



BACKPROPAGATION NEURAL NETWORK PADA DATA YANG TAK STASIONER (STUDI KASUS : JUMLAH PENDERITA PENYAKIT EBOLA)

DINITA RAHMALIA^{1*}, M. SYAIFUL PRADANA²

^{1,2}Program Studi Matematika, Universitas Islam Darul Ulum Lamongan

*dinitarahmalia@gmail.com

ABSTRAK

Ebola adalah penyakit yang disebabkan oleh virus ebola. Karena banyaknya penderita penyakit ebola, diperlukan suatu metode peramalan jumlah penderita penyakit ebola. Pada penelitian ini akan digunakan metode Neural Network (NN) pada data jumlah penderita penyakit ebola yang tak stasioner. Cara kerja NN mirip dengan sistem syaraf manusia. Salah satu jenis NN yang digunakan untuk masalah peramalan adalah Backpropagation dimana model Backpropagation adalah terdapat *hidden layer* di antara input dan output. Pada penelitian ini akan dilakukan dua simulasi Backpropagation berdasarkan pengambilan posisi data testing. Simulasi pertama adalah simulasi Backpropagation dengan posisi data testing berada di waktu akhir. Simulasi kedua adalah simulasi Backpropagation dengan posisi data testing berada di waktu tersebar. Pengambilan posisi data testing di waktu akhir memberikan hasil peramalan pada data training yang lebih bagus daripada pengambilan posisi data testing di waktu tersebar. Pengambilan posisi data testing di waktu tersebar memberikan hasil peramalan pada data testing yang lebih bagus daripada pengambilan posisi data testing di waktu akhir.

Kata Kunci: Neural Network, Backpropagation, Time Series, Data tak Stasioner

Ebola is a disease caused by the Ebola virus. Because of the large number of people with Ebola, a method for forecasting the number of people with Ebola is needed. In this study, the Neural Network (NN) method will be used in the data of people with Ebola who are not stationary. The mechanism of NN is similar to the human nervous system. One type of NN used for forecasting problems is Backpropagation where a hidden layer between input and output is found. In this study two Backpropagation simulations will be conducted based on the position taking of data testing. The first simulation is a Backpropagation simulation with the position of data testing at the final time. The second simulation is a Backpropagation simulation with the position of data testing at the time of spread. Taking the position of data testing at the final time gives forecasting results on training data that are better than taking the position of testing data at the time of spread. Taking the position of data testing at spread time gives forecasting results on testing data that are better than taking the position of testing data at the end time.

Keywords: Neural network, backpropagation, time series, nonstationary data

1 Pendahuluan

Di tengah perkembangan zaman yang pesat, telah banyak berbagai macam penyakit yang telah muncul, salah satunya adalah ebola. Ebola adalah penyakit yang disebabkan oleh virus ebola. Virus ebola pertama kali muncul pada tahun 1976 di Sudan dan Republic Congo.

Pada tahun 2014 wabah ebola terbesar muncul di Afrika Barat dimulai dari Guinea dan menjadi perhatian dunia. Menurut data WHO, hingga 18 November 2015 telah terjadi 28598 kasus dengan 11299 dinyatakan meninggal. Sampai saat ini masih belum ada vaksin atau pengobatan khusus untuk korban penyakit ebola. Karena banyaknya penderita penyakit ebola, diperlukan suatu metode peramalan jumlah penderita penyakit ebola.

Ada beberapa metode yang dapat digunakan untuk peramalan, yaitu : *exponential smoothing*, yaitu peramalan yang ditentukan oleh nilai data aktual, hasil peramalan sebelumnya, nilai parameter yang digunakan [1], *kalman filter*, yaitu peramalan yang ditentukan oleh estimasi dan kovarians *error* dari tahap prediksi dan tahap koreksi [2],[3], *autoregressive integrated moving average (ARIMA)*, yaitu peramalan yang ditentukan oleh nilai signifikansi dari autokorelasi (ACF), partial autokorelasi (PACF) pada data [4],[5], dan *fuzzy logic*, yaitu peramalan yang menggunakan fungsi keanggotaan dan beberapa aturan (*rules*) dalam pengambilan kesimpulan [6],[7]. Pada penelitian ini akan digunakan metode *Neural Network (NN)* pada data jumlah penderita penyakit ebola. NN diperkenalkan oleh Mc Culloch dan Pitts pada tahun 1943. Cara kerja NN mirip dengan sistem syaraf manusia. Salah satu jenis NN yang digunakan untuk masalah peramalan adalah Backpropagation dimana model Backpropagation adalah terdapat *hidden layer* di antara input dan output [8],[9].

