

LEMBAR PENGESAHAN

Deteksi Obesitas pada Anak Usia 6-12 tahun di Indonesia Menurut Kontribusi *Macronutrients* (Energi, Protein, Lemak, Karbohidrat, Serat) dengan Metode Regresi Logistik Biner dan *Neural Networks* (SOM-RBFNN)

TUGAS AKHIR

Diajukan Untuk Memenuhi Salah Satu Syarat Kelulusan Program Studi S-1 Jurusan Statistika Fakultas Matematika dan Ilmu Pengetahuan Alam Institut Teknologi Sepuluh Nopember

Oleh :

HANNY ADIATI
NRP 1310 100 058

Disetujui oleh Pembimbing Tugas Akhir

Dr. Brodjol Sutijo Suprih Ulama, M. Si.
NIP : 19660125 199002 1 001

()



Mengetahui
Ketua Jurusan Statistika FMIPA-ITS

Dr. Muhammad Mashuri, MT
NIP. 19620408 198701 1 001

SURABAYA, JULI 2014

Deteksi Obesitas pada Anak Usia 6-12 tahun di Indonesia Menurut Kontribusi *Macronutrients* (Energi, Protein, Lemak, Karbohidrat, Serat) dengan Metode Regresi Logistik Biner dan *Neural Networks* (SOM-RBFNN)

Nama : Hanny Adiati
NRP : 1310100058
Jurusan : Statistika FMIPA – ITS
Pembimbing : Dr. Brodjol Sutijo Suprih Ulama, M.Si.

ABSTRAK

*Obesitas pada anak merupakan salah satu masalah kesehatan di Indonesia. Obesitas tergolong penyakit yang memiliki penyebab multifaktorial yang salah satu faktor penyebabnya ditentukan oleh asupan gizi yang masuk dalam tubuh. *Macronutrients* (energi, protein, lemak, karbohidrat dan serat) yang masuk dalam tubuh dapat menjadi salah satu faktor gizi utama untuk mendeteksi status obesitas pada anak. Regresi Logistik biner dan Radial Basis Neural Networks (RBFNN) merupakan metode yang sering digunakan dalam klasifikasi dan deteksi penyakit. Salah satu yang menjadi hal penting dalam RBFNN adalah inisialisasi pembobot awal. Self Organizing Maps (SOM) merupakan salah satu metode untuk mendapatkan inisialisasi pembobot awal pada RBFNN (SOM-RBFNN). Dalam penelitian ini, didapatkan hidden layer yang memberikan hasil terbaik adalah 2 hidden layer. Kesimpulan akhir yang didapatkan adalah regresi logistik biner dan neural networks dengan SOM-RBFNN memberikan ketepatan klasifikasi yang tidak jauh berbeda dalam upaya deteksi obesitas berdasarkan kontribusi *macronutrients* pada anak usia 6-12 tahun di Indonesia.*

*Kata Kunci: Obesitas anak, *Macronutrientst*, Klasifikasi, Regresi Logistik Biner, Self Organizing mapping (SOM), Radial Basis Function Neural Network (RBFNN), Ketepatan Klasifikasi.*

(Halaman ini sengaja dikosongkan)

**Obesity Detection of Children 6-12 Years Age in Indonesia
based on Macronutrients Contribution (Energy, Protein, Fat,
Carbohydrate, Fiber) using Binary Logistic Regression and
Neural Networks (SOM-RBFNN)**

Nama : Hanny Adiati
NRP : 1310100058
Jurusan : Statistika FMIPA – ITS
Pembimbing : Dr. Brodjol Sutijo Suprih Ulama, M.Si

ABSTRACT

Nowaday obesity is become a common problem in Indonesia. Childhood obesity was become a serious problem because have a latent effect for their future. Obesity is classified as a disease which have a multifactoral causes that one of contributing factor is determined by the intake of nutrients which actually consume by human. Macronutrients (energy, protein, fat, carbohydrate and fiber) that enters the body can be one of the major nutritional factor to detect the status of obesity in children. Binary Logistic Regression and Radial Basis Neural Network (RBFNN) is a method often used in classification and detection of disease. Self Organizing Mapping (SOM) is one method to get the initial weighting of RBFNN. The aim of this study was to classify obesity by binary logistic regression and neural networks. All subjects are children 6-12 years old measured by ministry of health in Indonesia. This research effort to detect obesity using binary logistic regression method and RBFNN based SOM (SOM-RBFNN). In this research 2 hidden layer known as the best node in hidden layer of SOM-RBFNN. The conclusion is neural networks and logistic regression both were good classifier for obesity detection and they were not significantly different in classification obesity of children 6-12 years age in Indonesia based on macronutrients contribution (Energy, Protein, Fat, Carbohydrate, Fiber).

