

PERBANDINGAN METODE KLASIFIKASI REGRESI LOGISTIK BINER DAN RADIAL BASIS FUNCTION NETWORK PADA BERAT BAYI LAHIR RENDAH (Studi Kasus: Puskesmas Pamenang Kota Jambi)

Riama Oktaviyani Samosir¹, Yuciana Wilandari², Hasbi Yasin³

¹Mahasiswa Jurusan Statistika FSM Universitas Diponegoro

^{2,3}Staff Pengajar Jurusan Statistika FSM Universitas Diponegoro

riamasamosir45@gmail.com, yuciana.wilandari@gmail.com, hasbiyasin17@gmail.com

ABSTRACT

Low Birth Weight (LBW) is one of the main causes of infant mortality. LBW must be identified and predicted before the baby birth by observing historical data of expectant. This research aims to analyze the classification of status newborn in order to reduce the risk of LBW. The statistical method used are the Binary Logistic Regression and Radial Basis Function Network. The data used in this final project is birth weight at Pamenang Jambi City health center in 2014. In this research, the data are divided into training data and testing data. Training data will be used to generate the model and pattern formation, while testing the data is used to measure how the accuracy of the representative model or pattern formed in classifying data through confusion tables. The results of analysis showed that the Binary Logistic Regression method gives 81,7% of classification accuracy for training data and 77,4% of classification accuracy for testing data, while Radial Basis Function Network method gives 92,96% of classification accuracy for training data and 80,64% of classification accuracy for testing data. Radial Basis Function Network method has better classification accuracy than the Binary Logistic Regression method.

Keywords: Low Birth Weight (LBW), Binary Logistic Regression, Radial Basis Function Network, Classification, Confusion

1. PENDAHULUAN

Bayi Berat Lahir Rendah (BBLR) adalah neonatus dengan berat badan kurang dari 2500 gram pada saat lahir [6]. Bayi dengan Berat Badan Lahir Rendah memiliki risiko yang lebih tinggi terhadap kejadian gangguan pertumbuhan dan perkembangan pada masa-masa berikutnya [8]. Selain faktor genetik, berat badan bayi baru lahir ditentukan oleh status gizi janin. Status gizi janin ditentukan antara lain oleh status gizi ibu waktu melahirkan dan keadaan ini dipengaruhi pula oleh status gizi ibu pada waktu konsepsi.

Melihat masih tingginya kejadian BBLR, maka perlu dilakukan identifikasi dan prediksi bayi sebelum lahir dengan cara memperhatikan data historis ibu hamil. Dalam statistika, metode yang dapat digunakan untuk memetakan status berat bayi lahir adalah dengan menggunakan metode klasifikasi. Terdapat beberapa metode klasifikasi, baik dari yang klasik maupun yang modern. Pada metode klasik, yang sering digunakan untuk klasifikasi adalah metode regresi logistik dan analisis diskriminan, sedangkan untuk metode modern, yang beberapa telah dikembangkan saat ini antara lain *Neural Network*, *Support Vector Machine*, *Learning Vector Quantization*, *Naive Bayes*, *Decision Tree*, *Fuzzy Sets*, *Genetic Algorithm*, dan *Rough Sets*. Di dalam metode *Neural Network* terdapat beberapa metode, salah satunya adalah *Radial Basis Function Network*.

Berdasarkan hal di atas, penulis ingin mengetahui faktor-faktor yang mempengaruhi status berat bayi baru lahir serta melakukan analisis klasifikasi bayi baru lahir guna mengurangi risiko Berat Bayi Lahir Rendah (BBLR) menggunakan metode Regresi Logistik Biner dan *Radial Basis Function Network* untuk klasifikasi status berat bayi baru lahir pada Puskesmas Pamenang Kota Jambi.

2. TINJAUAN PUSTAKA

2.1. Klasifikasi

Klasifikasi dapat didefinisikan sebagai pekerjaan yang melakukan pelatihan/pembelajaran terhadap fungsi target f yang memetakan setiap set atribut (fitur) x ke satu dari sejumlah label kelas y yang tersedia [7].

