

**PERBANDINGAN METODE *NAÏVE BAYES* DAN *BAYESIAN REGULARIZATION NEURAL NETWORK (BRNN)* UNTUK KLASIFIKASI SINYAL PALSU PADA INDIKATOR *STOCHASTIC OSCILLATOR* (Studi Kasus: Saham PT Bank Rakyat Indonesia (Persero) Tbk Periode Januari 2017 – Agustus 2019)**

Fredy Yoseph Marianto<sup>1</sup>, Tarno<sup>2</sup>, Di Asih I Maruddani<sup>3</sup>

<sup>1,2,3</sup>Departemen Statistika FSM Universitas Diponegoro

Email: [tarno.stat@gmail.com](mailto:tarno.stat@gmail.com)

**ABSTRAK**

Keputusan untuk membeli atau menjual saham merupakan kunci utama untuk memperoleh keuntungan dalam *trading* dan investasi. Salah satu indikator yang dapat digunakan dalam menentukan momentum untuk membeli atau menjual saham adalah *Stochastic Oscillator*. Sebagai indikator yang sensitif terhadap pergerakan harga saham, *Stochastic Oscillator* sering mengeluarkan sinyal palsu yang mengakibatkan kerugian dalam transaksi. Terdapat 9 atribut yang diduga dapat mengidentifikasi apakah suatu sinyal yang keluar dari indikator *Stochastic Oscillator* merupakan sinyal palsu atau tidak. Tujuan dari penelitian ini adalah melakukan klasifikasi atau deteksi sinyal dengan metode *Naïve Bayes* dan *Bayesian Regularization Neural Network (BRNN)*, dan kemudian membandingkan tingkat akurasi hasil klasifikasi antara kedua metode. Hasil dari penelitian ini menunjukkan bahwa hanya terdapat 6 atribut yang dapat digunakan untuk mengidentifikasi apakah suatu sinyal yang keluar merupakan sinyal palsu atau tidak, yaitu kondisi IHSG, kondisi *high price*, kondisi *low price*, kondisi *close price*, posisi %K, dan posisi %D, serta tingkat akurasi dari metode *Naïve Bayes* adalah sebesar 76,92%, sedangkan akurasi dari metode BRNN adalah sebesar 80,77%. Dapat disimpulkan bahwa dalam penelitian ini, metode BRNN lebih baik dibandingkan dengan metode *Naïve Bayes* untuk mendeteksi sinyal palsu yang keluar dari indikator *Stochastic Oscillator*.

Kata kunci: *Stochastic Oscillator*, Sinyal Palsu, Klasifikasi, *Naïve Bayes*, BRNN, Akurasi

**1. PENDAHULUAN**

Saham adalah jenis produk investasi pada pasar modal yang paling populer. Investasi saham merupakan metode keuangan untuk menambah kekayaan dalam suatu jangka waktu dengan membeli dan menyimpan sebuah portfolio atau kumpulan aset. Memiliki definisi yang sama dengan investasi saham, *trading* saham menjadi metode yang juga banyak dilakukan untuk memperoleh keuntungan dalam dunia saham. Dalam *trading* saham, analisis yang dominan digunakan adalah analisis teknikal. Analisis teknikal adalah metode untuk memprediksi pergerakan harga dan tren pasar di masa depan dengan melihat grafik di masa lalu (Halim, 2015). Salah satu indikator yang sering digunakan pada analisis teknikal adalah *Stochastic Oscillator* (ISP, 2017).

*Stochastic Oscillator* adalah indikator daya gerak yang digunakan dalam analisis teknikal untuk membandingkan harga penutupan terhadap rentang harga dalam suatu periode tertentu. Pada umumnya, indikator *Stochastic Oscillator* digunakan untuk menentukan kondisi jenuh beli (*overbought*) dan jenuh jual (*oversold*). Namun banyak *trader* juga menggunakan *Stochastic Oscillator* (SO) sebagai landasan dalam mengambil keputusan untuk membeli (*buy*) maupun menjual (*sell*) saham walaupun tidak dalam kondisi *overbought* maupun *oversold*. Hal tersebut yang sering membuat para *trader* mendapati sinyal yang salah (sinyal palsu) dalam *trading* sehingga menimbulkan kerugian.

