

Pengklasifikasian Status Gizi Balita di Puskesmas Sempaja Samarinda menggunakan Probabilistic Neural Network (PNN) Tahun 2019**Classification of Toddler Nutritional Status at Puskesmas Sempaja Samarinda using Probabilistic Neural Network (PNN) in 2019****Putri Ayu Dwi Lestari¹, Memi Nor Hayati² dan Yuki Novia Nasution³**^{1,2}Laboratorium Statistika Terapan FMIPA Universitas Mulawarman³Laboratorium Matematika Komputasi FMIPA Universitas MulawarmanE-mail: putriayudlestari@gmail.com**Abstract**

Probabilistic Neural Network (PNN) is a model in Artificial Neural Networks (ANN) that is used for classification. PNN depends on the smoothing parameter (α). PNN has the advantage of being able to value of problems that previously existed in the back propagation method of ANN. The PNN method in this study was applied to the nutritional status of toddlers. Assessment of the nutritional status of toddlers can be determined through measurements of the human body known as anthropometry. Parameters for determining nutritional status based on anthropometry are age, weight and height. Therefore, in this study, a classification of the nutritional status of children under five is carried out to determine whether the toddler is experiencing good nutrition or poor nutrition. It was found that PNN with the best classification accuracy rate on the nutritional status of toddlers, namely the proportion of training data and testing data of 50%: 50% with $\alpha = 1$, with accuracy results between training data and training data of 85% and accuracy results between data testing of the training data by 70%.

Keywords : probabilistic neural network, smoothing parameters, toddler nutritional status**Pendahuluan**

Data mining adalah proses yang mempekerjakan satu atau lebih teknik pembelajaran komputer (*machine learning*) untuk menganalisis dan mengekstraksi pengetahuan (*knowledge*) secara otomatis. Definisi lain diantaranya adalah pembelajaran berbasis induksi (*induction-based learning*) adalah proses pembentukan definisi-definisi konsep umum yang dilakukan dengan cara mengobservasi contoh-contoh spesifik dari konsep-konsep yang akan dipelajari. *Knowledge Discovery in Database* (KDD) adalah penerapan metode saintifik pada *data mining*. Dalam konteks ini *data mining* merupakan satu langkah dari proses KDD (Hermawati, 2013).

Menurut Prasetyo (2012), klasifikasi merupakan suatu pekerjaan menilai objek data untuk memasukkannya ke dalam kelas tertentu dari sejumlah kelas yang tersedia. Menurut Specht (1990) dalam Sofha dkk (2015), *Probabilistic Neural Network* (PNN) merupakan Jaringan Saraf Tiruan (JST) yang dapat digunakan untuk menyelesaikan masalah klasifikasi. Proses yang dilakukan oleh PNN dapat berlangsung lebih cepat bila dibandingkan dengan *JST Back Propagation*.

Pentingnya gizi sebagai modal pembangunan bangsa menunjukkan bahwa perlu adanya penanganan yang serius terkait masalah kekurangan gizi di Indonesia. Status gizi adalah keadaan tubuh sebagai akibat dari penyerapan dan penggunaan nutrisi dari makanan. Terpenuhi atau

tidaknya asupan gizi pada balita dapat dilihat berdasarkan status gizinya. Status gizi baik atau normal adalah merupakan keadaan yang sangat diinginkan oleh semua orang (Supariasa, 2002).

Jumlah status gizi balita di Kota Samarinda meningkat pada tahun 2012 sampai dengan tahun 2013, kemudian tahun 2014 menurun secara signifikan. Jumlah balita gizi buruk kembali meningkat pada tahun 2015, kemudian terus meningkat pada tahun 2016 tercatat ada 67 balita gizi buruk, terdiri 37 balita laki-laki dan 30 balita perempuan dengan persentase perawatan balita gizi buruk mencapai 100%. Kasus gizi buruk balita terbanyak ditemukan di wilayah kecamatan Sungai Pinang, terbanyak kedua ditemukan di wilayah Samarinda Ilir (Dinas Kesehatan Kota Samarinda, 2016)

Menurut Sartika (2011), Penilaian status gizi balita dapat ditentukan melalui pengukuran tubuh manusia yang dikenal dengan istilah Antropometri. Antropometri itu sendiri merupakan standar yang dipakai di Indonesia dalam menentukan status gizi balita yang mengacu pada *World Health Organization – National Centre for Health Statistics* (WHO – NCHS).