Tabel 1. Matriks Konfusi Untuk Klasifikasi Dua Kelas

Hasil Observasi	Kelas hasil prediksi	
	Kelas = 1	Kelas = 0
Kelas = 1	f_{11}	f_{10}
Kelas = 0	f_{01}	f_{00}

Akurasi hasil klasifikasi dihitung dengan formula sebagai berikut:

$$\begin{aligned} \text{Akurasi} &= \frac{\text{Jumlah data yang diprediksi secara benar}}{\text{jumlah prediksi yang dilakukan}} \\ &= \frac{f_{11} + f_{00}}{f_{11} + f_{10} + f_{01} + f_{00}} \end{aligned}$$

$$\begin{aligned} \text{Laju Eror} &= \frac{\text{Jumlah data yang diprediksi secara salah}}{\text{jumlah prediksi yang dilakukan}} \\ &= \frac{f_{10} + f_{01}}{f_{11} + f_{10} + f_{01} + f_{00}} \end{aligned}$$

2.2. Regresi Logistik Biner

Regresi logistik biner adalah salah satu metode statistika yang menggambarkan hubungan antara variabel respon (y) dengan satu atau lebih variabel prediktor (x), dimana variabel respon dalam regresi logistik adalah biner atau dikotomi yaitu hanya memiliki dua kategori. Hasil untuk setiap pengamatan dapat diklasifikasikan sebagai “sukses” atau “gagal”. Klasifikasi ini diwakili dengan $y = 1$ untuk hasil pengamatan “sukses” dan $y = 0$ untuk hasil pengamatan “gagal” [4]. Menurut Agresti [1] variabel y akan mengikuti distribusi Bernoulli untuk setiap observasi tunggal dan ditentukan probabilitas $P(Y = 1) = \pi$ dan $P(Y = 0) = 1 - \pi$.

Secara umum, model regresi logistik dapat ditulis dalam bentuk

$$\pi(\mathbf{x}) = \frac{e^{\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p}}{1 + e^{\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p}} \quad (1)$$

Metode yang digunakan untuk estimasi nilai-nilai parameter yang tidak diketahui adalah metode *Maximum Likelihood*. Dalam mengestimasi parameter, metode ini memaksimalkan probabilitas dari kumpulan data yang diamati [4]. Data yang diamati dalam regresi logistik biner mengikuti distribusi Bernoulli, fungsi peluangnya adalah

$$f(y_i; \pi(x_i)) = \pi(x_i)^{y_i} [1 - \pi(x_i)]^{1 - y_i}$$

Karena pengamatan diasumsikan independen, fungsi likelihoodnya diekspresikan sebagai berikut

$$l(\beta) = \prod_{i=1}^n \pi(x_i)^{y_i} [1 - \pi(x_i)]^{1 - y_i} \quad (2)$$

Prinsip metode *maximum likelihood* menyatakan bahwa untuk mengestimasi β , digunakan nilai yang memaksimalkan Persamaan (2).

$$L(\beta) = \ln\{l(\beta)\} = \ln\left\{\prod_{i=1}^n \{\pi(x_i)\}^{y_i} \{1 - \pi(x_i)\}^{1 - y_i}\right\} \quad (3)$$

Estimasi parameter yang digunakan dalam model regresi logistik biner diperoleh dengan metode iterasi Newton-Raphson dengan langkah-langkah sebagai berikut [2]:

1. Dipilih taksiran awal untuk β , misal $\hat{\beta} = 0$
2. Dihitung $\mathbf{X}'(\mathbf{Y} - \boldsymbol{\pi}(\mathbf{x}_i))$ dan $\mathbf{X}'\mathbf{V}\mathbf{X}$, selanjutnya dihitung invers dari $\mathbf{X}'\mathbf{V}\mathbf{X}$
3. Pada setiap $(s + 1)$ dihitung taksiran baru yaitu

$$\hat{\beta}^{(s+1)} = \hat{\beta}^{(s)} + \{\mathbf{X}'\mathbf{V}\mathbf{X}\}^{-1} \{\mathbf{X}'(\mathbf{Y} - \boldsymbol{\pi}(\mathbf{x}_i))\}$$
4. Iterasi berakhir jika diperoleh $\hat{\beta}^{(s+1)} \cong \hat{\beta}^{(s)}$