Pada penelitian sebelumnya, peramalan menggunakan Backpropagation telah digunakan pada data yang stasioner [10],[11]. Data yang stasioner adalah data yang sifatnya tidak dipengaruhi oleh waktu dan tidak menunjukkan adanya trend sedangkan data yang tidak stasioner menunjukkan adanya trend [5]. Karena grafik jumlah penderita penyakit ebola tidak stasioner, maka pada penelitian ini akan digunakan data yang tak stasioner. Peramalan menggunakan Backpropagation pada data tak stasioner hampir mirip bila dibandingkan dengan data stasioner namun ditentukan oleh bentuk partisi antara data training dan data testing. Pada [12], pengambilan posisi data training sebanyak 80% dari dataset sedangkan sisanya 20% dari dataset digunakan sebagai data testing. Pada [9], pengambilan posisi data training adalah data dengan nomor ganjil dan posisi data testing adalah data dengan nomor genap, sehingga terdapat kemiripan antara bentuk pola pada data training dan data testing.

Pada penelitian ini akan dilakukan dua simulasi Backpropagation berdasarkan pengambilan posisi data testing. Simulasi pertama adalah simulasi Backpropagation dengan posisi data testing berada di waktu akhir. Simulasi kedua adalah simulasi Backpropagation dengan posisi data testing berada di waktu tersebar. Dari data yang digunakan, akan ditentukan input dan output, kemudian dihitung nilai korelasi antara input dan output [12]. Setelah itu untuk mendapatkan hasil peramalan, digunakan algoritma Backpropagation. Sebelum Backpropagation dilakukan, partisi data ke dalam data training dan data testing [9]. Dari hasil simulasi Backpropagation, diperoleh nilai *Mean Square Error (MSE)* yang konvergen mendekati nilai minimum.

2 Tinjauan Pustaka

2.1 Neural Network

Neural Network (NN) diperkenalkan oleh Mc Culloch dan Pitts pada tahun 1943. Cara kerja neural network mirip dengan sistem syaraf manusia yaitu :

1. Sinyal dikirim di antara neuron melalui penghubung.
2. Penghubung antar neuron memiliki bobot yang akan memperkuat atau memperlemah sinyal.
3. Untuk menentukan keluaran, setiap neuron menggunakan fungsi aktivasi yang dikenakan pada jumlah masukan yang diterima.

Dalam NN, fungsi aktivasi dipakai untuk menentukan keluaran suatu neuron. Argumen fungsi aktivasi adalah kombinasi linier antara masukan x_i dengan bobot w_i

$$net = \sum_i x_i w_i \quad (1)$$

$$f(net) = f\left(\sum_i x_i w_i\right) \quad (2)$$

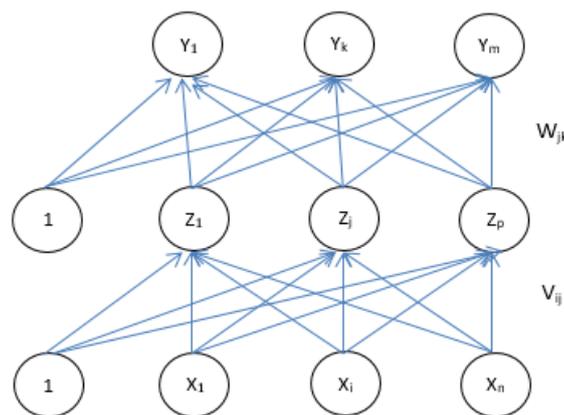
Pada umumnya, sifat fungsi aktivasi adalah : kontinu, terdiferensial, dan tidak turun. Pada penelitian ini, karena nilai target adalah data kuantitatif dan numerik, maka fungsi aktivasi yang dipakai adalah sigmoid biner dengan range (0-1) [9].

$$f(net) = \frac{1}{1 + e^{-net}} \quad (3)$$

$$f'(net) = f(net)(1 - f(net)) \quad (4)$$

2.2 Backpropagation

Backpropagation adalah salah satu jenis NN yang sering digunakan dalam proses prediksi. Algoritma Backpropagation terdiri dari beberapa unit input x_1, x_2, \dots, x_n , beberapa unit *hidden layer* z_1, z_2, \dots, z_p , dan beberapa unit output y_1, y_2, \dots, y_m . Dalam unit input dan *hidden layer* terdapat bias yang bernilai 1. Bobot v_{ij} menghubungkan unit input x_i menuju unit *hidden layer* z_j . Bobot w_{jk} menghubungkan unit *hidden layer* z_j menuju unit output y_k . Dalam algoritma Backpropagation, terdapat tiga fase perhitungan yaitu : propagasi maju, propagasi mundur, dan update matriks bobot. Model Backpropagation dapat dilihat pada Gambar 1.



