

PERAMALAN PERSEDIAAN DARAH JENIS *WHOLE BLOOD* (WB) DI PMI KOTA SURABAYA DENGAN *NEURAL NETWORK*

Teguh Herlambang^{1*}, Ahmad Syafiq Kamil², Azmi Khulama Devi³
Program Studi Sistem Informasi Universitas Nahdlatul Ulama Surabaya^{1,2,3}
Unusa Kampus B Jalan Jemursari 51-57 Surabaya, Indonesia
teguh@unusa.ac.id*

Abstrak– Palang Merah Indonesia (PMI) adalah lembaga yang mendistribusikan persediaan darah. Pentingnya fungsi darah tersebut, maka PMI harus menjaga kestabilan stock darah. Hal tersebut dilakukan untuk menjamin ketersediaan darah, akan tetapi permasalahan yang dihadapi oleh pihak PMI yaitu adanya kelebihan darah yang mengakibatkan terjadinya pembuangan darah. Untuk meminimalkan kejadian tersebut maka dibutuhkan sebuah peramalan kebutuhan darah. Data permintaan darah dinormalisasikan terlebih dahulu dan selanjutnya dilakukan proses peramalan menggunakan metode Neural Network Backpropagation. Pada setiap jenis darah peramalan terbaik didapatkan pada epoch yang berbeda-beda. Pada jenis darah WB peramalan terbaik terjadi pada epoch 3000 dengan function $Y = 1176,93 - 18,3264x + 0,142822 x^2$. dan dengan error 0,044016.

Kata Kunci – Neural Network, Palang Merah Indonesia, Peramalan, *Whole Blood*

I. PENDAHULUAN

Darah yang diambil langsung dari pendonor disebut dengan *Whole Blood* (WB) atau darah lengkap yang bercampur dengan antikoagulan yang sudah tersedia dalam kemasan kantong darah dengan tujuan mencegah penggumpalan darah donor sehingga darah tersebut dapat disimpan dan diberikan kepada orang yang membutuhkan darah (pasien). PMI Kota Surabaya setiap harinya mendapatkan rata-rata 500 kantong darah dari pendonor. Sedangkan untuk kebutuhan darah yang telah didistribusikan

ke beberapa tempat mencapai 400 kantong darah per hari [1]. Dari hasil diatas menjelaskan bahwa terdapat kelebihan stok darah (*overstock*) setiap harinya. Untuk meminimalisir terjadinya *overstock* dan meningkatkan pelayanan serta kesejahteraan masyarakat khususnya bagi orang yang membutuhkan darah, maka diperlukan sebuah peramalan kebutuhan darah.

Peramalan atau prediksi telah dilakukan dalam berbagai bidang baik teknologi, pendidikan, ekonomi ataupun kesehatan. Pada bidang teknologi metode prediksi seringkali diterapkan pada berbagai wahana yaitu misil [2], kapal selam tanpa awak [3][4], dan kereta cepat dengan magnet [5]. Pada bidang ekonomi juga diterapkan untuk prediksi harga saham [6][7]. Pada bidang pendidikan juga digunakan untuk prediksi jumlah siswa atau lulusan. Sedangkan pada bidang kesehatan adalah prediksi jumlah pasien, prediksi jenis penyakit yang dapat berkembang pada kurun waktu tertentu dan prediksi atau peramalan jumlah permintaan darah.

Peramalan jumlah permintaan darah sangat diperlukan di bidang kesehatan. Darah sangat berperan penting dalam kehidupan manusia [8]. Peramalan adalah proses untuk memperkirakan beberapa kebutuhan dimasa yang akan datang meliputi kebutuhan dalam kuantitas, waktu dan lokasi. Salah satu metode yang dapat digunakan ialah metode *Jaringan syaraf tiruan propagasi balik*.

