

**Klasifikasi Data Berat Bayi Lahir Menggunakan *Weighted Probabilistic Neural Network* (WPNN)**

**(Studi Kasus di Rumah Sakit Islam Sultan Agung Semarang)**

**Hasbi Yasin<sup>1</sup>, Dwi Ispriyanti<sup>2</sup>**

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

e-mail: <sup>1</sup> [hasbiyasin@live.undip.ac.id](mailto:hasbiyasin@live.undip.ac.id), <sup>2</sup> [dwiispriyanti@yahoo.com](mailto:dwiispriyanti@yahoo.com)

**DOI: 10.14710/medstat.10.1.61-70**

**Article Info:**

Received: 28 April 2017

Accepted: 14 Juni 2017

Available Online: 14 Agustus 2017

**Keywords:**

*Birthweight, Classification, LBW, WPNN.*

**Abstract:** Low Birthweight (LBW) is one of the causes of infant mortality. Birthweight is the weight of babies who weighed within one hour after birth. Low birthweight has been defined by the World Health Organization (WHO) as weight at birth of less than 2,500 grams (5.5 pounds). There are several factors that influence the BWI such as maternal age, length of gestation, body weight, height, blood pressure, hemoglobin and parity. This study uses a Weighted Probabilistic Neural Network (WPNN) to classify the birthweight in RSI Sultan Agung Semarang based on these factors. The results showed that the birthweight classification using WPNN models have a very high accuracy. This is shown by the model accuracy of 98.75% using the training data and 94.44% using the testing data.

## 1. PENDAHULUAN

Salah satu indikator untuk mengetahui derajat kesehatan masyarakat adalah Angka Kematian Neonatal (AKN). AKN adalah jumlah bayi yang meninggal satu bulan pertama setelah kelahiran (0-28 hari) yang dinyatakan dalam 1.000 kelahiran hidup pada tahun yang sama. AKN di Indonesia periode 5 tahun terakhir sejak 2007 mengalami stagnansi. Berdasarkan laporan SDKI (Survei Demografi dan Kesehatan Indonesia) 2007 dan 2012 AKN diestimasikan sebesar 19 per 1.000 kelahiran hidup (Kemenkes RI, 2013). Berdasarkan perkiraan organisasi kesehatan dunia *World Health Organization* (WHO) hampir semua (98%) dari lima juta kematian neonatal terjadi di negara berkembang. Lebih dari dua pertiga kematian itu terjadi pada periode neonatal dini (0-7 hari), yang umumnya dikarenakan Berat Bayi Lahir (BBL) kurang dari 2.500 gram (Azikin, 2011).

BBLR merupakan salah satu faktor utama yang berpengaruh terhadap kematian perinatal dan neonatal. Berdasarkan data dari *The Fifty Sixth Session of Regional Committee WHO for South-East Asia*, pada tahun 2005, kematian bayi terjadi pada usia neonatal dengan penyebab infeksi 33%, asfiksia atau trauma 28%, BBLR 24%, kelainan bawaan 10% dan lain-lain 5%. Risiko kematian BBLR 4 kali lebih besar dibandingkan bayi lahir dengan berat badan lebih dari 2500 gram (Yulifah dan Yuswanto, 2009). Bayi berat lahir rendah mempunyai kecenderungan ke arah peningkatan terjadinya infeksi dan mudah terserang komplikasi. Masalah pada BBLR yang sering terjadi adalah gangguan pada

sistem pernafasan, susunan saraf pusat, kardiovaskular, hematologi, gastro intestinal, ginjal dan termoregulasi (Kemenkes RI, 2014). Tingginya angka kejadian BBLR dipengaruhi oleh beberapa faktor antara lain faktor maternal, faktor janin serta faktor lingkungan (Jaya, 2009).

Klasifikasi terhadap status BBL dapat dilakukan dengan beberapa metode pendekatan, baik parametrik dan nonparametrik. Salah satu metode klasifikasi dengan pendekatan nonparametrik adalah metode *Neural Network* (NN). NN merupakan sebuah sistem pemrosesan informasi yang memiliki karakteristik mirip dengan jaringan syaraf pada makhluk hidup (Fausset, 1994). Salah satu model *Neural Network* yang digunakan untuk pengklasifikasian adalah *Probabilistic Neural Network* (PNN). PNN terdiri dari empat lapisan, yakni lapisan input, lapisan pola, lapisan penjumlahan dan lapisan output (Mishra, 2013). PNN sering digunakan untuk pengklasifikasian karena dapat memetakan setiap pola masukan ke sejumlah klasifikasi dengan proses yang cepat jika dibandingkan dengan model NN lain, dan dapat memetakan pola terhadap kelas secara optimal alias memiliki akurasi yang tinggi (Sofha *et al.*, 2015). PNN yang klasik menggunakan jarak euclid dan setiap kelas klasifikasi terboboti dengan nilai yang sama. Oleh karena itu Ramakrishnan dan Selvan (2006) melakukan modifikasi pada pembobotan setiap kelas klasifikasi yang dikenal dengan *Weighted PNN* (WPNN). Hasil modifikasi PNN menunjukkan adanya peningkatan akurasi dalam ketepatan klasifikasi yang dihasilkan (Ramakrishnan & El Emary, 2009). Oleh karena itu, dalam penelitian ini akan dilakukan pengklasifikasian status BBL dengan cara memperhatikan data historis ibu hamil di Rumah Sakit Islam Sultan Agung Semarang periode Januari-Desember tahun 2014. Metode klasifikasi yang digunakan dalam penelitian ini adalah *Weighted Probabilistic Neural Network* (WPNN).