Menurut Hosmer dan Lemeshow (2000) [4], untuk menguji signifikansi dari parameter dalam model digunakan uji rasio *likelihood* dan uji Wald. Uji rasio *likelihood* digunakan untuk mengetahui apakah variabel prediktor secara bersama-sama mempengaruhi respon. Hipotesis dalam uji rasio *likelihood* yaitu

$$H_0 : \beta_1 = \beta_2 = \dots = \beta_p = 0$$

$$H_1 : \text{paling sedikit ada satu } \beta_j \neq 0 \text{ dengan } j = 1, 2, \dots, p$$

Statistik uji rasio *likelihood* adalah $G = -2 \ln \left(\frac{\text{likelihood tanpa variabel bebas}}{\text{likelihood dengan variabel bebas}} \right)$

Kriteria uji yaitu H_0 ditolak jika $G > \chi^2_{(\alpha, p)}$.

Sedangkan uji Wald dilakukan untuk mengetahui signifikansi parameter terhadap variabel respon. Hipotesis uji Wald yaitu

$$H_0 : \beta_j = 0 \text{ dengan } j = 1, 2, \dots, p$$

$$H_1 : \beta_j \neq 0 \text{ dengan } j = 1, 2, \dots, p$$

Statistik uji wald adalah $W_j = \left\{ \frac{\hat{\beta}_j}{se(\hat{\beta}_j)} \right\}^2$

Kriteria uji yaitu H_0 ditolak jika $W_j > \chi^2_{(\alpha, 1)}$.

Model yang diperoleh diuji kesesuaiannya, uji kesesuaian model digunakan untuk mengetahui apakah model efektif dalam menjelaskan variabel hasil. Hipotesis yang digunakan dalam uji kesesuaian model yaitu

$$H_0 = \text{Model sesuai (Nilai observasi sama dengan nilai prediksi)}$$

$$H_1 = \text{Model tidak sesuai (Nilai observasi tidak sama dengan nilai prediksi)}$$

Statistik uji yang digunakan adalah $\hat{C} = \sum_{k=1}^g \frac{(O_k - n\pi_k)^2}{n_k \pi_k (1 - \pi_k)}$

Kriteria uji yang digunakan yaitu tolak H_0 jika $\hat{C} > \chi^2_{(\alpha, g-2)}$.

2.3. Neural Network

Neural Network dikembangkan sebagai model matematika yang menyerupai pola pikir manusia atau jaringan syaraf makhluk hidup [9]. *Radial Basis Function Network* (RBFN) didesain untuk membentuk pemetaan nonlinear dari variabel input ke unit *hidden layer* dan pemetaan linear dari *hidden layer* ke output. Dalam teknik RBFN dilakukan pemilihan fungsi $F(\mathbf{x})$ sebagai berikut

$$F(\mathbf{x}) = \sum_{i=1}^n w_i^{(2)} \varphi \|\mathbf{x} - \mathbf{x}_i\| + b_2 \quad (4)$$

Dimana $\{w_i^{(2)} \varphi \|\mathbf{x} - \mathbf{x}_i\|, i = 1, 2, \dots, n\}$ adalah himpunan fungsi nonlinier yang disebut fungsi radial basis dan $\|\cdot\|$ adalah norm jarak *Euclidean* [3].

Algoritma perhitungannya adalah sebagai berikut [5]:

1. Menghitung $\|x_i - x_k\|$ yaitu norm jarak *Euclidean*

$$\|x_i - x_k\| = D_{i,k} = \sqrt{\sum_{j=1}^p (x_{i,j} - x_{k,j})^2} \quad \text{dimana } i,k = 1, 2, \dots, n; j = 1, 2, \dots, p \quad (5)$$

2. Menghitung $\varphi_{i,k} = \varphi\|x_i - x_k\|$ hasil aktivasi dengan fungsi basis radial dari jarak data dikalikan bias

$$\varphi_{i,k} = e^{-(b1 \cdot D_{i,k})^2} \quad (6)$$

dengan: $b1 = \frac{\sqrt{-\ln(0.5)}}{\text{spread}}$, spread merupakan bilangan real positif.