Metode ini ialah proses pengolahan informasi yang terinspirasi oleh sistem saraf secara biologis, seperti proses informasi pada otak manusia [9]. Pada paper ini dilakukan kajian peramalan pada permintaan jenis darah khususnya jenis darah Whole Blood (WB) atau darah lengkap di PMI kota Surabaya dengan metode Neural Network Backpropagation.

A. Metode Neural Network Backpropagation

Neural network (NN) adalah paradigma pengolahan informasi yang terinspirasi oleh sistem saraf secara biologis, seperti proses

informasi pada otak manusia [9]. *Backpropagation* adalah metode penurunan gradien untuk meminimalkan kuadrat eror keluaran. Terdapat tiga tahapan yang harus dilakukan dalam pelatihan jaringan, yaitu tahap perambatan maju (*forward propagation*), tahap perambatan balik (*backpropagation*), tahap perubahan bobot dan bias. Berikut terdapat skema algoritma Neural Network *Backpropagation*.

Tabel 1. Algoritma Neural Network *Backpropagation*

Inisialisasi
Fase 1: Propagasi Maju
$z_{in_j} = v_{0j} + \sum_{i=0}^n x_i v_{ij}$ (Algoritma perhitungan hidden layer) $z_j = f(z_{in_j})$ (Algoritma perhitungan sinyal output dari hidden unit) $f(z) = \frac{1}{1+e^{-z}}$ (log sigmoid) $y_{in_k} = w_{0k} + \sum_{i=1}^p z_i w_{jk}$ (jumlah sinyal output dari unit output) $y_k = f(y_{in_k})$ (Algoritma perhitungan sinyal output dari unit output)
Fase 2: Propagasi Mundur
$\delta_k = (t_k - y_k) f'(y_{in_k})$ (faktor δ unit output) $\Delta w_{jk} = \alpha \delta_k z_j$ (koreksi bobot) $\Delta w_{0k} = \alpha \delta_k$ (koreksi bobot) $\delta_{in_j} = \sum_{k=1}^m \delta_k w_{jk}$ (faktor δ unit hidden) $\delta_j = \delta_{in_j} f'(z_{in_j})$ (faktor koreksi eror) $\Delta v_{jk} = \alpha \delta_j x_i$ (koreksi bobot) $\Delta v_{0j} = \alpha \delta_j$ (koreksi bobot)
Fase 3: Perubahan Bobot
$w_{jk}(\text{baru}) = w_{jk}(\text{lama}) + \Delta w_{jk}$ (perubahan bobot garis yang menuju ke unit keluaran) $v_{ij}(\text{baru}) = v_{ij}(\text{lama}) + \Delta v_{ij}$ (perubahan bobot garis yang menuju ke unit tersembunyi)

II. HASIL SIMULASI DAN ANALISA

Pada paper ini dilakukan peramalan pada jenis darah WB dengan epoch 3000, 4000 dan 5000 dengan 10, 20 dan 30 hidden layer. Data yang didapatkan dari PMI mulai Januari 2013 sampai desember 2017. Proses peramalan dilakukan dalam dua tahap yaitu

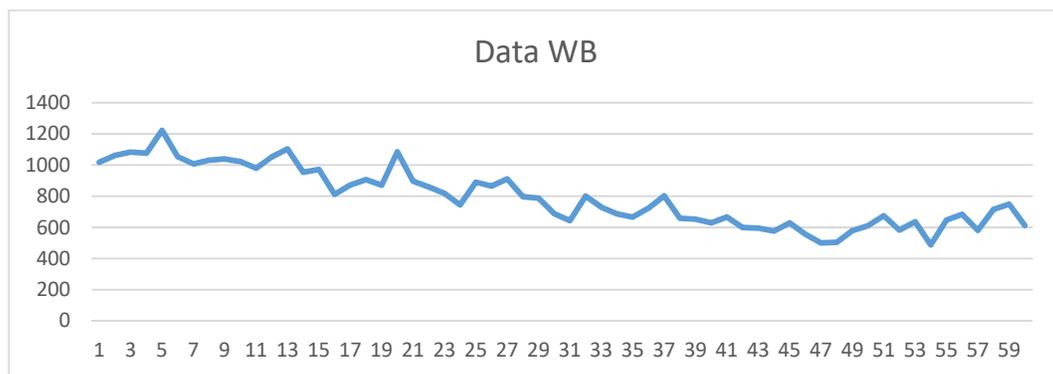
pelatihan dan pengujian. Berikut pada Tabel 2. adalah data jenis darah WB. Berikut adalah data jenis darah WB tahun 2013-2017 yang tampak pada Tabel 2.