Klasifikasi dapat didefinisikan sebagai proses untuk menyatakan suatu objek data sebagai salah satu kategori (kelas) yang telah didefinisikan sebelumnya (Zaki *et al*, 2013). Metode klasifikasi yang menggunakan konsep dasar teorema Bayes dalam proses pembelajarannya adalah *Naïve Bayes Classifier*. Selain itu, teorema Bayes juga digunakan dalam metode yang saat ini banyak dikembangkan, yaitu jaringan syaraf tiruan (*Artificial Neural Network*) tepatnya dalam algoritma *Bayesian Regularization Neural Network* (BRNN). Algoritma *Bayesian Regularization Neural Network* (BRNN) adalah salah satu algoritma yang digunakan untuk mengatasi permasalahan *overfitting* yang sering terjadi dalam pembelajaran jaringan syaraf tiruan (Perez-Rodriguez *et al*, 2013).

## 2. TINJAUAN PUSTAKA

### 2.1. Indikator *Stochastic Oscillator*

Indikator *Stochastic Oscillator* digunakan untuk mengukur kekuatan relatif dari harga terakhir terhadap rentang harga tertinggi dan harga terendah selama periode rentang waktu yang diinginkan. *Stochastic Oscillator* terdiri atas 2 indikator perbandingan yaitu %K (*stochastic* cepat) dan %D (*stochastic* lambat), serta batas kondisi *overbought* dan *oversold*.

### 2.2. Sinyal Palsu (*False Signal*)

Sinyal palsu (*false signal*) adalah sinyal yang mengakibatkan kerugian pada trader dari transaksi jual-beli yang dilakukan. Pada umumnya indikasi tersebut sering muncul ketika sinyal beli (*buy*) keluar berlawanan dengan tren harga saham yang menurun.

### 2.3. Seleksi Atribut menggunakan Uji Independensi

Menurut Han *et al* (2012), dalam *data mining* seringkali membutuhkan *data integration*, yaitu penggabungan data dari banyak tempat penyimpanan data. Dalam *data integration*, redundansi menjadi salah satu masalah penting. Beberapa redundansi dapat dideteksi dengan uji independensi. Dicontohkan dua atribut, dengan menggunakan uji independensi dapat mengukur kekuatan satu atribut menyiratkan atribut yang lain berdasarkan data yang ada.

Hipotesis:

$H_0$ : Variabel A dan variabel B tidak berhubungan

$H_1$ : Variabel A dan variabel B berhubungan

Statistik Uji:

$$\chi^2 = \sum_{i=1}^c \sum_{j=1}^r \frac{(n_{ij} - e_{ij})^2}{e_{ij}}$$

dengan :  $e_{ij} = \frac{n_i n_j}{N}$ ,  $n_i = \sum_j n_{ij}$ , dan  $n_j = \sum_i n_{ij}$

Kriteria Uji:  $H_0$  ditolak jika  $\chi^2 > \chi_{\alpha, ab}^2$ . Dengan derajat bebas yang digunakan adalah  $(r - 1) \times (c - 1)$ .

### 2.4. Klasifikasi

Menurut 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. Umumnya, pengukuran kinerja klasifikasi dilakukan dengan membentuk matriks konfusi seperti pada Tabel 1:

**Tabel 1.** Matriks Konfusi untuk Klasifikasi Dua Kelas

Hasil Hasil Prediksi	Kelas Observasi	
	Kelas = 0	Kelas = 1
Kelas = 0	$f_{00}$	$f_{10}$
Kelas = 1	$f_{01}$	$f_{11}$

Akurasi hasil klasifikasi dan kesalahan prediksi dapat dihitung dengan formula, sebagai berikut:

$$Akurasi = \frac{f_{00} + f_{11}}{f_{00} + f_{01} + f_{10} + f_{11}}$$

$$APER = \frac{f_{01} + f_{10}}{f_{00} + f_{01} + f_{10} + f_{11}}$$

Untuk mengetahui hasil prediksi suatu metode klasifikasi sudah akurat atau belum, perlu dilakukan pengujian statistika menggunakan uji statistik *Press's Q*, yaitu dengan membandingkan antara jumlah ketepatan klasifikasi dengan total pengamatan dan banyaknya kelompok (Hair *et al*, 2006).

Hipotesis:

$H_0$ : Pengklasifikasian tidak akurat

$H_1$ : Pengklasifikasian akurat

Statistik Uji:

$$Press's Q = \frac{[N - qK]^2}{N(K - 1)}$$

dengan:  $N = f_{00} + f_{01} + f_{10} + f_{11}$ ,  $q = f_{00} + f_{11}$ , dan  $K$  adalah banyaknya kelompok.