Berdasarkan latar belakang yang telah dijelaskan sebelumnya, penelitian kali ini, penulis mengusulkan penelitian yang berjudul "Pengklasifikasian Status Gizi Balita Di Puskesmas Sempaja Samarinda Menggunakan

Probabilistic Neural Network (PNN) Tahun 2019”.

Data Mining

Data mining adalah proses yang mempekerjakan satu atau lebih teknik pembelajaran komputer (*machine learning*) untuk menganalisis dan mengekstraksi pengetahuan (*knowledge*) secara otomatis. Definisi lain diantaranya adalah pembelajaran berbasis induksi (*induction-based learning*) adalah proses pembentukan definisi-definisi konsep umum yang dilakukan dengan cara mengobservasi contoh-contoh spesifik dari konsep-konsep yang akan dipelajari. *Knowledge Discovery in Database* (KDD) adalah penerapan metode saintifik pada *data mining*. Dalam konteks ini *data mining* merupakan satu langkah dari proses KDD (Hermawati, 2013).

Konsep Klasifikasi

Menurut Prasetyo (2012), klasifikasi merupakan suatu pekerjaan menilai objek data untuk memasukkannya ke dalam kelas tertentu dari sejumlah kelas yang tersedia. Dalam klasifikasi ada dua pekerjaan utama yang dilakukan, yaitu (1) pembangunan model sebagai prototipe untuk disimpan sebagai memori dan (2) penggunaan model tersebut untuk melakukan pengenalan/klasifikasi/prediksi pada suatu objek data lain agar diketahui di kelas mana objek data tersebut dalam model yang sudah disimpannya.

Jaringan Syaraf Tiruan (JST)

Menurut Hermawan dan Suyanto (2006), JST didefinisikan sebagai suatu sistem pemrosesan informasi yang mempunyai karakteristik menyerupai jaringan saraf manusia. JST tercipta sebagai suatu generalisasi model matematis dari pemahaman manusia (*human cognition*) yang didasarkan atas asumsi sebagai berikut:

1. Pemrosesan informasi terjadi pada elemen sederhana yang disebut *neuron*.
2. Isyarat mengalir di antara sel saraf/*neuron* melalui suatu sambungan penghubung.
3. Setiap sambungan penghubung memiliki bobot yang bersesuaian. Bobot ini akan digunakan untuk menggandakan/mengalihkan isyarat yang dikirim melaluinya.
4. Setiap sel saraf akan menerapkan fungsi aktivasi terhadap isyarat hasil penjumlahan berbobot yang masuk kepadanya untuk menentukan isyarat keluarannya.

Probabilistic Neural Network (PNN)

Menurut Specht (1990) dalam Sofha dkk (2015), *probabilistic neural network* (PNN) merupakan JST yang dapat digunakan untuk menyelesaikan masalah klasifikasi. Proses yang

dilakukan oleh PNN dapat berlangsung lebih cepat bila dibandingkan dengan *JST Back Propagation*. Hal ini disebabkan PNN hanya membutuhkan satu kali iterasi pelatihan bila dibandingkan dengan *JST Back Propagation* yang membutuhkan beberapa kali iterasi pelatihan.

Struktur PNN terdiri atas empat lapisan, yaitu *input layer*, *pattern layer*, *summation layer* dan *decision layer*.

1. Input layer

Input layer merupakan objek yang terdiri atas nilai 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 x dengan vektor bobot v_{ij} yang dikalikan dengan bobot bias. Fungsi aktivasi yang digunakan adalah fungsi aktivasi berbasis radial, yaitu dengan rumus:

$$radbas(n) = e^{-n^2} \quad (1)$$

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 A jika nilai peluang masuk kelas A $\{f_A(x)\}$ paling besar dibandingkan peluang masuk ke kelas lainnya (Kusumadewi, 2004a).

