

BAB 2

TINJAUAN PUSTAKA

2.1. Tinjauan Statistik

2.1.1. *Time Series* Non Linier

Time Series atau biasa disebut Deret Waktu adalah kumpulan data-data yang merupakan data historis dalam suatu periode waktu tertentu. Data yang dapat dijadikan deret waktu harus bersifat kronologis yang artinya data harus memiliki periode waktu yang berurutan. Dari suatu rangkaian waktu akan dapat diketahui apakah peristiwa kejadian gejala dan variabel yang diamati berkembang mengikuti pola-pola perkembangan yang teratur. A.Triangga (2020) menuturkan bahwa deret waktu yang dimaksud tidak lain adalah serangkaian pengamatan terhadap suatu peristiwa, kejadian, gejala atau variabel yang diambil dari waktu ke waktu yang tercatat dengan teliti sesuai urutan kejadian kemudian disusun sebagai data statistik. Deret waktu (*time series*) ini dapat digunakan oleh suatu manajemen sebagai landasan untuk membuat keputusan baik di masa sekarang maupun di masa yang akan datang dikarenakan biasanya kejadian di masa yang lalu akan berlanjut di masa yang akan datang. Hal yang harus diperhatikan sebelum melakukan prediksi *time series* adalah.

1. Adanya ketergantungan masa depan dengan masa lampau.
2. Aktivitas masa yang akan datang mengikuti pola masa lalu.
3. Hubungan keterkaitan masa lalu dan masa kini dapat ditentukan melalui pengamatan

Metode analisis runtun waktu terus berkembang sejak Box dan Jenkins (1976). Metode Box Jenkins dapat bekerja dengan baik jika data sampel diambil dari proses yang stasioner atau dapat dibawa ke bentuk stasioner (Wei, 1994). Box dan Jenkins (1976) adalah pelopor yang memodelkan runtun waktu secara matematis, dengan nama model *Autoregressives Moving Average* (ARMA). Model yang terbentuk termasuk dalam kelas model linier. Tahapan kerja metode ini meliputi tahap persiapan data, pemilihan model, pendugaan parameter, pemeriksaan model dan peramalan. Persiapan data termasuk diferensi dan transformasi dilakukan agar stasioneritas terpenuhi. Menurut Rukun dan Sudarno (2017), model untuk ARMA dapat dilihat pada persamaan berikut:

$$Y_t = \mu + \sum_{i=1}^p \phi_i Y_{t-i} + \sum_{j=1}^q \theta_j \epsilon_{t-j} + \epsilon_t, \epsilon_t \sim N(0, \sigma^2) \quad (2.1)$$

Dengan :

Y_t = Variabel dependen pada waktu t

ϕ_i = Koefisien model AR yang menunjukkan bobot (i = 1,2,3,..i)

θ_j = Koefisien model MA yang menunjukkan bobot (i = 1,2,3,..j)

μ = fungsi tren determinan

ϵ_t = sesatan yang lampau

Pada perkembangannya ditemukan fakta bahwa data ekonomi pada umumnya memiliki sifat *nonlinear* serta varian yang berubah dari waktu ke waktu (heteroskedastik). Dalam kondisi ini metode Box-Jenkins mungkin memberikan jawaban yang kurang memuaskan. Hal ini menjadikan inspirasi untuk mengkaji model runtun waktu *nonlinear*. Salah satu bentuk hubungan *nonlinear* adalah adanya sifat heteroskedastik, yaitu varian proses yang berubah bergantung waktu. Model heteroskedastik yang pertama diperkenalkan oleh Engle (1982) yang diberi nama model *Autoregressives Conditional Heteroscedasticity* (ARCH). Menurut Rukun dan Sudarno (2017) mengasumsikan bahwa suku sesatan ϵ_t dari Persamaan (2.1) berpola nonlinier terhadap sesatan yang lampau, seperti pada persamaan (2.2) dan (2.3) berikut:

$$\epsilon_t = \sigma_t v_t, v_t \sim N(0, \sigma^2) \quad (2.2)$$

$$\sigma_t^2 = \alpha_0 + \sum_{k=1}^s \alpha_k \epsilon_{t-k}^2 \quad (2.3)$$

Dimana :

σ_t = rerata sesatan lampau

v_t = Koefisien ($t = 1, 2, 3, \dots, n$)

α_k = jumlah guncangan

Keberadaan sifat heteroskedastik dapat diketahui dengan uji Multiplikator Lagrange (*LM test*) yang dikemukakan oleh Lee *et al.* (1993). Seperti yang dikutip Rukun dan Sudarno (2017) model *nonlinear* dapat berupa ketergantungan terhadap pengamatan terdahulu, seperti dituliskan dalam persamaan (4) :

$$Y_t = \mu + \sum_{i=1}^p \omega_i \phi(Y_{t-i}) + \epsilon_t \quad (2.4)$$

Dengan ϕ fungsi *nonlinier* seperti fungsi logistic, fungsi eksponensial, fungsi eksponensial, fungsi polinomial dan fungsi *radial basis*. Sedangkan ω_i merupakan penduga dari fungsi *nonlinier*.

2.1.2. Machine Learning

Machine Learning merupakan salah satu cabang dari *artificial intelligence* (kecerdasan buatan) yang saat ini terus mengalami perkembangan dan semakin populer akhir-akhir ini.. Hal ini terkait dengan bidang ilmu komputer lainnya misalnya robotic, pengolahan Bahasa, pengolahan citra, dll. Ketika kita mengembangkan model *machine learning* untuk membuat prediksi, ada titik fokus berat yang tertuju kepada algoritma, kode dan hasil yang didapatkan. *Machine learning* pada perkembangannya memiliki keterkaitan dengan statistika. Pada statistika itu sendiri berperan sebagai basis pembelajaran yang memanfaatkan teori statistik untuk melakukan inferensi dan interpretasi dari model, sedangkan *machine learning* memiliki fokus pada penggunaan model untuk memprediksi data baru. Berasal dari latar belakang matematika inilah, keduanya memiliki kedekatan yaitu pada model dan penjelasan prediksi. Dengan dasar itulah, maka statistika dan machine learning membentuk satu konsep yang

dikenal dengan *statistical machine learning*. *Statistical Machine Learning* dapat diartikan teknik yang mengacu untuk memprediksi masa depan dan mendapatkan pengetahuan dari data secara rasional.

Pada *statistical machine learning*, pemilihan sampel data (atau *training data*) menjadi hal yang sangat penting. Apabila *training data* tidak mampu merepresentasikan populasi, maka model yang dihasilkan pembelajaran (*training*) tidak bagus. Untuk itu, biasanya terdapat juga *test data*. Mesin dilatih menggunakan *training data*, kemudian diuji kinerjanya menggunakan *test data*. Representasi populasi dapat diketahui dengan menyelidiki fitur-fitur (*features* atau karakteristik) yang dimiliki oleh data. Secara ringkas, istilah *training* adalah proses membangun model dan *testing* adalah proses menguji kinerja model pembelajaran. *Dataset* adalah kumpulan data (sampel dalam statistik). Sampel ini adalah data yang kita gunakan untuk membuat model maupun mengevaluasi model *machine learning* (FMIPA UGM, 2019).

2.1.3. Deep Learning

Deep Learning (*deep machine learning, or deep structured learning, or hierarchical learning, or sometimes DL*) adalah cabang dari *machine learning* berdasarkan satu set algoritma yang digunakan untuk model abstraksi tingkat tinggi pada data dengan menggunakan beberapa lapisan implementasi dan menggunakan struktur yang kompleks atau sebaliknya, terdiri dari beberapa transformasi nonlinear. Teknik dan algoritma dalam *Deep Learning* dapat digunakan baik untuk kebutuhan *supervised learning, unsupervised learning* dan *semi-supervised learning* dalam berbagai aplikasi. Dengan adanya Teknologi *Deep Learning*, produk-produk seperti self-driving car, face recognition atau voice recognition dapat

dihasilkan. Ini merupakan kunci untuk mengontrol suara di perangkat konsumen seperti ponsel, tablet, TV dan lainnya.

