

BAB II

TINJAUAN PUSTAKA

2.1 Landasan Teori

2.1.1 Pasar Modal

Pasar modal adalah pasar dari berbagai instrumen keuangan (sekuritas) jangka panjang yang dapat diperjualbelikan, baik dalam bentuk hutang (obligasi) maupun modal sendiri (saham) yang diterbitkan pemerintah atau perusahaan swasta. Pada dasarnya fungsi pasar modal sebagai wahana demokratisasi kepemilikan saham yang ditunjukkan dengan semakin banyaknya institusi dan individu yang memiliki saham perusahaan yang telah *go public*. (Suad Husnan, 1994)

Sebagaimana telah disinggung sebelumnya, pasar modal mempunyai peranan penting dalam mobilisasi dana untuk menunjang pembangunan nasional. Akses dana dari pasar modal telah mengundang banyak perusahaan nasional maupun patungan untuk menyerap dana masyarakat tersebut dengan tujuan yang beragam. Namun, sasaran utamanya adalah meningkatkan produktivitas kerja melalui ekspansi usaha dan/atau mengadakan pembenahan struktur modal untuk meningkatkan daya saing perusahaan.

Instrumen-instrumen pasar modal Indonesia yang memungkinkan mobilisasi dana masih relatif terbatas jika dibandingkan dengan bursa-bursa dunia yang sudah mapan. Kendati demikian, dalam usia yang relatif muda, pasar modal Indonesia telah menjadi wahana penting diluar perbankan untuk menyediakan

dana yang diperlukan dunia usaha melalui penjualan saham dan obligasi serta derivatifnya.

2.1.2 Investasi

Investasi merupakan suatu aktiva yang digunakan perusahaan untuk pertumbuhan kekayaan (*Accretion wealth*) melalui distribusi hasil investasi (seperti bunga, royalti, dividen, dan uang sewa) untuk apresiasi nilai investasi atau untuk mendapat manfaat lain bagi perusahaan yang berinvestasi, seperti manfaat yang diperoleh melalui hubungan perdagangan. Persediaan dan aktiva tetap bukan merupakan investasi (SAK, 1999).

Investasi dapat diartikan sebagai kegiatan menanamkan modal baik langsung maupun tidak langsung, dengan harapan pada waktunya nanti pemilik modal mendapatkan sejumlah keuntungan dari hasil penanaman modal tersebut (Hamid, 1995)

Investasi merupakan suatu kegiatan penempatan dana pada sebuah atau sekumpulan aset selama periode tertentu dengan harapan dapat memperoleh penghasilan dan/atau peningkatan nilai investasi (Jones, 2004). Pengertian investasi tersebut menunjukkan bahwa tujuan investasi adalah meningkatkan kesejahteraan investor, baik sekarang maupun dimasa yang akan datang (Dhuwita, 2003).

2.1.3 Strategi Investasi pasif

Strategi investasi pasif mendasarkan diri pada asumsi bahwa : (a) pasar modal tidak melakukan *mispricing*; dan (b) meskipun terjadi *mispricing*, para

pemodal berpendapat mereka tidak bisa mengidentifikasi dan memanfaatkannya (Lena T.C.Y, 1999). Dengan kata lain, penganut strategi ini tidak bermaksud untuk mengalahkan (*outperform*) pasar tetapi lebih kepada bertindak sebaik yang terjadi di pasar, mereka bertindak seolah-olah pasar efisien dan menerima perkiraan konsensus mengenai kembalian dan risiko, melihat harga saham saat ini sebagai sarana peramalan terbaik terhadap nilai sebuah sekuritas (Jones, 2004)

Pengadopsi strategi pasif bertujuan untuk menyusun portofolio yang sesuai dengan preferensi risiko atau pola arus kas yang mereka inginkan. Misalnya, Jika investor menginginkan risiko yang kecil, maka mereka akan membentuk portofolio yang terdiri atas saham-saham yang mempunyai beta rendah. Investor yang ingin mendapat arus kas tertentu, mungkin memilih saham-saham yang membagikan dividen secara teratur. Investor yang mempunyai tarif pajak tinggi cenderung membentuk portofolio yang tidak membagikan dividen yang terlalu tinggi. Dengan strategi pasif maka biaya transaksi akan diminimumkan. Para Investor dapat menganut strategi *buy and hold*, atau melakukan investasi pada portofolio yang disusun sesuai indeks pasar.

Strategi *buy and hold*, menyangkut keputusan untuk membeli saham-saham dan menahannya sampai waktu yang cukup lama untuk memenuhi tujuan tertentu (Sawidji, 1997). Tujuan utamanya adalah untuk menghindari tingginya biaya transaksi, biaya pencarian informasi, dan sebagainya. Investor percaya bahwa strategi semacam ini, dalam jangka waktu yang cukup lama, akan menghasilkan hasil yang sama baiknya apabila dibandingkan dengan manajemen investasi yang aktif (artinya aktif melakukan jual beli, aktif mencari informasi

yang dipandang relevan, dan sebagainya). Portofolio yang dimiliki pemodal mungkin cukup besar ataupun cukup kecil. Pemodal perlu melakukan strategi reinvestasi dari dividen yang diperoleh dari portofolio investasinya dan portofolio yang dimiliki mungkin didominasi oleh saham-saham tertentu. Meskipun demikian, perubahan portofolio dimungkinkan apabila dirasa risiko portofolio sudah tidak sesuai dengan preferensi risiko pemodal.

Pemodal juga dapat melakukan strategi dengan membentuk portofolio yang mirip dengan suatu indeks pasar. Misalnya membentuk portofolio yang komposisinya mirip dengan indeks LQ 45. Cara semacam ini disebut sebagai *Index fund*. *Index fund* yang dibentuk mungkin dibuat sama dengan indeks pasar yang terdiri atas saham-saham yang paling aktif diperdagangkan, saham *blue chip* (saham-saham yang dinilai mempunyai kualitas baik dengan sejarah memperoleh laba dan pembayaran dividen yang konsisten), ataupun saham-saham berkapitalisasi kecil (Suad Husnan, 1998).

2.1.4 Strategi Investasi Aktif

Strategi ini mendasarkan diri pada asumsi bahwa (a) pasar modal melakukan kesalahan dalam penentuan harga (*mispriced*); dan (b) para pemodal berpendapat bisa mengidentifikasi *mispriced* ini dan memanfaatkannya (apakah kedua asumsi itu benar, masih merupakan masalah yang perlu diteliti) (Lena T.C.Y, 1999).

Mereka yang menganut strategi aktif pada dasarnya tidak percaya sepenuhnya pada konsep pasar modal yang efisien. Meskipun demikian tidak

berarti pemodal akan menganut strategi aktif atau pasif secara mutlak. Mereka mungkin menginvestasikan sebagian dana mereka dengan menganut strategi aktif dan sisanya mendasarkan pada strategi pasif.

Mereka yang menggunakan strategi investasi aktif dapat menggunakan analisis fundamental, analisis teknikal atau *market timing*. Kedua tipe analisis yang pertama akan dibahas pada sub bab selanjutnya. sedangkan *market timing* pada dasarnya menentukan kapan seharusnya pemodal membeli atau menjual (atau melakukan *short selling*). Dengan demikian analisis ini merupakan variasi dari analisis teknikal.

Sebagian besar pemodal tampaknya masih memilih untuk melakukan strategi aktif meskipun terdapat berbagai bukti yang mendukung hipotesis pasar yang efisien, dan kinerja dari berbagai pemodal institusional yang menganut strategi pasif, yang ternyata juga memberikan kinerja yang cukup baik. Alasan mengapa mereka tetap melakukannya adalah keinginan untuk memperoleh imbalan yang sangat besar dari strategi yang mereka lakukan.

Salah satu bentuk strategi aktif yang sering dilakukan adalah pemilihan sekuritas. Strategi ini dilakukan terhadap saham-saham yang diperkirakan akan memberikan *abnormal return* positif, dan biasanya dilakukan dengan analisis fundamental, meskipun terkadang analisis teknikal juga digunakan (atau kombinasi keduanya).

Upaya untuk melakukan pemilihan saham nampaknya memang mempunyai justifikasi. McEnally dan Todd (1992) menunjukkan bahwa pemodal yang berhasil memilih saham-saham yang termasuk 25% penghasil return

tertinggi, dan konsisten mempertahankan pilihannya, akan berhasil menghindari tahun-tahun kerugian. Sebaliknya apabila seorang pemodal memilih saham-saham yang termasuk 25% terburuk, dan tidak merubahnya, akan berada dalam posisi memperoleh kerugian yang cukup berarti terutama pada tahun-tahun buruk. Periode pengamatan yang digunakan oleh kedua peneliti tersebut adalah 1946-1989.

Dalam pemilihan saham tersebut, tampaknya peran para analis saham cukup berarti. Kemampuan analis, waktu yang dicurahkan, dan informasi yang dimiliki para analis sekuritas tersebut nampaknya merupakan keunggulan apabila dibandingkan dengan analisis yang dilakukan oleh pemodal individual. Umumnya saran yang diberikan oleh analis sekuritas menyangkut *buy*, *sell* atau *hold*.

Selain melakukan pemilihan sekuritas, salah satu bentuk lain strategi aktif adalah penggantian sektor (*sector rotation*). Dengan cara ini pemodal merubah komposisi portofolionya, dari memusatkan pada suatu sektor menjadi pemusatan sektor lain, atau lebih merata, dan berbagai variasi lainnya. Pemodal mungkin menggeser portofolionya dari *value stocks* ke *growth stocks*, atau *cyclical stock* atau sebaliknya

2.1.5 Efisiensi Pasar Modal

Efisiensi pasar modal merupakan salah satu indikator untuk menentukan kualitas suatu pasar modal. Semakin tinggi derajat efisiensinya, maka kualitas pasar modal tersebut akan semakin baik. Pada dasarnya terdapat dua jenis efisiensi pasar modal, yakni efisiensi internal dan efisiensi eksternal (Sri Handari dkk, 1996).

Pasar modal semakin efisien internal apabila biaya transaksi dalam perdagangan saham semakin rendah. Jadi, efisiensi ini dikaitkan dengan besarnya biaya untuk melakukan pembelian atau penjualan suatu saham. Sementara itu derajat efisiensi eksternal akan ditentukan oleh kecepatan penyesuaian harga saham dipasar modal terhadap informasi baru. Dengan kata lain, apabila harga saham di pasar modal mencerminkan semua informasi yang ada (dan berhubungan dengan saham tersebut), maka pasar modal akan memiliki efisiensi eksternal yang semakin tinggi. Dari pengertian efisiensi eksternal tersebut, maka dapat disimpulkan bahwa jenis efisiensi ini akan dikaitkan dengan informasi, artinya efisiensi pasar modal akan diukur secara informasional (Sri Handaru dkk, 1996). Hal yang sama juga diungkapkan Suad Husnan (1996) melalui pernyataan bahwa pasar modal yang efisien adalah pasar modal yang harga sekuritas-sekuritasnya mencerminkan semua informasi yang relevan dengan cepat.