Algoritma PNN

Menurut Kusumadewi (2004b), algoritma pengklasifikasian pada PNN dengan memisalkan matriks V adalah data *training* adalah sebagai berikut:

1. Menetapkan: Matriks *input* X berukuran $q \times p$ di mana q adalah jumlah data *input* dan p adalah banyaknya variabel *input*. Data *input* dapat berupa data *training* atau data *testing*.

$$X = \begin{bmatrix} X_{11} & X_{12} & \dots & X_{1j} & \dots & X_{1p} \\ X_{21} & X_{22} & \dots & X_{2j} & \dots & X_{2p} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ X_{k1} & X_{k2} & \dots & X_{kj} & \dots & X_{kp} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ X_{q1} & X_{q2} & \dots & X_{qj} & \dots & X_{qp} \end{bmatrix}$$

dimana:

- k = banyaknya pengamatan data *input* (1,2,..., q)
 - j = banyaknya variabel data *input* (1,2,..., p)
2. Menetapkan matriks target W yang bersesuaian dengan matriks V , berukuran q

(terdiri dari r kelas). Di mana matriks target **W** ini terdiri dari 2 kelas, dengan vektor target akan bernilai (1,0) untuk kelas 1 dan (0,1) untuk kelas 2 dengan;

$$V = \begin{bmatrix} V_{11} & V_{12} & \dots & V_{1j} & \dots & V_{1p} \\ V_{21} & V_{22} & \dots & V_{2j} & \dots & V_{2p} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ V_{i1} & V_{i2} & \dots & V_{ij} & \dots & V_{ip} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ V_{n1} & V_{n2} & \dots & V_{nj} & \dots & V_{np} \end{bmatrix}; W = \begin{bmatrix} w_{1h} \\ w_{2h} \\ \vdots \\ w_{ih} \\ \vdots \\ w_{nh} \end{bmatrix}$$

dimana:

i = banyaknya baris pada data *training* (1,2,...,n)

h = kelas data yang bersesuaian dengan data *training* (1,2,..., r)

3. Menetapkan bobot bias lapisan input

$$b = \frac{\sqrt{-\ln(0,5)}}{\sigma} \quad (2)$$

dimana:

b = bobot bias lapisan input

α = parameter penghalus dengan $0 < \alpha \leq 1$

4. Masing-masing poin dikerjakan untuk *k*=1 sampai *q* pada semua data *input* (data *training* dan data *testing*):

- a. Mencari jarak matriks **X** terhadap matriks **V**. Perhitungan jarak merupakan jarak Euclid antara vektor input x_k dengan vektor bobot v_i dikalikan bobot bias sebagai berikut:

$$D_{ki} = \sqrt{\sum_{j=1}^p (X_{kj} - V_{ij})^2} \quad (3)$$

dimana:

D_{ki} = jarak data ke *k* dan ke *i* pada matriks jarak Euclid antara vektor input x_k dengan vektor bobot v_i

X_{kj} = data ke *k* variabel ke *j* pada matriks **X**

V_{ij} = data ke *i* variabel ke *j* pada matriks **V**

- b. Mencari nilai aktivasi a_{1ki} . Perhitungan nilai aktivasi yang menggunakan fungsi *radbas* dilakukan pada setiap indeks matriks jarak sebagai berikut:

$$a_{1ki} = e^{-(b_i D_{ki})^2} \quad (4)$$

dimana

a_{1ki} = nilai aktivasi baris ke *k* dan kolom ke *i*

b_i = bobot bias lapisan input ke *i*

- c. Melakukan perhitungan nilai probabilitas tiap kelompok dilakukan dengan melakukan perkalian antara matriks pada nilai aktivasi dan matriks target **W** sebagai berikut :

$$a_{2kh} = \sum_{i=1}^n (a_{1ki} * W_{ih}); \quad (5)$$

dimana:

a_{2kh} = penjumlahan nilai aktivasi dikalikan nilai target ke *k* pada matriks **X** dan data ke *i* pada matriks **V**

W_{ih} = data ke *i* kelas ke *h* pada matriks target **W**

- d. Mencari nilai maksimum (*z*) dari a_{2kh} dengan rumus hingga $a_{2kz} = \max (a_{2kh}$

$$| h=1,2,\dots,r)$$

- e. Menetapkan *z* sebagai kelas dari klasifikasi.