Keywords : Childhood obesity, macronutrients, binary logistic regression, Self Organizing Mapping (SOM), Radial Basis Function Neural Networks (RBFNN), Classification Accuracy

(Halaman ini sengaja dikosongkan)

DAFTAR GAMBAR

	Halaman
Gambar 2.1	Arsitektur Jaringan RBFNN 14
Gambar 2.2	Klasifikasi Status Gizi Menurut WHO-NCHS 2005 (Menteri Kesehatan RI, 2010) 21
Gambar 3.1	Diagram Alir Metode Penelitian.....25
Gambar 4.1	Arsitektur Jaringan Syaraf Tiruan Menggunakan Dua Node Hasil <i>Clustering</i> SOM pada Kelompok Anak Laki-laki.....39
Gambar 4.2	Arsitektur Jaringan Syaraf Tiruan Menggunakan Dua Node Hasil <i>Clustering</i> SOM pada Kelompok Anak Perempuan41

(Halaman ini sengaja dikosongkan)

DAFTAR TABEL

	Halaman
Tabel 3.1 Variabel Respon dan Prediktor dalam Penelitian ...	23
Tabel 4.1 Pra Pemrosesan Data Input	27
Tabel 4.2 Statistika Deskriptif Data Konsumsi <i>Macronutrients</i>	28
Tabel 4.3 Uji Serentak Variabel Prediktor Tahap Pertama pada Kelompok Anak Laki-laki.....	30
Tabel 4.4 Uji Parsial Variabel Prediktor Tahap Pertama pada Kelompok Anak Laki-laki.....	31
Tabel 4.5 Uji Serentak Variabel Prediktor Tahap Kedua pada Kelompok Anak Laki-laki.....	31
Tabel 4.6 Uji Parsial Variabel Prediktor Tahap Kedua pada Kelompok Anak Laki-laki	32
Tabel 4.7 Ketepatan Klasifikasi pada Kelompok Anak Laki-laki.....	32
Tabel 4.8 <i>Odds Ratio</i> Kelompok Anak Laki-laki	33
Tabel 4.9 Uji Serentak Variabel Prediktor Tahap Pertama pada Kelompok Anak Perempuan	34
Tabel 4.10 Uji Parsial Variabel Prediktor Tahap Pertama pada Kelompok Anak Perempuan	34
Tabel 4.11 Uji Serentak Variabel Prediktor Tahap Kedua pada Kelompok Anak Perempuan	35
Tabel 4.12 Uji Parsial Variabel Prediktor Tahap Kedua pada Kelompok Anak Perempuan.....	36
Tabel 4.13 Ketepatan Klasifikasi pada Kelompok Anak Perempuan	36
Tabel 4.14 <i>Odds Ratio</i> Kelompok Anak Perempuan.....	37
Tabel 4.15 Nilai Mean dan Standard Deviasi Pada 2 <i>Cluster</i> Kelompok Anak Laki-laki	38

Tabel 4.16 Nilai Mean dan Standard Deviasi Pada 3 <i>Cluster</i> Kelompok Anak Laki-laki	38
Tabel 4.17 Nilai Mean dan Standard Deviasi Pada 4 <i>Cluster</i> Kelompok Anak Laki-laki	38
Tabel 4.18 Nilai Mean dan Standard Deviasi Pada 5 <i>Cluster</i> Kelompok Anak Laki-laki	38
Tabel 4.19 Nilai Mean dan Standard Deviasi Pada 10 <i>Cluster</i> Kelompok Anak Laki-laki	39
Tabel 4.20 Nilai Mean dan Standard Deviasi Pada 2 <i>Cluster</i> Kelompok Anak Perempuan	40
Tabel 4.21 Nilai Mean dan Standard Deviasi Pada 3 <i>Cluster</i> Kelompok Anak Perempuan	40
Tabel 4.22 Nilai Mean dan Standard Deviasi Pada 4 <i>Cluster</i> Kelompok Anak Perempuan	40
Tabel 4.23 Nilai Mean dan Standard Deviasi Pada 5 <i>Cluster</i> Kelompok Anak Perempuan	40
Tabel 4.24 Nilai Mean dan Standard Deviasi Pada 10 <i>Cluster</i> Kelompok Anak Perempuan	40
Tabel 4.25 Nilai Performansi Pada Masing-masing <i>hidden</i> <i>layer</i>	41
Tabel 4.26 Nilai Taksiran Pembobot Model RBF	43
Tabel 4.27 Ketepatan Klasifikasi Pada Data <i>Training</i> dan <i>Testing</i> untuk Metode Regresi Logistik Biner dan <i>Neural Networks</i>	43
Tabel 5.1 Nilai Taksiran Pembobot Model RBF	45

DAFTAR LAMPIRAN

	Halaman
Lampiran A Data Obesitas Anak Usia 6-12 Tahun Indonesia (2010)	51
Lampiran B Tabel Standard Deviasi Penentuan Obesitas	53
Lampiran C <i>Syntax</i> Clustering Menggunakan SOM	63
Lampiran D Tabel Mean dan Standard Deviasi Hasil Clustering Menggunakan SOM	64
Lampiran E <i>Syntax</i> Klasifikasi Menggunakan RBFNN	67

(Halaman ini sengaja dikosongkan)

BAB II TINJAUAN PUSTAKA

2.1 Regresi Logistik Biner

Regresi logistik biner merupakan salah satu metode regresi yang menggambarkan hubungan antara suatu variabel respon (*outcome* atau *dependent*) dengan satu atau lebih variabel prediktor (*explanatory* atau *independent*). Regresi logistik hanya digunakan untuk kasus khusus yaitu apabila variabel respon (Y) merupakan variabel kualitatif yang bersifat biner atau dikotomis. Variabel dikotomis adalah variabel yang hanya mempunyai dua kemungkinan nilai, misalnya sukses dan gagal.