Teknik *deep learning* akhir-akhir ini mendapatkan banyak perhatian dari para peneliti karena pencapaian hasilnya yang bagus. Penggunaan *deep learning* ini dapat mencapai akurasi ketepatan yang tinggi, dan terkadang melebihi kinerja tingkat abstraksi pada beberapa kasus. Model dilatih dengan menggunakan sejumlah data yang besar dan dipadukan dengan arsitektur *neural network* yang mengandung banyak lapisan. Meskipun istilah *deep learning* pada neural network sudah ada sejak 2006, tapi baru beberapa tahun kebelakang istilah ini dimunculkan lagi. Hal itu dikarenakan dua hal. Pertama, metode *deep learning* membutuhkan dataset dalam jumlah besar, dengan begitu kemampuan akurasi yang tinggi dari *deep learning* ini baru terlihat nyata. Yang kedua, *deep learning* dengan dataset yang besar membutuhkan perangkat komputasi dengan performa yang tinggi untuk meningkatkan kecepatan pemrosesan. Menurut Hafizan dan Dina (2018) alasan yang kedua inilah merupakan penyebab metode *deep learning* kini menjadi sangat digemari oleh para peneliti, karena saat ini perangkat komputasi, seperti GPU dengan performa tinggi dan cloud computing yang semakin berkembang, sehingga membuat metode ini kian cepat berkembang pesat (Hamdani, 2019).

2.1.4. Statistika Deskriptif

Statistika deskriptif adalah teknik statistika yang digunakan untuk menganalisis data dengan cara mendeskripsikan atau menggambarkan data yang

telah terkumpul sebagaimana adanya tanpa bermaksud membuat kesimpulan yang berlaku untuk umum atau generalisasi. Analisis ini hanya berupa akumulasi dari data dasar dalam bentuk deskripsi dengan arti bahwa analisis ini tidak mencari atau menerangkan keterkaitan suatu hubungan, menguji hipotesis, membuat ramalan, atau melakukan penarikan kesimpulan. (Shelly, 2021).

2.1.5. Normalisasi Data

Normalisasi data adalah mengubah data ke dalam bentuk yang paling cocok untuk proses *data mining*. Normalisasi dilakukan untuk mengubah skala data numerik menjadi data dalam bentuk baru yang bernilai sama. Normalisasi yang digunakan adalah *min-max normalization*. Rumus *min-max normalization* sebagai berikut (Chamidah dalam Shelly, 2021):

$$V' = \frac{V - Min_A}{Max_A - Min_A} (New_{max_A} - New_{min_A}) + New_{min_A} \quad (2.5)$$

Keterangan :

- V' = Nilai yang dicari
- V = Nilai pada variable A
- Max_A = Nilai maksimal variabel A
- Min_A = Nilai minimal variable A
- New_{max_A} = Rentang nilai maksimal pada variable A
- New_{min_A} = Rentang nilai minimal pada variable A

2.1.6. *Balancing Data*

Balancing data adalah merubah data yang tidak seimbang (*imbalance data*) menjadi data yang seimbang (*balance*). Suatu kondisi ketidakseimbangan dalam jumlah data training antara dua kelas yang berbeda, salah satu kelasnya menunjukkan jumlah data yang sangat besar (kelas mayoritas), sedangkan kelas lainnya menunjukkan jumlah data yang sangat kecil (kelas minoritas) (Yahya dalam Shelly, 2021). Salah satu solusi untuk *imbalance data* adalah dengan menggunakan SMOTE (*Synthetic Minority Oversampling Technique*), yaitu teknik *sampling* yang dapat meningkatkan akurasi dari pengklasifikasi untuk kelas minor dengan cara membangkitkan data baru berdasarkan k tetangga terdekat.


SMOTE sendiri memiliki beberapa metode yaitu *oversampling* dan *undersampling*. *Oversampling* adalah metode pembangkitan data minoritas sebanyak data mayoritas. Sedangkan *undersampling* adalah metode untuk mengambil beberapa data mayoritas sehingga jumlah data mayoritas sama besar jumlahnya dengan jumlah data minoritas. Pada penelitian ini, data pada kelas minoritas dilakukan *oversampling* dengan mengambil data pada kelas minoritas dan menambah sampel sintetis di sepanjang garis yang menghubungkan salah satu atau semua k tetangga terdekat data kelas minoritas tersebut. Jumlah tetangga k dipilih secara acak. Formula untuk membangkitkan data dengan SMOTE adalah sebagai berikut (Yahya dalam Shelly, 2021) :

$$X_{new} = X_i + (\hat{X}_k - X_i) \times \delta \quad (2.6)$$

Dimana X_{new} = data sintetis baru, X_i = data dari kelas minoritas, \hat{X}_k = data dari k tetangga terdekat yang memiliki jarak terdekat dengan X_i , dan δ = bilangan acak antara 0 dan 1 .

2.1.7. Jaringan Syaraf Tiruan

Jaringan Syaraf merupakan salah satu representasi buatan dari otak manusia yang selalu mencoba untuk mensimulasikan proses pembelajaran pada otak manusia tersebut. Istilah buatan disini digunakan dikarenakan jaringan syaraf ini diimplementasikan dengan menggunakan program komputer yang mampu menyelesaikan sejumlah proses perhitungan selama proses pembelajaran. Otak manusia berisi berjuta-juta sel syaraf yang bertugas untuk memproses informasi. Tiap-tiap sel bekerja seperti suatu prosesor sederhana. Masing-masing sel tersebut saling berinteraksi sehingga mendukung kemampuan kerja otak manusia.



Gambar 2.1. Susunan Syaraf Manusia

Pada gambar 2.1 menunjukkan susunan syaraf pada manusia. Setiap sel syaraf (neuron) akan memiliki satu inti sel, inti sel ini nanti yang akan bertukar untuk melakukan pemrosesan informasi. Informasi yang datang akan diterima oleh dendrit. Selain menerima informasi, dendrit juga menyertai axon sebagai keluaran dari suatu pemrosesan informasi. Informasi hasil olahan ini akan menjadi masukan bagi neuron lain yang mana antar dendrit kedua sel tersebut dipertemukan dengan synapsis. Informasi yang dikirimkan antar neuron ini berupa rangsangan yang

dilewatkan melalui dendrit. Informasi yang datang dan diterima oleh dendrit akan dijumlahkan dan dikirim melalui axon ke dendrit akhir yang bersentuhan dengan dendrit dari neuron yang lain. Informasi ini akan diterima oleh neuron lain jika memenuhi batasan tertentu, yang sering dikenal dengan nama nilai ambang (*threshold*). Pada kasus ini, neuron tersebut dikatakan teraktivasi. Hubungan antar neuron terjadi secara adaptif, artinya struktur hubungan tersebut terjadi secara dinamis. Otak manusia selalu memiliki kemampuan untuk belajar dengan melakukan adaptasi.

Jaringan Syaraf Tiruan adalah paradigma pengolahan informasi yang terinspirasi oleh system saraf secara biologis seperti proses informasi pada otak manusia. Elemen kunci dari paradigma ini adalah struktur dari system pengolahan informasi yang terdiri dari sejumlah besar elemen pemrosan yang saling berhubungan (neuron), bekerja serentak untuk menyelesaikan masalah tertentu. Cara kerja JST ini seperti cara kerja manusia, yaitu belajar melalui contoh. Kelebihan-kelebihan yang diberikan JST antara lain ;

1. Belajar Adaptif, yaitu kemampuan untuk mempelajari bagaimana melakukan pekerjaan berdasarkan data yang diberikan untuk pelatihan atau pengalaman awal.
2. *Self-Organization*. Sebuah JST dapat membuat organisasi sendiri atau representatif dari informasi yang diterimanya selama waktu belajar.

3. *Real Time Operation*. Perhitungan JST dapat dilakukan secara parallel sehingga perangkat keras yang dirancang dan diproduksi secara khusus dapat mengambil keuntungan dari kemampuan ini.