Haugen (1997) menyatakan bahwa terdapat tiga bentuk efisiensi pasar modal, tiap-tiap bentuk tersebut berhubungan dengan sekelompok informasi yang semakin luas jika dibandingkan dengan tingkat sebelumnya. Ketiga bentuk itu adalah efisiensi lemah, efisiensi setengah kuat, dan efisiensi kuat.

Efisiensi bentuk lemah (*weak-form efficiency*) menunjukkan bahwa harga merefleksikan semua informasi yang terangkum dalam catatan harga masa lalu. dalam keadaan ini investor tidak dapat memperoleh tingkat keuntungan yang lebih tinggi dari keadaan normal secara konsisten dengan menggunakan informasi harga di waktu lalu. Dengan kata lain informasi ini tidak relevan untuk memperoleh tingkat hasil yang berlebih (Haugen, 1997).

Efisiensi bentuk setengah kuat (*semi-strong form efficiency*) adalah keadaan yang tidak hanya mencerminkan harga-harga diwaktu lalu, tetapi juga informasi yang dipublikasikan. Akibatnya dalam keadaan ini investor tidak dapat memperoleh keuntungan diatas normal secara konsisten dengan memanfaatkan informasi publik (Haugen, 1997).

Tingkat efisiensi terakhir yaitu efisiensi bentuk kuat (*strong-form efficiency*), dicapai jika harga tidak hanya mencerminkan informasi harga diwaktu lalu dan informasi yang dipublikasikan, tetapi juga informasi yang dapat diperoleh dari analisis fundamental tentang perusahaan dan perekonomian serta informasi-informasi lain yang tidak atau belum dipublikasikan. Dalam keadaan semacam ini harga sekuritas akan menjadi sangat wajar, dan tidak ada investor yang mampu memperoleh perkiraan yang lebih baik mengenai harga saham secara konsisten (Haugen, 1997).

2.1.6 Teknik Analisis Saham

Pengambilan keputusan investor untuk melakukan investasi pada saham selalu mempertimbangkan faktor perolehan dan risiko. Risiko diidentifikasi dengan fluktuasi atau ketidakpastian. Walaupun pertumbuhan dari perolehan diinginkan, tetapi fluktuasi tajam yang memunculkan risiko tinggi selalu diupayakan ditekan.

Analisis saham dibutuhkan untuk menentukan kelas risiko dan perolehan surat berharga sebagai dasar keputusan investasi. Analisis tersebut dilakukan dengan dasar sejumlah informasi yang diterima investor atas suatu jenis saham

tertentu. Keputusan investasi akan berbeda apabila merupakan hasil analisis yang berbeda, dari susunan informasi yang berbeda, selama dengan kondisi yang berbeda dengan preferensi risiko yang relevan untuk berbagai investor. Francis (1983) mengemukakan dua pendekatan dalam penilaian sekuritas, yaitu analisis fundamental (*fundamental approach*) dan analisis teknikal (*technical approach*).

2.1.6.1 Analisis Fundamental

Analisis fundamental merupakan teknik analisis saham yang mempelajari tentang keuangan mendasar dan fakta ekonomi dari perusahaan sebagai langkah penilaian saham perusahaan. Asumsi yang digunakan adalah harga saham yang terjadi merupakan refleksi dari informasi mengenai saham tertentu. Hal ini terjadi apabila efisiensi pasar modal sekurang-kurangnya dalam bentuk setengah kuat. Para investor yang mengambil keputusan berdasarkan faktor fundamental ini biasanya cenderung lebih senang menghindari risiko (*risk averse*).

Dalam menerapkan analisis fundamental ini pada praktiknya akan selalu mengasumsikan bahwa pembentukan harga suatu saham dipengaruhi oleh berita yang datangnya secara acak (*random walk*) dan harga saham akan secara cepat menyesuaikan dengan keadaan berita tersebut. Sehingga analisis fundamental akan lebih tepat digunakan apabila kondisi pasar modal berada dalam tingkat efisiensi setengah kuat dan kuat.

Asumsi lainnya dari analisis fundamental ini adalah sebagai berikut (Huang, 1990) :

1. Investor adalah rasional dan berperilaku *risk averse*

Investor tersebut akan mencari saham yang memberikan keuntungan maksimal apabila risiko yang dihadapi sama besarnya, atau akan mencari saham yang memberikan risiko terkecil apabila keuntungan yang diperoleh sama.

2. Teori Jalan Acak (*The theory of random walk*)

Berita akan datang secara acak. Berita baik, secara teoritis akan mengangkat harga saham bersangkutan. sebaliknya, berita buruk akan mendorong harga saham untuk turun.

3. Teori pasar yang efisien (*The theory of Efficient Market*)

Pasar dapat dikatakan efisien apabila berita-berita yang datang secara cepat beredar ke seluruh investor yang ada.

2.1.6.2 Analisis Teknikal

Analisis Teknikal merupakan teknik analisis saham yang dilakukan dengan menggunakan data historis mengenai perkembangan harga saham dan volume perdagangan saham dalam pola grafik. dan kemudian digunakan sebagai model pengambilan keputusan. Penawaran dan permintaan akan digunakan untuk memprediksi tingkat harga mendatang dan pergerakannya. Analisis teknikal merupakan teknik analisis yang paling banyak dilakukan oleh para investor, bahkan penelitian Taylor dan Aller (1992) dalam Fernandez-Rodriguez dkk (1999)

menyatakan bahwa lebih dari 90% investor memberikan bobot yang lebih tinggi pada penggunaan analisis teknikal dibandingkan analisis fundamental dalam membeli atau menjual saham.

Asumsi dalam analisis teknikal antara lain (Huang, 1990 dan Sri Handari dkk, 1996)

1. Kejadian di pasar menggambarkan segalanya (*Market action discount everything*)

Reaksi pasar akan terjadi sesuai dengan kondisi pasar tersebut, dimana apabila tawaran jual (*offer*) lebih banyak dibandingkan tawaran beli (*bid*) maka harga akan bergerak turun. Demikian pula sebaliknya apabila tawaran jual lebih sedikit dibandingkan dengan tawaran beli maka harga akan bergerak naik.

2. Harga bergerak mengikuti tren (*Price move in trends*)

Harga saham akan bergerak sesuai dengan keadaan pasar, seperti yang telah dijelaskan sebelumnya. Apabila suatu harga saham telah bergerak baik naik ataupun turun maka harga saham tersebut untuk selanjutnya akan mengikuti pola sebelumnya sampai berita atau isu yang terbaru ada.

3. Masa lalu akan terulang dengan sendirinya (*History repeat itself*)

Pergerakan harga saham yang pernah terjadi akan selalu melekat dibenak seorang investor dan cenderung untuk menjadi acuan bagi seorang investor untuk mengambil keputusan investasi.

Analisis teknikal akan tepat digunakan apabila kondisi pasar modal tidak efisien dalam bentuk lemah, atau dengan kata lain tidak *random walk*. Sesuai

dengan salah satu asumsi dalam analisis teknikal yang berbunyi *history repeat itself*. maka kondisi pasar modal yang saham-saham tidak bergerak acak dan dapat diprediksi akan membuat analisis teknikal bermanfaat bagi investor.

Analisis teknikal dapat didefinisikan sebagai penggunaan data spesifik yang berasal dari transaksi dipasar untuk analisis baik harga saham agregat (indeks pasar maupun rata-rata industri) atau harga saham tunggal. (Jones, 2004).

Pendekatan teknikal dalam investasi pada dasarnya adalah refleksi ide bahwa harga bergerak dalam tren yang ditentukan oleh perubahan perilaku investor terhadap berbagai macam tekanan ekonomi, moneter, politik dan psikologis. Seni analisis teknikal, dalam kaitannya sebagai seni, digunakan untuk mengidentifikasi perubahan tren pada tahap awal dan untuk menjaga bentuk investasi sampai beratnya menunjukkan bahwa tren akan berbalik (Pring, Edward dan Magee (1958) mengartikulasikan asumsi dasar yang mendasari analisis teknikal sebagai berikut :

1. Nilai pasar ditentukan oleh interaksi antara penawaran dan permintaan
2. Penawaran dan permintaan diatur oleh berbagai faktor, baik rasional maupun irasional.
3. Harga sekuritas cenderung untuk bergerak pada sebuah tren yang bertahan untuk waktu yang cukup lama, disamping fluktuasi kecil dipasar.
4. Perubahan didalam tren disebabkan oleh pergeseran penawaran dan permintaan.

5. Pergeseran pada penawaran dan permintaan, dengan tidak memperhatikan mengapa pergeseran terjadi, dapat dideteksi cepat atau lambat pada grafik transaksi pasar.
6. beberapa pola grafik cenderung mengalami pengulangan.

2.1.7 Multifraktal

Ide dasar pengembangan eksponen Hurst adalah model otokorelasi. Pada otokorelasi biasa menggunakan data sebagai satu kesatuan deret waktu, sedangkan pada analisis R/S (*Rescaled range Analysis*, sebutan untuk mendapatkan eksponen Hurst) data dipecah menjadi beberapa bagian, dan analisis R/S dilakukan terhadap masing-masing data yang terpecah. Misalkan kita memiliki data deret waktu Y_1, \dots, Y_N data ini kemudian dipecah menjadi beberapa bagian dengan panjang yang sama, dengan masing-masing terdiri atas y_1, \dots, y_t .

Nilai R diperoleh dari persamaan :

$$R_N = \text{Maks}X_{(t,N)} - \text{min}X_{(t,N)}$$

Nilai X diperoleh dari persamaan :

$$X_{t,N} = \sum_{u=1}^t (x_u - \mu_N)$$

Dimana μ_N adalah rata-rata deret waktu selama periode N. Nilai S merupakan deviasi standard data deret waktu yang kita miliki. Dapat diperoleh dengan persamaan

$$S_N = \left[\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_N)^2 \right]^{\frac{1}{2}}$$

Rasio R/S dari R dan Deviasi Standard S dari deret waktu utama dapat dihitung dengan hukum empiris sebagai berikut (Yao dkk, 1999) : $R/S = N^H$. Nilai Eksponen Hurst dapat dihitung sebagai berikut :

$$H = \log(R/S)/\log(N)$$

Dimana nilai H berada diantara 0 dan 1 ($0 < H < 1$). Estimasi nilai H dapat diperoleh dengan melakukan perhitungan slope grafik log R/S terhadap N menggunakan regresi.