Gambar 1: Model Backpropagation

Pada propagasi maju, perhitungan menggunakan fungsi aktivasi dilakukan mulai dari input, *hidden layer*, dan output secara berurutan. Pada propagasi mundur, perhitungan faktor kesalahan dilakukan mulai dari output, *hidden layer*, dan input secara berurutan. Setelah itu, dilakukan perubahan nilai pada matriks bobot [8].

Algoritma Backpropagation menggunakan satu *hidden layer* dapat dinyatakan sebagai berikut :

bppgt(V, W)

1. Inisialisasi matrik bobot V dan W dengan bilangan acak kecil antara -0,5 sampai 0,5.
 $e = 1$

while($e \leq \max \text{epoch} \ \&\& \text{MSE} \geq \min \text{MSE}$)

for($d = 1 : \text{datasize}$)

2. Tiap unit input menerima sinyal dan meneruskan ke unit *hidden layer*.

Propagasi Maju

3. Hitung semua keluaran di unit *hidden layer* $z_j, j = 1, 2, \dots, p$

$$z_net_j = v_{oj} + \sum_{i=1}^n x_i v_{ij} \quad (5)$$

$$z_j = f(z_net_j) = \frac{1}{1 + e^{-z_net_j}} \quad (6)$$

4. Hitung semua keluaran di unit output $y_k, k = 1, 2, \dots, m$

$$y_net_k = w_{ok} + \sum_{j=1}^p z_j w_{jk} \quad (7)$$

$$y_k = f(y_net_k) = \frac{1}{1 + e^{-y_net_k}} \quad (8)$$

Propagasi Mundur

5. Hitung faktor δ unit output berdasarkan kesalahan di setiap unit output $y_k, k = 1, 2, \dots, m$

$$\delta_k = (t_k - y_k) f'(y_net_k) \quad (9)$$

6. Hitung perubahan bobot

$$\Delta w_{jk} = \alpha \delta_k z_j, \quad k = 1, 2, \dots, m \quad j = 0, 1, 2, \dots, p \quad (10)$$

7. Hitung faktor δ unit *hidden layer* berdasarkan kesalahan di setiap unit *hidden layer* $z_j, j = 1, 2, \dots, p$

$$\delta_net_j = \sum_{k=1}^m \delta_k w_{jk} \quad (11)$$

$$\delta_j = \delta_net_j f'(z_net_j) \quad (12)$$

8. Hitung perubahan bobot

$$\Delta v_{ij} = \alpha \delta_j x_i, \quad j = 1, 2, \dots, p \quad i = 0, 1, 2, \dots, n \quad (13)$$

Update Matriks Bobot

9. Hitung matriks bobot yang baru

$$w_{jk} = w_{jk} + \Delta w_{jk} \quad (14)$$

$$v_{ij} = v_{ij} + \Delta v_{ij} \quad (15)$$

end

10. Hitung nilai *Mean Square Error* (MSE)

$$MSE = \frac{1}{datasize} \sum_{d=1}^{datasize} \frac{1}{m} \sum_{k=1}^m (T_{dk} - Y_{dk})^2 \quad (16)$$

dengan T_{dk} adalah nilai target dan Y_{dk} adalah hasil keluaran di unit output.

$e = e + 1$

end

2.3 Korelasi Data

Korelasi adalah hubungan linear antara dua variabel $a_i, i=1,2,\dots,n$ dan $b_i, i=1,2,\dots,n$. Koefisien korelasi dapat dihitung menggunakan persamaan (17). Nilai dari koefisien korelasi berkisar antara $-1 \leq r \leq 1$. Jika korelasi bernilai +1, maka hubungan dua variabel sempurna bernilai positif. Jika korelasi bernilai -1, maka hubungan dua variabel sempurna bernilai negatif. Jika korelasi bernilai 0, maka tidak ada hubungan dua variabel. Jadi korelasi yang kuat bernilai mendekati +1 atau mendekati -1 [5],[13].

$$r_{ab} = \frac{S_{ab}}{\sqrt{S_{aa}S_{bb}}} \quad (17)$$

Dengan :

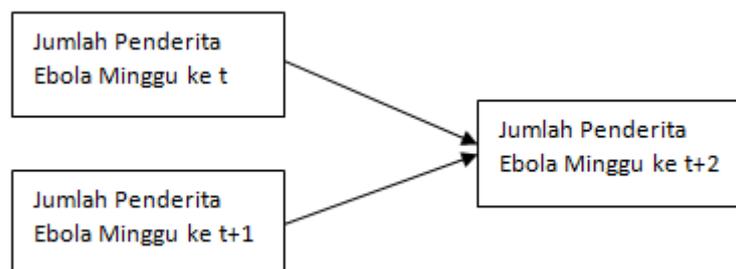
$$S_{ab} = \frac{1}{n-1} \sum_{i=1}^n (a_i - \bar{a})(b_i - \bar{b}) \quad (18)$$