## **2. TINJAUAN PUSTAKA**

### **2.1. Berat Bayi Lahir (BBL)**

Berat lahir adalah berat bayi yang ditimbang dalam 1 (satu) jam setelah lahir. Penimbangan ini perlu dilakukan untuk mengetahui apakah berat bayi lahir normal atau rendah. Bayi Berat Lahir Rendah (BBLR) atau *low birth weight infant* didefinisikan sebagai semua berat bayi yang baru lahir dengan berat lahir kurang dari 2.500 gram (Novita, 2011). Kejadian BBLR dipengaruhi oleh beberapa faktor antara lain faktor maternal, faktor janin serta faktor lingkungan. Faktor maternal antara lain usia ibu, status gizi ibu (tinggi dan berat badan, hemoglobin, tekanan darah dst.), paritas, jarak kehamilan, pendidikan ibu serta penyakit ibu. Faktor janin meliputi hidramnion atau polihidramnion, kehamilan ganda, dan kelainan janin. Sementara faktor lingkungan antara lain fasilitas kesehatan, gaya hidup (perokok, alkohol), serta keadaan sosial ekonomi (Jaya, 2009).

### **2.2. Probabilistic Neural Network**

*Probabilistic Neural Network* (PNN) merupakan algoritma klasifikasi dan merupakan suatu algoritma NN yang menggunakan fungsi probabilistik, tidak membutuhkan dataset yang besar dalam tahap pembelajarannya, serta memiliki kelebihan yaitu dapat mengatasi permasalahan yang ada pada *Back-Propagation* (BP) yaitu dapat mengatasi waktu pelatihan yang lama, terjebak pada global minimum, dan sulitnya perancangan arsitektur jaringan (Specht, 1990). Berdasarkan paper yang ada, PNN dapat digunakan untuk mengklasifikasikan secara akurat pada beberapa penelitian serta memiliki beberapa kelebihan dibandingkan dengan BP. Namun, PNN memiliki masalah pada penentuan parameter smoothing yang biasanya ditentukan dengan cara *trial and error* atau *user defined*.

Struktur PNN terdiri atas empat lapisan, seperti yang terlihat pada Gambar 1 yaitu *input layer*, *pattern layer*, *summation layer*, dan *decision layer*.

1. Lapisan Input (*Input layer*)

Lapisan ini merupakan objek yang terdiri atas nilai ciri yang akan diklasifikasikan pada  $r$  kelas.

2. Lapisan pola (*pattern layer*)

*Pattern layer* menggunakan satu node untuk setiap data pelatihan yang digunakan. Setiap node pola merupakan vektor jarak dari vektor *input* dengan vektor bobot  $V_{ij}$  yang dikalikan dengan bobot bias. Pada *pattern layer* inilah data *input* akan diolah oleh fungsi aktivasi. Fungsi aktivasi yang digunakan adalah fungsi aktivasi berbasis radial, yaitu dengan rumus (Kusumadewi, 2004):