Nilai eksponen Hurst (H) menggambarkan probabilitas bahwa dua event konsekutif dapat muncul. Jika nilai $H = 0,5$ maka data deret waktu bertipe acak, terdiri atas event-event yang tidak berhubungan. Nilai H selain 0,5 menggambarkan bahwa objek observasi tidak independen, Ketika $0 \leq H < 0,5$, sistem yang diteliti merupakan deret ergodic dan antipersisten dengan frekuensi pembalikan yang tinggi dan volatilitas yang tinggi. Disamping kelaziman yang ada mengenai konsep pembalikan rata-rata pada literatur ekonomi dan keuangan, hanya ditemukan beberapa deret waktu antipersisten. Bagi kondisi ketiga ($0,5 < H \leq 1,0$), H mendeskripsikan deret persisten dan adanya tren yang ditunjukkan oleh efek ingatan jangka panjang (*long memory effects*). Kekuatan bias bergantung pada seberapa besar nilai H diatas 0,5. Semakin rendah nilai H, lebih banyak noise pada sistem dan deret lebih mendekati keacakan.(Yao dkk, 1999).

2.1.8 Metode Analisis Teknikal

Terdapat berbagai macam metode yang dapat digunakan untuk melakukan prediksi nilai sebuah data runtun waktu seperti harga saham atau indeks saham.

Beberapa diantaranya *Auto Regressive* (AR), *Moving Average* (MA), *Autoregressive Integrated Moving Average* (ARIMA), *Vector Auto Regression* (VAR), Jaringan Syaraf Tiruan, Algoritma Genetika, dan Logika Fuzzy. Pada tulisan ini hanya akan dibahas dua metode analisis teknikal yaitu ARIMA (*Autoregressive Integrated Moving Average*) dan Jaringan Syaraf Tiruan.

2.1.8.1 ARIMA (*Autoregressive Integrated Moving Average*)

Dalam analisis teknikal, terdapat metode-metode yang merupakan *basic trading rules* yaitu indikator-indikator berupa *moving average*, *exponential moving average*, dan *trend line* (Parisi dan Vasquez, 2000; Fernandez-Rodriguez, 1999,2000,2001)

Metode *moving average* adalah salah satu metode analisis teknikal sederhana. Dilakukan dengan cara mencari rata-rata bergerak dari harga saham harian selama beberapa periode, banyaknya periode yang sering digunakan untuk perhitungan ini adalah 5, 10 dan 100 periode. Metode *moving average* yang lainnya adalah *exponential moving average* yang memiliki prinsip yang hampir sama dengan MA, tetapi EMA mempertimbangkan bobot dari periode sebelumnya. Sementara itu metode *trend line* adalah metode perkiraan harga saham dengan menggunakan teknik regresi sederhana dengan waktu sebagai variabel bebasnya.

Model ARIMA merupakan model yang dikembangkan secara intensif oleh George Box dan Gwilyn Jenkins sehingga nama mereka sering disinonimkan dengan proses ARIMA yang diterapkan untuk analisis dan peramalan data runtun

waktu (*time series*). ARIMA sebenarnya adalah teknik untuk mencari pola yang paling cocok dari sekelompok data (*curve fitting*), dengan demikian ARIMA memanfaatkan sepenuhnya data masa lalu dan sekarang untuk melakukan peramalan jangka pendek yang akurat. Contoh pemakaian model ARIMA adalah peramalan harga saham dipasar modal yang dilakukan para pialang yang didasarkan pada pola perubahan harga saham dimasa lampau (Sugiarto dan Harijono, 2000). ARIMA juga telah digunakan pada beberapa penelitian empiris di Bursa Efek Jakarta, misalnya penelitian Ibnu Qizam (2001) yang menggunakan ARIMA untuk menganalisis kerandoman perilaku laba perusahaan di Bursa Efek Jakarta, penelitian tersebut mengambil kesimpulan bahwa metode ARIMA masih relevan dalam menggambarkan perilaku laba.

Dalam melakukan analisis empiris menggunakan data runtun waktu, para peneliti dan ekonometrisi menghadapi beberapa tantangan (Gujarati, 1995:709 dalam Firmansyah, 2000), yaitu : *pertama*, studi empiris dengan basis data runtun waktu mengasumsikan bahwa data runtun waktu adalah stasioner. Asumsi ini memiliki konsekuensi penting dalam menterjemahkan data dan model ekonomi. Hal ini karena data yang stasioner pada dasarnya tidak mempunyai variasi yang terlalu besar selama periode pengamatan dan mempunyai kecenderungan untuk mendekati nilai rata-ratanya (Insukindro, 1994; Gujarati, 1995; Engle dan Granger, 1987). *Kedua*, dalam regresi suatu variabel runtun waktu dengan variabel runtun waktu yang lain, seorang peneliti menginginkan bahwa koefisien determinasi R^2 memiliki nilai yang tinggi tetapi seringkali tidak terdapat keterkaitan yang berarti antara kedua variabel tersebut. Situasi ini

mengindikasikan adanya permasalahan regresi lancung (*spurious regression*), akibatnya antara lain koefisien regresi penaksir tidak efisien, uji baku umum untuk koefisien regresi menjadi tidak valid. *Ketiga*, model regresi dengan data runtun waktu seringkali digunakan untuk keperluan peramalan atau prediksi. Hasil prediksi tidak akan valid apabila data yang digunakan tidak stasioner.

Ada beberapa alasan yang dapat dikemukakan mengapa digunakan teknik peramalan yang tidak menggunakan model struktural, dimana persamaannya menunjukkan hubungan antar variabel yang berdasar pada teori ekonomi dan logika. Meskipun mungkin sebenarnya landasan teori yang digunakan untuk membentuk suatu model ada, tetapi data variabel bebas yang diperlukan ternyata tidak tersedia. Selain itu, terkadang penyebab pergerakan suatu variabel sulit dideteksi (Firmansyah, 2000).

2.1.8.1.1 Notasi Dalam model ARIMA

Secara umum model ARIMA (Box-Jenkins) dirumuskan dengan notasi sebagai berikut (Harijono dan Sugiarto, 2000) :

ARIMA (p,d,q)

dalam hal ini,

p menunjukkan orde / derajat *Autoregressive* (AR)

d menunjukkan orde / derajat *Differencing* (pembedaan) dan

q menunjukkan orde / derajat *Moving Average* (MA)

2.1.8.1.2 Model *Autoregressive* (AR)

Model *Autoregressive* adalah model yang menggambarkan bahwa variabel dependen dipengaruhi oleh variabel dependen itu sendiri pada periode-periode dan waktu-waktu sebelumnya (Sugiarto dan Harijono, 2000). Secara umum model *autoregressive* (AR) mempunyai bentuk sebagai berikut :

$$Y_t = \theta_0 + \theta_1 Y_{t-1} + \theta_2 Y_{t-2} + \dots + \theta_p Y_{t-p} - e_t$$

Dimana,

Y_t : deret waktu stasioner

θ_0 : Konstanta

Y_{t-1}, \dots, Y_{t-p} : Nilai masa lalu yang berhubungan

$\theta_1, \dots, \theta_p$: Koefisien atau parameter dari model *autoregressive*

e_t : residual pada waktu t

Orde dari model AR (yang diberi notasi p) ditentukan oleh jumlah periode variabel dependen yang masuk dalam model. Sebagai contoh :

$Y_t = \theta_0 + \theta_1 Y_{t-1}$ adalah model AR orde 1 dengan notasi ARIMA (1,0,0)

$Y_t = \theta_0 + \theta_1 Y_{t-1} + \theta_2 Y_{t-2}$ adalah model AR orde 2 dengan notasi ARIMA (2,0,0)

Model diatas disebut sebagai model *autoregressive* (regresi diri sendiri) karena model tersebut mirip dengan persamaan regresi pada umumnya, hanya saja yang menjadi variabel independen bukan variabel yang berbeda dengan variabel dependen melainkan nilai sebelumnya (lag) dari variabel dependen (Y_t) itu sendiri

Banyaknya nilai lampau yang digunakan oleh model, yaitu sebanyak p,

menentukan tingkat model ini. Apabila hanya digunakan satu lag dependen, maka model ini dinamakan model autoregressive tingkat satu (*first-order autoregressive*) atau AR(1). Apabila nilai yang digunakan sebanyak p lag dependen, maka model ini dinamakan model autoregressive tingkat p (*p-th order autoregressive*) atau AR(p).

2.1.8.1.3 Model *Moving Average* (MA)

Secara umum model moving average mempunyai bentuk sebagai berikut :

$$Y_t = \phi_0 + \phi_1 e_{t-1} - \phi_2 e_{t-2} - \dots - \phi_n e_{t-q}$$

dimana,

- Y_t : Deret waktu stasioner
- ϕ_0 : konstanta
- ϕ_1, \dots, ϕ_n : koefisien model moving average yang menunjukkan bobot. Nilai koefisien dapat memiliki tanda negatif atau positif, tergantung hasil estimasi.
- e_{t-q} : residual lampau yang digunakan oleh model, yaitu sebanyak q, menentukan tingkat model ini.

Perbedaan model moving average dengan model autoregressive terletak pada jenis variabel independen. Bila variabel independen pada model autoregressive adalah nilai sebelumnya (lag) dari variabel dependen (Y_t) itu sendiri, maka pada model moving average sebagai variabel independennya adalah nilai residual pada periode sebelumnya.

Orde dari nilai MA (yang diberi notasi q) ditentukan oleh jumlah periode variabel independen yang masuk dalam model. Sebagai contoh :

$Y_t = \phi_0 + \phi_1 e_{t-1}$ adalah model MA orde 1 dengan notasi ARIMA (0,1,1)

$Y_t = \phi_0 + \phi_1 e_{t-1} - \phi_2 e_{t-2}$ adalah model MA orde 2 dengan notasi ARIMA (0,0,2)

2.1.8.1.4 Model ARMA (Autoregressive Moving Average)

Sering kali karakteristik Y tidak dapat dijelaskan oleh proses AR saja atau MA saja, tetapi harus dijelaskan oleh keduanya sekaligus. Model yang memuat kedua proses ini biasa disebut model ARMA. Bentuk umum model ini adalah :

$$Y_t = \gamma_0 + \delta_1 Y_{t-1} + \delta_2 Y_{t-2} + \dots + \delta_n Y_{t-p} - \lambda_1 e_{t-1} - \lambda_2 e_{t-2} - \dots - \lambda_n e_{t-q}$$

Di mana Y_t dan e_t sama seperti sebelumnya, γ_t adalah konstanta, δ dan λ adalah koefisien model. Jika model menggunakan dua lag dependen dan tiga lag residual, model itu dilambangkan dengan ARMA (2,3)

2.1.8.1.5 Model ARIMA

Dalam praktek banyak ditemukan bahwa data ekonomi bersifat non-stasioner sehingga perlu dilakukan modifikasi, dengan melakukan pembedaan (*differencing*), untuk menghasilkan data yang stasioner. Pembedaan dilakukan dengan mengurangi nilai pada suatu periode dengan nilai pada periode sebelumnya.