$$S_{aa} = \frac{1}{n-1} \sum_{i=1}^n (a_i - \bar{a})^2 \quad (19)$$

$$S_{bb} = \frac{1}{n-1} \sum_{i=1}^n (b_i - \bar{b})^2 \quad (20)$$

3 Metodologi

Persiapan Data : Dari data jumlah penderita penyakit ebola yang diperoleh, tentukan input dan output menggunakan korelasi. Berdasarkan hasil korelasi, jumlah penderita penyakit ebola pada minggu ke t+2 dipengaruhi oleh jumlah penderita penyakit ebola pada minggu ke t dan jumlah penderita penyakit ebola pada minggu ke t+1, maka input yaitu : jumlah penderita penyakit ebola pada minggu ke t dan jumlah penderita penyakit ebola pada minggu ke t+1 serta output yaitu jumlah penderita penyakit ebola pada minggu ke t+2.



Gambar 2: Input dan Output yang Digunakan

Pada penelitian ini partisi data yang akan digunakan untuk data training sebesar 80% dari seluruh data dan data testing sebesar 20% dari seluruh data. Dua simulasi Backpropagation akan dilakukan berdasarkan pengambilan posisi data testing. Simulasi pertama adalah simulasi Backpropagation dengan posisi data testing berada di waktu akhir. Simulasi kedua adalah simulasi Backpropagation dengan posisi data testing berada di waktu tersebar.

Transformasi Input dan Output ke dalam Range [0.1-0.9] : Fungsi aktivasi yang digunakan dalam proses prediksi adalah fungsi sigmoid biner yang memiliki nilai minimum 0 dan maksimum 1. Namun karena fungsi sigmoid biner tidak pernah menyentuh nilai 0 maupun 1, maka input dan output harus ditransformasikan ke dalam range [0.1-0.9] sebelum proses training dimulai.

Inisialisasi Matriks Bobot : Sebelum proses training dimulai, tentukan matriks bobot awal yang menghubungkan input, *hidden layer* dan output dengan bilangan acak kecil antara -0,5 sampai 0,5.

Proses Training : Proses training menggunakan data training sebesar 80% dari data keseluruhan. Aturan pemberhentian dalam proses training dapat berupa maksimum epoch atau nilai MSE terkecil telah dicapai.

Matriks Bobot Baru : Proses training pada data training menghasilkan nilai matriks bobot yang baru. Matriks bobot inilah yang akan digunakan pada proses training data testing.

Proses Testing : Proses training menggunakan data testing yang telah ditentukan sebelumnya. Aturan pemberhentian adalah 1 epoch untuk menghitung nilai MSE. Nilai MSE adalah nilai rata-rata dari kuadrat selisih nilai target dengan nilai prediksi. Nilai MSE dapat dihitung dari persamaan (16).

De-normalisasi Data : Setelah nilai MSE terkecil tercapai, lakukan de-normalisasi pada data testing untuk mengembalikan data ke dalam bentuk asalnya sehingga dapat diinterpretasikan.

4 Hasil Simulasi

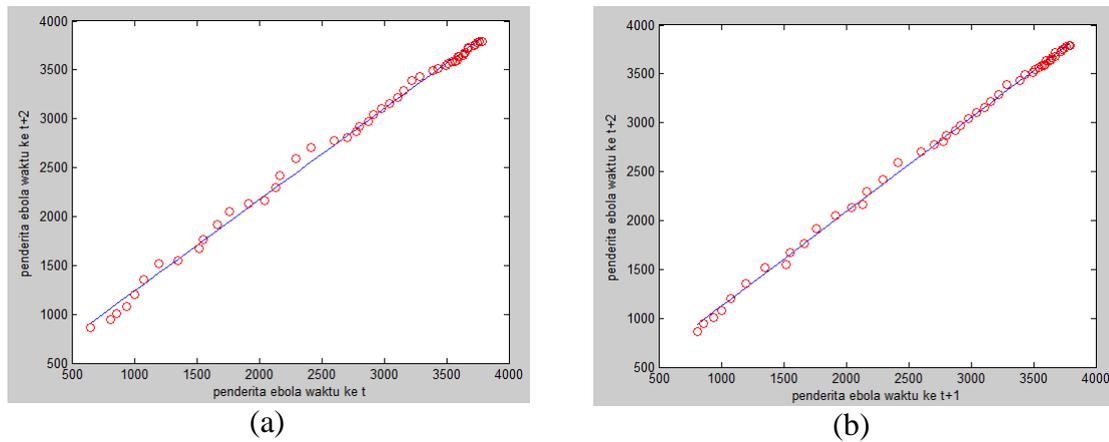
Data yang digunakan dalam penelitian ini adalah data penderita penyakit ebola di Guinea dari minggu ke 35 pada tahun 2014 sampai dengan minggu ke 33 pada tahun 2015 sehingga data yang diperoleh adalah 53 minggu. Dua simulasi Backpropagation akan dilakukan berdasarkan pengambilan posisi data testing. Simulasi pertama adalah simulasi Backpropagation dengan posisi data testing berada di waktu akhir. Simulasi kedua adalah simulasi Backpropagation dengan posisi data testing berada di waktu tersebar. Kedua simulasi menggunakan parameter Backpropagation sebagai berikut :