Normalisasi Data

Menurut Prasetyo (2014), variabel yang memiliki nilai yang besar memiliki pengaruh yang lebih kecil dalam melakukan prediksi klasifikasi daripada variabel yang memiliki nilai yang kecil. Untuk mengatasi masalah tersebut, dapat digunakan teknik normalisasi sehingga semua variabel terdapat di dalam jangkauan yang sama. Cara menentukan nilai normalisasi adalah dengan menghitung nilai rata-rata dan varian seperti pada Persamaan (6) dan Persamaan (7).

$$\bar{X}_j = \frac{1}{n} \sum_{i=1}^n X_{ij} \quad (6)$$

$$\sigma_j^2 = \frac{1}{n-1} \sum_{i=1}^n (X_{ij} - \bar{X}_j)^2 \quad (7)$$

$$X_{ij} = \frac{X_{ij} - \bar{X}_j}{\sigma_j} \quad (8)$$

dimana:

n = banyak data

X_{ij} = data ke-*i* pada variabel ke-*j* dimana $i=1,2,\dots,n$ dan $j=1,2,\dots,p$

\bar{X}_j = rata-rata variabel ke-*j*

σ_j = standar deviasi variabel ke-*j*

σ_j^2 = varians variabel ke-*j*

\hat{X}_{ij} = normalisasi data ke-*i* variabel ke-*j*

Data Training dan Data Testing

Data yang digunakan dalam klasifikasi umumnya dibagi menjadi data *training* dan data *testing*. Data atau vektor yang sudah diketahui sebelumnya untuk label kelas dan digunakan untuk membangun model *classifier* disebut dengan data *training*. Data atau vektor yang belum diketahui (dianggap belum diketahui) label kelasnya menggunakan model *classifier* yang sudah dibangun disebut data *testing* (Prasetyo,2014). Jumlah data *training* dan data *testing* dapat dihitung menggunakan Persamaan (9) dan Persamaan (10).

$$\text{jumlah data training} = \text{Proporsi data training} \times n \quad (9)$$

$$\text{jumlah data testing} = n - \text{jumlah data training} \quad (10)$$

dimana: *n* = Jumlah seluruh data (data *training* + data *testing*)

Akurasi

Menurut Prasetyo (2012), sebuah sistem yang melakukan klasifikasi diharapkan dapat

melakukan klasifikasi semua set data dengan benar, tetapi tidak dapat dipungkiri bahwa kinerja suatu sistem tidak bisa 100% benar. Sehingga, sebuah sistem klasifikasi juga harus diukur kinerjanya. Umumnya, pengukuran kinerja klasifikasi dilakukan dengan matriks konfusi (*confusion matrix*).

Untuk menghitung akurasi digunakan formula sebagai berikut:

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

Untuk menghitung laju *error* (kesalahan prediksi) digunakan formula sebagai berikut:

$$\begin{aligned} \text{laju error} &= \frac{\text{jumlah data yang diprediksi secara salah}}{\text{jumlah prediksi yang dilakukan}} \\ &= \frac{f_{10} + f_{01}}{f_{11} + f_{10} + f_{01} + f_{00}} \end{aligned} \quad (12)$$

Balita

Balita terbagi menjadi dua kategori berdasarkan karakteristiknya yaitu batita (1-3 tahun) dan anak usia prasekolah (3-5 tahun). Batita dan anak usia pra sekolah memiliki karakteristik pada laju pertumbuhan yang berbeda. Seorang batita memiliki laju pertumbuhan yang lebih cepat daripada anak usia pra sekolah. Asupan makanan pada batita pun juga masih membutuhkan peranan orang tua. Berbeda dengan anak pra sekolah, mereka sudah bisa memilih makanan sesuai selera mereka. Pada anak pra sekolah, perilaku juga mulai berubah karena pada masa ini mereka mulai mengenal lingkungan sekitar (Nugraha dkk, 2017).

