah seseorang atau sekelompok orang asing yang berdiam atau bertempat tinggal pada suatu negara dan melakukan perjalanan wisata di wilayah negara dimana orang tersebut tinggal.

3. Wisatawan Domestik (*Domestic tourist*)

Wisatawan domestik adalah wisatawan dalam negeri, yaitu seseorang atau kelompok warga negara yang merupakan penduduk suatu negara yang melakukan perjalanan wisata dalam batas wilayah negaranya sendiri tanpa melewati perbatasan negaranya.

4. Indigenous foreign tourist

Indigenous foreign tourist adalah warga negara suatu negara tertentu yang karena tugasnya atau jabatannya di luar negeri pulang ke negara asalnya dan melakukan perjalanan wisata di wilayah negaranya sendiri.

5. Transit tourist

Transit tourist adalah wisatawan yang sedang melakukan perjalanan wisata ke suatu negara tertentu, yang menumpang kapal udara, kapal laut atau kereta api yang terpaksa mampir atau singgah pada suatu pelabuhan, airport atau stasiun bukan atas kemauannya sendiri.

6. Business tourist


Business tourist adalah orang yang melakukan perjalanan yang mengadakan perjalanan untuk tujuan lain bukan wisata tetapi perjalanan dilakukannya setelah tujuan utamanya selesai.

C. JARINGAN SYARAF TIRUAN

1. Pengertian Jaringan Syaraf

Pao & Rao (1993 : 352) mendefinisikan jaringan syaraf secara biologis sebagai suatu kelompok pengolahan elemen dalam suatu kelompok yang khusus yang membuat perhitungan sendiri dan memberikan hasilnya kepada kelompok

kedua dan berikutnya. *Neuron* adalah satuan unit pemroses terkecil pada otak, bentuk sederhana dari sebuah *neuron* menurut para ahli yang diilustrasikan dalam gambar 2.3



Gambar 2.3. Sel *Neuron* (Fausset.1994 : 6)

Jaringan otak manusia tersusun tidak kurang dari 10^{13} *neuron* yang masing-masing terhubung oleh sekitar 10^{15} dendrit. *Neuron* memiliki berbagai komponen utama sebagai berikut (Fausett, 1994 : 6) :


- a. *Dendrit*, berfungsi saluran penyampai sinyal atau informasi dari satu *neuron* ke *neuron* lain
- b. *Badan sel (soma)*, berfungsi sebagai tempat pengolahan informasi.
- c. *Akson (neurit)*, berfungsi mengirimkan implus-impuls ke sel saraf lainnya.

Neuron memiliki sistem kerja terhadap suatu informasi yang masuk melalui *dendrit*. Suatu informasi atau sinyal masuk melalui *sinapsis* yang dalam pemrosesannya melalui proses kimiawi selanjutnya informasi akan diolah oleh *badan sel (soma)*. Hasil pengolahan informasi akan diteruskan ke *akson (neurit)* untuk disampaikan ke *soma* lain sehingga berakhir pada respon manusia terhadap

sinyal atau informasi tersebut. Secara garis besar jaringan syaraf terbentuk dari jutaan bahkan lebih struktur dasar *neuron* yang saling terhubung dan terintegrasi satu dengan yang lain sehingga dapat melaksanakan aktifitas secara teratur dan terus menerus sesuai dengan respon yang dibutuhkan.

2. Pengertian Jaringan Syaraf Tiruan (*Neural Network*)

Jaringan syaraf tiruan merupakan pengembangan dari jaringan syaraf pada otak manusia yang direpresentasikan melalui pemrograman komputer. Menurut Sri Kusumadewi (2003 : 207), Jaringan syaraf tiruan adalah salah satu representasi buatan dari otak manusia yang selalu mencoba untuk mensimulasikan proses pembelajaran pada otak manusia. Istilah buatan digunakan karena jaringan syaraf ini diimplimentasikan dengan menggunakan program komputer yang mampu menyelesaikan sejumlah proses perhitungan selama proses pembelajaran. Gambar 2.4 adalah dasar pembuatan jaringan syaraf buatan yang mensimulasikan berdasarkan otak manusia :



Gambar 2.4. Diagram Jaringan Syaraf Buatan

Jaringan syaraf tiruan pertama kali ditemukan oleh Warren Mc. Coloch dan Walter Pitts dalam tulisannya yang berjudul: “*A Logical Calculus of the idea*