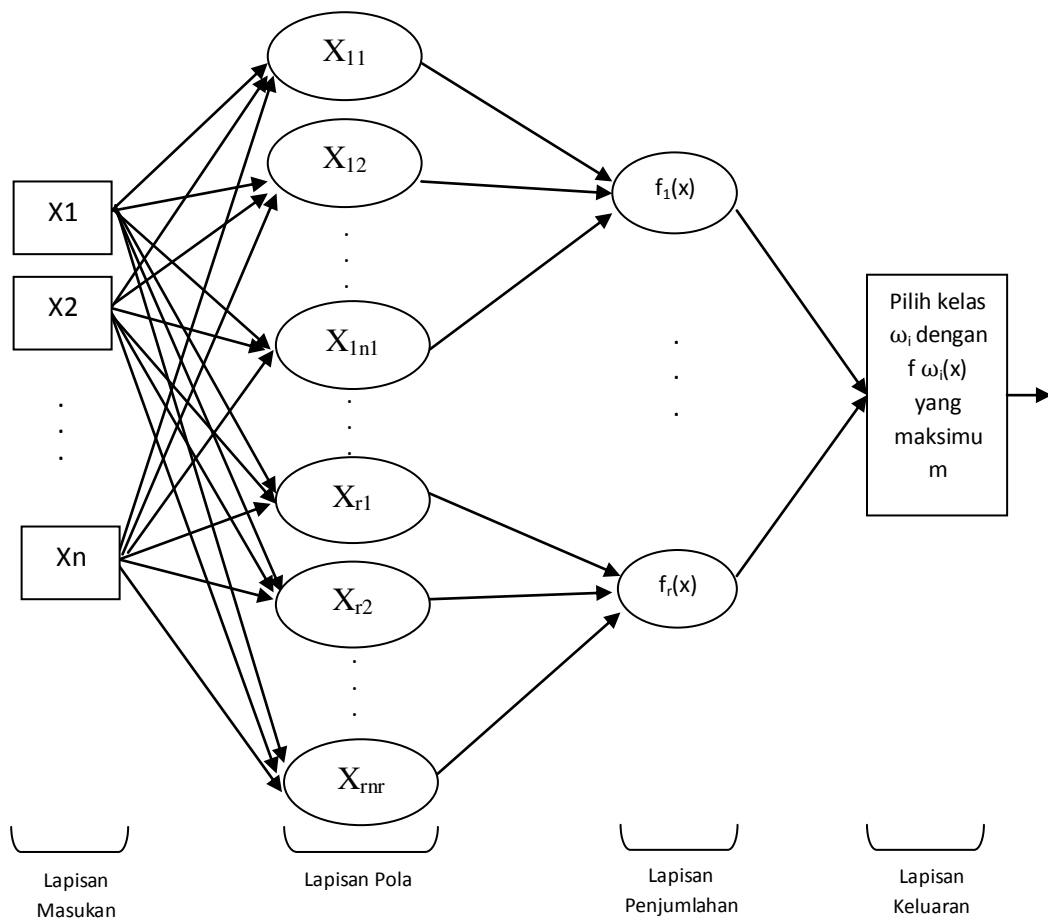
$$radbas(n) = \exp(-n^2), \text{ dengan } n = \text{neuron.}$$

3. Lapisan penjumlahan (*summation layer*)

*Summation layer* menerima masukan dari setiap node *pattern layer* yang terkait dengan kelas yang ada. *Summation layer* merupakan hasil penjumlahan dari *pattern layer* setiap kelasnya

4. Lapisan keluaran/keputusan (*output layer*)

Menentukan kelas dari *input* yang diberikan. *Input*  $x$  akan masuk kelas 1 jika nilai peluang masuk ke kelas 1  $\{f_1(x)\}$  paling besar dibandingkan peluang masuk ke kelas lainnya.



**Gambar 1.** Struktur model *Probabilistic Neural Network*

### 2.3. *Weighted Probabilistic Neural Network (WPNN)*

Menurut Ramakrishnan dan Selvan (2006) salah satu modifikasi dari PNN adalah dengan menambahkan faktor pembobot antara lapisan pola (*Pattern Layer*) dan lapisan penjumlahan (*Summation Layer*) pada model PNN yang konvensional. Sehingga model ini dinamakan dengan *Weighted Probabilistic Neural Network (WPNN)*. Sehingga struktur model WPNN adalah seperti pada Gambar 2. Nilai pembobot ini akan tinggi untuk pola dengan tingkat pemisahan kelas yang tinggi, begitu juga sebaliknya.

Misalkan matriks data *training* adalah  $\mathbf{M}$ . Algoritma pengujian dengan WPNN adalah sebagai berikut:

1. Tetapkan: Matriks input  $\mathbf{X}$  berukuran  $q \times p$   
Vektor target  $\mathbf{T}$  yang bersesuaian dengan matriks  $\mathbf{M}$ , berukuran  $n$  (terdiri dari  $r$  kelas).

2. Inisialisasi: Bobot lapisan input :  $\mathbf{V} = \mathbf{M}$

$$\text{Bobot bias lapisan input: } b = \frac{\sqrt{-\ln(0,5)}}{\sigma} \text{ dengan } \sigma = (0, 1]$$

$$\text{Bobot lapisan output: } \mathbf{W} = \mathbf{HT}.$$

$$\text{dengan } \mathbf{X} = \begin{bmatrix} X_{11} & X_{12} & \cdots & X_{1p} \\ X_{21} & X_{22} & \cdots & X_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ X_{q1} & X_{q1} & \cdots & X_{qp} \end{bmatrix}; \mathbf{V} = \begin{bmatrix} V_{11} & V_{12} & \cdots & V_{1p} \\ V_{21} & V_{22} & \cdots & V_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ V_{n1} & V_{n1} & \cdots & V_{np} \end{bmatrix}; \mathbf{W} = \begin{bmatrix} W_{1h} \\ W_{2h} \\ \vdots \\ W_{nh} \end{bmatrix}$$

dengan  $h=1, 2, \dots, r$  (kelas target yang bersesuaian dengan data latih).