Pada umumnya, data di dunia bisnis akan menjadi stasioner setelah dilakukan pembedaan pertama. Jika setelah dilakukan pembedaan pertama ternyata data masih belum stasioner, perlu dilakukan pembedaan berikutnya. Data

yang dipakai sebagai input model ARIMA adalah data hasil transformasi yang sudah stasioner, bukan data asli. Beberapa kali proses *differencing* dilakukan dinotasikan dengan d . Misalnya data asli belum stasioner, lalu dilakukan pembedaan pertama dan menghasilkan data yang stasioner. Dapat dikatakan bahwa series tersebut melalui proses *differencing* satu kali, $d=1$. Namun jika ternyata deret waktu tersebut baru stasioner pada pembedaan kedua, maka $d=2$, dan seterusnya.

Model ARIMA biasanya dilambangkan dengan $ARIMA(p,d,q)$ yang mengandung pengertian bahwa model tersebut menggunakan p nilai lag dependen, d tingkat proses differensiasi, dan q lag residual. Simbol model sebelumnya dapat juga dinyatakan dengan simbol ARIMA, misalnya :
 $MA(2)$ dapat ditulis dengan $ARIMA(0,0,2)$
 $AR(1)$ dapat ditulis dengan $ARIMA(1,0,0)$
 $ARMA(1,2)$ dapat ditulis dengan $ARIMA(1,0,2)$
Dan sebagainya.

2.1.8.2 Jaringan Syaraf Tiruan

Jaringan Syaraf Tiruan merupakan teknologi yang lahir dari upaya manusia untuk mencari tahu bagaimana sistem koordinasi hewan terjadi, bagaimana syaraf bekerja, mengoptimasi diri, dan mampu menjadi pusat segala sistem hayati hewan (Situngkir dan Surya, 2003a).

Suatu jaringan saraf tiruan memproses sejumlah besar informasi secara paralel dan terdistribusi, hal ini terinspirasi oleh model kerja otak biologis.

Beberapa definisi tentang jaringan saraf tiruan adalah sebagai berikut :

1. Jaringan Syaraf Tiruan adalah suatu struktur pemroses informasi yang terdistribusi dan bekerja secara paralel, terdiri atas elemen pemroses (yang memiliki memori lokal dan beroperasi dengan informasi lokal) yang diinterkoneksi bersama dengan alur sinyal searah yang disebut koneksi. Setiap elemen pemroses memiliki koneksi keluaran tunggal yang bercabang (*fan out*) ke sejumlah koneksi kolateral yang diinginkan (setiap koneksi membawa sinyal yang sama dari keluaran elemen pemroses tersebut). Keluaran dari elemen pemroses tersebut dapat merupakan sebarang jenis persamaan matematis yang diinginkan. Seluruh proses yang berlangsung pada setiap elemen pemroses harus benar-benar dilakukan secara lokal, yaitu keluaran hanya bergantung pada nilai masukan pada saat itu yang diperoleh melalui koneksi dan nilai yang tersimpan dalam memori lokal. (Hecht-Nielsen, 1988)
2. Haykin, S. (1994), mendefinisikan jaringan saraf sebagai berikut: Sebuah jaringan saraf adalah sebuah prosesor yang terdistribusi paralel dan mempunyai kecenderungan untuk menyimpan pengetahuan yang didapatkannya dari pengalaman dan membuatnya tetap tersedia untuk digunakan. Hal ini menyerupai kerja otak dalam dua hal yaitu: (1) Pengetahuan diperoleh oleh jaringan melalui suatu proses belajar; (2) Kekuatan hubungan antar sel saraf yang dikenal dengan bobot sinapsis digunakan untuk menyimpan pengetahuan.

3. Zurada, J.M. (1992), mendefinisikan Jaringan Syaraf Tiruan sebagai sistem saraf tiruan atau jaringan saraf tiruan adalah sistem selular fisik yang dapat memperoleh, menyimpan dan menggunakan pengetahuan yang didapatkan dari pengalaman.


Neuron adalah unit pemroses informasi yang menjadi dasar dalam pengoperasian Jaringan syaraf tiruan. Neuron terdiri atas tiga elemen pembentuk (Siang, 2005:23) :

- a) Himpunan unit-unit yang dihubungkan dengan jalur koneksi. Jalur-jalur tersebut memiliki bobot / kekuatan yang berbeda-beda. Bobot yang bernilai positif akan memperkuat sinyal dan yang bernilai negatif akan memperlemah sinyal yang dibawanya. Jumlah, Struktur, dan pola hubungan antar unit-unit tersebut akan menentukan arsitektur jaringan (dan juga model jaringan yang terbentuk).
- b) Suatu unit penjumlah yang akan menjumlahkan input-input sinyal yang sudah dikalikan dengan bobotnya.
- c) Fungsi aktivasi yang akan menentukan apakah sinyal dari input neuron akan diteruskan ke neuron lain ataukah tidak.

Gambar skematik tipikal neuron dapat dilihat pada gambar 2.1

Gambar 2.1

Saraf Biologis



Sumber : Situngkir dan surya 2003b.

Teknologi Jaringan syaraf tiruan memberikan perubahan epistemologis pada sistem pemrograman dibandingkan pemrograman tradisional. Jaringan Syaraf Tiruan memproses informasi dengan cara yang sangat berbeda dengan cara konvensional. Perbedaan pemrograman Jaringan Syaraf Tiruan dan cara konvensional disajikan pada Tabel 2.1:

Tabel 2.1
Perbedaan Pemrograman Jaringan Syaraf Tiruan dan Pemrograman Tradisional


Jaringan Syaraf Tiruan	Pemrograman Tradisional
Komputasi dilakukan secara paralel dan terdistribusi dalam unit pemrosesan data dengan jumlah yang banyak	Komputasi dilakukan secara serial
Informasi terdistribusi dalam jaringan- Jaringan Syaraf Tiruan	Informasi teralokasi dalam tempat tertentu
disebut teknologi pemroses paralel terdistribusi (<i>Parallel distributed processing</i>)	

Sumber : Situngkir dan surya 2003b diringkas.

Pemrosesan informasi dalam Jaringan Syaraf Tiruan dapat disingkat sebagai berikut : Sinyal (baik berupa aksi ataupun potensial) muncul sebagai masukan unit (sinapsis); efek dari tiap sinyal ini dinyatakan sebagai bentuk perkalian dengan sebuah nilai bobot untuk mengindikasikan kekuatan dari sinapsis. Semua sinyal yang diberi pengali bobot ini kemudian dijumlahkan satu sama lain untuk menghasilkan unit aktivasi. Jika aktivasi ini melampaui sebuah batas ambang tertentu maka unit tersebut akan memberikan keluaran dalam bentuk respon terhadap masukan. Unit aktivasi ini kemudian dibandingkan dengan sebuah nilai ambang, dan hasilnya dimasukkan kedalam fungsi transfer (fungsi non-linier) yang akan menghasilkan sebuah keluaran. Secara ringkas proses tersebut dapat digambarkan dalam gambar 2.2

Gambar 2.2

Neuron buatan McCulloch-Pitts sebagai operator matematis



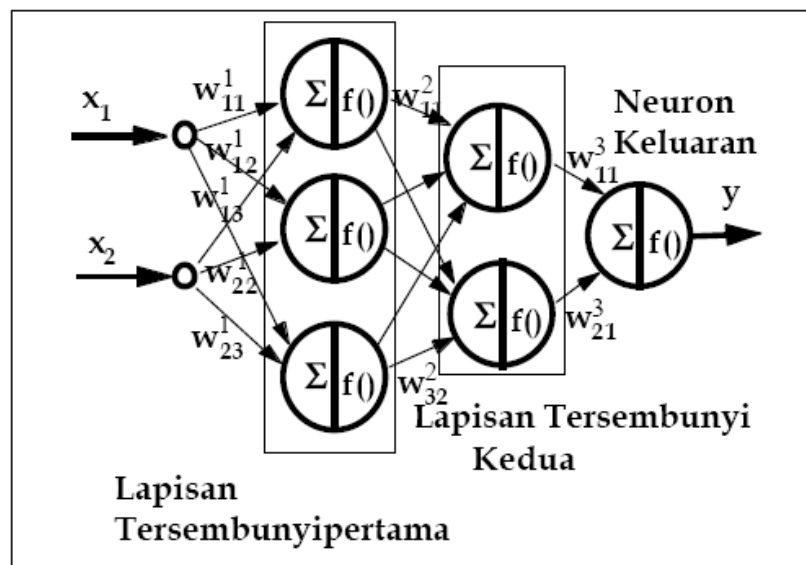
Sumber : Situngkir dan Surya, 2003b

Aktivasi dari unit masukan diatur dan diteruskan melalui jaring hingga nilai dari keluaran dapat ditentukan. Jaring berperan sebagai fungsi vektor yang mengambil satu vektor pada masukan dan mengeluarkan satu vektor lain pada keluaran. Model Jaringan Syaraf Tiruan dapat memiliki sebuah lapisan bobot, dimana masukan dihubungkan langsung dengan keluaran, atau beberapa lapisan yang didalamnya terdapat beberapa lapisan tersembunyi, karena berada tersembunyi diantara neuron masukan dan keluaran. jaring syaraf menggunakan unit tersembunyi untuk menghasilkan representasi pola masukan secara internal didalam jaring syaraf. Fungsi transfer (*non-linier*) yang digunakan dalam tiap neuron (baik dilapisan masukan, keluaran, atau lapisan tersembunyi) dapat berupa

fungsi nilai ambang, fungsi linier, fungsi sigmoid, ataupun fungsi gaussian, tergantung dari karakter neuron sesuai keinginan kita. Hal ini dapat dilihat pada gambar 2.3