Tabel 2 Data jenis darah WB

Data WB												
	Jan	Feb	Mar	April	Mei	Juni	Juli	Agust	Sep	Okt	Nov	Des
2013	1018	1062	1083	1076	1222	1053	1007	1031	1039	1023	979	1052
2014	1103	953	972	812	872	906	871	1085	897	859	818	744
2015	890	865	911	797	787	687	643	801	730	686	666	723
2016	803	659	653	629	666	599	595	576	629	557	500	504
2017	579	611	675	583	637	488	647	684	581	715	749	612

Gambar 1 merupakan data *time series* permintaan jenis darah WB, dapat dilihat bawasanya data permintaan darah mengalami naik dan turun yang tidak terlalu signifikan. Hal ini disebabkan oleh permintaan jenis darah WB dari masyarakat cenderung mengalami kenaikan dan penurunan yang stabil.

Pelatihan *White Blood* menggunakan data input yang telah dipolakan dengan 36 pola dan menggunakan data WB berupa data ribuan. Pelatihan yang dilakukan menggunakan 9 variasi dengan beberapa hidden dan *epoch*, untuk hasil pelatihan ditunjukkan pada Tabel 3.



Gambar 1 Grafik permintaan jenis darah WB

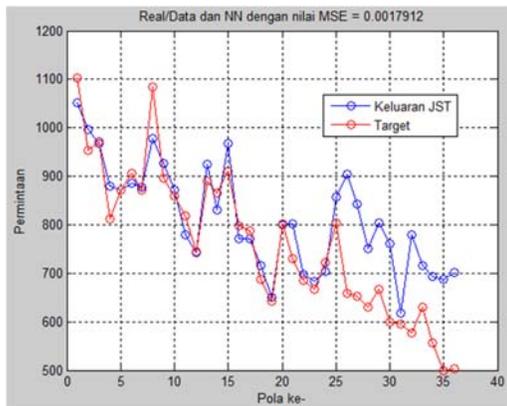
Pada Tabel 3 ditunjukkan bahwa hasil MSE terkecil di masing – masing *epoch* terjadi dengan *hidden layer* yang berbeda – beda. Untuk *epoch* 3000 dengan *hidden layer* 10 menghasilkan nilai MSE 0,0017912. Selanjutnya, pada *epoch* 4000 MSE terkecil dengan *hidden layer* 10 menghasilkan nilai MSE 0,0015173. Berikutnya, pada *epoch* 5000 MSE terkecil dengan *hidden layer* 20 menghasilkan nilai MSE 0,0010187. Hasil

pelatihan dengan *epoch* 3000, 4000, dan 5000 terdapat pada Gambar 2, 3 dan 4.

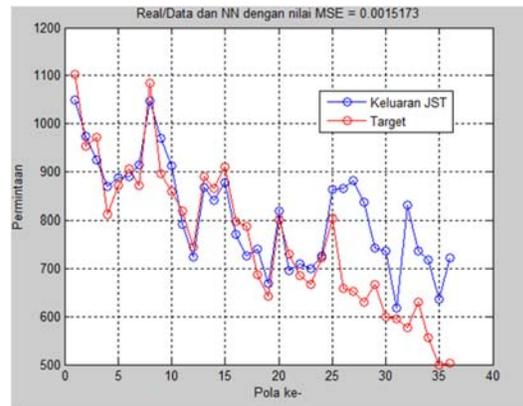
Pada Gambar 2 terlihat bahwa hasil keluaran JST dan target (*real data*) pada *epoch* 3000 memiliki *error* yang cukup kecil dan kondisi ini berhenti karena *epoch* yang ditentukan telah terpenuhi, hal tersebut ditunjukkan dengan grafik keluaran JST dan target (*real data*) dengan MSE 0,0017912.