Untuk memudahkan, maka variabel respon / dependen diberi notasi Y dan variabel prediktor / independen dinotasikan dengan X. Apabila Y menghasilkan dua kategori, misalnya "1" jika sukses dan "0" jika gagal, maka variabel Y tersebut mengikuti distribusi Bernoulli, dengan fungsi probabilitas adalah

:

$$f(y_i) = p_i^{y_i} (1 - p_i)^{1 - y_i}, \quad y_i = 0, 1 \quad (2.1)$$

dimana : jika $y_i = 0$, maka $f(y_i) = 1 - p$
jika $y_i = 1$, maka $f(y_i) = p$

Distribusi dari variabel dependen ini merupakan pembeda antara regresi logistik dengan regresi linier. Pada regresi linier variabel dependennya diasumsikan berdistribusi normal sedangkan untuk variabel dependen pada regresi logistik bersifat dikotomis. Fungsi logistik adalah sebagai berikut.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2.2)$$

Untuk mendapatkan nilai $f(x)$ antara 0 dan 1 maka nilai x dapat berkisar antara $-\infty$ dan ∞ yang dihasilkan melalui rumus sebagai berikut.

$$f(-\infty) = \frac{1}{1 + e^{-(-\infty)}} = 0 \quad (2.3)$$

$$f(\infty) = \frac{1}{1 + e^{-\infty}} = 1 \quad (2.4)$$

Bentuk dari model *Regresi Logistik* dengan variabel independen p adalah sebagai berikut .

$$\pi(x) = \frac{\exp(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p)}{1 + \exp(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p)} \quad (2.5)$$

Dengan menggunakan transformasi logit dari $\pi(x)$, maka model logistik dikotomus dapat ditulis sebagai berikut:

$$g(x) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p \quad (2.6)$$

Uraian tentang transformasi logit adalah sebagai berikut.

$$\begin{aligned} g(x) &= \ln \frac{\pi(x)}{1 - \pi(x)} \\ &= \ln \left[\frac{\left(\frac{\exp\{\beta_0 + \beta_1 x_1 + \dots + \beta_p x_p\}}{1 + \exp\{\beta_0 + \beta_1 x_1 + \dots + \beta_p x_p\}} \right)}{1 - \left(\frac{\exp\{\beta_0 + \beta_1 x_1 + \dots + \beta_p x_p\}}{1 + \exp\{\beta_0 + \beta_1 x_1 + \dots + \beta_p x_p\}} \right)} \right] \\ &= \ln \left[\frac{\left(\frac{\exp\{\beta_0 + \beta_1 x_1 + \dots + \beta_p x_p\}}{1 + \exp\{\beta_0 + \beta_1 x_1 + \dots + \beta_p x_p\}} \right)}{\left(\frac{1}{1 + \exp\{\beta_0 + \beta_1 x_1 + \dots + \beta_p x_p\}} \right)} \right] \\ &= \ln \left[\exp\{\beta_0 + \beta_1 x_1 + \dots + \beta_p x_p\} \right] \end{aligned}$$

$$\text{Sehingga } g(x) = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p \quad (2.7)$$

Selanjutnya $g(x)$ disebut dengan *Model Logit* dan merupakan fungsi linear dalam parameter-parameternya.

Dalam regresi logistik diasumsikan bahwa suatu amatan dari variabel dependen dapat dinotasikan sebagai $Y = \pi(x) + \varepsilon$. Nilai ε biasa disebut *error* dan merupakan simpangan pengamatan dari rataannya. Sehingga dengan obyek pengamatan yang dikotomus dinyatakan, jika :

$$Y = 1, \text{ maka } \varepsilon = 1 - \pi(x) \text{ dengan probabilitas } \pi(x) \quad (2.8)$$

$$Y = 0, \text{ maka } \varepsilon = -\pi(x) \text{ dengan probabilitas } 1 - \pi(x) \quad (2.9)$$

Dan dapat dinyatakan bahwa ε memiliki $E(\varepsilon) = 0$ dan $\text{var}(\varepsilon) = \pi(x)[1 - \pi(x)]$ yang mengikuti distribusi Binomial (Hosmer, 1989).