3. Kerjakan untuk  $k=1$  sampai  $q$ , pada semua data yang akan diuji:

- a. Cari jarak  $X_k$  terhadap  $V_i, i=1, 2, \dots, n$  sebagai berikut:

$$D_{ki} = \sqrt{\sum_{j=1}^p (X_{kj} - V_{ij})^2}$$

- b. Cari aktivasi  $a1_{ki}$  sebagai berikut:

$$a1_{ki} = \exp\left((-b_i D_{ki})^2\right); \text{ dengan } i=1, 2, \dots, n.$$

- c. Cari  $a2_{kh}$  sebagai berikut:

$$a2_{kh} = \sum_{i=1}^n (a1_{ki} W_{ih}); \text{ dengan } W_{ih} = \text{adalah perkalian antara jarak mahalanobis}$$

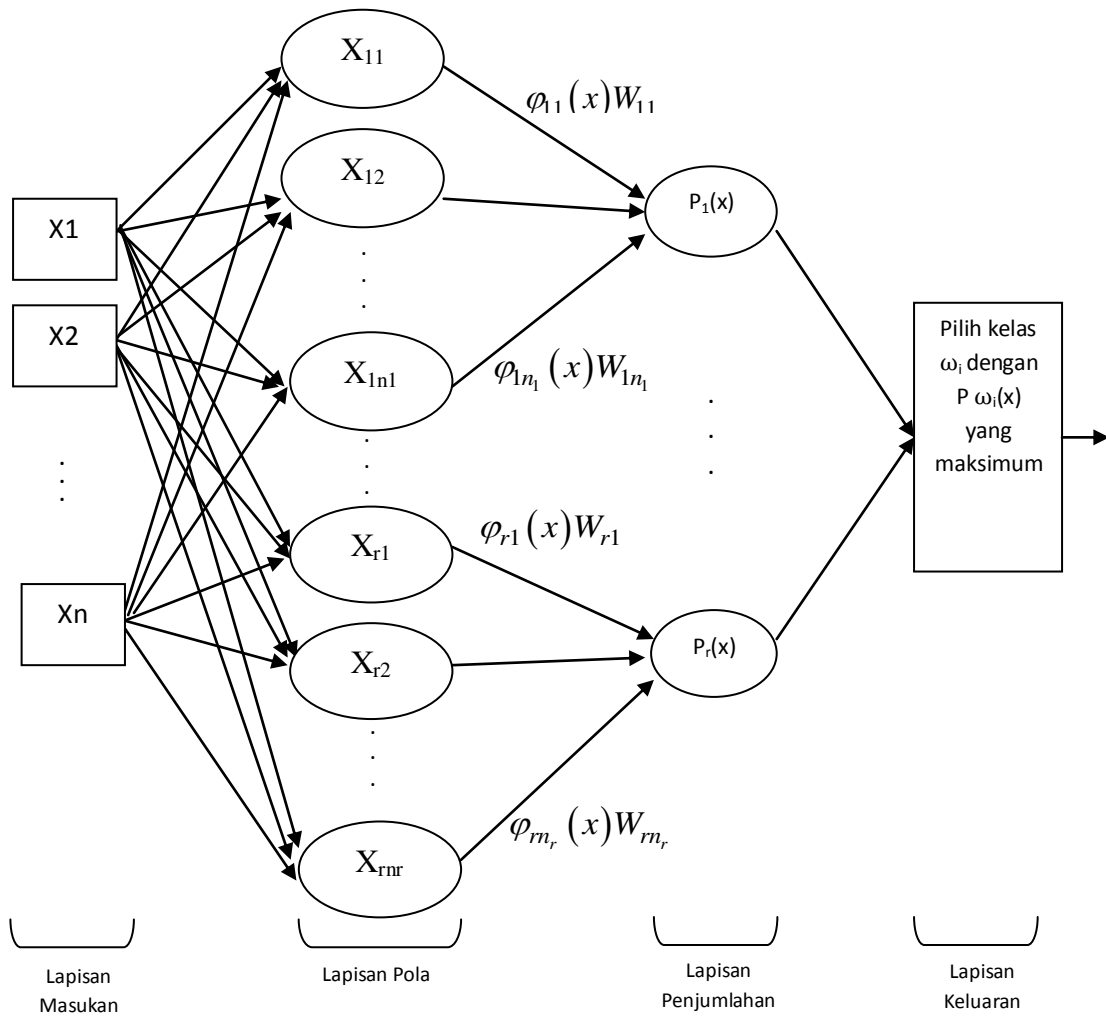
dengan vector target yang bersesuaian dan  $h=1, 2, \dots, r$ .

- d. Cari  $z$  sedemikian hingga  $a2_{kz} = \max(a2_{kh} | h=1, 2, \dots, r)$ .

- e. Tetapkan  $z$  sebagai kelas dari  $X_k$ .

### 2.4. *Metode Holdout*

Salah satu metode estimasi kinerja metode klasifikasi yang sederhana adalah metode *holdout*. Metode *holdout* membagi data pengamatan menjadi dua bagian yang digunakan secara berurutan untuk tahap pelatihan dan pengujian (Vercellis, 2009). Metode ini secara sederhana mengambil data training secara acak dari data yang ada dan kemudian menyisihkan data sisanya untuk digunakan sebagai data testing. Biasanya jumlah data latih yang digunakan berada diantara setengah dan dua pertiga dari keseluruhan data.