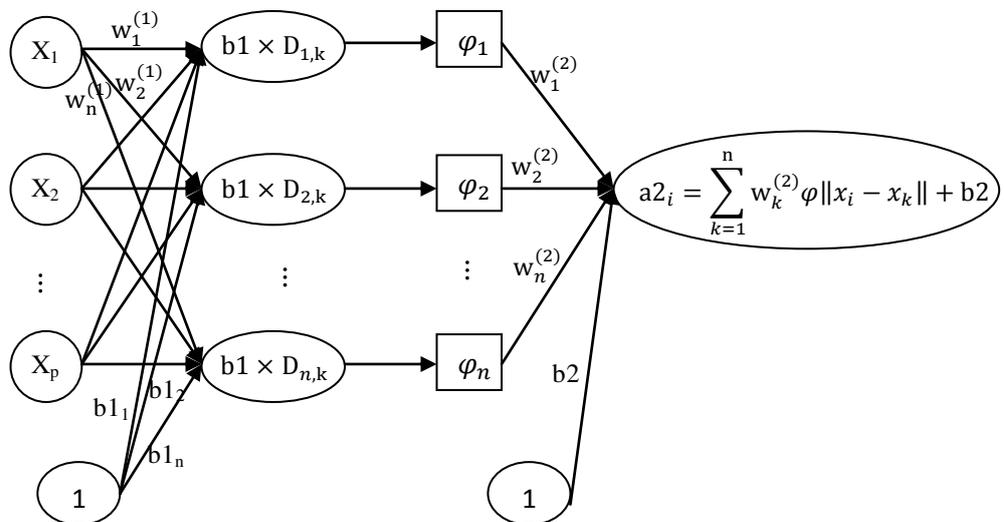
3. Menghitung bobot lapisan dan bobot bias lapisan, $w_k^{(2)}$ dan $b2$ dengan menyelesaikan persamaan linier berikut yang dapat diselesaikan dengan metode *Least Square*.

$$\begin{aligned} \varphi_{1,1} w_1^{(2)} + \varphi_{1,2} w_2^{(2)} + \dots + \varphi_{1,n} w_n^{(2)} + b2 &= d_1 \\ \varphi_{2,1} w_1^{(2)} + \varphi_{2,2} w_2^{(2)} + \dots + \varphi_{2,n} w_n^{(2)} + b2 &= d_2 \\ \dots & \\ \varphi_{n,1} w_1^{(2)} + \varphi_{n,2} w_2^{(2)} + \dots + \varphi_{n,n} w_n^{(2)} + b2 &= d_n \end{aligned} \quad (7)$$

4. Menghitung output RBFN $a2_i$, pada setiap $i = 1, 2, \dots, n$.

$$a2_i = \varphi_{i,1} w_1^{(2)} + \varphi_{i,2} w_2^{(2)} + \dots + \varphi_{i,n} w_n^{(2)} + b2 \quad (8)$$

Model arsitektur RBFN diberikan pada Gambar 1.



Gambar 1. Arsitektur *Radial Basis Function Network*

3. METODE PENELITIAN

3.1. Jenis dan Sumber Data

Data yang digunakan sebagai studi kasus pada tugas akhir ini berupa data sekunder yaitu data Berat Bayi Lahir Rendah (BBLR) yang diambil dari hasil pencatatan pemeriksaan kandungan dan kelahiran pada PUSKESMAS (Pusat Kesehatan Masyarakat) Kecamatan Pamenang Kota Jambi pada tahun 2014.