2.1.1 Estimasi Parameter pada Regresi Logistik Biner

Pada regresi logistik biner, metode yang umum digunakan untuk mengestimasi koefisien parameter adalah dengan menggunakan *Maximum Likelihood Estimation* (MLE). Pada metode ini, dibentuk fungsi *likelihood* yang merupakan probabilitas dari data observasi sebagai fungsi dari parameter-parameter yang tidak di-ketahui. Berikut ini adalah fungsi *likelihood* untuk (x_i, y_i) .

$$\pi(x_i)^{y_i} [1 - \pi(x_i)]^{1-y_i} \quad (2.10)$$

Dengan menggunakan metode MLE didapatkan persamaan *likelihood* berikut:

$$\sum_{i=1}^n y_i x_{ij} - \sum_{i=1}^n x_{ij} \hat{\pi}(x_i) = 0 \quad ; j = 0, 1, \dots, p \quad (2.11)$$

Koefisien parameter untuk model regresi logistik adalah $\hat{\pi}(x_i)$.

2.1.2 Pengujian Estimasi Parameter

a. Pengujian Estimasi Parameter Secara Serentak

Pengujian estimasi parameter secara serentak dilakukan untuk memeriksa keberartian koefisien β secara serentak (multivariat) terhadap variabel respon. Hipotesis yang digunakan adalah sebagai berikut.

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

$$H_1 : \text{Paling tidak terdapat satu } \beta_i \neq 0; \quad i = 1, 2, \dots, p$$

$$\text{Statistik uji: } G = -2 \ln \frac{\left(\frac{n_1}{n}\right)^{n_1} \left(\frac{n_0}{n}\right)^{n_0}}{\sum_{i=1}^n \hat{\pi}_i^{y_i} (1 - \hat{\pi}_i)^{(1-y_i)}} \quad (2.12)$$

$$\text{dengan: } n_1 = \sum_{i=1}^n y_i \quad n_0 = \sum_{i=1}^n (1 - y_i) \quad n = n_1 + n_0$$

Statistik uji G adalah *Likelihood Ratio Test* dengan nilai G mengikuti distribusi *Chi-Square* sehingga H_0 ditolak jika $G > \chi^2_{(v, \alpha)}$ dengan v derajat bebas adalah banyaknya parameter dalam model tanpa β_0 .

b. Pengujian Estimasi Parameter Secara Parsial

Setelah melakukan pengujian secara serentak, maka kemudian dilakukan pengujian signifikansi terhadap koefisien β secara parsial (univariat) terhadap variabel respon yaitu dengan membandingkan parameter hasil maksimum *likelihood*, dugaan β dengan standard error parameter tersebut. Hipotesis pengujian parsial adalah sebagai berikut,

$$H_0 : \beta_i = 0$$

$$H_1 : \beta_i \neq 0 \quad ; \quad i = 1, 2, \dots, p$$

$$\text{Statistik uji: } W = \frac{\hat{\beta}_i}{SE(\hat{\beta}_i)} \quad (2.13)$$

Statistik uji W disebut juga sebagai Statistik uji Wald, mengikuti distribusi normal sehingga H_0 ditolak jika $|W| > Z_{\alpha/2}$ dan dapat diperoleh melalui persamaan berikut,

$$W^2 = \frac{\hat{\beta}_i^2}{SE(\hat{\beta}_i)^2} \quad (2.14)$$

Statistik uji tersebut mengikuti distribusi *Chi-Squared* sehingga H_0 ditolak jika $W^2 > \chi^2_{(v,\alpha)}$ dengan v adalah *degrees of freedom* (banyaknya prediktor).

2.1.3 Interpretasi Koefisien Parameter dan *Odds Ratio*

Intepretasi terhadap koefisien parameter dilakukan untuk menentukan kecenderungan/hubungan fungsional antara variabel prediktor dengan variabel respon serta menunjukkan pengaruh perubahan nilai pada variabel yang bersangkutan.

Odds ratio (e^β) diartikan sebagai kecenderungan variabel respon memiliki suatu nilai tertentu jika diberikan nilai pada variabel rediktor. Keputusan tidak terdapat hubungan antara variabel prediktor dengan variabel respon diambil jika nilai *Odds ratio* (ψ) = 1.

Jika nilai *Odds ratio* (ψ) < 1, maka antara variabel prediktor dan variabel respon terdapat hubungan negatif setiap kali perubahan nilai variabel bebas (x) dan jika *Odds ratio* (ψ) > 1 maka antara variabel prediktor dengan variabel respon terdapat hubungan positif setiap kali perubahan nilai variabel bebas (x).

2.2 *Neural Networks*

Menurut Fausett (1994), *Neural Networks* atau yang lebih dikenal dengan Jaringan Syaraf Tiruan adalah suatu pemrosesan informasi menggunakan karakteristik-karakteristik performa yang mirip dengan proses penyampaian impuls syaraf manusia. *Neural Network* dikembangkan dengan model persamaan matematis dengan menggunakan beberapa asumsi berikut ini:

- a. Pemrosesan informasi terjadi pada elemen yang paling sederhana yang disebut neuron (node)
- b. Antara neuron satu dengan yang lain saling berhubungan dan memiliki koneksi
- c. Setiap koneksi menghubungkan satu node dengan node yang lain dan memiliki nilai pembobot tertentu

- d. Setiap node memiliki fungsi aktivasi (biasanya tidak linear) sebagai input dan juga untuk menentukan hasil output

Karakteristik lain dari neural network adalah adanya arsitektur yang merupakan koneksi antar node. Dibutuhkan suatu fungsi aktivasi yang merupakan metode menentukan pembobot antar koneksi dan biasa disebut dengan *training* atau pembelajaran.