Kriteria Uji:  $H_0$  ditolak jika  $Press's Q > \chi_{\alpha,1}^2$ .

## 2.5. Naïve Bayes

Klasifikasi *Naïve Bayes* merupakan salah satu metode klasifikasi yang berakar pada teorema Bayes. Ciri utama dari Klasifikasi *Naïve Bayes* ini adalah asumsi yang sangat kuat akan independensi dari masing-masing kondisi atau kejadian (Prasetyo, 2012). Formula Naive Bayes untuk klasifikasi adalah sebagai berikut:

$$P(Y|X) = \frac{P(Y) \prod_{g=1}^p P(X_g|Y)}{P(X)}$$

Probabilitas  $P(X)$  selalu tetap sehingga dalam perhitungan prediksi dapat dihilangkan dan hanya menghitung bagian  $P(Y) \prod_{g=1}^p P(X_g|Y)$  dengan memilih nilai yang terbesar sebagai kelompok yang terpilih sebagai hasil prediksi.

## 2.6. Neural Network (NN)

*Neural Network* (NN) adalah suatu jaringan yang memodelkan sistem saraf otak manusia (yang disebut *neuron*) dalam melaksanakan tugas pengenalan pola, salah satunya yaitu klasifikasi (Suyanto, 2019).

Menurut Siang (2005), *Neural Network* (NN) ditentukan oleh 3 hal penting, yaitu pola hubungan antar *neuron* (disebut arsitektur jaringan), metode untuk menentukan bobot penghubung (disebut algoritma), dan fungsi aktivasi

### 2.6.1 Bayesian Regularization Neural Network (BRNN)

*Bayesian Regularization* (BR) merupakan algoritma pelatihan jaringan syaraf tiruan yang memperbaiki nilai bobot dan bias berdasarkan optimasi Levenberg-Marquardt (Pan *et al*, 2013). Algoritma BR bertujuan untuk meminimalkan kombinasi kuadrat galat dan bobot (disebut fungsi objektif), kemudian menentukan kombinasi yang benar sehingga menghasilkan suatu jaringan yang baik (Pan *et al*, 2013). Fungsi objektif pelatihan dinotasikan sebagai berikut (Yue *et al*, 2011):

$$F(\mathbf{w}) = \alpha E_w + \beta E_D$$

dengan  $E_w$  adalah jumlah kuadrat dari bobot jaringan dan  $E_D$  adalah jumlah kuadrat dari galat jaringan. Pembaharuan parameter fungsi objektif dihitung menggunakan rumus:

$$\alpha^{MP} = \frac{\gamma}{2E_w(\mathbf{w}^{MP})} \quad \text{dan} \quad \beta^{MP} = \frac{n - \gamma}{2E_D(\mathbf{w}^{MP})}$$

dengan  $\gamma = k - 2\alpha^{MP} \text{tr}(\mathbf{H}^{MP})^{-1}$  adalah jumlah parameter efektif,  $k$  adalah jumlah parameter dalam jaringan, dan  $n$  adalah jumlah data dalam proses pembelajaran.

Algoritma metode BRNN adalah sebagai berikut:

1. Inisialisasi parameter  $\alpha$ ,  $\beta$ , dan bobot jaringan  $\mathbf{w}$
2. Menerapkan algoritma Levenberg-Marquardt untuk meminimalkan fungsi objektif  $F(\mathbf{w})$
3. Menghitung parameter efektif  $\gamma$
4. Menghitung estimasi baru untuk parameter fungsi objektif  $\alpha^{MP}$  dan  $\beta^{MP}$
5. Mengulang langkah 2 sampai 4 sampai diperoleh titik konvergen.

### 2.6.2 Arsitektur Bayesian Regularization Neural Network (BRNN)

*Bayesian Regularization Neural Network* (BRNN) terdiri atas 3 lapisan yaitu  $p$  *node input layer*,  $s$  *node hidden layer*, dan 1 *node output layer*. Setiap *hidden unit* merupakan hasil transformasi dari fungsi aktivasi yang dalam hal ini adalah fungsi tangen hiperbolik yang dinotasikan:

$$g_k(x) = \frac{e^{2x}-1}{e^{2x}+1}, \quad -\infty < x < \infty$$

## 3. METODE PENELITIAN

### 3.1. Jenis dan Sumber Data

Jenis data yang digunakan dalam penelitian ini adalah data gabungan antara data primer dan data sekunder, yaitu data saham harian PT Bank Rakyat Indonesia (Persero) Tbk (BBRI) periode Januari 2017 sampai Agustus 2019.