Immanent in Nervous Activity” pada tahun 1943 di *buletin of Mathematical Biophysics* (Fausett, 1994 : 22). Jaringan syaraf tiruan merupakan salah satu sistem pemrosesan informasi yang didesain dengan menirukan cara kerja otak manusia dalam menyelesaikan suatu masalah dengan melakukan proses belajar melalui perubahan bobot sinapsisnya. Jaringan syaraf tiruan mampu mengenali kegiatan dengan berbasis pada data masa lalu. Data masa lalu akan dipelajari oleh jaringan syaraf tiruan sehingga mempunyai kemampuan untuk memberi keputusan terhadap data yang belum pernah dipelajari.

Menurut Fausett (1994 : 3), karakteristik jaringan syaraf tiruan ditentukan oleh faktor-faktor berikut :


- a. Pola hubungan antara *neuron-neuron* (arsitektur jaringan)
- b. Metode penentuan bobot pada jaringan (metode pelatihan atau pembelajaran)
- c. Fungsi aktivasi yang dikerjakan pada *neuron*.

Jaringan syaraf tiruan telah dikembangkan sebagai generalisasi model matematik dari kognisi manusia atau biologi *neural network* yang berbasis pada asumsi berikut:

- a. Pemrosesan Informasi terjadi pada banyak elemen sederhana yang disebut *neuron*.
- b. Sinyal diberikan antara *neuron* lewat jalinan koneksi.
- c. Setiap jalinan koneksi mempunyai bobot yang mengalikan sinyal yang ditransmisikan.

- d. Setiap *neuron* menerapkan fungsi aktivasi yang biasanya non linear terhadap jumlah sinyal masukan terbobot yang menentukan sinyal keluaran.

Jaringan *neural* dikarakteristikan berdasarkan *layer* atau lapisan-lapisan pemrosesan yang direpresentasikan dengan arsitektur pada gambar 2.5 :



Gambar 2.5. Arsitektur Jaringan *Neural Network* (Fausset, 1994 : 21)

Sebuah *neuron* disebut juga dengan unit pemrosesan. Sebuah input diterima *neuron* sebelumnya dan menggunakannya untuk menghitung sinyal output yang dilanjutkan ke *layer-layer* lain. Dalam jaringan syaraf tiruan terdapat tiga jenis *layer* antara lain:

- a. Lapisan input (*input layer*) : bertugas menerima data dari luar jaringan

- b. Lapisan tersembunyi (*hidden layer*): mengolah data input dan menghasilkan data output di dalam jaringan
- c. Lapisan output (*output layer*) : bertugas mengirim data ke luar jaringan.

Secara umum, analogi jaringan syaraf biologi terhadap jaringan syaraf buatan ditunjukkan dengan tabel 2.1. : (Puspitaningrum, 2006 ; 3)

Jaringan Syaraf Biologis	Jaringan Syaraf Tiruan
Badan sel (<i>soma</i>)	<i>Neuron</i>
Dendrit	Input
Akson	Output
Sinapsis	Bobot

Tabel 2.1. Analogi jaringan syaraf biologis terhadap jaringan syaraf Tiruan

Untuk dapat menyelesaikan suatu permasalahan jaringan syaraf tiruan memerlukan algoritma pembelajaran atau pelatihan, yaitu bagaimana sebuah konfigurasi jaringan dapat dilatih untuk mempelajari data historis yang ada. Dalam Fausett (1994 : 15), disebutkan bahwa algoritma pembelajaran atau pelatihan digolongkan menjadi dua, yaitu :

a. Pembelajaran Terawasi (Supervised learning)

Pembelajaran mengasumsikan bahwa terdapat guru atau supervisor dalam proses training. Pembelajaran ini dapat digunakan dalam lingkungan yang pasti dimana terdapat parameter-parameter pada sejumlah pasang data masukan dan target keluaran yang berfungsi sebagai guru untuk melatih jaringan hingga diperoleh bobot yang diinginkan.

b. Pembelajaran tak terawasi (*Unsupervised learning*)

Pembelajaran yang harus mengidentifikasi informasi dari kelas pola sebagai bagian dari proses pembelajaran. Tugas dari pembelajaran tak terawasi lebih abstrak dan kurang terdefinisi. Dalam pelatihannya, perubahan bobot jaringan dilakukan berdasarkan parameter tertentu dan jaringan dimodifikasi menurut ukuran parameter tersebut.