Neural networks terdiri dari banyak neuron di dalamnya. Neuron-neuron ini akan dikelompokkan ke dalam beberapa layer. Neuron yang terdapat pada tiap layer dihubungkan dengan neuron pada layer lainnya. Hal ini tentunya tidak berlaku pada layer input dan output, tapi hanya layer yang berada di antaranya. Informasi yang diterima di layer input dilanjutkan ke layer-layer dalam ANN secara satu persatu hingga mencapai layer terakhir/layer output. Layer yang terletak di antara input dan output disebut sebagai *hidden layer*.

Neural network memperoleh nilai bobot dari suatu algoritma pembelajaran tertentu. Bobot ini dilakukan dalam melakukan transformasi dari node input ke node output. Algoritma pembelajaran merupakan tahap penyesuaian terhadap bobot yang telah terbentuk secara random. Penentuan nilai bobot secara umum dirumuskan sebagai berikut:

$$w_{ij}(n+1) = w_{ij}(n) + \Delta w_{ij}(n) \quad (2.15)$$

dengan $w_{ij}(n)$ = bobot awal yang ditentukan secara acak pada tahap inisialisasi. Algoritma pembelajaran digunakan untuk menghitung $\Delta w_{ij}(n)$.

Secara keseluruhan, pemodelan menggunakan Neural Network adalah sebagai berikut.:

1. Penentuan pembobot awal

Pembobot awal yang akan digunakan adalah pembobot awal pada koneksi antara layer input dan layer hidden (layer ke-1) serta antara *hidden layer* (layer ke-2) dan layer output.

2. *Training* neural network

Model neural network akan ditraining pada suatu nilai *epoch* dan dilakukan penilaian terhadap *learning rate* untuk mendapatkan nilai ketepatan prediksi yang tinggi.

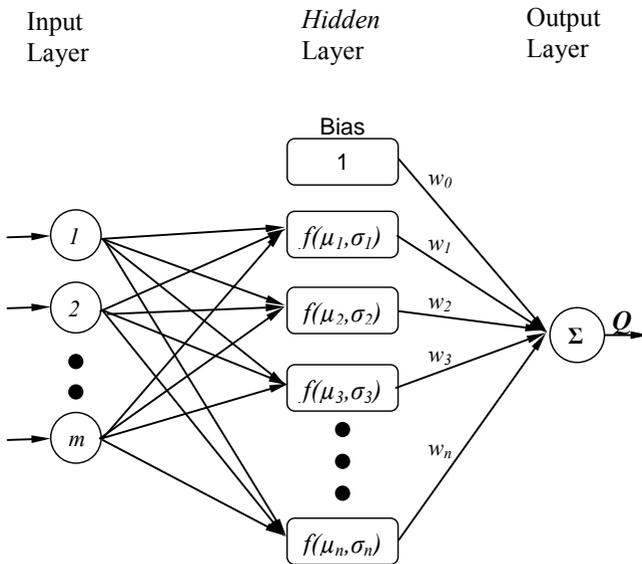
3. Pengujian Model *Neural Networks*

Testing atau pengujian dilakukan dengan menggunakan data *testing* yang merupakan pasangan dari data training yang digunakan untuk mencari pembobot model neural network. Langkah selanjutnya adalah dilakukan pengukuran terhadap ketepatan model dan nilai MSE (*mean square error*) model.

Menurut Kustiyo dan Tjandrasa (2004) terdapat beberapa model neural network yang dapat digunakan untuk klasifikasi. Antara lain adalah *single layer perceptron*, *adaline*, dan *multilayer perceptron (MLP)*. MLP merupakan *feedforward network* yang sedikitnya memiliki satu *hidden layer*. Model ini dapat digunakan untuk menangani klasifikasi non linear karena dapat membentuk daerah keputusan yang lebih kompleks. Dalam penelitian ini akan dibentuk pemodelan Neural Network menggunakan fungsi Radial Basis (*Radial Basis Function*).

2.3 *Radial Basis Function Neural Network (RBFNN)*

Radial Basis Function Neural Network (RBFNN) adalah metode neural network yang mengikuti paradigma pembelajaran *hybrid* (gabungan *supervised* dan *unsupervised learning*). Dengan menggunakan aturan pembelajaran pengkoreksian error dan kompetitif, neural network dengan menggunakan fungsi jaringan *Radial Basis Function* (RBF) biasa digunakan untuk klasifikasi pola, aproksimasi fungsi, prediksi dan kontrol (Puspitaningrum, 2006). Berikut ini adalah gambaran dari arsitektur jaringan Fungsi Radial Basis.