### 3.2. Variabel Penelitian

Variabel pada penelitian ini terdiri dari variabel respon (Y) dan beberapa variabel prediktor (X). Adapun variabel-variabel tersebut adalah sebagai berikut:

1. Variabel respon  
 $Y$  = Status sinyal, 0 = sinyal palsu, 1 = sinyal tidak palsu
2. Variabel prediktor  
 $X_1$  = kondisi IHSB,  $X_2$  = kondisi *open price*,  $X_3$  = kondisi *high price*,  
 $X_4$  = kondisi *low price*,  $X_5$  = kondisi *close price*,  $X_6$  = kondisi *volume*,  
 $X_7$  = posisi %K,  $X_8$  = posisi %D, dan  $X_9$  = sinyal saham.

### 3.3. Teknik Pengolahan Data

Data yang telah dikumpulkan dalam penelitian ini kemudian diolah dengan menggunakan metode klasifikasi Naïve Bayes dan *Bayesian Regularization Neural Network* (BRNN) menggunakan bantuan software Microsoft Excel 2013, dan R 3.6.0. Tahapan analisis dalam penelitian ini adalah sebagai berikut:

1. Mempersiapkan data status sinyal saham BBRI.
2. Melakukan uji independensi variabel respon terhadap masing-masing atribut.
3. Membagi data menjadi 80% data *training* dan 20% data *testing*.
4. Melakukan pengolahan data menggunakan metode klasifikasi *Naïve Bayes* dengan langkah-langkah sebagai berikut:
  - a. Menghitung probabilitas prior ( $P(Y)$ ) dari data *testing* berdasarkan data *training*.
  - b. Menghitung probabilitas atribut terhadap masing-masing kelas ( $P(\mathbf{X}|Y)$ ) pada data *testing* berdasarkan data *training*.
  - c. Menghitung perkalian probabilitas dengan probabilitas atribut pada masing-masing kelas ( $P(Y)P(\mathbf{X}|Y)$ ).
  - d. Mencari nilai maksimal dari ( $P(Y)P(\mathbf{X}|Y)$ ) pada kedua kelas.
  - e. Menghitung ketepatan klasifikasi dan misklasifikasi (APER) berdasarkan pola yang diperoleh dari data *training*.
  - f. Menilai keakuratan prediksi keanggotaan kelompok dengan uji *Press's Q*.
5. Melakukan pengolahan data menggunakan metode *Bayesian Regularization Neural Network* (BRNN) dengan langkah-langkah sebagai berikut:
  - a. Inisialisasi bobot dan bias awal pada jaringan, serta parameter pada fungsi objektif
  - b. Menerapkan algoritma Levenberg-Marquardt untuk meminimalkan fungsi objektif  $F(\mathbf{w}) = \alpha E_w + \beta E_D$ .
  - c. Menghitung parameter efektif  $\gamma$ .
  - d. Menghitung estimasi baru untuk parameter fungsi objektif  $\alpha^{MP}$  dan  $\beta^{MP}$ .
  - e. Mengulangi langkah (b) sampai (d) sampai diperoleh titik konvergensi dengan pemulihan nilai bobot dan bias pada jaringan.
  - f. Menghitung output BRNN
  - g. Menghitung ketepatan klasifikasi dan misklasifikasi (APER) berdasarkan pola yang diperoleh dari data *training*.
  - h. Menilai keakuratan prediksi keanggotaan kelompok dengan uji *Press's Q*.
6. Membandingkan ketepatan klasifikasi antara metode *Naïve Bayes* dan *Bayesian Regularization Neural Network* (BRNN).
7. Melakukan deteksi atau klasifikasi sinyal palsu pada data baru dengan metode *Naïve Bayes* dan *Bayesian Regularization Neural Network* (BRNN).

## 4. HASIL DAN PEMBAHASAN

### 4.1 Deskripsi Data

Berdasarkan data penelitian, terdapat 259 sinyal yang tergolong dalam sinyal palsu dan sinyal palsu yang ditampilkan pada Tabel 2:

**Tabel 2.** Status Sinyal Palsu dan Tidak Palsu pada Saham Harian BBRI

Klasifikasi	Jumlah	Prosentase
Sinyal palsu	122	47.10 %
Sinyal tidak palsu	137	52.90 %

Berdasarkan Tabel 2, diketahui bahwa terdapat 122 sinyal yang tergolong ke dalam sinyal palsu (47,10%) dan 137 sinyal yang tergolong ke dalam sinyal tidak palsu (52,90%).