Selain mempunyai kelebihan-kelebihan tersebut, JST juga mempunyai kelemahan-kelemahan berikut :

1. Tidak efektif jika digunakan untuk melakukan operasi-operasi numerik dengan presisi tinggi.
2. Tidak efisien jika digunakan untuk melakukan operasi algoritma aritmatik, operasi logika dan simbolis.
3. Untuk operasi JST butuh pelatihan sehingga bila jumlah datanya besar, waktu yang digunakan untuk operasi proses sangat lama.

Artificial Neural Network (ANN) atau JST memiliki sifat adaptif, yaitu dapat belajar dari data-data sebelumnya dan mengenal pola data yang selalu berubah. Metode *Artificial Neural Network (ANN)* atau JST menggunakan elemen perhitungan non-linier dasar yang disebut neuron yang diorganisasikan sebagai jaringan yang saling berhubungan, sehingga mirip dengan jaringan syaraf manusia. JST dapat digunakan untuk menyelesaikan persoalan yang tidak terstruktur dan memecahkan masalah pengelompokan pola karena proses pembelajaran. Melatih *Artificial Neural Network (ANN)* atau JST adalah untuk mencapai keseimbangan antara kemampuan memorisasi, yaitu kemampuan mengambil kembali secara sempurna sebuah pola yang telah dipelajari. Kemampuan JST bisa berupa respon


yang bisa diterima terhadap pola-pola masukan yang serupa dengan pola-pola yang sebelumnya telah dipelajari. Hasil ini sangat bermanfaat bila pada suatu saat ke dalam JST itu dimasukkan informasi baru yang elum pernah dipelajari, maka *Artificial Neural Network (ANN)* atau JST itu masih akan tetap dapat memberikan tanggapan yang baik dan memberikan keluaran yang paling mendekati. (Masters,1993) seperti dikutip (Setyandy, 2012) penggunaan JST sangat unggul dibandingkan beberapa metode lain dengan beberapa syaraf yaitu :

1. Data yang digunakan memiliki sifat 'fuzzy', artinya terdapat gradient nilai dari suatu parameter ke parameter lain.
2. Data yang digunakan memiliki pola yang sangat sulit ditebak maupun diperhitungkan secara ststistik. Salah satu kelebihan JST adalah menemukan pola yang tidak dapat ditemukan oleh otak manusia
3. Data menunjukkan sifat non-linier yang signifikan.

2.1.7.1. Komponen Jaringan Syaraf

Ada beberapa tipe jaringan syaraf, namun demikian, hampir semuanya memiliki komponen-komponen yang sama. Seperti halnya otak manusia, jaringan syaraf juga terdiri-dari beberapa neuron, dan ada hubungan antara neuron-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.



Gambar 2.2. Struktur neuron jaringan syaraf

2.1.7.2. Arsitektur Jaringan Syaraf Tiruan

Baik atau tidaknya suatu model JST, salah satunya dapat ditentukan oleh hubungan antarneuron atau yang biasa disebut sebagai arsitektur jaringan. Neuron-neuron tersebut terkumpul dalam lapisan-lapisan yang disebut neuron layer. Umumnya, neuron-neuron yang terletak pada lapisan yang sama akan memiliki keadaan yang sama. Pada setiap lapisan yang sama, neuron-neuron akan memiliki fungsi aktivasi yang sama. Apabila neuron-neuron dalam suatu lapisan (misalkan lapisan tersembunyi) akan dihubungkan dengan neuron-neuron pada lapisan yang lain (misalkan lapisan output), maka setiap neuron pada lapisan tersebut (misalkan lapisan tersembunyi) juga harus dihubungkan dengan setiap lapisan pada lapisan lainnya (misalkan lapisan output). Lapisan-lapisan penyusun JST dibagi menjadi tiga, antara lain :

1. Lapisan Input (*Input Layer*)

Unit-unit dalam lapisan input disebut unit-unit input yang bertugas menerima pola inputan dari luar yang menggambarkan suatu permasalahan.

2. Lapisan Tersembunyi (*Hidden Layer*)

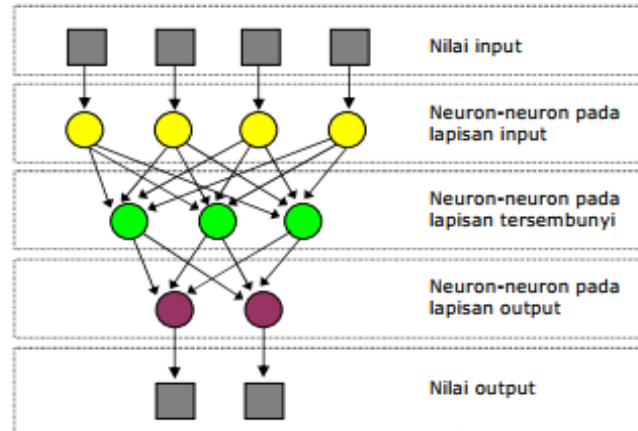
Unit-unit dalam lapisan tersembunyi disebut unit-unit tersembunyi, yang mana nilai outputnya tidak dapat diamati secara langsung.

3. Lapisan Output (*Output Layer*)

Unit-unit dalam lapisan output unit-unit output, yang merupakan solusi JST terhadap suatu permasalahan.

Jaringan syaraf yang digunakan pada penelitian ini adalah *model Deep Belief Network* yang dipadukan dengan *Restricted Boltzmann Machine* termasuk pada Jaringan Syaraf dengan lapisan tunggal. 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. Pada Gambar 2.3 tersebut, lapisan input memiliki 3 neuron, yaitu X_1 , X_2 dan X_3 . Sedangkan pada lapisan output memiliki 2 neuron yaitu Y_1 dan Y_2 . Neuron-neuron pada kedua lapisan saling berhubungan. Seberapa besar hubungan antara 2 neuron ditentukan oleh bobot yang bersesuaian. Hubungan neuron-neuron pada kedua lapisan tersebut ditentukan oleh bobot yang bersesuaian W_{11} , W_{12} , W_{21} , W_{22} , W_{31} , dan W_{32} . Semua unit input akan dihubungkan dengan setiap unit output. Pada jaringan syaraf tersebut, neuron-neuron akan dikumpulkan dalam lapisan-lapisan (*layer*) yang disebut dengan lapisan neuron (*neuron layers*). Biasanya 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 yang lainnya, yang sering dikenal dengan nama lapisan tersembunyi (*hidden layer*). Contoh JST yang lain menggunakan lapisan tunggal adalah ADALINE, *Hopfield*, *Perceptron*.



Gambar 2.3. Jaringan Syaraf dengan lapisan tunggal

2.1.7.3. Fungsi Aktivasi

Faktor terpenting dalam menentukan kelakuan suatu neuron adalah fungsi aktivasi dan pola bobotnya. Fungsi aktivasi merupakan suatu fungsi yang akan mentransformasikan suatu input menjadi suatu output tertentu. Pada Jaringan Syaraf Tiruan, suatu informasi akan diterima oleh input, kemudian input tersebut akan diproses melalui suatu fungsi perambatan. Argumen fungsi aktivasi adalah net masukan (kombinasi linear masukan dan bobotnya). Jika $net = \sum x_i w_i$ dengan x_i merupakan input sedangkan w_i merupakan bobot, maka fungsi aktivasinya adalah (ITS,2020):

$$f(net) = f(\sum x_i w_i) \quad (2.7)$$


Fungsi Aktivasi yang digunakan pada penelitian ini adalah fungsi aktivasi sigmoid biner dan sigmoid bipolar.

a. 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 (Gambar 2.4). Fungsi sigmoid biner dirumuskan sebagai:

$$y = f(x) = \frac{1}{1+e^{-\sigma x}} \quad (2.8)$$

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



Gambar 2.4. Fungsi Aktivasi : Sigmoid Biner

b. Fungsi Sigmoid Bipolar

Fungsi sigmoid bipolar hampir sama dengan fungsi sigmoid biner, hanya saja output dari fungsi ini memiliki range antara 1 sampai -1 (Gambar 2.5).