Status Gizi Balita

Status gizi adalah keadaan tubuh sebagai akibat dari penyerapan dan penggunaan nutrisi dari makanan. Terpenuhi atau tidaknya asupan gizi pada balita dapat dilihat berdasarkan status gizinya. Status gizi baik atau normal adalah merupakan keadaan yang sangat diinginkan oleh semua orang (Supriasa, 2002).

Antropometri

Menurut Sartika (2011), Penilaian status gizi balita dapat ditentukan melalui pengukuran tubuh manusia yang dikenal dengan istilah Antropometri. Antropometri itu sendiri merupakan standar yang dipakai di Indonesia dalam menentukan status gizi balita yang mengacu pada *World Health Organization – National Centre for Health Statistics (WHO – NCHS)*.

Hasil dan Pembahasan

1. Statistika Deskriptif

Dalam melakukan analisis statistika deskriptif dilakukan dengan menampilkan tabel untuk melihat nilai maksimum, nilai minimum, rata-rata dan standar deviasi dari tiga variabel yang digunakan yaitu UB, TB, serta BB. Adapun nilai-nilai tersebut dapat dilihat pada Tabel 1

Tabel 1 Statistika Deskriptif

Variabel	Maks	Min	Rata-rata	Standar Deviasi
UB (X_1)	60	1	28,45	20,171
TB (X_2)	115	51	85,94	16,737
BB (X_3)	21	3	10,57	3,690

2. Normalisasi Data

Dalam melakukan normalisasi data digunakan Persamaan (6), (7) dan (8) untuk 73 data klasifikasi status gizi balita.

3. Menentukan Smoothing Parameter

Klasifikasi PNN merupakan metode yang bergantung pada nilai *smoothing parameter* (α) yang digunakan. Dalam penelitian ini penentuan *smoothing parameter* dilakukan dalam selang 0,1 sampai 1.

4. Melakukan Randomisasi Data

Selanjutnya melakukan randomisasi data yang bertujuan agar setiap data memiliki kesempatan yang sama untuk menjadi data *training* dan *testing*.

5. Membagi Data Training dan Testing

Langkah berikutnya membagi data menjadi data *training* dan *testing* yang nanti akan digunakan dalam menentukan klasifikasi status gizi balita menggunakan PNN. Dengan proporsi 90%:10% diperoleh data *training* sebanyak 66 dan data *testing* sebanyak 7. Pembagian data *training* dan data *testing* dilakukan dengan perhitungan yang sama untuk proporsi 50%:50%, 60%:40%, 70%:30%, dan 80%:20%.

6. Klasifikasi PNN

Perhitungan nilai klasifikasi PNN dilakukan dalam beberapa tahap. Berikut adalah langkah-langkah klasifikasi PNN untuk proporsi data *training* dan data *testing* sebesar 90%:10% dengan nilai *smoothing parameter* (α) adalah 0,1.

a. Menetapkan Matriks Data Pengamatan Pada Data Training

Matriks data pengamatan pada data *training* disebut dengan matriks V berisi tentang faktor-faktor yang mempengaruhi status gizi balita pada data *training*, sehingga pada matriks V hanya menggunakan data *training*. Pada proporsi 90%:10% data *training* berjumlah 66 data dengan variabel yang digunakan berjumlah 3 yaitu UB,

TB dan BB, sehingga diperoleh matriks V berukuran 66×3 .