## 4.2 Uji Independensi antara Variabel Respon dengan Variabel Prediktor

Hipotesis

$H_0$ : Variabel X dan variabel Y tidak berhubungan

$H_1$ : Variabel X dan variabel Y berhubungan

Taraf Signifikansi  $\alpha = 5\%$

Statistik Uji:

Hasil perhitungan nilai  $\chi^2$  (*chi-square*) untuk masing-masing variabel ditampilkan pada Tabel 3:

**Tabel 3.** Keputusan Uji  $\chi^2$  antara Variabel Respon (Y) dan Variabel Prediktor (X)

Vaiabel	$\chi^2$	db	$\chi^2_{tabel}$	<i>p-value</i>	Keputusan
$X_1$	9,3236	1	3,841	0,002262	$H_0$ ditolak
$X_2$	1,3383	1	3,841	0,2473	$H_0$ diterima
$X_3$	14,542	1	3,841	0,000137	$H_0$ ditolak
$X_4$	25,832	1	3,841	0,0000003724	$H_0$ ditolak
$X_5$	19,837	1	3,841	0,000008435	$H_0$ ditolak
$X_6$	0,19939	1	3,841	0,6552	$H_0$ diterima
$X_7$	20,134	2	5,991	0,000004246	$H_0$ ditolak
$X_8$	14,246	2	5,991	0,0008063	$H_0$ ditolak
$X_9$	0,0043358	1	3,841	0,9475	$H_0$ diterima

Berdasarkan hasil pada Tabel 3 dapat diketahui bahwa variabel  $X_1$ ,  $X_3$ ,  $X_4$ ,  $X_5$ ,  $X_7$ , dan  $X_8$  berhubungan dengan variabel respon (Y). Sehingga variabel-variabel prediktor (X) yang digunakan dalam proses klasifikasi adalah variabel kondisi IHSG, variabel kondisi *high price*, variabel kondisi *low price*, variabel kondisi *close price*, variabel posisi %K, dan variabel posisi %D.

## 4.3 Klasifikasi Naïve Bayes

Pada proses klasifikasi, pembagian 80% data *training* dan 20% data *testing* dilakukan dengan pengambilan menggunakan *simple random sampling*. Sebanyak 207 data digunakan sebagai data *training* dan 52 data digunakan sebagai data *testing*.

### 4.3.1 Menghitung Probabilitas Prior

Berdasarkan data *training* yang telah dibentuk, diperoleh probabilitas prior untuk masing-masing kelas adalah sebagai berikut:

$$P(Y = 0) = 0,4831 \text{ dan } P(Y = 1) = 0,5169$$

### 4.3.2 Menghitung Probabilitas Atribut Masing-masing Kelas

Probabilitas atribut untuk masing-masing kelas adalah:

a. Kelas sinyal palsu (0)

$$P(X_1 = 0|Y = 0) = 0,56, P(X_1 = 1|Y = 0) = 0,44$$

$$P(X_3 = 0|Y = 0) = 0,52, P(X_3 = 1|Y = 0) = 0,48$$

$$P(X_4 = 0|Y = 0) = 0,53, P(X_4 = 1|Y = 0) = 0,47$$

$$P(X_5 = 0|Y = 0) = 0,57, P(X_5 = 1|Y = 0) = 0,43$$

$$P(X_7 = 1|Y = 0) = 0,16, P(X_7 = 2|Y = 0) = 0,65, P(X_7 = 3|Y = 0) = 0,19$$

$$P(X_8 = 1|Y = 0) = 0,13, P(X_8 = 2|Y = 0) = 0,70, P(X_8 = 3|Y = 0) = 0,17$$

b. Kelas sinyal tidak palsu (1)

$$P(X_1 = 0|Y = 1) = 0,4206, P(X_1 = 1|Y = 1) = 0,5794$$

$$P(X_3 = 0|Y = 1) = 0,3458, P(X_3 = 1|Y = 1) = 0,6542$$

$$P(X_4 = 0|Y = 1) = 0,2804, P(X_4 = 1|Y = 1) = 0,7196$$

$$P(X_5 = 0|Y = 1) = 0,3178, P(X_5 = 1|Y = 1) = 0,6822$$

$$P(X_7 = 1|Y = 1) = 0,0561, P(X_7 = 2|Y = 1) = 0,5327,$$

$$P(X_7 = 3|Y = 1) = 0,4112$$

$$P(X_8 = 1|Y = 1) = 0,0654, P(X_8 = 2|Y = 1) = 0,5607$$

$$P(X_8 = 3|Y = 1) = 0,3738$$

### 4.3.3 Perkalian Probabilitas Prior dengan Probabilitas Atribut Masing-masing Kelas

Hasil probabilitas akhir diperoleh melalui perkalian antara probabilitas prior dan probabilitas atribut masing-masing kelas.