Gambar 2.3

Tipikal Sebuah Jaringan Syaraf Tiruan



Sumber : situngkir dan surya, 2003b

2.1.8.3 Komponen Jaringan Syaraf

Terdapat beberapa tipe jaringan syaraf, hampir semuanya memiliki komponen-komponen yang sama. Seperti halnya otak manusia, jaringan syaraf juga terdiri atas beberapa neuron dan ada hubungan antar neuron tersebut. Neuron-neuron tersebut akan mentransformasikan informasi yang diterima melalui sambungan keluarnya menuju ke neuron-neuron yang lain. Pada jaringan syaraf, hubungan ini dikenal dengan nama bobot. Informasi tersebut disimpan pada suatu nilai tertentu pada bobot tersebut. Neuron ini sebenarnya mirip dengan sel neuron biologis. Neuron-neuron buatan tersebut bekerja dengan cara yang sama pula dengan neuron biologis. Informasi (disebut dengan: input) akan dikirim ke neuron dengan bobot kedatangan tertentu. Input ini akan diproses oleh suatu fungsi perambatan yang akan menjumlahkan nilai-nilai semua bobot yang datang. Hasil penjumlahan ini kemudian akan dibandingkan dengan suatu nilai ambang (*threshold*) tertentu melalui fungsi aktivasi setiap neuron. Apabila input tersebut melewati suatu nilai ambang tertentu, maka neuron tersebut akan diaktifkan, tapi kalau tidak, maka neuron tersebut tidak akan diaktifkan. Apabila neuron tersebut diaktifkan, maka neuron tersebut akan mengirimkan output melalui bobot-bobot outputnya ke semua neuron yang berhubungan dengannya. (Kusumadewi, 2003)

Pada Jaringan syaraf, neuron-neuron akan dikumpulkan dalam lapisan (*layer*) yang disebut dengan lapisan neuron (*neuron layer*). Neuron-neuron pada satu lapisan akan dihubungkan dengan lapisan-lapisan sebelum dan sesudahnya

(kecuali lapisan input dan lapisan output). Informasi yang diberikan pada jaringan syaraf akan dirambatkan lapisan ke lapisan. Mulai dari lapisan input sampai ke lapisan output melalui lapisan lainnya, yang sering disebut sebagai lapisan tersembunyi (*hidden layer*).

2.1.8.4 Arsitektur Jaringan Syaraf

2.1.8.4.1 Jaringan dengan lapisan tunggal (*single layer net*)

Jaringan dengan lapisan tunggal hanya memiliki satu lapisan dengan bobot-bobot terhubung. Jaringan ini hanya menerima input kemudian secara langsung akan mengolahnya menjadi output tanpa harus melalui lapisan tersembunyi.

2.1.8.4.2 Jaringan dengan banyak lapisan (*multilayer net*)

Jaringan dengan banyak lapisan memiliki 1 atau lebih lapisan yang terletak diantara lapisan input dan lapisan output (memiliki 1 atau lebih lapisan tersembunyi). Umumnya, ada lapisan bobot-bobot yang terletak antara 2 lapisan yang bersebelahan. Jaringan dengan banyak lapisan ini dapat menyelesaikan permasalahan yang lebih sulit daripada jaringan dengan lapisan tunggal, tentu saja dengan pembelajaran yang lebih rumit. Namun demikian, pada banyak kasus, pembelajaran pada jaringan dengan banyak lapisan ini lebih sukses dalam menyelesaikan masalah.


2.1.8.5. Fungsi Aktivasi

Ada beberapa fungsi aktivasi yang sering digunakan dalam jaringan syaraf tiruan,

antara lain :

a. **Fungsi Undak Biner (*Hard Limit*)**

Jaringan dengan lapisan tunggal sering menggunakan fungsi undak (step function) untuk mengkonversikan input dari suatu variabel yang bernilai kontinu ke suatu output biner (0 atau 1)




Undak Biner (*hard limit*)

Fungsi undak biner (*hard limit*) dirumuskan sebagai :

$$y = \begin{cases} 0, & \text{jika } x \leq 0 \\ 1, & \text{jika } x > 0 \end{cases}$$

b. **Fungsi undak biner (*Threshold*)**

Fungsi undak biner dengan menggunakan nilai ambang sering juga disebut dengan fungsi nilai ambang (*Threshold*) atau fungsi Heaviside.




Undak Biner (*threshold*)

Fungsi undak biner (dengan nilai ambang θ) dirumuskan sebagai

$$y = \begin{cases} 0, & \text{jika } x < \theta \\ 1, & \text{jika } x \geq \theta \end{cases}$$

c. Fungsi Bipolar (Symetric Hard Limit)

Fungsi bipolar sebenarnya hampir sama dengan fungsi undak biner, hanya saja output yang dihasilkan berupa 1, 0 atau -1



Fungsi *Symetric Hard Limit* dirumuskan sebagai :


$$y = \begin{cases} 1, & \text{jika } x > 0 \\ 0, & \text{jika } x = 0 \\ -1, & \text{jika } x < 0 \end{cases}$$

d. Fungsi Bipolar (dengan threshold)

Fungsi bipolar sebenarnya hampir sama dengan fungsi undak biner dengan threshold. Hanya saja keluaran yang dihasilkan berupa 1, 0, atau -1

Fungsi bipolar (dengan nilai ambang θ) dirumuskan sebagai


$$y = \begin{cases} 1, & \text{jika } x \geq \theta \\ -1, & \text{jika } x < \theta \end{cases}$$



e. Fungsi Linear (Identitas)


Fungsi linear memiliki nilai output yang sama dengan nilai inputnya. Fungsi ini dirumuskan sebagai :

$$y = x$$



f. Fungsi Saturating Linear

Fungsi ini akan bernilai 0 jika inputnya kurang dari $\frac{1}{2}$, dan akan bernilai 1 jika inputnya lebih dari $\frac{1}{2}$. Sedangkan jika nilai input terletak antara $-\frac{1}{2}$ dan $\frac{1}{2}$, maka outputnya akan bernilai sama dengan nilai input ditambah $\frac{1}{2}$




Saturating Linear

Fungsi *saturating linear* dirumuskan sebagai :

$$y = \begin{cases} 1; & \text{jika } x \geq 0,5 \\ x + 0,5; & \text{jika } -0,5 \leq x \leq 0,5 \\ 0; & \text{jika } x \leq -0,5 \end{cases}$$

g. Fungsi Symetric Saturating Linear

Fungsi ini akan bernilai -1 jika inputnya kurang dari -1, dan akan bernilai 1 jika inputnya lebih dari 1. Sedangkan jika nilai input terletak antara -1 dan 1, maka outputnya akan bernilai sama dengan nilai inputnya.



Symetric Saturating Linear

Fungsi symetric saturating linear dirumuskan sebagai :

$$y = \begin{cases} 1; & \text{jika } X \geq 1 \\ x; & \text{jika } -1 \leq x \leq 1 \\ -1; & \text{jika } X \leq -1 \end{cases}$$

h. Fungsi Sigmoid Biner

Fungsi ini digunakan untuk jaringan syaraf yang dilatih dengan menggunakan metode backpropagation. Fungsi sigmoid biner memiliki nilai pada range 0 sampai 1. Oleh karena itu, fungsi ini sering digunakan untuk jaringan syaraf yang membutuhkan nilai output yang terletak pada interval 0 sampai 1. Namun, fungsi ini bisa juga digunakan oleh jaringan syaraf yang nilai outputnya 0 atau 1.

Fungsi sigmoid biner dirumuskan sebagai :

$$y = f(x) = \frac{1}{1 + e^{-\sigma x}}$$

Dengan : $f'(x) = \sigma f(x)[1 - f(x)]$

i. Fungsi Sigmoid Bipolar

Fungsi sigmoid bipolar hampir sama dengan fungsi sigmoid biner, hanya saja output dari fungsi ini memiliki range antara 1 sampai -1

Fungsi sigmoid bipolar dirumuskan sebagai :

$$y = f(x) = \frac{1 - e^{-x}}{1 + e^{-x}}$$

$$\text{Dengan : } f'(x) = \frac{\sigma}{2} [1 + f(x)][1 - f(x)]$$

Fungsi ini sangat dekat dengan fungsi hyperbolic tangent. Keduanya memiliki range antara -1 sampai 1. Untuk fungsi hyperbolic tangent, dirumuskan sebagai :

$$y = f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

Atau :

$$y = f(x) = \frac{1 - e^{-2x}}{1 + e^{-2x}}$$

$$\text{Dengan : } f'(x) = [1 + f(x)][1 - f(x)]$$

2.1.8.6. Proses Pembelajaran

Terdapat dua tipe pembelajaran dalam Jaringan Syaraf Tiruan, yaitu :

(Kusumadewi, 2003)

a. **Pembelajaran terawasi (*supervised learning*)**

Metode pembelajaran pada jaringan syaraf disebut terawasi jika *output* yang diharapkan telah diketahui sebelumnya. Pada proses pembelajaran, satu pola *input* akan diberikan ke satu neuron pada lapisan *input*. Pola ini akan dirambatkan di sepanjang jaringan syaraf hingga sampai ke neuron pada lapisan *output*. Lapisan *output* ini akan membangkitkan pola *output* yang nantinya akan dicocokkan dengan pola *output* targetnya. Apabila terjadi perbedaan antara pola *output* hasil pembelajaran dengan pola target, maka disini akan muncul error. Apabila nilai error ini masih cukup besar, mengindikasikan bahwa masih perlu dilakukan lebih banyak pembelajaran lagi. Terdapat berbagai tipe pembelajaran terawasi beberapa diantaranya *Hebb Rule*, *Perceptron*, *Delta Rule*, *Backpropagation*, *Heteroassociative Memory*, *Bidirectional Associative Memory (BAM)*, *Learning Vector Quantization (LVQ)*.

Penelitian ini akan menggunakan propagasi balik (*backpropagation*) sebagai metode pembelajaran. Propagasi balik merupakan algoritma pembelajaran yang terawasi dan biasanya digunakan oleh perceptron dengan banyak lapisan untuk mengubah bobot-bobot yang terhubung dengan neuron-neuron yang ada pada lapisan tersembunyinya. Algoritma propagasi balik menggunakan *error output* untuk mengubah nilai bobot-bobotnya dalam arah mundur (*backward*). Untuk mendapatkan error ini, tahap perambatan maju (*forward propagation*) harus dikerjakan terlebih dahulu. Pada saat perambatan maju, neuron-neuron diaktifkan dengan menggunakan fungsi aktivasi sigmoid,

yaitu :

$$f(x) = \frac{1}{1 + e^{-x}}$$

Algoritma *backpropagation* :

- Inisialisasi bobot (ambil bobot awal dengan nilai random yang cukup kecil).
- Kerjakan langkah-langkah berikut selama kondisi berhenti bernilai FALSE :
 1. Untuk tiap-tiap pasangan elemen yang akan dilakukan pembelajaran, kerjakan :

Feedforward :

- a. Tiap-tiap unit input (X_i , $i=1,2,3,\dots,n$) menerima sinyal x_i dan meneruskan sinyal tersebut ke semua unit pada lapisan yang ada di atasnya (lapisan tersembunyi).
- b. Tiap-tiap unit tersembunyi (Z_j , $j=1,2,3,\dots,p$) menjumlahkan sinyal-sinyal input terbobot :

$$z_in_j = v_{0j} + \sum_{i=1}^n x_i v_{ij}$$

Gunakan fungsi aktivasi untuk menghitung sinyal outputnya :

$$Z_j = f(z_in_j)$$

Dan kirimkan sinyal tersebut ke semua unit di lapisan atasnya (unit-unit output).