Learning rate α : 0,2
 Jumlah *hidden layer* : 2
 Maksimum epoch : 1000

4.1 Korelasi Data Penderita Penyakit Ebola

Hasil korelasi data pada penderita penyakit ebola dapat dilihat pada Gambar 3(a) dan Gambar 3(b). Gambar 3(a) adalah korelasi jumlah penderita penyakit ebola pada minggu ke t terhadap jumlah penderita penyakit ebola pada minggu ke $t+2$. Nilai korelasi dihitung berdasarkan persamaan (17) sehingga diperoleh korelasi antara jumlah penderita penyakit ebola pada minggu ke t terhadap jumlah penderita penyakit ebola pada minggu ke $t+2$ adalah 0,998. Gambar 3(b) adalah korelasi jumlah penderita penyakit ebola pada minggu ke $t+1$ terhadap jumlah penderita penyakit ebola pada minggu ke $t+2$. Nilai korelasi dihitung berdasarkan persamaan (17) sehingga diperoleh korelasi antara jumlah penderita penyakit

ebola pada minggu ke $t+1$ terhadap jumlah penderita penyakit ebola pada minggu ke $t+2$ adalah 0,999.

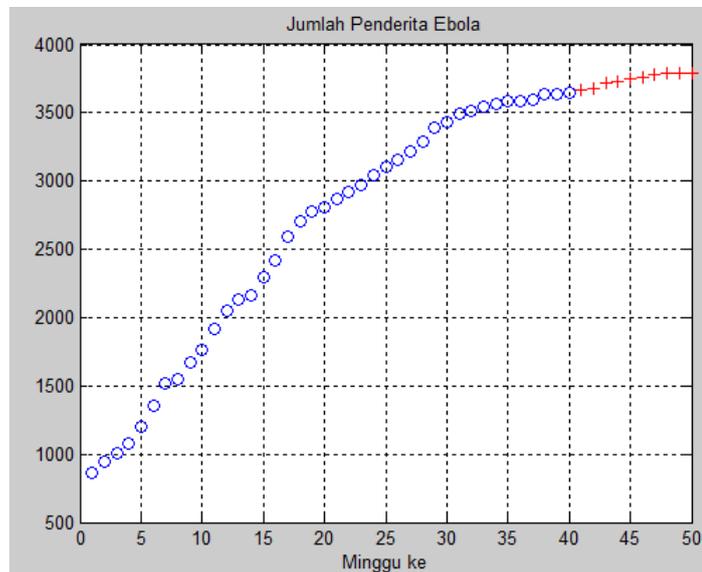


Gambar 3: Korelasi Data pada Penderita Penyakit Ebola

4.2 Simulasi Backpropagation dengan Posisi Data Testing di Waktu Akhir

Berdasarkan hasil korelasi data, jumlah penderita penyakit ebola pada minggu ke $t+2$ dipengaruhi oleh jumlah penderita penyakit ebola pada minggu ke t dan pada minggu ke $t+1$.

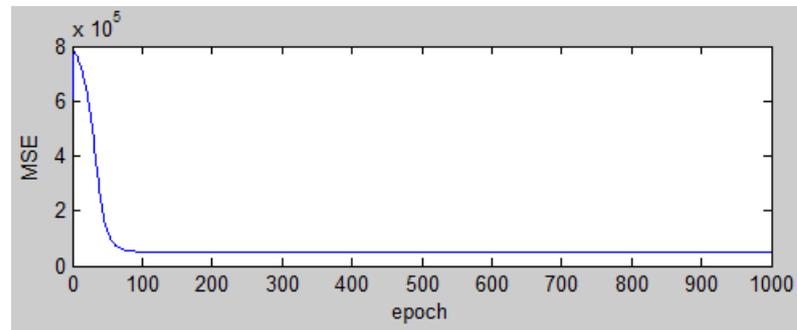
Sebelum algoritma Backpropagation diterapkan, terlebih dahulu partisi data menjadi data training sebanyak 80% dari jumlah data dan data testing sebanyak 20% dari jumlah data. Pada bagian ini, data training adalah data minggu ke 1 sampai minggu ke 40 sedangkan data testing adalah minggu ke 41 sampai minggu ke 50. Gambar 4 adalah grafik jumlah penderita penyakit ebola selama 50 minggu beserta bentuk partisi data training dan data testing.