3. Arsitektur Jaringan Syaraf Tiruan (*Neural Network*)

Neuron dikelompokkan berdasarkan lapisan-lapisan. *Neuron* yang terletak pada lapisan yang sama akan memiliki keadaan yang sama. Pada setiap lapisan yang sama, *neuron* akan memiliki fungsi aktivasi yang sama. Apabila *neuron* dalam satu lapisan tersembunyi akan dihubungkan dengan *neuron* pada lapisan output maka setiap *neuron* pada lapisan tersembunyi juga harus dihubungkan dengan setiap lapisan outputnya. Ada beberapa arsitektur jaringan syaraf, antara lain: (Kusumadewi, 2003: 212-214)

a. Jaringan lapisan tunggal (*single layer net*)

Jaringan dengan lapisan tunggal hanya memiliki satu lapisan dengan bobot-bobot terhubung. Jaringan ini menerima input kemudian secara langsung akan mengolahnya menjadi output tanpa harus melalui lapisan tersembunyi. Arsitektur jaringan lapisan tunggal (*single layer net*) ditunjukkan pada gambar 2.6.


b. Jaringan lapisan banyak (*multilayer layer net*)

Jaringan dengan banyak lapisan memiliki 1 atau lebih lapisan yang terletak diantara lapisan input dan lapisan output (memilik 1 atau lebih lapisan


tersembunyi). Lapisan-lapisan bobot yang terletak antara 2 lapisan yang bersebelahan. Jaringan dengan banyak lapisan ini dapat menyelesaikan permasalahan yang lebih sulit dari pada lapisan dengan lapisan tunggal dalam hal pembelajaran akan lebih rumit. Arsitektur jaringan lapisan banyak (*multilayer layer net*) ditunjukkan pada gambar 2.7.

c. Jaringan lapisan kompetitif (*competitive layer net*)


Hubungan antar *neuron* pada lapisan kompetitif tidak diperlihatkan dalam arsitektur tetapi ada di dalam arsitektur. Lapisan kompetitif menunjukkan salah satu contoh arsitektur jaringan dengan lapisan kompetitif yang memiliki bobot $-\eta$. Arsitektur jaringan lapisan kompetitif (*competitive layer net*) ditunjukkan pada gambar 2.8.



Gambar 2.6. Arsitektur Jaringan lapisan tunggal (*single layer net*)



Gambar 2.7. Arsitektur Jaringan lapisan banyak (*multilayer layer net*)



Gambar 2.8. Arsitektur Jaringan lapisan kompetitif (*competitive layer net*)

D. Uji *White Noise*

Proses *white noise* merupakan proses ε_i yang seriesnya terdiri dari variabel random yang tidak berkorelasi dengan rata-rata, variansi konstan dan kovariannya adalah nol. (Wei, 2006:15).

$$E(\varepsilon_i) = 0, \quad (2.15)$$

$$Var(\varepsilon_i) = \sigma_t^2 \quad (2.16)$$

$$\gamma_k = cov(\varepsilon_t, \varepsilon_{k+t}) = 0 \text{ untuk } k \neq 0 \quad (2.17)$$

ε_t merupakan barisan yang tidak memiliki korelasi. Dengan demikian, proses *white noise* stasioner menggunakan fungsi autokovariansi

$$\gamma_k = \begin{cases} \sigma_t^2, & \text{jika } k = 0 \\ 0, & \text{jika } k \neq 0 \end{cases} \quad (2.18)$$

Dan fungsi autokorelasi dan autokorelasi parsial sebagai berikut (Wei, 2006:16)

$$\rho_k = \begin{cases} 1, & \text{jika } k = 0 \\ 0, & \text{jika } k \neq 0 \end{cases} \quad (2.19)$$

$$\phi_{kk} = \begin{cases} 1, & \text{jika } k = 0 \\ 0, & \text{jika } k \neq 0 \end{cases} \quad (2.20)$$

Uji *white noise* dapat ditentukan dengan menggunakan uji autokorelasi (ACF) dan autokorelasi parsial (PACF) residual pada analisis *error*-nya. Uji ini digunakan untuk mendeteksi ada tidaknya korelasi residual antar *lag*. Apabila *lag* pada plot autokorelasi dan autokorelasi parsial tidak melebihi garis kepercayaan maka dapat dikatakan tidak ada *lag* yang signifikan dimana *error* bersifat acak sehingga asumsi *white noise* terpenuhi.