- c. Tiap-tiap unit output (Y_k , $k=1,2,3,\dots,m$) menjumlahkan sinyal-sinyal input terbobot.

$$y_in_j = w_{0k} + \sum_{i=1}^p z_i w_{jk}$$

Gunakan fungsi aktivasi untuk menghitung sinyal outputnya :

$$y_k = f(y_{in_k})$$

Dan kirimkan sinyal tersebut ke semua unit dilapisan atasnya (unit-unit output).

Backpropagation

- d. Tiap-tiap unit output (Y_k , $k=1,2,3,\dots,m$) menerima target pola yang berhubungan dengan pola input pembelajaran, hitung informasi error nya :

$$\delta_k = (t_k - y_k) f'(y_{in_k})$$

Kemudian hitung koreksi bobot (yang nantinya akan digunakan untuk memperbaiki nilai w_{jk}) :

$$\Delta W_{jk} = \alpha \delta_k z_j$$

Hitung juga koreksi bias (yang nantinya akan digunakan untuk memperbaiki nilai w_{0k}) :

$$\Delta w_{0k} = \alpha \delta_k$$

Kirimkan δ_k ini ke unit-unit yang ada dilapisan bawahnya.

- e. Tiap-tiap unit tersembunyi (Z_j , $j=1,2,3,\dots,p$) menjumlahkan delta inputnya (dari unit-unit yang berada pada lapisan di atasnya) :

$$\delta_{in_j} = \sum_{i=1}^m \delta_k w_{jk}$$

Kalikan nilai ini dengan turunan dari fungsi aktivasinya untuk menghitung informasi error :

$$\delta_j = \delta_{in_j} f'(z_{in_j})$$

Kemudian hitung koreksi bobot (yang nantinya akan digunakan untuk memperbaiki nilai v_{ij}):

$$\Delta v_{jk} = \alpha \delta_j x_i$$

Kemudian hitung koreksi bias (yang nantinya akan digunakan untuk memperbaiki nilai v_{0j}):

$$\Delta v_{0j} = \alpha \delta_j$$

- f. Tiap-tiap unit output (Y_k , $k=1,2,3,\dots,m$) memperbaiki bias dan bobotnya ($j=0,1,2,\dots,p$):

$$w_{jk}(\text{baru}) = w_{jk}(\text{lama}) + \Delta w_{jk}$$

Tiap-tiap unit tersembunyi (Z_j , $j=1,2,3,\dots,p$) memperbaiki bias dan bobotnya ($i=0,1,2,\dots,n$)

$$v_{ij}(\text{baru}) = v_{ij}(\text{lama}) + \Delta w_{ij}$$

2. Tes Kondisi berhenti

b. Pembelajaran tak terawasi (*unsupervised learning*)

Pembelajaran tak terawasi tidak memerlukan target output. Pada metode ini, tidak dapat ditentukan hasil yang seperti apakah yang diharapkan selama proses pembelajaran. Selama proses pembelajaran, nilai bobot disusun dalam suatu range tertentu tergantung pada nilai input yang diberikan. Tujuan pembelajaran ini adalah mengelompokkan unit-unit yang hampir sama dengan suatu area tertentu. Pembelajaran ini biasanya sangat cocok untuk

pengelompokan (klasifikasi) pola. Contoh metode pembelajaran tak terawasi adalah jaringan kohonen (*kohonen network*)

2.1.8.7 Jaringan Syaraf Tiruan untuk prediksi data deret waktu

Dalam analisis sistem keuangan, kita mengenal dua penggunaan utama model jaring syaraf tiruan, yaitu :

- Model Jaringan Syaraf Tiruan digunakan sebagai model multi-agen; dalam hal ini neuron-neuron dipandang sebagai agen-agen pelaku ekonomi yang saling berinteraksi satu sama lain yang menghasilkan fenomena yang dilihat sebagai faktor agregasi dalam analisis yang dibangun. Hal ini dapat dilihat dalam beberapa karya heuristik seperti dalam Zimmerman dkk, 2001. Dalam sosiologi metode ini dapat ditemui dalam situngkir (2003).
- Model Jaringan Syaraf Tiruan digunakan sebagai perseptron (perceptron) yang mempelajari sebuah data deret waktu sedemikian hingga mampu melakukan identifikasi dan aproksimasi dari data deret waktu tersebut.

Penelitian ini berkonsentrasi pada penggunaan model kedua, yaitu bagaimana menggunakan model Jaringan syaraf tiruan untuk melakukan prediksi atau peramalan terhadap sebuah data keuangan deret waktu yang diberikan.

2.1.8.8 Galat Propagasi Balik (*Error Back Propagation*)

Dalam menggunakan model Jaringan syaraf tiruan dengan model / varian yang disebut sebagai Perseptron Multi Lapisan (*Multi Layer Perceptron*) yang memiliki n_i lapisan masukan, n_h lapisan tersembunyi, dan n_o lapisan keluaran tidak

ada hubungan intra lapisan atau loop dengan topologi standard: n_i - n_h - n_o . Untuk menentukan topologi dari jaring syaraf yang hendak digunakan untuk aproksimasi data deret waktu sangat bergantung pada kerumitan data yang hendak diaproksimasi. Ini merupakan bentuk pengaturan diri sendiri pada titik kritis (*Self Organized Criticality*) yang ditemui dalam model Jaringan syaraf tiruan. Jaringan Syaraf multi lapisan pada dasarnya selalu dapat digambarkan sebagai sebuah Jaringan syaraf satu lapis. Tiap neuron akan dilatih sedemikian rupa untuk dapat memahami data deret waktu yang kita berikan. Model latihan atau training yang digunakan adalah pelatihan Galat Propagasi Balik.

Pelatihan sebuah jaringan yang menggunakan propagasi balik terdiri atas tiga langkah (Kristanto, 2004), yaitu :


- a) Pelatihan pola input secara *feedforward*
- b) Perhitungan dan *back propagation* dari kumpulan kesalahan.
- c) Penyesuaian bobot

Sesudah pelatihan, aplikasi dalam Jaringan hanya terdiri atas fase *feed forward*. Jika pelatihan menjadi lambat, sebuah jaringan yang dilatih dapat menghasilkan outputnya sendiri secara cepat.

Galat Propagasi Balik merupakan model training yang sangat populer dikalangan pengguna model Jaringan Syaraf Tiruan arus maju (*multi layer feed forward neural network*). Gambar mekanisme Galat Propagasi balik dapat dilihat pada Gambar 2.4. Model training galat propagasi balik merupakan aturan koreksi kesalahan dimana kesalahan keluaran jaring syaraf dipropagasikan kembali kedalam lapisan tersembunyi untuk diproses kembali.

Gambar 2.4

Galat Propagasi Balik




Sumber : Situngkir dan surya, 2003b

Pada kondisi awal, jaring syaraf akan memberikan nilai acak untuk bobot dan nilai bias dari masing-masing neuron. Kemudian kesalahan keluaran dengan nilai bobot dan nilai bias tersebut akan dimasukkan lagi kedalam lapisan tersembunyi demikian seterusnya hingga kesalahan minimum diperoleh. Dalam tiap proses training kita dapati nilai kesalahan atau galat dan training akan berhenti setelah nilai galat tertentu.

Gambar 2.5

Contoh topologi jaring Syaraf 2-1 dengan tujuan mencapai nilai minima global atau titik galat terendah.



Sumber : situngkir dan surya, 2003b

Setiap kali dilakukan iterasi atau ditemukannya nilai galat, maka nilai faktor bobot akan berubah dengan metode *gradient descent*, dalam metode ini nilai bobot akan diperbaharui.

Pada metode standard propagasi balik, *gradient descent* dan *gradient descent with momentum*, proses pelatihan biasanya berjalan cukup lambat. Untuk lebih mempercepat pelatihan, algoritma pelatihan selanjutnya diperbaiki dengan dua alternatif, yaitu menggunakan teknik heuristik dan menggunakan teknik optimasi numeris (pada MATLAB kedua metode ini disediakan dalam *batch mode*).

Dalam penelitian ini akan digunakan metode *Gradient Descent with momentum and Adaptive Learning Rate* (`traingd`). Fungsi *Gradient Descent* dengan *adaptive learning* akan memperbaiki bobot-bobot berdasarkan *gradient descent* dengan *learning rate* yang bersifat *adaptive*. Pada *gradient descent* standard (`traingd`), selama proses pembelajaran, *learning rate* akan bernilai

konstan. Apabila learning rate terlalu tinggi, maka algoritma menjadi tidak stabil. Sebaliknya, jika learning rate terlalu kecil maka algoritma akan sangat lama dalam mencapai kekonvergenan. Kita akan sangat sulit untuk menentukan berapa nilai *learning rate* yang optimal sebelum proses pelatihan berlangsung. Pada kenyataannya, nilai *learning rate* yang optimal ini akan terus berubah selama proses pelatihan seiring dengan berubahnya nilai fungsi kinerja. Pada *gradient descent* dengan *adaptive learning rate*, nilai *learning rate* akan diubah selama proses pelatihan untuk menjaga agar algoritma ini senantiasa stabil selama proses pelatihan.

Algoritma *gradient descent* dengan *adaptive learning rate*, dasarnya sama dengan algoritma *gradient descent* standard dengan beberapa perubahan. Pertama-tama dihitung terlebih dahulu nilai output jaringan dan error pelatihan. Pada setiap epoch, bobot-bobot baru dihitung dengan menggunakan *learning rate* yang ada. Kemudian dihitung kembali output jaringan dan error pelatihan. Jika perbandingan antara error pelatihan yang baru dengan error pelatihan lama melebihi maksimum kenaikan kinerja (`max_perf_inc`), maka bobot-bobot baru tersebut akan diabaikan, sekaligus nilai *learning rate* akan dikurangi dengan cara mengalikannya dengan `lr_dec`. Sebaliknya, apabila perbandingan antara *error* pelatihan baru dengan error pelatihan lama kurang dari maksimum kenaikan kinerja, maka nilai bobot-bobot akan dipertahankan, sekaligus nilai *learning rate* akan dinaikkan dengan cara mengalikannya dengan `lr_inc`.