Gambar 2.1. Arsitektur Jaringan RBFNN

Untuk mendapatkan model RBFNN terbaik, diperlukan kombinasi yang tepat antara jumlah variabel input, jumlah node (cluster) pada unit hidden layers, nilai tengah dan standar deviasi (skala atau *width*) dari variabel input pada setiap node, yang berimplikasi pada jumlah parameter yang optimal. Untuk mendapatkan sejumlah node yang diinginkan dilakukan dengan mengelompokkan data. Salah satu metode pengelompokan data yang digunakan dalam penelitian ini adalah metode *Self Organizing Maps* (SOM). Dengan terbentuknya kelompok data, maka nilai tengah dan varians variabel input pada setiap kluster dapat dihitung. Komponen invers varians pada fungsi aktivasi RBFNN merupakan bobot dari suatu pergeseran, sehingga diperlukan nilai interval untuk varians tersebut. Nilai varians suatu variabel input pada suatu node yang berada diluar interval mengindikasikan hubungan input dengan node tidak memberi sumbangan yang signifikan pada model RBFNN,

sehingga perlu dihapus. Penentuan model terbaik dari RBFNN dapat diketahui dengan kriteria nilai Mean Square Error (MSE) (Puspitaningrum, 2006)

Sutijo, Subanar dan Guritno (2008) mengatakan RBFNN didesain untuk membentuk pemetaan non linier dari variabel input ke unit hidden layer dan pemetaan linier dari hidden layer ke output. Sehingga pada RBFNN dilakukan pemetaan input dari ruang berdimensi p ke output ruang berdimensi satu.

$$s: \mathcal{R}^p \rightarrow \mathcal{R}^1 \quad (2.16)$$

Berdasarkan teori interpolasi multivariate : Jika diberikan N buah titik berbeda $\{x_i \in \mathcal{R}^p \ i=1,2,\dots,N\}$ yang berhubungan dengan N buah bilangan real $\{d_i, \ d_i \in \mathcal{R}^1 \ i=1,2,\dots,N\}$, fungsi $F: \mathcal{R}^N \rightarrow \mathcal{R}^1$ adalah fungsi yang memenuhi $F(x_i) = d_i, \ i=1,2,\dots,N$

Agar memenuhi teori di atas, interpolasi dengan menggunakan fungsi $F(x)$ harus meloloskan semua data. Teori interpolasi multivariate secara ringkas dapat dinyatakan dengan:

$$F: \mathcal{R}^N \rightarrow \mathcal{R}^1$$

$$F(x_i) = d_i, \ i=1,2,\dots,N \quad (2.17)$$

Pada pemodelan RBFNN dilakukan dengan memilih suatu fungsi $F(x)$ sehingga (2.17) dipenuhi. Interpolasi input-output dengan melihat desain model RBFNN, maka (2.17) dapat dinyatakan dengan:

$$F(x) = \sum_{i=1}^N w_i \phi(\|x - x_i\|) \quad (2.18)$$

dimana $\{\phi(\|x - x_i\|) \mid i=1,2,3,\dots,N\}$ adalah himpunan fungsi nonlinear yang disebut fungsi radial basis (Radial Basis Function = RBF) dan $\|\cdot\|$ adalah norm jarak Euclid.

Beberapa fungsi radial basis diantaranya adalah :

1. Fungsi Thin Plate Spline
 $\phi(z) = (z - \mu)^2 \log(z - \mu)$
2. Fungsi Multikuadratik
 $\phi(z) = |(z - \mu)^2 + \sigma^2|^{1/2}$
3. Fungsi Invers Multikuadratik
 $\phi(z) = |(z - \mu)^2 + \sigma^2|^{-1/2}$
4. Fungsi Gaussian
 $\phi(z) = \exp\{-|(z - \mu)^2 / \sigma^2|\}$

Menurut Brodjol Sutijo, Subanar dan Suryo Guritno (2008), fungsi radial basis yang sering digunakan adalah fungsi gaussian karena mempunyai sifat lokal, yaitu bila input dekat dengan rata-rata (pusat), maka fungsi akan menghasilkan nilai satu, sedangkan bila input jauh dari rata-rata, maka fungsi memberikan nilai nol. Apabila diketahui N buah titik data $\{x_i \in \mathbb{R}^p \ i=1,2,\dots,N\}$ pusat dari RBF maka persamaan (2.18) dapat ditulis :

$$\begin{bmatrix} \sigma_{11} & \sigma_{12} & \dots & \sigma_{1N} \\ \sigma_{21} & \sigma_{22} & \dots & \sigma_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{N1} & \sigma_{N2} & \dots & \sigma_{NN} \end{bmatrix} \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_n \end{bmatrix} = \begin{bmatrix} d_1 \\ d_2 \\ \vdots \\ d_N \end{bmatrix}$$

dimana $\sigma_{ij} = \phi(\|x_i - x_j\|)$
 $i, j = 1, 2, 3, \dots, N$

Persamaan diatas bila dinyatakan dalam bentuk matriks menjadi:

$$f w = d \quad (2.19)$$

dengan $d = (d_1, d_2, \dots, d_N)$

$w = (w_1, \dots, w_N)$ dan $f = \sigma_{ij}$

Matrik σ_{ij} adalah matrik interpolasi yang definit positif dan mempunyai invers. Pendekatan suatu fungsi dengan menggunakan RBFNN dilakukan dengan interpolasi untuk mendapatkan penyelesaian optimal dari ruang berdimensi tinggi ke dimensi yang lebih rendah.