a. Kelas sinyal palsu (0)

Untuk data pertama, didapat nilai  $P(Y = 0|X) = 0,014587$

b. Kelas sinyal tidak palsu (1)

Untuk data pertama, didapat nilai  $P(Y = 1|X) = 0,004295$

Berdasarkan perhitungan diatas, disimpulkan bahwa data pertama masuk dalam kelas sinyal palsu (0).

### 4.3.4 Ketepatan Klasifikasi *Naïve Bayes*

Dengan cara yang sama untuk data selanjutnya, hasil prediksi kelas ditampilkan pada matriks konfusi sebagai berikut:

**Tabel 4.** Matriks Konfusi Klasifikasi *Naïve Bayes*

Prediksi	Observasi	
	Palsu	Tidak Palsu
Palsu	15	5
Tidak Palsu	7	25

Berdasarkan Tabel 4 disimpulkan bahwa klasifikasi sinyal palsu dengan metode *Naïve Bayes* memiliki nilai akurasi 76,92% dengan tingkat kesalahan 23,08%.

### 4.3.5 Menilai Keakuratan Prediksi Keanggotaan Kelas pada Metode *Naïve Bayes*

Hipotesis

$H_0$ : Pengklasifikasian dengan metode *Naïve Bayes* tidak akurat

$H_1$ : Pengklasifikasian dengan metode *Naïve Bayes* akurat

Taraf signifikansi  $\alpha = 5\%$

Statistik uji:

*Press's Q* = 15,07692

Karena nilai *Press's Q* (15,07692) >  $\chi_{0,05;1}^2$  (3,841) maka  $H_0$  ditolak sehingga dapat disimpulkan bahwa pengklasifikasian dengan metode *Naïve Bayes* akurat.

## 4.4 Bayesian Regularization Neural Network (BRNN)

Seperti pada klasifikasi *Naïve Bayes*, data penelitian dibagi ke dalam dua bagian, yaitu data *training* dan data *testing* dengan masing-masing proporsi 80% dan 20%. Sebanyak 207 data digunakan sebagai data *training* dan 52 data digunakan sebagai data *testing*.

### 4.4.1 Pembentukan Model Bayesian Regularization Neural Network (BRNN)

Pada penelitian ini, terdapat 6 *node* pada *input layer*, 3 *node* pada *hidden layer*, dan 1 *node* pada *output layer*. Titik konvergensi yang ditetapkan adalah  $change = 0,001$  dan  $epochs = 100$ .

Tahapan pembentukan model BRNN adalah sebagai berikut:

1. Inisialisasi bobot dan parameter

Faktor skala dengan metode Nguyen-Widrow yang digunakan untuk inisialisasi bobot dan bias adalah  $\delta = 0.8406559$ , sedangkan inisialisasi awal untuk parameter dalam fungsi objektif adalah  $\alpha = 0$  dan  $\beta = 1$ .

2. Melakukan iterasi untuk mencapai titik konvergensi

Proses iterasi berhenti pada *epochs* ke-22 dan diperoleh bobot jaringan serta bias pada arsitektur BRNN adalah:

- Untuk *hidden unit* yang pertama

$$w_1 = -0,36913419, b_1 = 0,03446399, \theta_1^{[1]} = -0,00894986, \\ \theta_2^{[1]} = 0,05237093, \theta_3^{[1]} = -0,13270532, \theta_4^{[1]} = -0,09280931, \\ \theta_5^{[1]} = -0,12266754, \theta_6^{[1]} = -0,09458335.$$

- Untuk *hidden unit* yang kedua

$$w_2 = -0,394343738, b_2 = 0,046146623, \theta_1^{[2]} = 0,006031686, \\ \theta_2^{[2]} = 0,017629922, \theta_3^{[2]} = -0,170635019, \theta_4^{[2]} = -0,158079410, \\ \theta_5^{[2]} = -0,103788963, \theta_6^{[2]} = -0,050041678.$$