Fungsi sigmoid bipolar dirumuskan sebagai:

$$y = f(x) = \frac{1-e^{-x}}{1+e^{-x}} \quad (2.9)$$


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

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

$$y = f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.10)$$

$$\text{Atau } y = f(x) = \frac{1 - e^{-2x}}{1 + e^{-2x}} \quad (2.11)$$

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



Gambar 2.5. Fungsi Aktivasi : Sigmoid Bipolar

2.1.8. Regresi Logistik

Regresi logistik adalah bagian dari analisis regresi yang terkait dengan keterhubungan antara suatu variable independen terhadap variable dependen. Regresi logistik ini juga merupakan metode statistik tradisional yang digunakan untuk klasifikasi biner dan telah diadopsi sebagai model *Machine Learning* dasar. Sehingga bisa dikatakan bahwa Regresi Logistik adalah sebuah algoritma klasifikasi untuk mencari hubungan antara fitur (input) diskrit/kontinu dengan probabilitas hasil output diskrit tertentu. Analisis regresi logistik ini ada kaitannya dengan regresi linear yang disebut *Ordinary Least Squares (OLS) regression*. Namun perbedaan keduanya adalah regresi logistic peneliti memprediksi variable terikat yang berskala dikotomi. Skala dikotomi yang dimaksud adalah skala data nominal dengan dua kategori misalnya besar dan kecil, baik dan buruk atau berhasil dan gagal sedangkan OLS mewajibkan syarat bahwa *error varians (residual)* berdistribusi normal. Dan sebaliknya, pada regresi logistic tidak mensyaratkan asumsi tersebut. Berikut ini syarat dalam regresi logistic :

1. Regresi logistik tidak membutuhkan hubungan linear antar variabel independen dengan variable dependen.
2. Variable independen tidak memerlukan *multivariate normality*.
3. Asumsi homokedastisitas tidak diperlukan
4. Variabel bebas tidak perlu diubah ke dalam bentuk skala interval atau ratio.
5. Variabel dependen harus bersifat dikotomi (2 kategori)
6. Variabel independen tidak harus memiliki varian yang sama antar kelompok variabel
7. Kategori dalam variabel independen harus terpisah satu sama lain atau bersifat eksklusif

8. Sampel yang diperlukan dalam jumlah relatif besar, minimum dibutuhkan hingga 50 sampel data untuk sebuah variabel prediktor (independen).
9. Regresi logistik dapat menyeleksi hubungan karena menggunakan pendekatan non linier log transformasi untuk memprediksi odds ratio.

Persamaan model bentuk regresi logistik sama halnya dengan *OLS regression* sebagai berikut :

$$Y = \beta_0 + \beta_1 X + e \quad (2.12)$$

Bentuk umum model peluang regresi logistik diformulasikan sebagai berikut:

$$\text{logit}(p) = \beta_0 + \beta_1 X \quad (2.13)$$

$$\ln\left(\frac{p}{1-p}\right) = \beta_0 + \beta_1 X \quad (2.14)$$


$$\frac{p}{1-p} = e^{\beta_0 + \beta_1 X} \quad (2.15)$$

Sehingga

$$p = \frac{e^{\beta_0 + \beta_1 X}}{1 + e^{\beta_0 + \beta_1 X}} = \frac{1}{1 + e^{-(\beta_0 + \beta_1 X)}} \quad (2.16)$$

Dengan p adalah peluang kejadian sukses dengan nilai probabilitas $0 \leq p \leq 1$ dan β_j adalah nilai parameter dengan $j = 1, 2, \dots, i$ dan simbol e atau *exp* adalah fungsi eksponen dari residual. Perwujudan dari persamaan regresi logistik dapat dilihat dari gambar di bawah ini. Gambar tersebut menunjukkan hubungan nilai

X dan probabilitas (p) untuk masuk dalam kategori 1. β_0 menunjukkan lokasi tengah garis regresi sedangkan β_1 menunjukkan kemiringan garis regresi.



Sumber : Website Fakultas MIPA UGM 2018

Gambar 2.6 Grafik Regresi Logistik

2.1.9. Deep Belief Network

Untuk mengatasi keterbatasan dalam metode JST yang ada sebelumnya, maka Professor Geoffrey Hinton memperkenalkan *Deep Belief Networks (DBN)*. DBN (Bengio et al., 2006; Hinton et al., 2006) adalah model generatif probabilistik berlapis-lapis. Lapisan individu terdiri dari model grafis tidak terarah yang lebih sederhana, yang disebut Mesin Boltzmann Terbatas (RBM), biasanya dengan unit biner stokastik. *Deep Belief Networks (DBN)* merupakan suatu model graf yang mempresentasikan hierarki dari hasil keluaran (*output*) dari *Restricted Boltzman Machine (RBM)*. Model DBN menggabungkan nilai distribusi antara nilai vektor x dan *hidden layers* sebanyak h^k . Persamaan penggabungan sebagai berikut :

$$P(x, h^1, h^2, h^3, \dots, h^l) = \left(\prod_{k=0}^{l-2} P(h^k | h^{k+1}) \right) P(h^{l-1}, h^l) \quad (2.17)$$

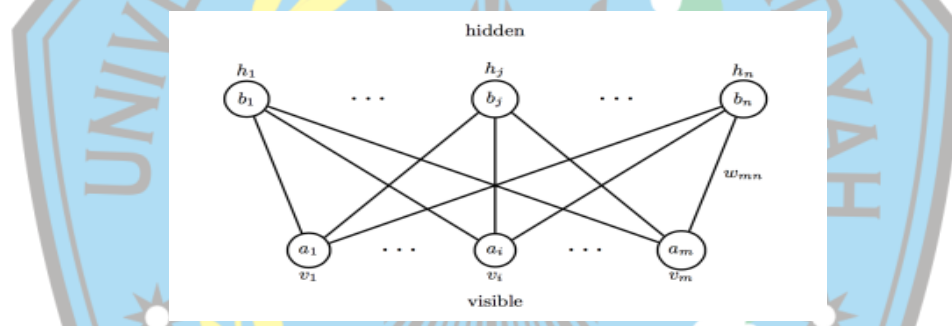
Dimana $x = h^0, P(h^{k-1}|h^k)$ adalah nilai distribusi bersyarat untuk unit yang terlihat pada unit yang tidak terlihat dari *RBM* level k , sedangkan untuk $P(h^{l-1}, h^l)$ adalah gabungan nilai distribusi dari unit yang terlihat dan unit tidak terlihat pada top level *RBM*.

2.1.10. Restricted Boltzmann Machine

Restricted Boltzmann Machine (RBM) merupakan aturan pembelajaran dengan menggunakan metode Boltzmann Machine (*Hinton et al, 2010*). *RBM* adalah model generatif probabilistik yang mampu secara otomatis mengekstrak fitur input data dengan menggunakan algoritma pembelajaran tanpa pengawasan (*Hinton, 2002; Smolensky, 1986*). *RBM* menggunakan arsitektur jaringan berulang (*recurrent network*). Secara teknis, *RBM* merupakan jaringan syaraf yang bersifat *stochastic* (jaringan syaraf yang berarti memiliki unit neuron berupa aktivasi biner yang bergantung pada neuron-neuron yang saling terhubung, sedangkan *stochastic* berarti aktivasi yang memiliki unsur probabilistik) yang terdiri dari dua binary unit yaitu *visible layer* merupakan state yang akan diobservasi dan *hidden layer* merupakan *feature detectors* serta unit bias. Selanjutnya masing-masing *visible* unit terhubung ke semua *hidden* unit yang diwakili oleh array bobot, sehingga setiap *hidden* unit juga terhubung ke semua *visible*.