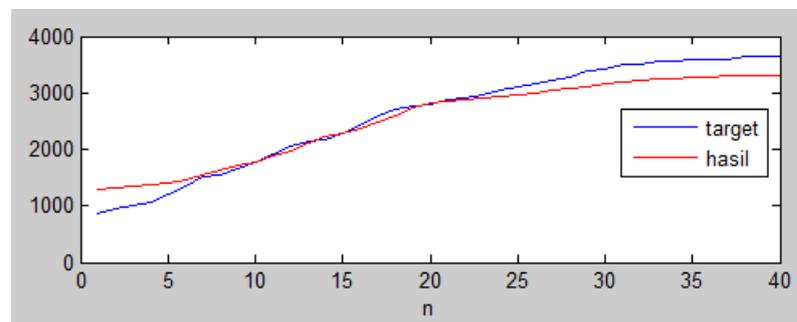
Gambar 4: Partisi data pada penderita penyakit ebola. Warna biru 'o' menyatakan data training dan warna merah '+' adalah data testing.

Gambar 5 adalah proses konvergensi pada data training sebanyak 1000 epoch dan diperoleh nilai MSE sebesar $4,75 \times 10^4$. Gambar 6 adalah hasil perbandingan antara nilai target dengan hasil perhitungan pada data training. Setelah proses training dilakukan, diperoleh bobot optimal yang akan digunakan pada data testing. Gambar 7 adalah hasil perbandingan antara nilai target dengan hasil perhitungan pada data testing. Pada data testing,

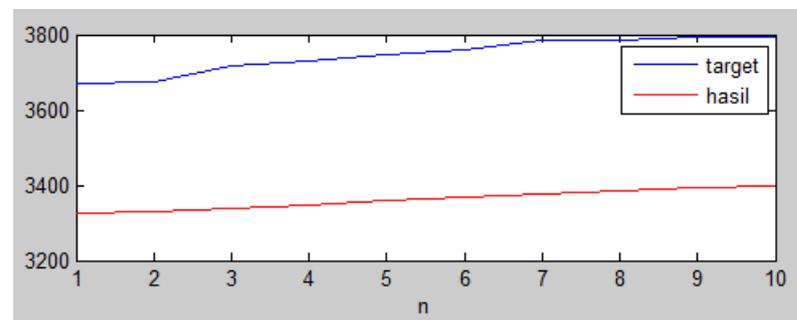
diperoleh MSE sebesar $1,4777 \times 10^5$. Pada hasil simulasi pada data testing terlihat bahwa hasil perhitungan belum dapat meramalkan dengan baik pada nilai target.



Gambar 5: Proses Konvergensi pada Data Training



Gambar 6: Perbandingan Nilai Target dan Hasil Perhitungan pada Data Training



Gambar 7: Perbandingan Nilai Target dan Hasil Perhitungan pada Data Testing

Simulasi juga dilakukan pada sepuluh percobaan dengan hasil seperti pada Tabel 1 :

Tabel 1: Nilai MSE pada simulasi Backpropagation dengan posisi data testing di waktu akhir

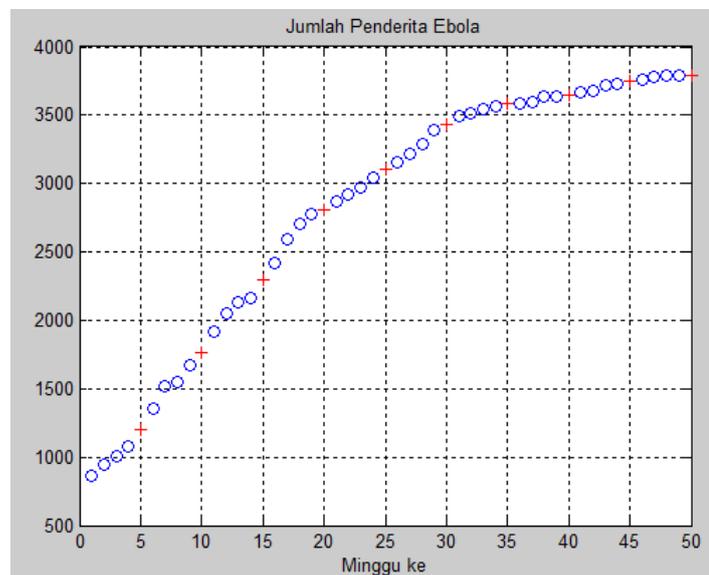
No	MSE Data Training ($\times 10^4$)	MSE Data Testing ($\times 10^5$)
1	4,9316	1,4767
2	4,7500	1,4777
3	4,8423	1,5167
4	4,9852	1,6146
5	4,9671	1,5513
6	4,8950	1,5888
7	4,8570	1,4992
8	4,6881	1,5187
9	4,8240	1,5496