- Untuk *hidden unit* yang ketiga

$$w_3 = 0.404781531, b_3 = -0,048983528, \theta_1^{[3]} = -0,010423588, \\ \theta_2^{[3]} = -0,003778552, \theta_3^{[3]} = 0,180541227, \theta_4^{[3]} = 0,179496469, \\ \theta_5^{[3]} = 0,098932045, \theta_6^{[3]} = 0,036230001.$$

Jumlah kuadrat dari semua bobot dan bias jaringan adalah  $E_w = 0,6581383$ . Berdasarkan hasil prediksi menggunakan model BRNN, jumlah kuadrat dari galat jaringan yaitu  $E_D = 45,29363$ .

Hasil pengolahan data menunjukkan bahwa jumlah parameter efektif  $\gamma = 5,904$ . Sehingga diperoleh:

$$\alpha = \frac{\gamma}{2E_w} 4,4854 \text{ dan } \beta = \frac{n-\gamma}{2E_D} = 2,2199$$

Oleh karena itu, pada *epochs* ke-22 nilai fungsi objektif yang didapat adalah  $F(\mathbf{w}) = 103,49930$ .

3. Menentukan output prediksi kelas

Pengkategorian hasil prediksi kelas menggunakan titik *cut off* yaitu 0,5. Hasil prediksi yang lebih kecil dari 0,5 akan masuk ke dalam kelas sinyal palsu (0), sedangkan hasil prediksi yang lebih besar atau sama dengan 0,5 akan masuk ke dalam kelas sinyal tidak palsu (1).

#### 4.4.2 Ketepatan Klasifikasi BRNN

Dengan cara yang sama untuk data selanjutnya, hasil prediksi kelas ditampilkan pada matriks konfusi sebagai berikut:

**Tabel 5.** Matriks Konfusi Klasifikasi dengan Metode BRNN

Prediksi	Observasi	
	Palsu	Tidak Palsu
Palsu	16	4
Tidak Palsu	6	26

Berdasarkan Tabel 5 disimpulkan bahwa klasifikasi sinyal palsu dengan metode BRNN memiliki nilai akurasi 80,77% dengan tingkat kesalahan 19,23%.

#### 4.4.3 Menilai Keakuratan Prediksi Keanggotaan Kelas pada Metode BRNN

Hipotesis

$H_0$ : Pengklasifikasian dengan metode BRNN tidak akurat

$H_1$ : Pengklasifikasian dengan metode BRNN akurat

Taraf signifikansi  $\alpha = 5\%$

Statistik uji:

*Press's Q* = 19,69231

Karena nilai *Press's Q* (19,69231) >  $\chi_{0.05;1}^2$  (3,841) maka  $H_0$  ditolak sehingga dapat disimpulkan bahwa pengklasifikasian dengan metode BRNN akurat.

#### 4.5 Perbandingan Ketepatan Klasifikasi *Naïve Bayes* dan *Bayesian Regularization Neural Network* (BRNN)

Karena nilai akurasi yang dihasilkan dari metode BRNN lebih besar dibandingkan dengan metode *Naïve Bayes* dan tingkat kesalahan (APER) metode BRNN lebih kecil dibandingkan dengan metode *Naïve Bayes*, maka dapat disimpulkan bahwa klasifikasi sinyal palsu yang keluar dari indikator *Stochastic Oscillator* pada saham harian PT Bank Rakyat Indonesia (Persero) Tbk (BBRI) periode Januari 2017 hingga Agustus 2019 lebih baik menggunakan metode *Bayesian Regularization Neural Network* (BRNN).

#### 4.6 Penerapan Metode *Naïve Bayes* dan *Bayesian Regularization Neural Network* (BRNN) untuk Data Baru

Set data baru yang digunakan adalah sinyal yang keluar dari indikator *stochastic oscillator* pada bulan September 2019. Deteksi atau klasifikasi untuk set data baru dengan metode *Naïve Bayes* dan BRNN menunjukkan hasil yang sama, yaitu:

**Tabel 6.** Hasil Klasifikasi Set Data Baru

No.	Tanggal	X1	X3	X4	X5	X7	X8	Kelas
1	03/09/2019	0	0	0	0	2	2	0
2	06/09/2019	1	1	1	1	3	2	1
3	10/09/2019	1	0	0	1	2	2	0
4	12/09/2019	0	1	1	1	2	2	1
5	17/09/2019	1	0	1	1	2	2	1
6	19/09/2019	0	0	0	0	2	2	0
7	20/09/2019	0	0	0	0	2	2	0
8	26/09/2019	1	1	1	1	2	2	1

Dimana kelas 0 berarti sinyal palsu dan kelas 1 berarti sinyal tidak palsu.