3.2. Variabel Penelitian

Variabel respon dan variabel prediktor yang digunakan disajikan dalam tabel berikut

Tabel 2. Variabel-Variabel Penelitian pada Puskesmas Pamenang

No	Variabel	Keterangan	Tipe	Kategori
1	Umur Ibu (tahun)	X_1	Rasio	Numerik
2	Frekuensi Pemeriksaan Kehamilan	X_2	Rasio	Numerik
3	Jumlah Anak	X_3	Rasio	Numerik
4	Berat Badan Ibu (kg)	X_4	Rasio	Numerik
5	Sistol Ibu	X_5	Rasio	Numerik
6	Diastol Ibu	X_6	Rasio	Numerik
7	Tinggi Badan Ibu (cm)	X_7	Rasio	Numerik
8	Ukuran LILA (cm)	X_8	Rasio	Numerik
9	Status Berat Bayi Lahir	Y	Nominal	0 = BBLR 1 = Non BBLR

3.3. Teknik Pengolahan Data

Pengolahan data dalam penelitian ini menggunakan metode Regresi Logistik Biner dan *Radial Basis Function Network* menggunakan Software *Excel*, *SPSS*, dan *Matlab*. Metode analisis yang dilakukan adalah sebagai berikut:

1. Mempersiapkan data status berat bayi lahir dan membagi data tersebut menjadi data *training* dan data *testing*. Data *training* yang digunakan adalah sebanyak 70% dari data status berat bayi yang lahir dan data *testing* yang digunakan adalah sebanyak 30% dari data status bayi yang lahir.
2. Melakukan pemodelan klasifikasi menggunakan metode Regresi Logistik Biner. Langkah analisis untuk analisis Regresi Logistik Biner adalah sebagai berikut:
 - a. Menginput data *training* dan *testing*
 - b. Menentukan model awal.
 - c. Melakukan uji signifikansi Rasio *Likelihood*.
 - d. Melakukan uji Wald.
 - e. Melakukan uji kesesuaian model.
 - f. Menentukan model akhir.
 - g. Membentuk tabel ketepatan klasifikasi menggunakan data *testing*.
 - h. Menghitung ketepatan klasifikasi dan misklasifikasi berdasarkan model model yang diperoleh dari data *training*.
3. Melakukan pengolahan data menggunakan metode *Radial Basis Function Network* dengan langkah-langkah sebagai berikut:
 - a. Menginput data *training* untuk variabel independen yang signifikan (yang diperoleh dari metode regresi logistik biner) dan data *testing*.
 - b. Menghitung jarak *Euclidean*.
 - c. Menentukan nilai spread.
 - d. Menghitung nilai aktivasi.
 - e. Menghitung bobot lapisan dan bobot bias lapisan dengan metode *Least Square*.
 - f. Menghitung output RBFN.
 - i. Menghitung ketepatan klasifikasi dan misklasifikasi berdasarkan pola yang diperoleh dari data *training*
4. Membandingkan ketepatan klasifikasi antara regresi logistik biner dan *Radial Basis Function Network*.

4. HASIL DAN PEMBAHASAN

4.1. Deskripsi Data

Deskripsi data status berat bayi baru lahir disajikan pada tabel berikut

Tabel 3. Deskripsi Variabel Respon (Y)

Kategori BBL	N	Persentase (%)
BBLR	30	29,412
NonBBLR	72	70,588
Total	102	100

Adapun pembagian data *training* dan *testing* adalah sebagai berikut

$$N_{training} = \left(\frac{70}{100} \times 72\right) + \left(\frac{30}{100} \times 30\right) = 50,4 + 9 \approx 60$$

$$N_{testing} = \left(\frac{30}{100} \times 72\right) + \left(\frac{70}{100} \times 30\right) = 21,6 + 21 \approx 43$$

4.2. Analisis Regresi Logistik Biner

Model awal regresi logistik yang terbentuk adalah sebagai berikut

$$\pi(x) = \frac{e^{(-18,302+0,039x_1+0,600x_2-1,459x_3+0,57x_4-0,019x_5+0,028x_6+0,034x_7+0,172x_8)}}{1+e^{(-18,302+0,039x_1+0,600x_2-1,459x_3+0,157x_4-0,019x_5+0,028x_6+0,034x_7+0,172x_8)}}$$

Uji rasio *likelihood* menghasilkan nilai G lebih besar dari nilai tabel $\chi^2_{(0,05;8)}$ yaitu $34,959 > 15,507$ atau $p\text{-value} < \alpha$ yaitu $0,000 < 0,05$, berarti paling sedikit ada satu variabel prediktor memberi pengaruh signifikan terhadap variabel respon. Uji Wald menunjukkan variabel prediktor yang memberi pengaruh signifikan terhadap variabel respon adalah variabel yang memiliki nilai $W_j > \chi^2_{(0,05,1)} = 3,841$ atau nilai $\text{sig} < \alpha = 0,05$. Dari hasil pengolahan menggunakan SPSS 13 diperoleh variabel yang signifikan adalah X_3 (jumlah anak) dan X_4 (berat badan ibu).