Tabel 3. Hasil pelatihan WB

No	Hidden	Epoch	MSE	Epoch	Terkecil
1	10	3000	0,0017912	3000	0,0017912
2	20	3000	0,0019698	3000	
3	30	3000	0,0022278	3000	
4	10	4000	0,0015173	4000	0,0015173
5	20	4000	0,0018982	4000	
6	30	4000	0,0022048	4000	
7	10	5000	0,0019659	5000	0,0010187
8	20	5000	0,0010187	5000	
9	30	5000	0,0010221	5000	



Gambar 2 Hasil pelatihan WB epoch 3000



Gambar 3 Hasil pelatihan WB epoch 4000

Pada Gambar 3 terlihat bahwa hasil keluaran NN dan target (*real data*) pada *epoch* 4000 memiliki hasil *error* yang memenuhi nilai yang telah ditentukan yaitu 0.001, kondisi ini berhenti pada *epoch* 3084. Hal tersebut ditunjukkan dengan grafik keluaran JST dan target (*real data*) dengan MSE 0,0015173.

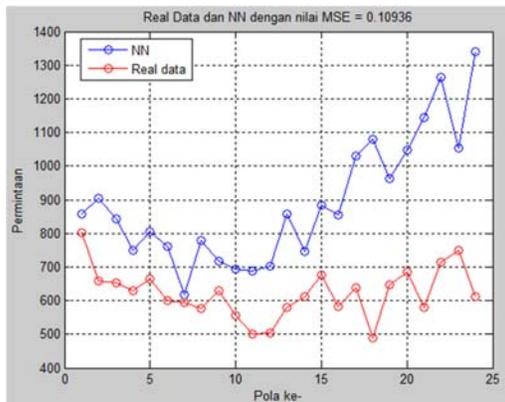
Pada Gambar 4 terlihat bahwa hasil keluaran NN dan target (*real data*) pada *epoch* 5000 memiliki *error* yang memenuhi nilai yang telah ditentukan yaitu 0,001, kondisi ini berhenti pada *epoch* 3084. Hal tersebut ditunjukkan dengan grafik keluaran JST dan target (*real data*) dengan MSE 0,0010187. Setelah dilakukan pelatihan, selanjutnya adalah proses pengujian.

Pengujian dilakukan menggunakan data *input* nilai WB yang telah ditetapkan sebagai data uji dan dipolakan menjadi 24 pola. Pengujian dilakukan dengan menggunakan nilai bobot dari masing – masing *epoch* yang memiliki nilai *error* terkecil, untuk hasil pengujian ditunjukkan pada Tabel 4.

Tabel 4 Hasil pengujian WB

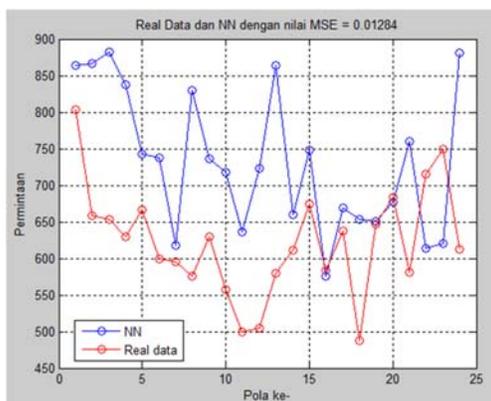
No	Epoch	MSE
1	3000	0,10936
2	4000	0,01284
3	5000	0,044016

Pada Tabel 4 ditunjukkan bahwa hasil pengujian di masing masing *epoch* memiliki MSE yang berbeda yaitu pada *epoch* 3000 menghasilkan MSE 0,10936, *epoch* 4000 menghasilkan MSE 0,01284, dan *epoch* 5000 menghasilkan MSE 0,044016. Hasil pengujian dengan *epoch* 3000, 4000, dan 5000 ditunjukkan pada Gambar 5, 6 dan 7.