10	4,6784	1,4542
----	--------	--------

4.3 Simulasi Backpropagation dengan Posisi Data Testing di Waktu Tesebar

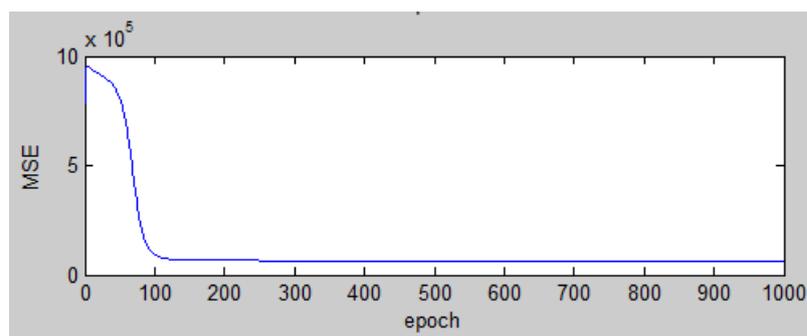
Berdasarkan hasil korelasi data, jumlah penderita penyakit ebola pada minggu ke $t+2$ dipengaruhi oleh jumlah penderita penyakit ebola pada minggu ke t dan pada minggu ke $t+1$.

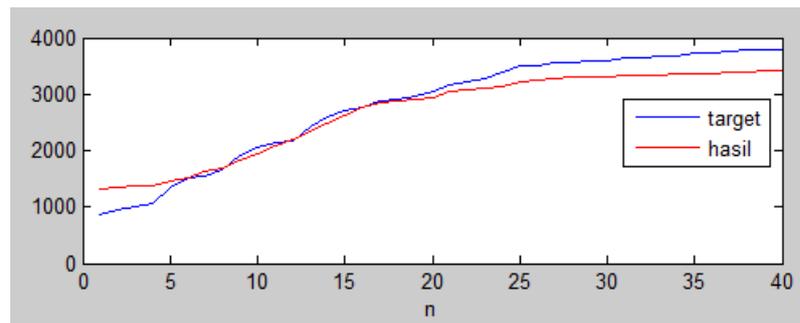
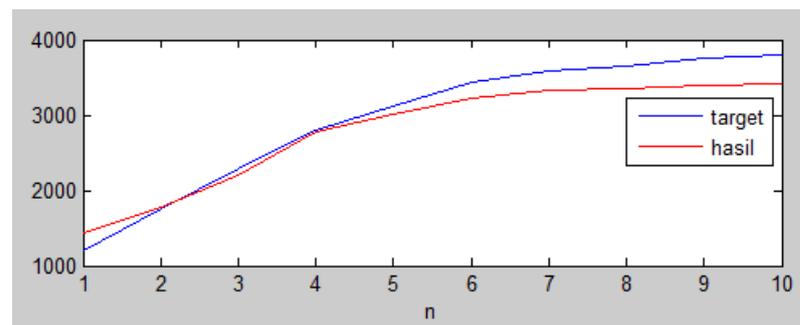
Sebelum algoritma Backpropagation diterapkan, terlebih dahulu partisi data menjadi data training sebanyak 80% dari jumlah data dan data testing sebanyak 20% dari jumlah data. Pada bagian ini, data training adalah data minggu yang bukan kelipatan lima sedangkan data testing adalah minggu dengan kelipatan lima seperti minggu ke 5, 10, 15, ..., 50. Gambar 8 adalah grafik jumlah penderita penyakit ebola selama 50 minggu beserta bentuk partisi data training dan data testing.



Gambar 8: Partisi data pada penderita penyakit ebola. Warna biru 'o' menyatakan data training dan warna merah '+' adalah data testing.

Gambar 9 adalah proses konvergensi pada data training sebanyak 1000 epoch dan diperoleh nilai MSE sebesar $6,1923 \times 10^4$. Gambar 10 adalah hasil perbandingan antara nilai target dengan hasil perhitungan pada data training. Setelah proses training dilakukan, diperoleh bobot optimal yang akan digunakan pada data testing. Gambar 11 adalah hasil perbandingan antara nilai target dengan hasil perhitungan pada data testing. Pada data testing, diperoleh MSE sebesar $5,3678 \times 10^4$. Pada hasil simulasi pada data testing terlihat bahwa hasil perhitungan cukup dapat meramalkan dengan baik pada nilai target.