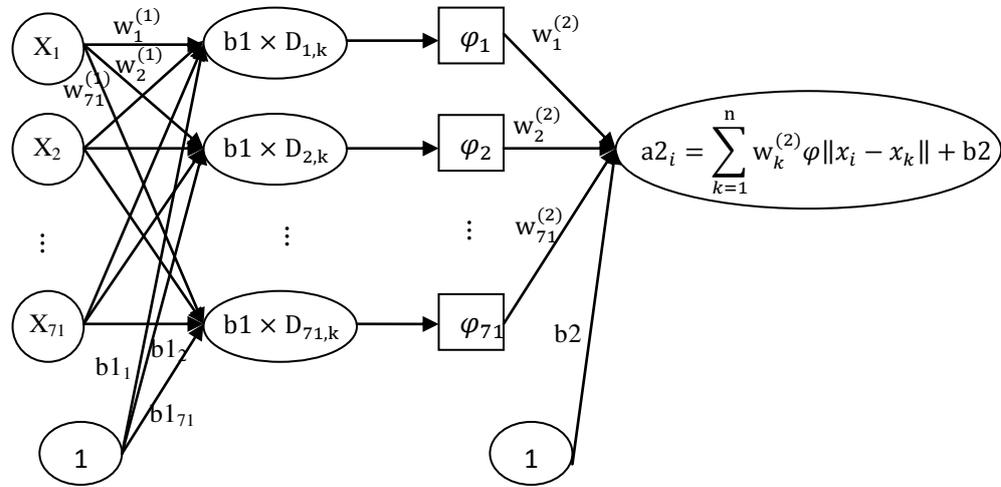
Sehingga terbentuk model kedua dengan tidak mengikutsertakan variabel-variabel prediktor yang tidak berpengaruh terhadap variabel respon yaitu

$$\pi(x) = \frac{e^{(-7,626-1,348x_3+0,202x_4)}}{1+e^{(-7,626-1,348x_3+0,202x_4)}}$$

Uji rasio *likelihood* menunjukkan bahwa nilai G lebih besar dari nilai tabel $\chi^2_{(0,05;2)}$ yaitu $31,035 > 5,991$ atau $p\text{-value} < \alpha$ yaitu $0,000 < 0,05$, hal ini menunjukkan bahwa minimal satu variabel prediktor memberi pengaruh signifikan terhadap variabel respon. Pada uji Wald diketahui bahwa variabel prediktor X_3 (jumlah anak) dan X_4 (berat badan ibu) memberi pengaruh yang signifikan terhadap variabel respon. Pada uji kesesuaian model menghasilkan nilai $\hat{C} < \chi^2_{(\alpha, g-2)}$ yaitu $6,382 < 15,507$ atau $p\text{-value} > \alpha$ yaitu $0,604 > 0,05$, diperoleh kesimpulan bahwa model sesuai dan nilai observasi sama dengan nilai prediksi.

4.3. Analisis Radial Basis Function Network

Model arsitektur RBFN diberikan pada Gambar 2.