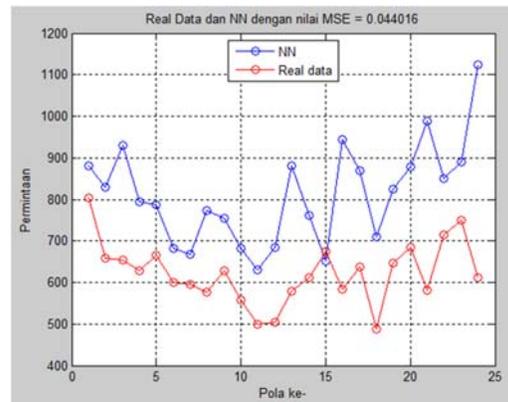
Gambar 5 Hasil Pengujian PRC epoch 3000

Hasil uji pada Gambar 5. terlihat bahwa hasil keluaran NN dan *real data* pada *epoch* 3000 memiliki MSE 0,10936. MSE tersebut menunjukkan bahwa peramalan yang dilakukan cukup baik. Hasil peramalan pada *epoch* 3000 menunjukkan bahwa MSE yang dihasilkan lebih baik dari pada hasil dari *epoch* 4000 dan 5000.



Gambar 6 Hasil pengujian WB epoch 4000

Pada Gambar 6. ditunjukkan bahwa hasil keluaran NN dan real data pada *epoch* 4000 memiliki 0,01284. MSE tersebut menunjukkan bahwa peramalan yang dilakukan masih dapat dimaksimalkan kembali dengan melakukan pelatihan ulang dan mengubah – ubah parameter yang diberikan.



Gambar 7 Hasil pengujian WB epoch 5000

Hasil uji pada Gambar 7 ditunjukkan bahwa hasil keluaran NN dan *real data* pada *epoch* 5000 memiliki MSE 0,044016. MSE tersebut menunjukkan bahwa peramalan yang dilakukan masih dapat dimaksimalkan kembali dengan melakukan pelatihan ulang.

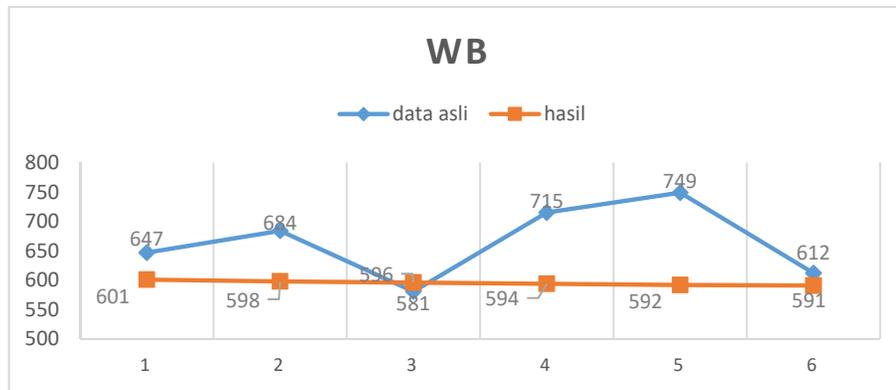
Dari ketiga hasil tersebut MSE terkecil ditunjukkan pada *epoch* 5000 dengan nilai 0,044016. Adapun *function* yang dapat digunakan untuk melakukan peramalan pada bulan selanjutnya yaitu :

$$Y = 1176,93 - 18,3264x + 0,142822 x^2$$

Y = hasil peramalan bulan selanjutnya.