2.4 SOM-RBFNN (Kombinasi *Self Organizing Maps* dengan *Radial Basis Function*)

Self Organizing Maps (SOM) merupakan perluasan dari jaringan kompetitif yang sering disebut sebagai jaringan Kohonen. Jaringan ini menggunakan metode pembelajaran *unsupervised*. Jaringan ini pertama kali diperkenalkan oleh Prof. Teuvo kohonen pada tahun 1982. Pada jaringan ini, suatu lapisan yang berisi neuron-neuron akan menyusun dirinya sendiri berdasarkan input nilai tertentu dalam suatu kelompok yang dikenal dengan istilah cluster. Selama proses penyusunan diri, cluster yang memiliki vektor bobot paling cocok dengan pola input (memiliki jarak paling dekat) akan terpilih sebagai

pemenang. Neuron yang menjadi pemenang beserta neuron-neuron tetangganya akan memperbaiki bobot-bobotnya. Metode SOM digunakan untuk pemetaan seperti clustering dimana prosesnya adalah suatu objek masuk pada cluster ke- j tergantung pada jarak yang ditetapkan. Jumlah neuron target sama dengan maksimum jumlah kelompok yang hendak kita buat. Dalam iterasinya, bobot neuron yang diubah tidak hanya bobot garis yang terhubung ke neuron pemenang saja, tetapi juga bobot neuron sekitarnya.

Berikut ini adalah tahapan dalam algoritma pembelajaran SOM:

Step 1: Inisialisasi bobot (W_{ij}) Tentukan parameter jarak (R)
Tentukan learning rate (α)

Step 2: Jika kondisi stop salah, lakukan step 3 – 8

Step 3: untuk semua input vektor x lakukan step 4 – 5

Step 4: untuk setiap j , $D(j) = \sum_i^n (W_{ij} - X_i)^2$

Step 5: dapatkan j sehingga $D(j)$ minimal

Step 6: untuk semua j yang berada dalam jarak dan untuk semua i
 $W_{ij} \text{ (baru)} = W_{ij} \text{ (lama)} + \alpha(X_i - W_{ij}) \text{ lama}$

Step 7: update learning rate

Step 8: Update jarak

Step 9: Uji kondisi stop (Stop jika $|W_{ij} \text{ baru} - W_{ij} \text{ (lama)}| \leq \epsilon$)

Kombinasi SOM dengan RBFNN banyak digunakan terutama untuk menentukan input node. Seperti pada penelitian Baboo, Subashini, dan Krishnaveni (2009) yang telah membandingkan performa ketepatan klasifikasi antara *Self Organizing Maps* (SOM) dengan RBF yang dikombinasikan dengan metode SOM pada penentuan input node. Pada penelitian tersebut diidentifikasi bahwa Radial Basis Function dengan menggunakan SOM dalam penentuan node input memiliki ketepatan klasifikasi yang lebih tinggi yaitu 96,9%.

2.5 Obesitas

Obesitas adalah suatu keadaan yang melebihi dari berat badan relatif seseorang, sebagai akibat penumpukan zat gizi

terutama karbohidrat, lemak dan protein. Obesitas juga merupakan suatu kelainan atau penyakit yang ditandai dengan penimbunan jaringan lemak tubuh secara berlebihan (Yussac, dkk, 2007). Secara garis besar faktor yang berperan terhadap terjadinya obesitas antara lain: jenis kelamin, umur, tingkat sosial ekonomi, faktor lingkungan, aktivitas fisik, kebiasaan makan, faktor psikologis dan faktor genetik (Salam, 1989). Banyak studi yang menunjukkan adanya kecenderungan anak obes untuk tetap obes pada masa dewasa (Guo *et al.*, 1994) yang dapat berakibat pada kenaikan risiko penyakit dan gangguan yang berhubungan dengan obesitas pada masa kehidupan berikutnya (Hadi, 2005). Anak obesitas juga cenderung mengalami peningkatan tekanan darah dan denyut jantung sekitar 20-30% penderita hipertensi. Berdasarkan hasil penelitian yang dilakukan oleh Himpunan Studi Obesitas Indonesia (HISOBI) tahun 2004, angka prevalensi obesitas (IMT \geq 30 kg/m²) mencapai 9,16 % pada pria dan 11,02 % pada wanita. Bahkan, saat ini penyakit obesitas banyak dialami anak-anak.