b. Menetapkan Matriks Input X

Matriks *input* X terdiri $X_{training}$ dan $X_{testing}$. Matriks pada $X_{training}$ sama dengan matriks V . Pada proporsi 90%:10% di dapatkan data *training* sebanyak 66 data dan data *testing* sebanyak 7 data. Dengan demikian diperoleh Matriks $X_{training}$ berukuran 66×3 dan $X_{testing}$ berukuran 7×3 .

c. Menentukan Matriks Target W

Matriks W merupakan matriks target yang disesuaikan dengan banyaknya data pada data *training*. Matriks W merupakan susunan dari vektor w dimana vektor w akan bernilai [0 1] jika kelas data status gizi baik adalah 1 dan vektor w akan bernilai [1 0] jika kelas data status gizi kurang baik adalah 0. Pada proporsi 90%:10%, matriks W berukuran 66×2 .

d. Membuat Pola PNN Menggunakan Data Training

Pembuatan pola PNN dilakukan untuk setiap proporsi data *training* dan data *testing*.

1. Perhitungan bobot bias lapisan input dilakukan menggunakan Persamaan (2). Hasil perhitungan bobot bias lapisan input dapat dilihat pada Tabel 2 sebagai berikut:

Tabel 2 Perhitungan Bobot Bias Lapisan *Input*

b	Parameter Smoothing
2,632769	0,1
1,861649	0,2
1,52003	0,3
1,316384	0,4
1,17741	0,5
1,074823	0,6
0,995093	0,7
0,930824	0,8
0,87759	0,9
0,832555	1

2. Perhitungan jarak Euclid untuk setiap data *training* terhadap data *training*, dilakukan menggunakan Persamaan (3).

Berikut perhitungan jarak Euclid antara data *training* ke-1 dengan data *training* :

$$D_{1;1} = \sqrt{(V_{1;1} - V_{1;1})^2 + (V_{1;2} - V_{1;2})^2 + (V_{1;3} - V_{1;3})^2}$$

$$= \sqrt{(-1,113 - (-1,113))^2 + (-1,072 - (-1,072))^2 + (-0,941 - (-0,941))^2}$$

$$= 0$$

$$D_{1;2} = \sqrt{(V_{1;1} - V_{2;1})^2 + (V_{1;2} - V_{2;2})^2 + (V_{1;3} - V_{2;3})^2}$$

$$= \sqrt{(-1,113 - (-0,221))^2 + (-1,072 - (0,183))^2 + (-0,941 - (0,549))^2}$$

$$= 2,143$$

Perhitungan jarak Euclid antar data *training* dilakukan untuk semua data *training*. Hasil perhitungan jarak Euclid antar data *training* dibentuk menjadi matriks jarak Euclid pada Tabel 3.

Tabel 3 Elemen Jarak Euclid Antar Data *Training*

Data Training	1	2	3	...	66
1	0	2,143	0,739	...	3,588
2	2,143	0	1,519	...	1,502
3	0,739	1,519	0	...	2,912
4	0,322	1,986	0,489	...	3,395
...
66	3,588	1,502	2,912	...	0

3. Perhitungan nilai aktivasi $a_{k;i}$ dengan Persamaan (4). Berikut merupakan perhitungan nilai aktivasi untuk data *training* ke-1:

$$a_{1;1} = e^{-(b_{0,1} D_{1;1})^2} = e^{-(2,633 \times 0)^2} = 1$$

$$a_{1;2} = e^{-(b_{0,1} D_{1;2})^2}$$

$$= e^{-(2,633 \times 2,143)^2}$$

$$= 1,51 \times 10^{-14}$$

Perhitungan nilai aktivasi dilakukan untuk semua data *training*. Hasil perhitungan nilai aktivasi antar data *training* dibentuk menjadi matriks aktivasi pada Tabel 4.