Untuk melatih *RBM*, sampel dari *training set* yang digunakan sebagai masukan untuk *RBM* melalui neuron *visible*, dan kemudian jaringan sampel bolak-balik antara neuron *visible* dan *hidden*. Tujuan dari pelatihan adalah untuk

pembelajaran koneksi bobot pada *visible* atau *hidden* dan bias aktivasi neuron sehingga RBM belajar untuk merekonstruksi data input selama fase di mana sampel neuron visible dari neuron hidden. Setiap proses sampling pada dasarnya berupa perkalian matriks-matriks antara sekumpulan sampel pelatihan dan matriks bobot, diikuti dengan fungsi aktivasi neuron, yaitu fungsi sigmoid (persamaan 2.8). Sampling antara lapisan *hidden* dan *visible* diikuti oleh modifikasi parameter (dikontrol oleh *learning rate*) Dan diulang untuk setiap kelompok data dalam *training set*, dan untuk *state* sebanyak yang diperlukan untuk mencapai konvergensi.



Gambar 2.7. RBM dengan variabel terlihat dan variabel tersembunyi

Arsitektur neural network RBM dapat dilihat pada gambar 2.7. Jaringan ini terdiri atas 2 (dua) unit neuron m variabel *visible* (terlihat) $v = (v_1, \dots, v_m)$ 3(tiga) neuron n variabel *hidden* (tersembunyi) $h = (h_1, \dots, h_n)$ dan 1 (satu) neuron bias pada lapisan *visible* dan 1 (satu) neuron bias pada lapisan hidden. Konfigurasi unit visible (v) dan unit hidden (h) memiliki energi (Hopfield, 1982) dalam (Nova, 2020) dimana a_i, b_j, v_i merupakan koefisien yang ditunjukkan pada persamaan berikut :

$$E(V, H) = -\sum_i a_i v_i - \sum_j b_j H_j - \sum_{i,j} v_i H_j W_{i,j} \quad (2.18)$$

Unit *hidden* diinisialisasi dan diperbarui menggunakan persamaan berikut, di mana H_j dari setiap unit hidden j diatur satu dengan probabilitas yang berarti bahwa variabel *hidden* (tersembunyi) bersyarat independen yang memberikan *state* atau satu sama lain, dan begitu pula sebaliknya. Dengan menggunakan pernyataan ini, kita dapat menulisnya dengan sebagai berikut :

$$p(h|v) = \sigma(b_j + \sum_i W_{ij}v_i) \quad (2.19)$$

$$p(v|h) = \sigma(c_i + \sum_j W_{ij}h_j) \quad (2.20)$$

Dimana $\sigma(\cdot)$ adalah fungsi aktivasi. Fungsi logistic, $\sigma(v) = \frac{1}{1+e^{-v}}$ adalah pilihan umum untuk fungsi aktivasi. Parameter W , b , dan v dilatih menggunakan algoritma *contrastive divergence*.

Algoritma *Contrastive Divergence* (CD) adalah algoritma pembelajaran untuk *Product of Experts* (PoE). PoE bekerja dengan menormalisasi produk dari beberapa model ahli dengan mempertimbangkan setiap variabel *hidden* dalam RBM sebagai ahli, RBM dapat dinyatakan sebagai kasus khusus PoE. Oleh karena itu, pelatihan CD menarik juga dalam konteks RBM. Sebagai model *unsupervised*, RBM tidak dapat menghitung dan menyebarkan kesalahan yang serupa dengan FFNN. Namun, seperti telah dibahas, kita dapat melakukan pengambilan sampel sampel Gibbs alternative untuk menciptakan rekonstruksi sampel masukan asli. CD memanfaatkan properti ini, dan menghitung kesalahan berdasarkan perbedaan

antara keadaan asli dan yang direkonstruksi. Bobot diperbarui mengikuti persamaan berikut :

$$\Delta W_{ij} = \epsilon (\langle v_i h_j \rangle_{data} - \langle v_i h_j \rangle_{recon}) \quad (2.21)$$

Dimana ϵ adalah tingkat pembelajaran dan kurung siku menunjukkan harapan di bawah distribusi tertentu, yaitu data atau rekonstruksi. Dengan kata lain, $\langle v_i h_j \rangle_{data}$ adalah produk antara unit asli *visible* j dan unit *hidden* yang diambil dari vector input. $\langle v_i h_j \rangle_{recon}$ dihitung secara ekuivalen, kecuali menggunakan rekonstruksi. Dengan kata lain $\langle \cdot \rangle$ adalah nilai rata-rata dari semua sample pelatihan. Beberapa RBM dapat ditumpuk untuk menghasilkan *Deep Belief Network* (DBN). Pada *deep belief network*, pengaktifan variabel *hidden* pada lapisan pertama adalah input ke lapisan ke dua. CD_k adalah ekstensi ke CD, dimana pengambilan sampel *Gibbs* dilakukan pada waktu bergantian dengan meningkatkan beban komputasi.

2.1.11. Pengukuran Performasi

Pengukuran kinerja klasifikasi yang terdapat pada data asli dan data hasil dari model klasifikasi dilakukan dengan menggunakan tabulasi silang (matriks konfusi/ *confusion matrix*) yang berisi informasi tentang kelas data asli yang direpresentasikan pada baris matriks dan kelas data hasil prediksi suatu algoritma yang direpresentasikan pada kolom klasifikasi. Seperti yang dikutip Prasetyo (2012), klasifikasi dapat didefinisikan sebagai pekerjaan yang melakukan pelatihan/pembelajaran terhadap fungsi target f yang memetakan setiap atribut

(fitur) x ke satu dari sejumlah label kelas y yang tersedia. Salah satu pengukur kinerja klasifikasi adalah tingkat akurasi. Pengukuran kinerja klasifikasi dapat dilakukan dengan membentuk Confusion matrix seperti pada tabel 2.1 berikut (Pristiyani,2016) :

Tabel 2.1. Confusion Matrix untuk Klasifikasi Dua Kelas

		Kelas Observasi		Total
		π_1	π_2	
Actual Membership	Hasil Prediksi	n_{1C}	$n_{1M} = n_1 - n_{1C}$	n_1
		$n_{2M} = n_2 - n_{2C}$	n_{2C}	n_2

Dimana :

n_{1C} = jumlah item dari π_1 yang terklasifikasi benar sebagai π_1

n_{1M} = jumlah item dari π_1 yang terklasifikasi benar sebagai π_2

n_{2C} = jumlah item dari π_2 yang terklasifikasi benar sebagai π_2

n_{2M} = jumlah item dari π_2 yang terklasifikasi benar sebagai π_1

Akurasi hasil klasifikasi dan kesalahan prediksi dapat dihitung dengan formula, sebagai berikut (Pristiyani,2016):

$$Akurasi = \frac{n_{1C} + n_{2C}}{n_1 + n_2} \quad (2.22)$$

MAPE (Mean Absolute Percentage Error) mengukur ukuran kesalahan dalam persentase. Hal ini dihitung sebagai rata-rata kesalahan persentase *unsigned*, seperti yang ditunjukkan pada contoh di bawah ini (Patma, *et al.*, 2018) :

$$MAPE = \frac{100}{N} \times \sum_{i=1}^N \left| \frac{x_i - \hat{x}_i}{x_i} \right| \quad (2.23)$$

Dimana $\{x_i\}$ adalah rangkaian waktu pengamatan aktual pada periode i . $\{\hat{x}_i\}$ adalah nilai peramalan pada deret waktu I dan N adalah jumlah data.