Dengan cara ini, apabila learning rate terlalu tinggi dan mengarah ke ketidakstabilan, maka learning rate akan diturunkan. Sebaliknya jika *learning rate*

terlalu kecil untuk menuju konvergensi, maka *learning rate* akan dinaikkan. Dengan demikian, maka algoritma pembelajaran akan tetap terjaga pada kondisi stabil.

Algoritma gradient descent with momentum and adaptive learning(traingdx) merupakan penggabungan antara algoritma *gradient descent with adaptive learning*(traingda) dan algoritma *gradient descent with momentum*(traingdm). Algoritma ini merupakan algoritma default yang digunakan oleh matlab karena memiliki performa kecepatan pelatihan yang tinggi.

2.2 Penelitian Terdahulu

2.2.1 Multifraktal

Razdan (2002) meneliti multifraktalitas pada Indeks Bombay Stock Exchange (BSE) dan mengambil kesimpulan bahwa data deret waktu indeks BSE berifat monofraktal dan dapat direpresentasikan oleh gerak brown sebagian.

Yoon dan Choi (2005) melakukan penelitian pada pasar nilai tukar won terhadap dolar dan KOSPI (Korean Stock Price Index) dengan menggunakan analisis R/S dan mengambil kesimpulan bahwa data tersebut memiliki kecenderungan efek tren yang bertahan dalam jangka panjang.

Hariadi dan Surya (2003) melakukan penelitian pada tiga saham BEJ, yaitu Telkom, Indosat dan HM Sampoerna dan mendapatkan hasil bahwa saham-saham tersebut memiliki kecenderungan tren jangka pendek, artinya perubahan nilai saham tidak dipengaruhi oleh perubahan nilai saham yang terpisah dalam selang waktu lama. Nilai dimensi fraktal yang lebih dari 1,5 mendukung

pernyataan pertama bahwa ketiga saham tidak memiliki kecenderungan untuk bertahan pada tren tertentu.

2.2.2 ARIMA

Analisis teknikal berupaya untuk menguji data historis dalam memprediksi harga saham guna melakukan pembelian atau penjualan suatu instrumen investasi (Fernandez-Rodriguez dkk, 1999). Karena kemampuannya tersebut, maka penelitian mengenai analisis teknikal menjadi kajian yang menarik dibursa saham luar negeri. Penelitian Brock dkk (1992) pada indeks Dow Jones Industrial Average (DJIA) di New York Stock Exchange (NYSE) menemukan bahwa metode statistik sederhana seperti moving average lebih mampu menjelaskan perilaku indeks harga saham dibandingkan metode-metode canggih seperti simulasi *bootstrap* pada berbagai alternatif *Capital Assets Pricing Model* (CAPM).

Fernandez-Rodriguez dkk(1999) melakukan penelitian mengenai teknikal analisis pada *Madrid Stock Exchange* dengan menggunakan *moving average* dengan periode yang berbeda-beda. Hal ini dilakukan untuk mengatasi kelemahan yang ada pada penelitian Brock dkk (1999). Hasil pada penelitian tersebut bahwa *technical trading rules* memiliki kemampuan untuk mempredisi return saham. Pada penelitian Fernandez-Rodriguez dkk (1999) ini juga digunakan metode ARIMA menggabungkan metode rata-rata bergerak dan autoregresi. Hasilnya adalah bahwa metode ARIMA dapat meningkatkan akurasi dalam memprediksi harga saham.

Parisi dan Vasquez (2000) melakukan penelitian mengenai analisis teknikal di pasar modal Chili yaitu Santiago Stock Exchange / Bolsa de Comercio de Santiago. Pada penelitian ini Parisi dan Vasquez menggunakan metode analisis teknikal seperti *moving average* dan *trading range break out*. Penelitian ini menyimpulkan bahwa metode *moving average* ternyata mampu memberikan hasil yang lebih baik.

Penerapan analisis teknikal dalam pasar uang juga telah dilakukan oleh Fernandez-Rodriguez dkk(2000) yang melakukan analisis pada mata uang negara-negara yang masuk dana EMS (*European Monetary System*). Penelitian ini dilakukan dengan berlandaskan pada pesimisme terhadap kualitas model-model peramalan kurs mata uang yang dipengaruhi tulisan Meese dan Rogoff (1983) yang menyatakan bahwa model dengan menggunakan variabel-variabel yang memperkirakan nilai kurs mata uang tidak lebih baik daripada model sederhana dalam analisis teknikal. Penelitian Fernandez-Rodriguez (2000) menemukan bahwa meskipun analisis teknikal mampu diterapkan dalam memperkirakan kurs mata uang asing, tetapi seringkali terdapat kesalahan prediksi.

Fernandez-Rodriguez (2001) melakukan penelitian lagi mengenai penerapan analisis teknikal di pasar saham *Madrid Stock Exchange*. Penelitian ini dilakukan dengan penelitian-penelitian yang telah dilakukan sebelumnya kebanyakan masih menggunakan satu indikator saja yaitu *moving average*, untuk memperbaiki penelitian yang telah ada tersebut maka juga dipergunakan indikator *moving average* yang lain yaitu *Generalized Moving Average* seperti *double moving average*. ARIMA akan bekerja dengan baik apabila data runut waktu yang

digunakan bersifat dependen atau berhubungan satu sama lain secara statistik (Sugiarto dan Harijono, 2000).

Suhartono (2005) melakukan studi pada tingkat inflasi di Indonesia, studi ini melakukan perbandingan terhadap metode Jaringan Syaraf Tiruan, ARIMA, dan ARIMAX (ARIMA dengan Analisis intervensi dan Variasi kalender). Hasil studi ini menunjukkan bahwa FFNN (*Feed Forward Neural Network*) dengan input model ARIMAX memberikan hasil terbaik untuk melakukan peramalan inflasi di Indonesia. Penelitian ini juga menunjukkan bahwa akurasi peramalan dengan model ARIMAX mirip dengan hasil FFNN dengan input yang berasal dari ARIMAX.

Nachrowi dan Usman (2007) melakukan studi pada IHSG dengan menggunakan model GARCH dan ARIMA, hasil dari studi ini menunjukkan bahwa model ARIMA(1,1,0) mempunyai kesalahan lebih kecil dalam memprediksi gerakan IHSG bila dibandingkan dengan Model GARCH (2,2). Hal ini disebabkan karena sulitnya mengidentifikasi variabel dominan yang dapat menjelaskan IHSG. Model ARIMA cenderung lebih unggul karena metode ini hanya memerlukan variabel penjelas yang merupakan variabel itu sendiri di masa lalu. Bila pergerakan variabel masa lalu sudah dapat mencerminkan semua informasi yang dapat mempengaruhi variabel itu, variabel penjelas lain peranannya menjadi sangat kecil.

2.2.3 Jaringan Syaraf Tiruan

Pada tahun 1940, Warren S McCulloch dan Walter Pitts mengemukakan

pembuatan suatu model matematika dan sel urat syaraf dan menghasilkan beberapa kesimpulan, yaitu aktivasi dari sebuah neuron McCulloch-Pitts berupa angka biner, neuron dihubungkan secara langsung dengan bobot, sebuah koneksi disebut *excitatory*, jika bobot bernilai positif, sedangkan yang lain disebut *inhibitory* jika bernilai negatif, dan beberapa neuron mempunyai *threshold* yang tetap, kalau input yang masuk ke neuron lebih besar dari ambang.

Coats dan Fant (1993) menemukan bahwa Jaringan Syaraf Tiruan lebih baik dalam menentukan perusahaan yang sehat dan perusahaan yang mengalami kesulitan ekonomi daripada *multiple discriminant model*. Lenard dkk (1995), Fletcher dan Goss (1993), dan Salchenberger dkk (1992) menemukan bahwa Jaringan Syaraf Tiruan lebih unggul daripada *logistic regression models*.

Chiang, dkk (1996) menggunakan FFNN dengan *Backpropagation* (BP) untuk melakukan peramalan nilai aset bersih / *Net Asset Value* (NAV) *mutual funds*. Prediksi dilakukan dengan menggunakan informasi ekonomi historis. Mereka membandingkan dengan hasil yang didapatkan dari peramalan dengan teknik ekonometrika tradisional dan menyimpulkan bahwa NN “melampaui model regresi secara signifikan” ketika tersedia data dalam jumlah terbatas.

Kuo dkk (1996) mendapatkan bahwa faktor kualitatif, seperti efek politis, selalu memainkan peran yang penting terhadap lingkungan pasar saham, dan mengajukan sistem peramalan pasar saham yang cerdas yang menggabungkan faktor kuantitatif maupun kualitatif. Hal ini diraih dengan mengintegrasikan NN dengan model *fuzzy delphi* (Bojadziew dan Bojadziew, 1997:hal 71); metode awal

digunakan untuk analisis kuantitatif dan integrasi keputusan, sementara metode kedua digunakan sebagai dasar model kualitatif. Mereka mengaplikasikan sistem tersebut pada pasar saham Taiwan.

Kim dan Chun (1998) menggunakan *Probabilistic NN*(PNN) yang telah diperbaiki, disebut *Arrayed Probabilistic Network* (APN), untuk memprediksi indeks pasar saham. Fitur esensial APN adalah bahwa model ini menghasilkan peramalan bertingkat dari nilai diskrit berganda alih-alih keluaran bipolar tunggal. Sebagai bagian dari studi mereka, mereka menggunakan grafik kesalahan, yang mem-*benchmark* dengan sebuah prediksi konstan, untuk membandingkan model FFNN dengan BP dengan PNN, APN, *recurrent NN* (RNN) dan *case based reasoning*. Mereka menyimpulkan bahwa APN cenderung untuk melampaui jaringan *recurrent* dan BP, tetapi *case base reasoning* cenderung melampaui keseluruhan jaringan

Franses (1998) membandingkan antara metode Jaringan Syaraf Tiruan dengan metode prediksi berbasis regresi, diperkuat dengan penelitian Castiglioni (2001) yang menyatakan model Jaringan syaraf merupakan bentuk komplementer dari model regresi dalam statistika, yaitu regresi non parametrik.