**Gambar 2.** Struktur model *Weighted Probabilistic Neural Network* (WPNN)

### 2.5. Ketepatan Klasifikasi

Matriks konfusi merupakan tabel pencatat hasil kerja sebuah klasifikasi. Tabel 1 merupakan matriks konfusi yang melakukan klasifikasi kategori biner. Setiap sel  $f_{ij}$  dalam matriks menyatakan banyaknya *record* (data) dari kelas  $i$  yang hasil prediksinya masuk ke kelas  $j$ . Misalnya, sel  $f_{11}$  adalah banyaknya data dalam kelas A yang secara benar dipetakan ke kelas A, dan  $f_{10}$  adalah data dalam kelas A yang dipetakan secara salah ke kelas B.

**Tabel 1.** Matriks Konfusi

$f_{ij}$		Kelas Hasil Prediksi ( $j$ )	
		Kelas = A	Kelas = B
Kelas asli ( $i$ )	Kelas = A	$f_{11}$	$f_{10}$
	Kelas = B	$f_{01}$	$f_{00}$

Berdasarkan isi matriks konfusi, dapat diketahui banyaknya data dari masing-masing kelas yang diprediksi secara benar, yaitu  $(f_{11} + f_{00})$ , dan data yang

diklasifikasikan secara salah, yaitu  $(f_{01} + f_{10})$ . Maka dapat dihitung tingkat akurasi dan tingkat kesalahan prediksi atau *Apparent Error Rates* (APER) (Johnson dan Wichern, 2007):

$$1. \text{ Akurasi} = \frac{(f_{11} + f_{00})}{(f_{11} + f_{01} + f_{10} + f_{00})}$$

$$2. \text{ Apparent Error Rates (APER)} = \frac{(f_{01} + f_{10})}{(f_{11} + f_{01} + f_{10} + f_{00})}$$

### 3. METODE PENELITIAN

#### 3.1. Sumber Data dan Variabel Penelitian

Data yang digunakan dalam penelitian ini merupakan data sekunder yang berasal dari buku status pasien ibu melahirkan yang terdapat pada Rekam Medis Rumah Sakit Islam Sultan Agung Semarang. Penelitian ini menggunakan dua variabel, yaitu berat bayi lahir sebagai variabel respon, sedangkan variabel prediktornya adalah faktor-faktor yang mempengaruhi berat bayi lahir yang berasal dari ibu seperti umur ibu, lama gestasi, tinggi badan, berat badan, tensi darah, hemoglobin serta paritas. Jumlah data yang digunakan adalah sebanyak 98 data.

**Tabel 2.** Variabel Penelitian

Variabel	Keterangan	Satuan
Y	Berat bayi lahir (BBL) BBL < 2500 gr = 1 BBL ≥ 2500 gr = 2	katégorik
X <sub>1</sub>	Usia ibu	Tahun
X <sub>2</sub>	Lama Gestasi (Kehamilan)	Minggu
X <sub>3</sub>	Tinggi badan ibu	Cm
X <sub>4</sub>	Berat badan ibu	Kg
X <sub>5</sub>	Tensi darah ibu	mmHg
X <sub>6</sub>	Hemoglobin ibu	g/dL
X <sub>7</sub>	Paritas	Anak

#### 3.2. Metode Analisis

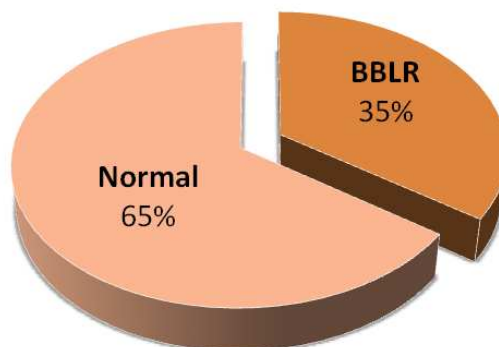
Penelitian ini menggunakan *software* GUI Matlab. Adapun Langkah-langkah yang dilakukan untuk klasifikasi risiko BBLR menggunakan WPNN dalam penelitian ini adalah sebagai berikut:

1. membagi data menjadi data *training* dan *testing* dengan prosedur *holdout*
2. menentukan nilai  $\sigma$  (*smoothing parameter*) secara *trial and error*,
3. membuat pola WPNN menggunakan data *training*,
4. menguji pola data *testing* berdasarkan data *training* tersebut,
5. menghitung nilai akurasi klasifikasi WPNN
6. ulangi langkah 1 sampai 5 sehingga diperoleh nilai akurasi yang tinggi
7. prediksi klasifikasi risiko BBLR dengan model terbaik

### 4. HASIL DAN PEMBAHASAN

Data yang digunakan adalah data BBL yang diperoleh dari Rekam Medis RSI Sultan Agung Semarang tahun 2014 sebanyak 98 unit observasi. Sebagai variabel respon (Y)

adalah BBL yang memiliki dua kategori yaitu BBLR dan Normal. Gambar 3 menunjukkan bahwa dari 98 sampel terdapat kejadian bayi BBLR sebanyak 34 bayi atau sebesar 35%. Sementara bayi lahir normal sebanyak 64 bayi atau sebesar 65%. Sedangkan statistik deskriptif dari masing-masing variabel prediktor disajikan dalam Tabel 3.