Tabel 2.2. Skala MAPE

Skala MAPE	Performa Variabel Peramalan
< 10%	Kemampuan model peramalan Sangat baik
10% - 20%	Kemampuan model peramalan baik
20% – 50%	Kemampuan model peramalan layak
>50%	Kemampuan model peramalan buruk

2.2. Tinjauan Non Statistik

2.2.1. Saham

Investasi dalam bentuk saham atau biasa disebut investasi saham merupakan pembelian surat berharga yang menunjukkan kepemilikan atau penyertaan modal investasi yang dilakukan oleh investor dalam suatu perusahaan. Menurut Darmadji

et. al (lihat Dian & Safiq, 2019), saham (*stock*) didefinisikan sebagai tanda penyertaan atau kepemilikan seseorang atau badan dalam suatu perusahaan atau perseroan terbatas. Saham berwujud selebar kertas yang menerangkan bahwa pemilik kertas tersebut adalah pemilik perusahaan yang menerbitkan surat berharga tersebut. Dengan menerbitkan saham, perusahaan-perusahaan yang membutuhkan suntikan modal bisa menjual saham kepada investor (penanam modal) dengan kata lain saham bisa diperjual belikan dalam pasar modal untuk kepentingan pendanaan perusahaan. *Investor* tersebut dapat mendapatkan keuntungan seperti memperoleh *dividen*, *capital gain* serta keuntungan non finansial lainnya. Keuntungan yang didapat melalui *capital gain* artinya keuntungan yang didapatkan dari hasil perbedaan harga saat pembelian dengan harga saat dijual. Namun dalam menentukan saham mana saja yang akan dibeli ataupun dijual tidaklah mudah. Sedangkan keuntungan yang diperoleh dari *dividen* dibagikan sesuai dengan penyertaan modal atau bagian sahamnya dimana yang diraih saat perusahaan yang menerbitkan saham mendapat keuntungan atau laba. Keuntungan lainnya dapat berupa *control management* yaitu hak menentukan kebijakan atas perusahaan yang dibeli. *Control management* diperoleh jika kepemilikan saham mencapai jumlah mayoritas.

Menurut Darmadji *et. al* (lihat Dian & Safiq, 2019), perusahaan yang melakukan investasi dalam bentuk saham mempunyai beberapa alasan, antara lain : untuk menebarkan resiko (*risk spread*), memperkokoh jaringan pasar, memperkuat

distribusi, menjaga suplai bahan baku jika perusahaan yang dibeli merupakan penyuplai (*supplier*) bahan baku dan memperkuat manajemen.

- a. Saham Biasa (*Common Stock*) adalah suatu sertifikat atau piagam yang memiliki fungsi sebagai bukti kepemilikan suatu perusahaan dengan berbagai aspek-aspek penting bagi perusahaan. Pemilik saham akan mendapatkan hak untuk menerima sebagian pendapatan tetap atau deviden dari perusahaan serta kewajiban menanggung resiko kerugian yang diderita perusahaan. Investor yang memiliki saham suatu perusahaan memiliki hak untuk ambil bagian dalam mengelola perusahaan sesuai dengan hak suara yang dimilikinya berdasarkan besar kecil saham yang dipunyai. Semakin banyak prosentase saham yang dimiliki maka semakin besar hak suara yang dimiliki untuk mengontrol operasional perusahaan atau bias dikatakan akuisisi. Secara sederhana, akuisi diartikan sebagai pembelian atau penguasaan atau pengambilan (*take over*) oleh perusahaan besar (*parent company*) terhadap perusahaan sasaran (*subsidiary company*). Dalam praktiknya, setelah proses akuisisi sering dilakukan proses penggabungan atau peleburan menjadi perusahaan baru memungkinkan timbulnya entitas hukum baru (*new legal entity*), misalnya Lippo Bank. Tetapi ada juga yang tetap mempertahankan legal entitas lama, misalnya Bimoli tetap menggunakan legal entitas lama meski sudah dibeli kelompok Salim Group. Perusahaan yang melakukan akuisisi mempunyai beberapa tujuan, antara lain; untuk mencari pendapatan dari pembagian deviden, memperkokoh jaringan pasar

(*network market*), memperkuat distribusi, penyebaran resiko, mencapai skala ekonomi (*economy to scale*) dan diversifikasi (*divercification*). Kegiatan ini bisa dilakukan langsung dengan perusahaan sasaran/target atau bisa melalui pasar modal. Perusahaan yang melakukan akuisisi pada prinsipnya adalah melakukan investasi. Oleh karena itu akuisisi dilakukan untuk jangka waktu yang lama (*long term investment*) dan dalam neraca dikelompokkan ke dalam pos investasi saham.

- b. Saham Preferen (*Prefered Stock*) adalah saham yang pemiliknya akan memiliki hak lebih dibanding hak pemilik saham biasa. Pemegang saham preferen akan mendapat dividen lebih dulu dan juga memiliki hak suara lebih dibanding pemegang saham biasa seperti hak suara dalam pemilihan direksi sehingga jajaran manajemen akan berusaha sekuat tenaga untuk membayar ketepatan pembayaran dividen preferen agar tidak lengser.

2.2.2. Bursa Efek

Menurut Undang-Undang Republik Indonesia No. 8 Tahun 1995 bahwasannya Pasar Modal atau yang disebut juga Bursa Efek adalah sebagai kegiatan yang bersangkutan dengan Penawaran Umum dan Perdagangan Efek, Perusahaan Publik yang berkaitan dengan Efek yang diterbitkan serta lembaga dan profesi yang berkaitan dengan Efek. Di mana efek adalah surat berharga, yaitu surat pengakuan hutang, surat berharga komersial, saham, obligasi, tanda bukti hutang, unit penyeteroran kontrak investasi kolektif, kontrak berjangka atas efek, dan setiap

derivatif dari efek. Fungsi Bursa Efek ini antara lain adalah pertama, menjaga kontinuitas pasar. Kedua, menciptakan harga efek yang wajar melalui mekanisme permintaan dan penawaran.

Pasar modal sangat sulit untuk diprediksi dikarenakan didorong oleh penawaran dan permintaan, perubahan ekonomi makro seperti inflasi atau ketidakstabilan politik dapat mempengaruhi seluruh pasar, sementara kegiatan seperti pengumuman keuangan perusahaan atau rilisnya produk berdampak hanya pada saham individu. Para *trader* juga mencari sinyal dalam pergerakan harga yang memberikan indikasi harga dimasa depan. Oleh karena itu, beberapa perdagangan didasarkan pada pergerakan harga dengan sendirinya juga dapat memicu aktivitas jual beli, sehingga menyebabkan penyesuaian harga lebih lanjut. *Investor* dan *trader* idealnya harus mempertimbangkan semua ini ketika mengevaluasi sebuah saham. Menurut Mudjiyono (2012), pelaku pasar dibagi menjadi dua kelompok: *Investor* yang membuat keputusan berdasarkan berita, fakta dan angka yang terkait dengan perusahaan dikenal sebagai analisis fundamental, sedangkan *trader* yang membuat keputusan berdasarkan histori harga saham dan *rumors* yang dikenal sebagai analisis teknikal.

Bursa Efek berperan signifikan dalam kegiatan pasar modal. Bursa Efek bertanggung jawab dalam menyediakan semua sarana perdagangan efek dan membuat peraturan yang berkaitan dengan kegiatan bursa. Bursa Efek juga mendorong partisipasi masyarakat serta badan usaha dalam memenuhi pembiayaan

nasional. Jika permintaan investasi tinggi, maka perusahaan akan meningkatkan jumlah penawaran saham kepada publik. Ini akan mendorong peningkatan aktivitas transaksi di pasar modal. Ditambah lagi, bursa efek juga berperan dalam menyediakan informasi perdagangan harian yaitu perubahan harga saham yang terjadi setiap harinya serta harga penutupan.

2.2.2.1. Bursa Efek Indonesia

Bursa Efek Indonesia (BEI) atau *Indonesian Stock Exchange* (IDX) merupakan pasar modal yang ada di Indonesia. Bursa Efek Indonesia memiliki peranan penting sebagai sarana bagi masyarakat untuk berinvestasi, yang merupakan salah satu alternatif penanaman modal. Bagi perusahaan, BEI membantu perusahaan untuk mendapatkan tambahan modal dengan cara *go public* yaitu kegiatan penawaran saham atau efek lainnya yang dilakukan oleh emiten (perusahaan yang *go public*) kepada masyarakat berdasarkan tata cara yang diatur oleh UU Pasar Modal dan Peraturan Pelaksanaannya (Basir, 2005) dalam Qoribulloh (2013).