Gambar 2. Arsitektur Radial Basis Function Network pada Data

Ketepatan klasifikasi metode RBFN diperoleh melalui algoritma berikut:

1. Menghitung $D_{i,k}$ (norm jarak *Euclidean*) yaitu $\|x_i - x_k\|$, dengan $i = 1, 2, \dots, 71, k = 1, 2, \dots, 71$

Tabel 4. Jarak Data Training terhadap Data Training

$D_{i,k}$	1	2	...	71
1	0	1,414	...	26,000
2	1,414	0	...	25,020
...
71	26,000	25,020	...	0,000

2. Menghitung nilai aktivasi $\varphi_{i,k} = e^{-(b1 \cdot D_{i,k})^2}$ dengan $b1 = \frac{\sqrt{-\ln(0.5)}}{\text{spread}}$

Tabel 5. Ketepatan Klasifikasi RBFN

Nilai Spread	Data Training (%)	Data Testing (%)
1	92,96	80,64
3	92,96	64,52
6	91,55	67,74
8	91,55	64,52
10	90,14	61,29

Maka digunakan nilai spread = 1.

$$b1 = \frac{\sqrt{-\ln(0.5)}}{\text{spread}} = \frac{\sqrt{-\ln(0.5)}}{1} = 0,83255$$

Tabel 6. Nilai Aktivasi Data Training

$\varphi_{i,k}$	1	2	...	71
1	1	0,25	...	3,19E-204
2	0,25	1	...	3,59E-189
...
71	3,19E-204	3,59E-189	...	1

3. Menghitung bobot lapisan ($w_k^{(2)}$) dan bobot bias lapisan (b2)

Persamaan linier untuk data *training* 1, 2, ..., 71

$$1w_1^{(2)} + 0,25w_2^{(2)} + \dots + 3,19 \times 10^{-204}w_{71}^{(2)} + b2 = 1$$

$$0,25w_1^{(2)} + 1w_2^{(2)} + \dots + 3,59 \times 10^{-189}w_{71}^{(2)} + b2 = 1$$

...

$$3,19 \times 10^{-204}w_1^{(2)} + 3,59 \times 10^{-189}w_2^{(2)} + \dots + 1w_{71}^{(2)} + b2 = 0$$

Dengan menggunakan *least square* maka diperoleh nilai bobot lapisan ($w_1^{(2)}$, $w_2^{(2)}$, ..., $w_{71}^{(2)}$) yaitu 0, -11,35054, ..., 0). Nilai bobot bias lapisan b2 yang diperoleh adalah sebesar 18,42376.

4. Menghitung output *Radial Basis Function Network* (a2) untuk data *training*

$$a2_1 = (1 \times 0) + (0,25 \times -11,35054) + \dots + (3,19 \times 10^{-204} \times 0) + 18,42376 = 1$$

$$a2_2 = (0,25 \times 0) + (1 \times -11,35054) + \dots + (3,59 \times 10^{-189} \times 0) + 18,42376 = 1$$

...

$$a2_{71} = (3,19 \times 10^{-204} \times 0) + (3,59 \times 10^{-189} \times -11,35054) + \dots + (1 \times 0) + 18,42376 = 0,66667$$

Selanjutnya akan dicari prediksi kelas untuk data *testing*. Prediksi kelas dihitung menggunakan data *testing* dengan pola data *training* yang telah dibuat sebelumnya. Algoritma perhitungannya adalah sebagai berikut:

- Menghitung $D_{i,k}$ (norm jarak *Euclidean*) yaitu $\|x_i - x_k\|$ dimana $i = 1, 2, \dots, 31$, $k = 1, 2, \dots, 71$

Tabel 7. Jarak Data *Testing* terhadap Data *Training*

$D_{i,k}$	1	2	...	71
1	10	9,05539	...	16
2	2,06155	1,11803	...	25,57831
...
31	2,402082	23	...	2,23607

- Menghitung nilai aktivasi $\varphi_{i,k} = e^{-(b1 \cdot D_{i,k})^2}$ dengan $b1 = \frac{\sqrt{-\ln(0.5)}}{\text{spread}}$

Tabel 8. Nilai Aktivasi Data *Testing*

$\varphi_{i,k}$	1	2	...	71
1	7,89E-31	2,07E-25	...	8,64E-78
2	0,05256	0,42045	...	1,12E-197
...
31	2,02E-174	5,69E-160	...	0,03125