**Gambar 3.** Diagram Status BBL

**Tabel 3.** Statistik Deskriptif Variabel Bebas (X) Data Penelitian

Variabel	Rata-rata	Simpangan baku	Min	Maks
X1	28,77	6,41	15	41
X2	38,56	2,25	24	42
X3	63,79	12,39	45	109
X4	153,18	6,37	139	166
X5	119,85	13,89	100	190
X6	11,90	1,35	7,8	14,6
X7	2,37	1,33	1	7

Tabel 3 menunjukkan bahwa rata-rata umur ibu (X1) melahirkan adalah 28,77 tahun dengan simpangan baku sebesar 6,41 dengan umur ibu melahirkan termuda adalah 15 tahun dan yang tertua adalah 41 tahun. Sementara untuk masa gestasi (X2) memiliki rata-rata sebesar 38,56 minggu, serta terdapat kejadian melahirkan yang hanya dalam masa gestasi 24 minggu bahkan ada yang lebih dari masa normal yaitu 42 minggu. Sama halnya dengan variabel bebas X1 dan X2, statistik deskriptif tentang variabel bebas lain seperti Berat badan (X3), Tinggi badan (X4), Tensi darah/sistolik (X5), Hb (X6) serta Paritas (X7) dapat dilihat pada Tabel 3.

#### 4.1 Klasifikasi Risiko BBLR Menggunakan WPNN

Klasifikasi menggunakan WPNN dilakukan untuk menentukan parameter-parameter bobot yang optimal, yaitu yang menghasilkan tingkat kesalahan terkecil. Ukuran kesalahan yang digunakan adalah *Apparent Error Rate* (APER). Pada penelitian ini, data terdiri dari 98 pengamatan, dengan pembagian 80% data training (80 observasi) dan 20% data testing (18 observasi). Pembagian data dilakukan dengan metode *holdout* yaitu data dipilih secara acak proporsional sesuai dengan banyaknya kelas klasifikasi. Proses penentuan model WPNN terbaik dilakukan dengan menggunakan GUI WPNN seperti pada Gambar 4. Hasil pengolahan data menunjukkan bahwa ketepatan klasifikasi cenderung sama untuk nilai penghalus lebih dari 0,5 seperti terlihat pada Tabel 4.



**Tabel 4.** Ketepatan Klasifikasi WPNN

Nilai Penghalus ( $\sigma$ )	Data Training (%)	Data Testing (%)
0,2	98,75	55,56
0,4	98,75	83,33
0,6	98,75	94,44
0,8	98,75	94,44
1	98,75	94,44

Berdasarkan parameter tersebut diperoleh informasi bahwa bobot lapisan input terdiri dari matriks berukuran 80 baris dan 7 kolom yang merupakan data trainingnya. Sedangkan nilai bobot bias lapisan input dengan nilai penghalus ( $\sigma$ ) sama dengan 1 adalah 0,8326. Dengan menggunakan metode WPNN maka bobot antara lapisan pola dan lapisan penjumlahan untuk setiap kelas klasifikasi akan berbeda-beda sesuai dengan jarak mahalnobis antar pengamatan dalam data training.