Bursa Efek Indonesia sendiri merupakan penggabungan dari Bursa Efek Jakarta (BEJ) dengan Bursa Efek Surabaya (BES). Demi efektivitas operasional dan transaksi, Pemerintah memutuskan untuk menggabung Bursa Efek Jakarta sebagai pasar saham dengan Bursa Efek Surabaya sebagai pasar obligasi dan derivative menjadi *Bursa Efek Indonesia* (BEI). Bursa hasil penggabungan ini mulai

beroperasi pada 1 Desember 2007. BEI sendiri menggunakan sistem perdagangan bernama Jakarta Automated Trading System (JATS) sejak 22 Mei 1995, menggantikan sistem manual yang digunakan sebelumnya. Sejak 2 Maret 2009, sistem JATS sendiri telah digantikan dengan sistem baru bernama JATS-NextG. Untuk memberikan informasi yang lebih lengkap tentang perkembangan bursa kepada publik, BEI menyebarkan data pergerakan harga saham melalui media cetak dan elektronik. Satu indikator pergerakan harga saham tersebut adalah indeks harga saham. Saat ini, BEI mempunyai beberapa jenis indeks, ditambah dengan indeks sektoral per 09 Mei 2019. Indeks-indeks tersebut adalah Indeks Harga Saham Gabungan (IHSG), LQ45, IDX30, IDX80, Kompas100, IDX-SMC Composite, IDX SMC Liquid, BUMN20, Indeks Saham Syariah Indonesia (ISSI), Jakarta Islamic Index (JII), JI70, Indeks Papan Utama, Indeks Papan Pengembangan, BISNIS-27, PEFINDO25, SRI_KEHATI, Infobank15, SMinfra18, MNC36, Investor33, PEFINDO i-Grade, IDX Quality30, IDX Value30, IDX Growth30, IDX ESG Leaders, IDX-MES BUMN 17, dan Indeks Sektoral.

2.2.3. Indeks LQ-45

Indeks LQ-45 adalah kumpulan 45 perusahaan dengan saham-saham yang mempunyai likuiditas yang tinggi atau sering ditransaksikan dan biasanya manajer investasi akan menempatkan dananya pada saham-saham yang termasuk dalam LQ45 untuk mengurangi resiko likuiditas. Indeks LQ45 dibuat dengan tujuan sebagai upaya pelengkap IHSG khususnya untuk menyediakan sarana yang obyektif

dan terpercaya bagi analisis keuangan, manajer investasi, investor dan pemerhati pasar modal dalam memonitor pergerakan harga saham yang aktif diperdagangkan di Bursa Efek Indonesia. LQ45 juga dianggap sebagai *benchmark* untuk menilai suatu kinerja investasi berbasis pasar modal. Berdasarkan Bursa Efek Indonesia (2020) Saham-saham pada indeks LQ45 harus memenuhi kriteria dan melewati seleksi utama sebagai berikut:

1. Termasuk dalam 60 perusahaan teratas dengan kapitalisasi pasar tertinggi dalam 12 bulan terakhir.
2. Termasuk dalam 60 perusahaan teratas dengan nilai transaksi tertinggi di pasar reguler dalam 12 bulan terakhir
3. Telah tercatat di BEI minimum 3 bulan.
4. Memiliki kondisi keuangan, prospek pertumbuhan dan nilai transaksi yang tinggi
5. Mengalami penambahan bobot *free float* menjadi 100% yang sebelumnya hanya 60% dalam porsi penilaian.

2.2.4. Laporan Keuangan

Laporan keuangan merupakan catatan keuangan dari suatu periode akuntansi yang digunakan untuk kinerja usaha tertentu, untuk menilai perkembangan usaha dan tanggung jawab dalam pengaturan keuangan. Menurut Harahap (2007), laporan keuangan menggambarkan kondisi keuangan dan hasil usaha suatu perusahaan pada

jangka waktu tertentu Laporan keuangan dapat memberikan informasi yang dibutuhkan bagi beberapa pihak serta dapat dijadikan pertimbangan dalam pengambilan keputusan dimasa yang akan datang. Tujuan laporan keuangan adalah menyediakan informasi mengenai posisi keuangan, kinerja keuangan, dan arus kas perusahaan serta perubahan posisi keuangan perusahaan yang bermanfaat bagi manajemen dalam pengambilan keputusan. Informasi-informasi tersebut sangat penting dan bermanfaat bagi pihak-pihak terkait untuk mendukung proses pengambilan keputusan ekonomi penting dan strategis sehingga perlu adanya analisis terhadap Pelaporan Keuangan suatu perusahaan. Menurut Kasmir (2011), tujuan dari analisis laporan keuangan adalah:

1. Untuk mengetahui posisi keuangan perusahaan dalam satu periode tertentu, baik aset, kewajiban, ekuitas maupun hasil usaha yang telah dicapai untuk beberapa periode.
2. Untuk mengetahui kelemahan-kelemahan apa saja yang menjadi kekurangan perusahaan.
3. Untuk mengetahui kekuatan-kekuatan yang dimiliki.
4. Untuk mengetahui langkah-langkah perbaikan apa saja yang perlu dilakukan ke depan berkaitan dengan posisi keuangan perusahaan saat ini.
5. Untuk melakukan penilaian kinerja manajemen ke depan, apakah perlu penyegaran atau tidak karena sudah dianggap berhasil atau gagal.

6. Sebagai pembanding dengan perusahaan sejenis tentang hasil yang mereka capai.

2.2.4.1. Rasio Keuangan

Menurut Harahap (2008), Rasio Keuangan adalah angka yang diperoleh dari hasil perbandingan dari satu pos laporan keuangan dengan pos lainnya yang mempunyai hubungan yang relevan dan signifikan. Rasio Keuangan ini dapat diimbaratkan sebagai menyederhanakan informasi yang menggambarkan hubungan antara pos tertentu dengan pos lainnya. Dengan penyederhanaan ini kita dapat menilai secara cepat hubungan antara pos tadi dan dapat membandingkannya dengan rasio lain sehingga kita dapat memperoleh informasi dan memberikan penilaian. Analisis Rasio ini memiliki keunggulan dibanding teknik analisis lain, diantaranya adalah sebagai berikut:

1. Rasio merupakan angka-angka atau ikhtisar statistik yang lebih mudah dibaca dan ditafsirkan.
2. Merupakan pengganti yang lebih sederhana dari informasi yang disajikan laporan keuangan yang sangat rinci dan rumit.
3. Mengetahui posisi perusahaan di tengah industri lain
4. Sangat bermanfaat untuk bahan dalam mengisi model-model pengambilan keputusan dan model prediksi.
5. Menstandarisir size perusahaan

6. Lebih mudah membandingkan perusahaan dengan perusahaan lain atau melihat perkembangan perusahaan secara periodik atau *time series*.
7. Lebih mudah melihat tren perusahaan serta melakukan prediksi di masa yang akan datang.

Disamping keunggulan tersebut, Analisis rasio memiliki beberapa keterbatasan yang harus disadari sewaktu-waktu penggunaannya agar kita tidak salah dalam penggunaannya. Menurut Harahap (2008), keterbatasan analisis rasio adalah sebagai berikut:

1. Kesulitan dalam memilih rasio yang tepat yang dapat digunakan untuk kepentingan pemakainya.
2. Keterbatasan yang dimiliki akuntansi atau laporan keuangan juga menjadi keterbatasan teknik ini seperti:
 - a. Bahan perhitungan rasio atau laporan keuangan itu banyak mengandung taksiran dan *judgement* yang dapat dinilai biasa atau subjektif,
 - b. Nilai yang terkandung dalam laporan keuangan dan rasio adalah nilai perolehan (*cost*) bukan harga pasar,
 - c. Klasifikasi dalam laporan keuangan bisa berdampak pada angka rasio.
 - d. Metode pencatatan yang tergambar dalam standar akuntansi bisa diterapkan berbeda oleh perusahaan yang berbeda.

3. Jika data untuk menghitung rasio tidak tersedia, akan menimbulkan kesulitan menghitung rasio.
4. Sulit jika data yang tersedia tidak sinkron.
5. Dua perusahaan dibandingkan bisa saja teknik dan standar akuntansi yang dipakai tidak sama. Oleh karenanya jika dilakukan perbandingan akan menimbulkan kesalahan.