Gambar 9: Proses Konvergensi pada Data Training**Gambar 10:** Perbandingan Nilai Target dan Hasil Perhitungan pada Data Training**Gambar 11:** Perbandingan Nilai Target dan Hasil Perhitungan pada Data Testing

Simulasi juga dilakukan pada sepuluh percobaan dengan hasil seperti pada Tabel 2 :

Tabel 2: Nilai MSE pada simulasi Backpropagation dengan posisi data testing di waktu tersebar

No	MSE Data Training ($\times 10^4$)	MSE Data Testing ($\times 10^4$)
1	5,9962	5,3962
2	6,1673	5,4487
3	6,0342	5,3476
4	6,3328	5,6375
5	6,1155	5,4672
6	6,0264	5,4042
7	6,0441	5,5424
8	6,0887	5,5417
9	6,2734	5,6700
10	6,2571	5,5482

5 Kesimpulan

Backpropagation merupakan salah satu jenis NN yang dapat digunakan dalam proses peramalan. Cara kerja Backpropagation menyerupai sistem syaraf manusia dimana pada model Backpropagation terdapat *hidden layer* di antara input dan output. Pada data tak stationer, posisi pengambilan data testing memberikan pengaruh pada hasil peramalan yang ditandai dengan nilai MSE. Simulasi juga dilakukan pada sepuluh percobaan. Pengambilan posisi data testing di waktu akhir memberikan hasil peramalan pada data training yang lebih bagus daripada pengambilan posisi data testing di waktu tersebar. Pengambilan posisi data testing di waktu tersebar memberikan hasil peramalan pada data testing yang lebih bagus daripada pengambilan posisi data testing di waktu akhir. Manfaat dari penelitian ini adalah

untuk memberikan informasi hasil peramalan berdasarkan posisi pengambilan data testing jika data yang digunakan tak stasioner.

Daftar Pustaka

- [1] D. Rahmalia, 'Estimation of Exponential Smoothing Parameter on Pesticide Characteristic Forecast using Ant Colony Optimization (ACO)', *Eksakta : Jurnal Ilmu-ilmu MIPA*, vol. 18, no. 1 pp. 56–63, 2018.
- [2] T. Herlambang, Z. Mufarrikhoh, D.F. Karya and D. Rahmalia, 'Estimation of Water Level and Steam Temperature Using Ensemble Kalman Filter Square Root (EnKF-SR)', *Journal of Physics : Conference Series*, vol. 1008, no. 1, 2018.
- [3] T. Herlambang, R.A. Rasyid, S. Hartatik and D. Rahmalia, 'Estimasi Posisi Mobile Robot Menggunakan Akar Kuadrat Unscented Kalman Filter (AK-UKF)', *Technology Science and Engineering Journal*, vol. 1, no. 2, 2017.
- [4] N.E. Chandra, S. Sarinem, 'Peramalan Penyebaran Jumlah Kasus Virus Ebola di Guinea dengan Metode Arima', *Unisda Journal of Mathematics and Computer Science (UJMC)*, vol. 2, no. 1 pp. 28-35, 2016.
- [5] D.C. Montgomery, C.L. Jennings and M. Kulahci, *Introduction to Time Series Analysis and Forecasting*. New Jersey : John Wiley and Sons
- [6] D. Rahmalia, T. Herlambang, 'Application Kohonen Network and Fuzzy C Means for Clustering Airports Based on Frequency of Flight', *Kinetik : Game Technology, Information System, Computer Network, Computing*, vol. 3, no. 3 pp. 229-236, 2018.
- [7] L.A. Matarneh, A. Sheta, S. Bani-Ahmad and J. Alshaer, 'Development of Temperature-based Weather Forecasting Models Using Neural Network and Fuzzy Logic', *International Journal of Multimedia and Obiquitous Engineering*, vol. 9, no. 12, pp. 343-366, 2014.
- [8] L. Fausett, *Fundamentals of Neural Networks*, USA: Prentice Hall, 1994.
- [9] J.J. Siang, *Jaringan Syaraf Tiruan dan Pemrogramannya Menggunakan Matlab*, Yogyakarta : Penerbit ANDI, 2009.
- [10] D. Rahmalia, N. Aini, 'Pengaruh Korelasi Data pada Peramalan Suhu Udara Menggunakan Backpropagation Neural Network', *Zeta-Math Journal*, vol. 4, no. 1 pp. 1-6, 2018.
- [11] D. Rahmalia, T. Herlambang, 'Prediksi Cuaca Menggunakan Algoritma Particle Swarm Optimization-Neural Network (PSO-NN)', *Prosiding Seminar Nasional Matematika dan Aplikasinya*, pp. 41-48, 2017.
- [12] J. Han, M. Kamber and J. Pei, *Data Mining Concepts and Techniques*, USA : Elsevier, 2012.
- [13] R.E. Walpole, R.H. Myers and S.L. Myers, *Probability & Statistics for Engineers & Scientists*. USA : Prentice Hall, 2012.