- Menghitung output *Radial Basis Function Network* (a2) untuk data *testing*

$$a2_1 = (7,89 \times 10^{-31} \times 0) + (2,07 \times 10^{-25} \times -11,35054) + \dots + (8,64 \times 10^{-78} \times 0) + 18,42376 = 6,23018$$

$$a2_2 = (0,05256 \times 0) + (0,42045 \times -11,35054) + \dots \times -11,35054 + \dots + (0,03125 \times 0) + 18,42376 = 1,42 \times 10^{-14} \approx 0$$

...

$$a2_{31} = (2,02 \times 10^{-174} \times 10^{-204} \times 0) + (5,69 \times 10^{-160} \times 10^{-189} \times -11,35054 + \dots + (0,03125 \times 0) + 18,42376 = 1,42 \times 10^{-14} \approx 0$$

4.4. Perbandingan Metode Regresi Logistik Biner dengan Metode RBFN

Dari hasil pengolahan menggunakan metode regresi logistik biner dan *Radial Basis Function Network* diperoleh ketepatan klasifikasi. Perbandingan nilai akurasi dapat dilihat melalui tabel berikut

Tabel 9. Perbandingan Ketepatan Klasifikasi

Model	Ketepatan Klasifikasi (%)	
	Data <i>Training</i>	Data <i>Testing</i>
Regresi Logistik Biner	81,7	77,4
RBFN	92,96	80,64

Tabel 9 menunjukkan bahwa pemodelan status berat bayi baru lahir menggunakan *Radial Basis Function Network* menghasilkan nilai akurasi klasifikasi yang lebih besar dibandingkan dengan model regresi logistik baik pada data *training* maupun data *testing*.

5. KESIMPULAN

Berdasarkan hasil dan pembahasan, diperoleh kesimpulan, variabel-variabel prediktor yang memberi pengaruh signifikan adalah jumlah anak (X_3) dan berat badan ibu (X_4). Ketepatan klasifikasi regresi logistik biner adalah sebesar 81,7% untuk data *training* dan 77,4% untuk data *testing*. Ketepatan klasifikasi bayi baru lahir pada Puskesmas Pamenang Kota Jambi menggunakan RBFN adalah sebesar 92,96% untuk data *training* dan 80,64% untuk data *testing*. Berdasarkan ketepatan klasifikasi yang diperoleh, maka dapat diketahui bahwa metode *Radial Basis Function Network* (RBFN) menghasilkan akurasi lebih tinggi dibandingkan metode Regresi Logistik Biner, baik untuk data *training* maupun data *testing*. Hal ini menunjukkan bahwa metode *Radial Basis Function Network* (RBFN) lebih baik diterapkan dalam klasifikasi data status berat bayi lahir di Puskesmas Pamenang Kota Jambi pada tahun 2014 dibandingkan dengan model Regresi Logistik Biner.

DAFTAR PUSTAKA

- [1] Agresti, A. 2002. *Categorical Data Analysis Second Edition*. Jhon Wiley & Sons, Inc: USA.
- [2] Hastie, T., Tibshirani, R. and Friedman, J. H. 2009. *The Elements of Statistical Learning: Data Mining, Inference and Prediction Second Edition*. New York: Springer Science Bussines Media.
- [3] Haykin, S. 1999. *Neural Network: A Comprehensive Foundation*. Inc, Prentice Hall.
- [4] Hosmer, D.W. and Lemeshow, S. 2000. *Applied Logistic Regression Second Edition*. Jhon Wiley & Sons, Inc: USA
- [5] Kusumadewi, S. 2004. *Membangun Jaringan Syaraf Tiruan Menggunakan Matlab & Excel Link*. Graha Ilmu.
- [6] Miyata, S.M., dan Atikah, P. 2010. *Nutrisi Janin dan Ibu Hamil*. Yogyakarta: Nuha Medika.
- [7] Prasetyo, E. 2012. *Data Mining Konsep dan Aplikasi Menggunakan MATLAB*. Yogyakarta: ANDI Yogyakarta.
- [8] Sunarti, E. 2004. *Mengasuh dengan Hati*. Jakarta: Elex Media Komputindo.
- [9] Warsito, B. 2009. *Kapita Selekta Statistika Neural Network*. Semarang: BP UNDIP.