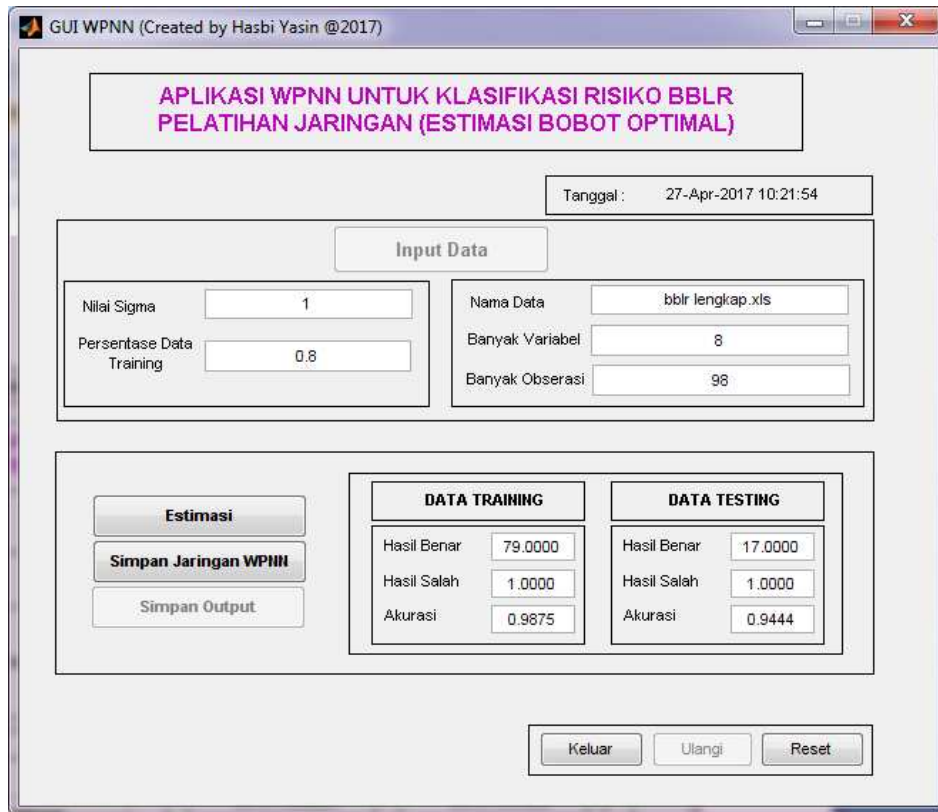
Model terbaik untuk pemodelan klasifikasi risiko BBLR yang dibangun berdasarkan parameter tersebut mempunyai tingkat akurasi model klasifikasi sebesar 98,75% untuk data training. Sedangkan dengan menggunakan data testing diperoleh tingkat akurasi sebesar 94,44%. Hal ini menunjukkan bahwa model WPNN dapat mengenali dengan baik pola dari klasifikasi risiko BBLR. Selanjutnya, dengan parameter bobot optimal yang diperoleh digunakan untuk memprediksi status BBL dari kelahiran seorang bayi.

#### 4.2 Aplikasi Klasifikasi Risiko BBLR Menggunakan GUI WPNN

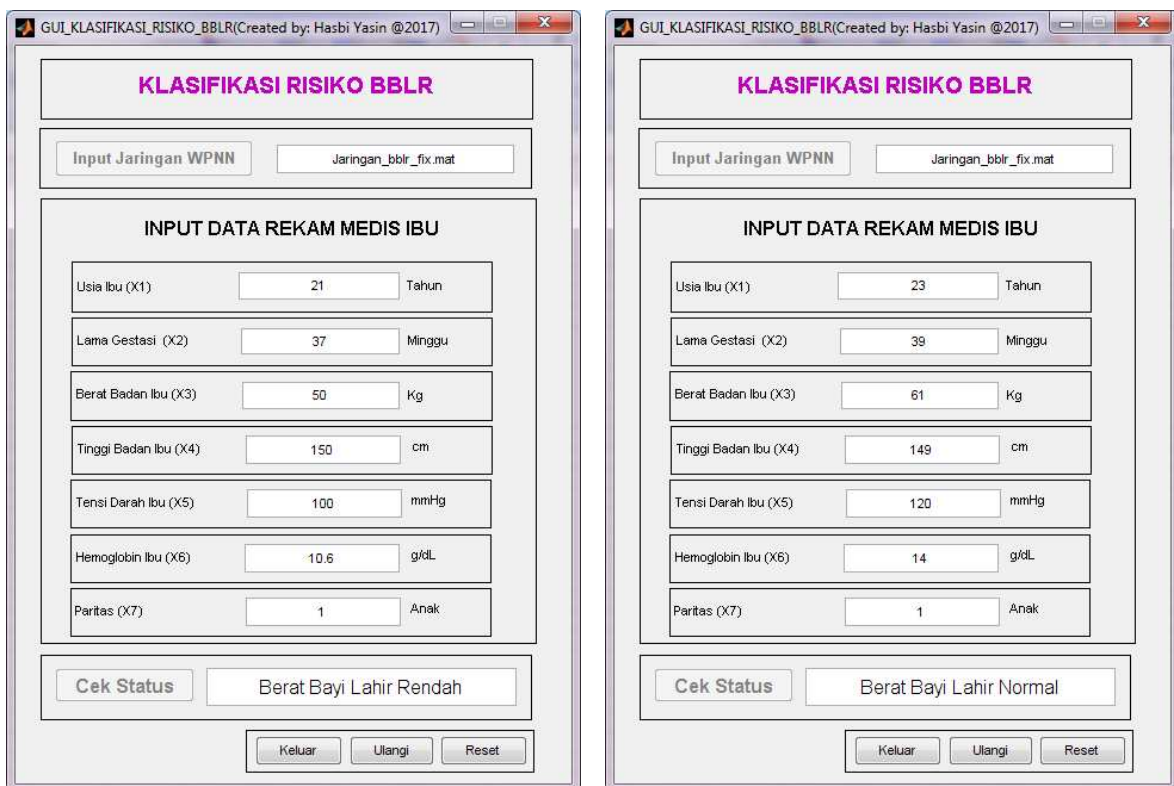
Setelah diperoleh bobot optimal dari model terbaik, maka langkah selanjutnya adalah membangun suatu aplikasi GUI untuk mengklasifikasikan status BBL dari kelahiran seorang bayi. Jaringan optimal dari hasil pengolahan data sebelumnya digunakan sebagai input bobot optimalnya. Input data yang digunakan adalah data rekam medis ibu melahirkan yang diperoleh dari RSI Sultan Agung Semarang. Tampilan contoh penggunaan GUI WPNN berdasarkan variabel yang digunakan dalam klasifikasi status BBL adalah seperti pada Gambar 5. Adapun langkah-langkahnya adalah:

1. Inputkan jaringan WPNN optimal dengan cara klik tombol “**Input Jaringan WPNN**” kemudian carilah file jaringan optimal hasil pelatihan dari Gambar 4.
2. Inputkan data rekam medis ibu melahirkan yang terdiri dari 7 variabel sesuai dengan masing-masing tempat telah disediakan.
3. Klik tombol “**Cek Status**” untuk prediksi status BBL pada bayi yang akan dilahirkan.
4. Klik “**Ulang**” untuk mengganti data rekam medis ibu.
5. Klik “**Reset**” untuk mengganti jaringan WPNN optimal.





**Gambar 4.** Tampilan GUI WPNN untuk penentuan bobot optimal



**Gambar 5.** Contoh Aplikasi GUI WPNN untuk Klasifikasi Status BBL

## 5. KESIMPULAN

Hasil penelitian menunjukkan bahwa pemodelan klasifikasi risiko BBLR dengan menggunakan model WPNN mempunyai tingkat akurasi yang sangat tinggi. Hal ini ditunjukkan dengan tingkat akurasi model klasifikasi yang dibangun berdasarkan data training adalah sebesar 98,75%. Sedangkan dengan menggunakan data testing diperoleh tingkat akurasi sebesar 94,44%.

## UCAPAN TERIMA KASIH

Penelitian ini dibiayai oleh dana DIPA PNPB FSM Universitas Diponegoro Tahun Anggaran 2016 sesuai dengan Surat Perjanjian Tugas Pelaksanaan Penelitian para Dosen di Departemen Statistika No. 1108/UN7.3.8/PG/2016 Tanggal 1 Maret 2016.

## DAFTAR PUSTAKA

- Azikin, G. 2011. *Gambaran Kejadian Bayi Berat Lahir Rendah (BBLR) di Rumah Sakit Umum*. <http://kebidanan-kti.blogspot.com/2011/11/gambaran-kejadian-bayi-berat-lahir-19.html>, (diakses pada hari Rabu, 10 Maret 2016).
- Fausset, L. 1994. *Fundamental of Neural Network: Architecture, Algorithm, and Application*. New Jersey: Prentice-Hall.
- Jaya, N. 2009. Analisis Faktor Resiko Kejadian Bayi Berat Lahir Rendah di Rumah Sakit Ibu dan Anak Siti Fatimah Kota Makassar. *Media Gizi Pangan* Vol. VII Edisi 1: 49-54.
- Kemendes RI. 2013. *Profil Kesehatan Indonesia 2012*. Jakarta: Kementerian Kesehatan Republik Indonesia.
- Kemendes RI. 2014. *Profil Kesehatan Indonesia 2013*. Jakarta: Kementerian Kesehatan Republik Indonesia.
- Kusumadewi, S. 2004. Klasifikasi Pola Menggunakan Jaringan Probabilistik. *Seminar Nasional Aplikasi Teknologi Informasi* Hal: J59-J64.
- Mishra, M., Jena, A. R., Das, Raja. 2013, A Probabilistic Neural Network Approach For Classification of Vehicle. *International Journal of Application or Innovation in Engineering & Management* Vol. 2, No. 7 : 367-371.
- Novita, R.V.T. 2011. *Keperawatan Maternitas*. Bogor: Ghalia Indonesia.
- Ramakrishnan, S., & El Emary, I.M.M., 2009, Comparative Study between Traditional and Modified Probabilistic Neural Networks, *Telecommunication System* 40:67-74. DOI 10.1007/s11235-008-9138-5.
- Ramakrishnan, S., & Selvan, S., 2006, Classification of Brain Tissues Using Multiwavelet Transformation and Probabilistic Neural Network. *International Journal of Simulation: Systems, Science and Technology, A Publication of the United Kingdom Simulation Society*, 7(9):9-25.
- Sofha, E., Yasin, H., & Rahmawati, R., 2015, Klasifikasi Data Berat Bayi Lahir Menggunakan Probabilistic Neural Network dan Regresi Logistik (Studi Kasus di Rumah Sakit Islam Sultan Agung Semarang Tahun 2014), *Jurnal Gaussian* Vol. 4 No. 4.
- Specht, D.F. 1990. *Probabilistic Neural Networks*. *Neural Networks* Vol. 3: 109-118.
- Vercellis, C. 2009. *Business Intelligence: Data Mining and Optimization for Decision Making*. Chichester: John Wiley & Sons Ltd.
- Yulifah, R. dan Yuswanto, T.J.A. 2009. *Asuhan Kebidanan Komunitas*. Jakarta: Salemba Medika.