Tabel 4 Elemen Nilai Aktivasi Antar Data *Training* $\alpha=0,1$

Data Trainin g	1	2	3	...	66
1	1	$1,51 \times 10^{-14}$	0,023	...	$1,75 \times 10^{-39}$
2	$1,51 \times 10^{-14}$	1	$1,14 \times 10^{-07}$...	$1,63 \times 10^{-07}$
3	0,023	$1,14 \times 10^{-07}$	1	...	$2,95 \times 10^{-27}$
4	0,488	$1,33 \times 10^{-12}$	0,19	...	$2,05 \times 10^{-25}$
...
66	$1,75 \times 10^{-39}$	$1,63 \times 10^{-07}$	$2,95 \times 10^{-27}$...	1

4. Melakukan perkalian antara matriks aktivasi dengan matriks W menggunakan persamaan (5). Kemudian menentukan

kelas dengan cara memilih nilai untuk masing-masing kelas dimana nilai yang dipilih yaitu yang memiliki nilai maksimal antara $a_{2,k,1}$ (Gizi Baik) dan $a_{2,k,2}$ (Gizi Kurang Baik).

Berikut penjumlahan nilai hasil perkalian matriks untuk data *training* pertama :

$$a_{2,1,1} = (a_{1,1} \times w_{1,1}) + (a_{1,2} \times w_{2,1}) + \dots + (a_{1,66} \times w_{66,1})$$

$$= 1 + 1,51 \times 10^{-14} + \dots + 1,75 \times 10^{-39} = 7,072$$

$$a_{2,1,2} = (a_{1,1} \times w_{1,2}) + (a_{1,2} \times w_{2,2}) + \dots + (a_{1,66} \times w_{66,2})$$

$$= 2,12 \times 10^{-30} + 0,042 + \dots + 1,58 \times 10^{-15} = 0,044$$

Dari hasil perhitungan di atas didapatkan nilai maksimal yaitu 7,072 sehingga untuk data *training* pertama masuk ke dalam kelas $a_{2,1,1}$ (Gizi Baik). Hasil klasifikasi pada data *training* dapat dilihat pada Tabel 5.

Tabel 5 Hasil Klasifikasi Untuk $\alpha = 0,1$ Pada Data *Training*

Data Training	Gizi Baik	Gizi Kurang Baik	Hasil Prediksi	Status Gizi
1	7,0719	0,0444	1	1
2	1,71	0,0023	1	0
3	4,1482	0,7856	1	1
4	6,2019	0,0622	1	1
5	0,0088	1,0546	0	0
...
66	1,9087	0,000029	1	0

a. Membuat Pola PNN Menggunakan Data *Testing*

Setelah pola PNN dibuat dengan data *training*, selanjutnya pola PNN dibuat menggunakan data *testing*. Langkah-langkah yang dilakukan adalah:

1. Perhitungan bobot bias lapisan input dilakukan sebelumnya menggunakan persamaan (2) dan hasil perhitungan bobot bias lapisan input dapat dilihat pada Tabel 1.2
2. Perhitungan jarak Euclid untuk setiap data *testing* terhadap data *training*.
3. Perhitungan nilai aktivasi $a_{1,ki}$ dengan Persamaan (4).
4. Melakukan perkalian antara matriks aktivasi dengan matriks W. Kemudian menentukan kelas dengan cara memilih nilai untuk masing-masing kelas.

Tabel 6 menunjukkan hasil klasifikasi pada data *testing*. Kolom hasil prediksi diperoleh

dengan membandingkan nilai kolom Gizi Baik dan Gizi Kurang Baik.

Tabel 6 Hasil Klasifikasi Untuk $\alpha = 0,1$ Pada Data *Testing*

Data ke-	Gizi Baik	Gizi Kurang Baik	Hasil Prediksi	Status Asli
1	1,50751	0,00021	1	1
2	1,58508	0,50238	1	1
3	0,52162	1,98816	0	1
4	5,69336	0,01193	1	0
5	4,52886	0,12511	1	1
6	0,23311	0,00004	1	0
7	0,05772	1,67974	0	0

7. Nilai Akurasi PNN

Setelah dilakukan perhitungan klasifikasi dengan menggunakan PNN selanjutnya adalah menghitung nilai akurasi PNN. Perhitungan akurasi dapat digunakan untuk mengukur sejauh mana PNN dapat melakukan pengklasifikasian terhadap Status Gizi Balita. Berikut adalah hasil akurasi dan laju *error* antar data *training* maupun data *testing* terhadap data *training* untuk proporsi 90:10 dengan $\alpha = 0,1$.