## 5. KESIMPULAN

Berdasarkan analisis yang telah dilakukan, diperoleh kesimpulan bahwa terdapat 6 variabel prediktor yang memiliki asosiasi terhadap variabel respon, yaitu variabel kondisi IHSG ( $X_1$ ), variabel kondisi *high price* ( $X_3$ ), variabel kondisi *low price* ( $X_4$ ), variabel kondisi *close price* ( $X_5$ ), variabel posisi %D ( $X_7$ ), dan variabel posisi %K ( $X_8$ ).

Berdasarkan hasil ketepatan klasifikasi, metode *Bayesian Regularization Neural Network* (BRNN) lebih baik diterapkan untuk klasifikasi sinyal palsu yang keluar dari indikator *Stochastic Oscillator* pada saham harian PT Bank Rakyat Indonesia (Persero) Tbk (BBRI) periode Januari 2017 hingga Agustus 2019 dibandingkan dengan metode *Naïve Bayes*. Hal ini didukung karena *Bayesian Regularization Neural Network* (BRNN) memiliki karakteristik yang adaptif yaitu belajar dari data *training* dan mengenal pola yang

selalu berubah tanpa harus memperhatikan data target yang ada. Sedangkan data target pada metode *Naive Bayes* dan hasil probabilitas dari data *input* sangat berpengaruh terhadap hasil *output*. Semakin besar nilai probabilitas dari data *input* yang dimasukkan maka hasil *output* cenderung semakin tidak konsisten.

Pada proses klasifikasi sinyal palsu, pengambilan sampel untuk pembagian data *training* dan data *testing* memberikan hasil yang berbeda setiap penyampelan, namun secara umum metode *Bayesian Regularization Neural Network* (BRNN) menunjukkan hasil yang lebih baik dibandingkan dengan metode *Naive Bayes*.

## DAFTAR PUSTAKA

- Hair, J. F., Black, W. C., Babin, B. J., dan Anderson, R. E. 2006. *Multivariate Data Analysis*. Seventh Edition. New Jersey: Prentice Hall.
- Halim, A. 2015. *Analisis Investasi di Aset Keuangan*. Jakarta: Mitra Wacana Media.
- Han, J., Kamber, M., dan Pei, J. 2012. *Data Mining: Concept and Techniques*. Third Edition. Waltham: Morgan Kaufmann Publishers.
- Investor Saham Pemula (ISP). 2017. *#YukBelajarSaham untuk Pemula*. Jakarta: PT Elex Media Komputindo.
- Pan, X., Lee, B., dan Zheng, C. 2013. A Comparison of Neural Network Backpropagation Algorithm for Electricity Load Forecasting. *Proceeding: IEEE International Workshop on Intelligent Energy System (IWIES)*, Hal. 22-27.
- Perez-Rodriguez, P., Gianola, D., Weigel, K. A., Rosa, G. J. M., dan Crossa, J. 2013. Technical Note: An R Package for Fitting Bayesian Regularized Neural Networks with Application in Animal Breeding. *Journal of Animal Science* Vol. 88, No. 2: Hal. 497 – 504.
- Prasetyo, E. 2012. *DATA MINING Konsep dan Aplikasi Menggunakan MATLAB*. Yogyakarta: ANDI Yogyakarta.
- Siang, J. 2005. *Jaringan Syaraf Tiruan dan Pemrogramannya Menggunakan MATLAB*. Yogyakarta: ANDI Yogyakarta.
- Suyanto. 2019. *DATA MINING UNTUK KLASIFIKASI DAN KLASTERISASI DATA*. Edisi Revisi. Bandung: INFORMATIKA.
- Yue, Z., Songzheng, Z., dan Tianshi, T. 2011. Bayesian Regularization BP Neural Network Model for Predicting Oil-Gas Drilling Cost. *Proceeding: International Conference on Business Management and Electronic Information (BMEI)*, Hal. 483-487.
- Zaki, M. J. dan Meira, M. J. 2013. *Data Mining and Analysis : Fundamental Concepts and Algorithms*. Cambridge: Cambridge University Press.