X = 60 + data ke i , dimana i merupakan data bulan selanjutnya yang akan dilakukan peramalan.

Implementasi 6 bulan terakhir:



Gambar 8 Implementasi WB

Dari Gambar 8 ditunjukkan grafik antara data asli dan hasil peramalan selama 6 bulan terakhir yang menunjukkan adanya ketidaksesuaian antara data asli dan hasil, sehingga terdapat rata – rata selisih yaitu 260 kantong darah. Untuk peramalan 5 bulan selanjutnya (Januari 2018- Mei 2018) ditunjukkan pada tabel 5.

Tabel 5. Hasil peramalan WB

Bulan ke	Hasil
61	590
62	589
63	589
64	589
65	589

III. KESIMPULAN

Dari hasil simulasi didapatkan bahwa peramalan terbaik terjadi pada *epoch* yang berbeda di masing - masing jenis darah. Pada jenis darah WB peramalan terbaik terjadi pada *epoch* 5000 dengan *function* $Y = 1176,93 - 18,3264x + 0,142822x^2$. Sehingga metode Neural Network Backpropagation dapat diterapkan untuk peramalan jenis darah WB atau jenis darah lainnya.

REFERENSI

- [1] Jutanto, Agung Tri, 2017. Donor Darah di Bulan Puasa. Surabaya, Surya.
- [2] Herlambang, T., 2017, “Design of a Navigation and Guidance System of Missile with Trajectory Estimation Using Ensemble Kalman Filter Square Root (EnKF-SR). International Conference on Computer Applications and Information Processing Technology (CAIPT)-IEEE, Bali Indonesia 8-10 August 2017.
- [3] Herlambang, T., Djatmiko E.B and Nurhadi H., 2015, “Navigation and Guidance Control System of AUV with Trajectory Estimation of Linear Modelling”, Proc. of International Conference on Advance Mechatronics, Intelligent Manufactre, and Industrial Automation, IEEE , ICAMIMIA 2015, Surabaya, Indonesia, pp. 184-187, Oct 15 – 17
- [4] Ermayanti, E., Aprilini, E., Nurhadi H, and Herlambang T, 2015, “Estimate and Control Position Autonomous Underwater Vehicle Based on Determined Trajectory using Fuzzy Kalman Filter Method”, International Conference on Advance Mechatronics, Intelligent Manufactre, and Industrial Automation (ICAMIMIA)-IEEE Surabaya Indonesia, 15 – 16 Oktober 2015.
- [5] Herlambang, T., 2017. “Estimasi Posisi Magnetic Levitation Ball Menggunakan Metode Akar Kuadrat Ensemble Kalman Filter (AK-EnKF)”, Rekayasa, Energi, Manufaktur Jurnal, Vol 2, No 1, 2017, ISSN: 2528-3723
- [6] Fidita, D.F., Puspandam, K. and Herlambang, T., 2017. “Stock Price Estimation Using Ensemble Kalman Filter Square Root Methods”, The First International Conference on Combinatorics, Graph Teory and Network Topology, University of Jember-Indonesia, 25-26 Nov 2017, Journal of Physics: Conf. Series 1008 (2018) 012026
- [7] Puspandam, K., Fidita, D.F dan Herlambang, T., 2017, “Estimasi Harga Saham PT. ABC dengan Algoritman Kalman Filter”, Zeta-Math Journal, Vol 3 No 2 November 2017. ISSN: 2459-9948.
- [8] Devi, A.K., and Herlambang, T, 2018, “Peramalan Kebutuhan Darah Jenis Packet Red Cells (PRC) di PMI Kota Surabaya dengan Metode Jaringan Syaraf Tiruan Propagasi Balik”, Zeta-Math Journal, Vol 4 No 1 Mei 2017. ISSN: 2459-9948.
- [9] Sutojo, T. dan, Edy Mulyanto , Vincent Suhartono, 2010. Kecerdasan Buatan. Yogyakarta: Andi.