Tabel 7 Hasil akurasi dan laju *error*

	Data Training	Data testing
Data Prediksi Benar	39	4
Jumlah Data	66	7
Hasil Akurasi	0,59091	0,57143
Persentase	59,091%	57,143%

Dari hasil persentase akurasi dapat diketahui bahwa pola PNN yang digunakan untuk proporsi antar data *training* 90%:10% dengan $\alpha = 0,1$ belum cukup baik untuk digunakan karena nilai persentase akurasi yang hanya 59,091%. Kemudian hasil persentase data *testing* terhadap data *training* dengan proporsi 90%:10% dan $\alpha = 0,1$ sebesar 57,143% juga belum cukup baik untuk digunakan. Keseluruhan proses dilakukan untuk semua proporsi data dan semua nilai α .

Kesimpulan

Berdasarkan dari hasil analisis dan pembahasan yang telah dilakukan didapatkan

kesimpulan dari klasifikasi PNN pada status gizi balita adalah sebagai berikut :

1. Perhitungan klasifikasi status gizi balita di Puskesmas Sempaja Samarinda menggunakan metode PNN yang paling baik yaitu pada proporsi 50%:50% dengan *smoothing parameter* (α) = 1.
2. Nilai akurasi tertinggi adalah 85% untuk data *training* dan 70% untuk data *testing*. Pada proporsi 50%:50% dengan *smoothing parameter* (α) = 1 didapatkan jumlah balita dengan status gizi baik sebanyak 54 balita dan status gizi kurang baik sebanyak 19 balita. Sehingga, hasil perhitungan metode PNN dengan hasil yang didapatkan dari Puskesmas Sempaja Samarinda Tahun 2019 dapat dikatakan akurat.

Daftar Pustaka

- Dinas Kesehatan Kota Samarinda (2016). Profil Kesehatan Kota Samarinda.
- Hermawan, A dan Suyanto. (2006). *Artificial Intelligence*. Bandung: Informatika Bandung.
- Hermawati, F.A. (2013). *Data Mining*. Yogyakarta: Penerbit Andi.
- Prasetyo, Eko. (2012). *Data Mining: Konsep Dan Aplikasi Menggunakan Matlab*. Yogyakarta: ANDI.
- Prasetyo, Eko. (2014). *Data Mining: Mengolah Data Menjadi Informasi Menggunakan Matlab*. Yogyakarta: ANDI.
- Kusumadewi, Sri. (2004a). *Membangun Jaringan Syaraf Tiruan Menggunakan Matlab Dan Excel Link*. Yogyakarta: Graha Ilmu.
- Kusumadewi, Sri. (2004b). Klasifikasi Pola Menggunakan Jaringan Probabilistik. *Seminar Nasional Aplikasi Teknologi Informasi 2004*.
- Nugraha, Satria D.N, Putri, Rekyan R.M, dan Wihandika, R.C. (2017). Penerapan *Fuzzy K-Nearest Neighbor* (FK-NN) Dalam Menentukan Status Gizi Balita. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*. Vol.1 No.9, 925-932.
- Sartika, Ratu A.D. (2011). Departemen Gizi Kesehatan Masyarakat, Fakultas Kesehatan Masyarakat, Universitas Indonesia. *MAKARA Kesehatan*. Vol. 15 No. 1 Juni 2011.
- Shofa, E., Yasin, H. dan Rahmawati, R. (2015). Klasifikasi Data Berat Bayi Lahir Menggunakan Probabilistic Neural Network (PNN) dan Regresi Logistic (Studi Kasus di Rumah Sakit Islam Sultan Agung Semarang Tahun 2014). *Jurnal Gaussian*.
- Supriasa. (2002). *Penilaian Status Gizi*. Jakarta: Buku Kedokteran EGC.