Zurada dkk (1998) mengadakan penelitian apakah kompleksitas dari respon mengukur dampak *logistic regression* atau *neural network* yang menghasilkan ketepatan klasifikasi tertinggi untuk perusahaan -perusahaan yang mengalami kesulitan keuangan (*financially distressed firms*). Penelitian ini menghasilkan kesimpulan bahwa *neural networks* tidak lebih unggul dibandingkan *logistic*

regression models untuk *traditional dichotomous response variable*, tetapi lebih unggul untuk *financial distressed response variable* yang lebih kompleks.

Aiken dan Bsat (1999) menggunakan sebuah FFNN yang dilatih dengan Algoritma Genetika untuk memprediksi nilai *Treasury Bill* Amerika Serikat tiga bulanan. Mereka menyimpulkan bahwa NN bisa digunakan untuk memprediksi nilai *Treasury Bill* dengan akurat.

Edelman dkk (1999) meneliti penggunaan NN dengan struktur identik dan dilatih secara independen untuk mengidentifikasi kesempatan arbitrase pada Indeks All-Ordinaries Australia. Keputusan perdagangan dibuat berdasar pada konsensus non-anonim prediksi komite dan Indeks Sharpe digunakan untuk mendapatkan performa perdagangan *out-of-sample*. Hasil empiris menunjukkan bahwa perdagangan teknikal berdasar pada prediksi NN melampaui strategi beli dan tahan (*buy-and-hold*) ataupun prediksi naif. Mereka menyimpulkan bahwa reliabilitas prediksi jaringan dan karenanya kinerja perdagangan meningkat secara dramatis dengan menggunakan ambang perdagangan dan pendekatan komite (menghasilkan beberapa jaringan dengan keluaran baik alih-alih hanya satu jaringan).

Thammano (1999) menggunakan model *neuro-fuzzy* untuk memprediksi nilai masa depan bank pemerintah terbesar di thailand. Masukan model adalah harga penutupan untuk saat ini dan tiga bulan lalu, dan rasio keuntungan ROA(*Return On Assets*), ROE(*Return On Equity*) dan P/E(*Price Earning*). Keluaran model adalah harga saham untuk tiga bulan kedepan. Dia menyimpulkan

bahwa arsitektur *neuro-fuzzy* dapat mengenali karakteristik umum pasar saham lebih cepat dan lebih akurat daripada algoritma dasar propagasi balik. Selain itu model ini juga dapat memprediksi kesempatan investasi pada kondisi krisis ekonomi ketika pendekatan statistik tidak dapat memberikan hasil yang memuaskan.

Trafalis (1999) menggunakan FFNN dengan BP dan perubahan mingguan pada 14 indikator untuk meramal perubahan pada indeks saham S&P 500 selama beberapa pekan. Disamping itu sebuah metodologi untuk melakukan *pre-processing* digunakan, yang mengikutsertakan diferensiasi dan normalisasi data, berhasil diimplementasikan. Tulisan tersebut mengajak pembaca melalui proses NN.

Tansel dkk(1999) membandingkan kemampuan optimisasi linier, NN dan GA untuk memodelkan data runtun waktu menggunakan kriteria akurasi permodelan, waktu terbaik dan waktu komputasional. Mereka menemukan bahwa metode optimisasi linear memberikan estimasi terbaik, meskipun GA dapat memberikan nilai yang sama jika batasan parameter dan resolusi dipilih dengan tepat, tetapi NN menghasilkan estimasi yang salah. Mereka memberikan catatan bahwa non-linearitas dapat diakomodasi oleh GA dan NN dan NN membutuhkan latar belakang teoritis yang lebih sedikit.

Garliauskas (1999) melakukan penelitian pada peramalan data runtun waktu pasar saham menggunakan algoritma komputasional NN dihubungkan dengan pendekatan fungsi kernel dan metode prediksi error rekursif. Ide utama pembelajaran NN dengan fungsi kernel adalah bahwa fungsi tersebut

menstimulasi perubahan bobot dalam kaitannya untuk mencapai konvergensi target dan fungsi keluaran peramalan. Dia menyimpulkan bahwa peramalan data keuangan runtun waktu dengan Jaringan Syaraf Tiruan lebih baik daripada statistika klasik dan metode lainnya.

Chan dkk (2000) meneliti peramalan data keuangan runtun waktu menggunakan FFNN dan data perdagangan harian dari Bursa Efek Shanghai (Shanghai Stock Exchange). Untuk memperbaiki kecepatan dan konvergensi mereka menggunakan algoritma pembelajaran gradien konjugasi dan menggunakan regresi linear berganda / *Multiple Linear Regression* (MLR) untuk inialisasi bobot. Mereka menyimpulkan bahwa NN dapat memodelkan runtun waktu secara memuaskan dan pendekatan pembelajaran dan inialisasi mengarah pada perbaikan pembelajaran dan penurunan biaya komputasi.

Kim dan Han (2000) menggunakan NN yang dimodifikasi dengan GA untuk memprediksi Indeks harga saham. Dalam penelitian ini, GA digunakan untuk mengurangi kompleksitas fitur ruang, dengan mengoptimisasi ambang untuk diskritisasi fitur, dan untuk mengoptimalkan bobot hubungan antar lapisan. Sasaran mereka adalah menggunakan diskritisasi fitur yang dicari secara global untuk mengurangi dimensionalitas ruang fitur, mengeliminasi faktor yang tidak relevan, dan mengurangi batasan penurunan gradien. Mereka menyimpulkan bahwa pendekatan GA melampaui model konvensional.

Romahi dan Shen (2000) mengembangkan sistem pakar yang berdasar pada aturan yang berevolusi untuk peramalan keuangan. Pendekatan mereka menggabungkan *Fuzzy Logic*(FL) dan induksi aturan dengan tujuan untuk

mengembangkan sebuah sistem dengan kemampuan generalisasi dan komprehensibilitas yang tinggi. Dengan cara ini perubahan dinamika pasar dimasukkan secara berkelanjutan dalam perhitungan sesuai dengan perubahan waktu dan aturan yang mendasari tidak menjadi daluwarsa. Mereka menyimpulkan bahwa metodologi yang digunakan menunjukkan hasil yang menjanjikan.

Abraham dkk (2001) menginvestigasi teknik *soft computing* (SC) hibrid untuk peramalan dan analisis tren pasar saham terotomatisasi. Mereka menggunakan analisis komponen utama untuk melakukan *pre-procesing* data masukan, NN untuk peramalan saham satu hari kedepan dan sistem neuro-fuzzy untuk menganalisis tren untuk nilai saham yang diprediksi. Untuk mendemonstrasikan teknik yang diajukan, mereka menganalisis data saham 24 bulan dari indeks utama Nasdaq-100 dan juga enam perusahaan yang terdapat didalamnya. Mereka menyimpulkan bahwa hasil peramalan dan prediksi tren menggunakan sistem hibrid yang diajukan menjanjikan dan membutuhkan analisis dan penelitian lanjutan.

Cao dan Tay (2001) menggunakan *Support Vector Machines* (SVM) untuk mempelajari harga indeks harian S&P 500. generalisasi error dengan memperhitungkan parameter bebas SVM dipelajari dan ditemukan memiliki dampak yang kecil terhadap solusi. Mereka menyimpulkan bahwa terdapat keunggulan dalam penggunaan SVM untuk melakukan peramalan data keuangan runtun waktu.

Hwarng (2001) menginvestigasi peramalan NN runtun waktu dengan

struktur ARMA(p,q). Menggunakan simulasi dan performa model Box-Jenkins sebagai benchmark. Disimpulkan bahwa FFNN dengan BP secara umum berkinerja baik dan konsisten untuk korespondensi runtun waktu struktur ARMA(p,q). Menggunakan desain blok penelitian lengkap teracak, dia menyimpulkan bahwa secara keseluruhan, untuk sebagian besar struktur, FFNN dengan BP memiliki kinerja lebih baik secara signifikan ketika tingkat gangguan tertentu diperhitungkan ketika melakukan pelatihan dalam jaringan.

Surya dan situngkir (2003a) menggunakan permodelan Jaringan syaraf tiruan untuk tujuan peramalan (*forecasting*) data keuangan deret waktu PT Telkom Indonesia selama tahun 2000 dan menghasilkan analisis regresi (kecocokan linier) dari data yang ditraining keakuratan data yang diaproksimasi dan diprediksi telah sangat baik (garis kecocokan linier berimpit dengan garis yang memetakan hasil aproksimasi dan target data yang diaproksimasi), tetapi perlu ditambahkan data untuk training jaring syaraf untuk memperkuat hasil analisis.

Surya dan Situngkir (2003b) melakukan prediksi pada fluktuasi harga saham (*closing*) PT Telkom untuk data deret waktu dari tahun awal 1993 hingga pertengahan 2003 dengan menggunakan metode Jaringan syaraf tiruan yang dilengkapi dengan peta poincare dalam persepsi model jaring syaraf yang dibuat untuk tujuan prediksi, menghasilkan hasil aproksimasi dan prediksi sangat baik dengan gradient mendekati 1 ($\sim 0,966$).

2.3 Kerangka Pemikiran

Indeks LQ 45 terdiri atas 45 saham ter-*liquid* dengan nilai kapitalisasi besar dan memiliki fundamental yang baik. Penelitian diawali dengan melihat

multifraktalitas pada Indeks LQ 45 periode Januari 1997 – April 2007. Jika data bersifat multifraktal maka terdapat implikasi bahwa terdapat persistensi dan kecenderungan tren pada data deret waktu sehingga memungkinkan untuk dilakukan peramalan pada data deret waktu yang ada.

Peramalan Indeks LQ 45 dilakukan dengan dua metode yaitu ARIMA (*Autoregressive Integrated Moving Average*) dan *Artificial Neural Network* (ANN). Data yang ada dibagi menjadi dua bagian yaitu periode model (*in-sample*) dan periode prediksi (*out-sample*). Pembentukan model dilakukan dengan menggunakan data yang terdapat pada periode model. Setelah diperoleh model terbaik dari tiap metode yang dapat digunakan untuk melakukan peramalan, dilakukan peramalan dengan model tersebut. Untuk mengetahui performa tiap metode peramalan, dilakukan peramalan baik pada data periode pembentukan model (*In Sample*), maupun periode testing (*out sample*) dengan menggunakan nilai MSE (*Mean Squared Error*). Nilai MSE dari kedua metode yang digunakan dibandingkan untuk mendapatkan metode yang memberikan tingkat kesalahan yang lebih kecil dibanding metode lainnya.

Kerangka Pemikiran diatas disajikan dalam bentuk gambar pada gambar

2.6

Gambar 2.6

Kerangka Pemikiran