Pada umumnya rasio keuangan bermacam-macam tergantung kepada kepentingan dan penggunaannya. Berikut ini jenis-jenis rasio keuangan :

1. Rasio Likuiditas

Rasio likuiditas merupakan rasio yang mengukur kemampuan perusahaan memenuhi kewajiban jangka pendeknya. Rasio-rasio ini dapat dihitung melalui sumber informasi tentang modal kerja yaitu pos-pos aktiva lancar dan utang lancar. Untuk dapat memenuhi kewajibannya yang sewaktuwaktu ini, maka perusahaan harus mempunyai alat-alat untuk membayar yang berupa aset-aset lancar yang jumlahnya harus jauh lebih besar daripada kewajiban-kewajiban yang harus segera dibayar berupa kewajiban-kewajiban lancar. Salah satu contoh dari Rasio Likuiditas adalah *Current Ratio* yang diperoleh dengan rumus :

$$\text{Current ratio} = \frac{\text{aktiva lancar}}{\text{hutang lancar}}$$

2. Rasio Aktivitas (Rasio Perputaran)

Menurut Harahap (2009), rasio aktivitas menggambarkan aktivitas yang dilakukan perusahaan dalam menjalankan operasinya baik dalam kegiatan penjualan, pembelian, dan kegiatan lainnya. Rasio ini digunakan untuk mengukur efektif tidaknya perusahaan dalam menggunakan dan mengendalikan sumber-sumber yang dimiliki oleh perusahaan. Rasio ini diukur dengan membandingkan penjualan dengan berbagai investasi dalam aktiva. Pada rasio ini, Semakin efektif dalam memanfaatkan dana semakin cepat perputaran dana tersebut, karena rasio aktivitas umumnya diukur dari perputaran masing-masing asset.

3. Rasio Profitabilitas

Menurut Harahap (2009), rasio profitabilitas menggambarkan kemampuan perusahaan mendapatkan laba melalui semua kemampuannya, dan sumber yang ada seperti kegiatan penjualan, kas, ekuitas, jumlah karyawan, jumlah cabang dan sebagainya. Perusahaan besar yang sudah *well-established* akan lebih mudah memperoleh modal dibanding dengan perusahaan kecil. Karena kemudahan akses tersebut berarti perusahaan besar memiliki fleksibilitas yang lebih besar pula. Contoh dari Rasio Profitabilitas antara lain sebagai berikut:

- a. *Return to Asset (ROA)*, diperoleh dengan rumus :

$$ROA = \frac{\text{Laba Bersih}}{\text{Total aktiva}}$$

- b. *Return to Equity (ROE)*, diperoleh dengan rumus :

$$ROE = \frac{\text{Laba Bersih}}{\text{Modal Sendiri}}$$

- c. *Gross Profit Margin (GPM)*, diperoleh dengan rumus :

$$GPM = \frac{\text{Laba Kotor}}{\text{Penjualan Bersih}}$$

- d. *Operating Profit Margin (OPM)*, diperoleh dengan rumus :

$$OPM = \frac{\text{Laba Operasional}}{\text{Penjualan Bersih}}$$

- e. *Net Profit Margin (NPM)*, diperoleh dengan rumus :

$$NPM = \frac{\text{Laba Bersih Setelah Pajak}}{\text{Penjualan Bersih}}$$

- f. *Earning Per Share (EPS)*, diperoleh dengan rumus :

$$EPS = \frac{\text{Laba Bersih}}{\text{Jumlah lembar saham}}$$

4. Rasio *Leverage*

Rasio *leverage* adalah rasio yang mengukur seberapa jauh perusahaan dibiayai oleh kewajiban atau pihak luar dengan kemampuan perusahaan yang digambarkan oleh ekuitas. Perusahaan yang baik mestinya memiliki komposisi modal yang lebih besar dari utang. Setiap penggunaan utang oleh perusahaan akan berpengaruh

terhadap rasio dan pengembalian. Rasio ini dapat digunakan untuk melihat seberapa resiko keuangan perusahaan. Contoh dari Rasio *Leverage* antara lain sebagai berikut

- a. *Debt to Asset Ratio (DAR)*, diperoleh dengan rumus :

$$DAR = \frac{\text{Total Hutang}}{\text{Total Aset}}$$

- b. *Debt to Equity Ratio (DER)*, diperoleh dengan rumus :

$$DER = \frac{\text{Total Hutang}}{\text{Modal Sendiri}}$$

Selain keempat rasio diatas, terdapat pula rasio performasi yang menunjukkan perkembangan perusahaan. Yang dimaksud rasio performasi ditunjukkan dengan *Price to Book Value (PBV)*, diperoleh rumus :

$$PBV = \frac{\text{Harga pasar saham}}{\text{Nilai Buku per saham}}$$

2.2.5. *Financial Distress*

Financial Distress secara umum (Husna *et al.*, 2021) dapat diartikan sebagai kondisi dimana keuangan perusahaan dalam keadaan tidak sehat atau krisis dan terjadi sebelum kebangkrutan. Kebangkrutan secara umum didefinisikan sebagai keadaan di mana perusahaan mengalami kegagalan menjalankan operasional perusahaan sehingga tidak dapat menghasilkan laba dan membayar kreditur mereka. Pada situasi tertentu, perusahaan akan mengalami kesulitan keuangan yang paling

ringan antara lain mengalami kesulitan likuiditas yaitu tidak mampu membayar gaji pegawai tepat waktu , tidak mampu membayar bunga pinjaman perusahaan). Berakumulasinya masalah likuiditas perusahaan disebabkan karena kegagalan memperoleh penjualan sehingga menyebabkan perusahaan tidak dapat memperoleh sumber pendanaan yang mencukupi, kemudian berlanjut pada kesulitan dalam pembayaran hutang, hingga pada akhirnya mencapai tingkat kesulitan yang tidak berujung. Indikator financial distress dapat dilihat dari analisis aliran kas, analisis strategi perusahaan, dan laporan keuangan perusahaan. Perusahaan dapat mengalami permasalahan dalam keuangannya karena kerugian hasil operasional yang terus-menerus, kemacetan pembayaran kredit pelanggan, buruknya pengelolaan modal kerja dan sejumlah alasan lain yang menyebabkan posisi ekonomi yang baik tidak dipertahankan. Jika tidak segera diatasi dengan benar, kesulitan ringan tersebut akan bisa berkembang menjadi kesulitan yang lebih besar, dan bisa sampai pada kebangkrutan. Terdapat empat kategori dalam menganalisis kesehatan keuangan dan potensi kebangkrutan perusahaan dapat dikelompokkan menjadi empat kategori yaitu:

- a. Perusahaan yang tidak mengalami kesulitan keuangan yaitu jika posisi keuangan jangka pendek maupun jangka panjang sehat sehingga tidak mengalami kebangkrutan.
- b. Perusahaan yang mengalami kesulitan keuangan dalam jangka pendek dan manajemennya berhasil mengatasi dengan baik sehingga tidak pailit.

- c. Perusahaan yang tidak mengalami kesulitan keuangan tetapi menghadapi kesulitan keuangan yang bersifat non keuangan sehingga dapat diambil keputusan yang menyatakan pailit.
- d. Perusahaan yang mengalami kesulitan keuangan dan manajemen tidak berhasil mengatasinya sehingga akhirnya pailit.

Setiap perusahaan mempunyai perjanjian-perjanjian dalam bentuk kewajiban yang harus dijelaskan sesuai jangka waktu yang telah disepakati. Jika kewajiban tersebut tidak dapat dilakukan, maka hal tersebut dapat menjadi tanda-tanda bahwa perusahaan tersebut sedang dalam kondisi *financial distress*. Menurut Shelly (2021), tanda-tanda perusahaan yang mengalami *financial distress* adalah sebagai berikut:

- a. Terjadi penurunan secara signifikan terhadap penjualan dan pendapatan
- b. Laba atau arus kas dari operasional mengalami penurunan.
- c. Penurunan total aktiva.
- d. Terjadi penurunan secara signifikan terhadap close price.
- e. Kemungkinan gagal yang besar dalam industri atau industri dengan risiko yang tinggi.
- f. Terjadi pemotongan *dividen* yang besar