Obesitas mempunyai dampak terhadap tumbuh kembang anak (aspek organik dan psikososial), anak berisiko tinggi obesitas di masa dewasa dan berpotensi mengalami berbagai penyakit kardiovaskuler dan diabetes mellitus, kelainan metabolik seperti atherogenesis, resistensi insulin, gangguan trombogenesis, dan karsinogenesis (Yussac *et al.*, 2007). Hasil penelitian menemukan bahwa dari 50 anak laki-laki yang mengalami gizi lebih, 86% akan mengalami kondisi tetap hingga dewasa dan dari 50 anak perempuan yang mengalami kegemukan akan tetap dengan status gizi lebih sebanyak 80% hingga dewasa. Kegemukan permanen cenderung akan terjadi bila kemunculannya pada saat anak berusia 5 – 7 tahun dan anak berusia 4 – 11 tahun (Hadi, 2005). Anak-anak dengan kelebihan berat badan atau kegemukan dapat mengalami kesulitan bergerak dan terganggu pertumbuhannya karena timbunan lemak yang berlebihan pada organ-organ tubuh yang seharusnya berkembang. Obesitas pada anak juga perlu diwaspadai, karena jika berlanjut

hingga dewasa biasanya lebih sulit diatasi, mungkin karena faktor penyebab yang sudah menahun dan sel-sel lemak yang sudah bertambah banyak dan bertambah besar ukurannya (Yussac *et al*, 2007).

2.5.1 Kontribusi *Macronutrients* sebagai Faktor Penyebab Obesitas

Manusia memerlukan makanan untuk tumbuh, bereproduksi, dan memelihara kesehatan yang baik. Tanpa makanan, tubuh kita tidak dapat menjaga suhunya, membangun atau memperbaiki jaringan, atau memelihara detak jantung. Memakan makanan yang benar dapat menghindarkan kita dari berbagai penyakit atau sembuh lebih cepat ketika penyakit menyerang. Faktor-faktor tersebut dan fungsi-fungsi penting lain dipenuhi dengan zat-zat kimia di dalam makanan kita yang disebut nutrisi. Nutrisi dikategorikan sebagai karbohidrat, protein, lemak, vitamin-vitamin dan mineral.

Selain pentingnya nutrisi dalam mempengaruhi kesehatan dan kelangsungan hidup manusia, nutrisi juga dapat menjadi faktor utama terhadap perkembangan penyakit kardiovaskuler . Nutrisi diklasifikasikan menjadi nutrisi dasar dan nutrisi makanan. Nutrisi dasar adalah nutrisi yang diproduksi di dalam tubuh kita dan tidak perlu didapatkan dari makanan. Contoh dari nutrisi ini adalah kolesterol, zat semacam lemak yang ada di semua sel hewan. Nutrisi makanan harus didapatkan dari makanan yang kita santap karena tubuh tidak memproduksi zat tersebut atau memproduksi dengan jumlah yang kurang mencukupi untuk memelihara pertumbuhan dan kesehatan. Enam jenis nutrisi yang ditemukan dalam makanan adalah karbohidrat, lemak, protein, vitamin, mineral dan air. Karbohidrat, lemak dan protein disebut sebagai *macronutrients*; menyusun sebagian besar asupan makanan sehari-hari. *Macronutrients* ini berfungsi sebagai bahan mentah untuk pembangunan dan pemeliharaan jaringan serta sebagai bahan bakar berbagai aktifitas fisik dan metabolisme penunjang hidup.

Beberapa penelitian kontribusi *macronutrients* sebagai faktor penyebab obesitas antara lain dilakukan oleh *American Journal of Epidemiology* pada tahun 2013 yang menyatakan bahwa *macronutrients* memiliki peranan dalam penentuan status obesitas (Park, et al, 2013). Selain itu, terdapat kesimpulan bahwa karbohidrat merupakan *macronutrients* paling kuat dan positif terkait dengan peningkatan prevalensi obesitas (Crichton dan Tefft, 2013). Oleh karena itu dapat dikatakan *macronutrients* memegang peran yang penting dalam menentukan status obesitas seseorang.

2.5.2 Pengukuran Obesitas pada Anak

Obesitas pada anak-anak dan remaja diidentifikasi berdasarkan kriteria pengukuran antropometri dan atau pemeriksaan laboratorik. Bahan rujukan untuk penentuan status gizi dengan pengukuran antropometri yang digunakan di seluruh dunia adalah Harvard (Boston), WHO-NCHS, Tanner dan Kanada (Supriasa et al., 2001). Sedangkan baku rujukan klasifikasi status gizi di Indonesia berdasar Keputusan Menteri Kesehatan RI: No 1995/MENKES/SK/XII/2010 tentang Standar Antropometri Penilaian Status Gizi Anak adalah berdasarkan baku rujukan WHO-NCHS 2005. Baku acuan ini terpilih karena jauh lebih mendekati kriteria meliputi data WHO-NCHS terambil dengan metode sampling yang benar, berjumlah besar, mencakup semua etnis dan geografis dari sejak lahir hingga berusia 18 tahun (Arisman, 2004).

Ambang batas yang digunakan adalah dengan menentukan Z-score atau standar deviasi (SD). Berikut adalah tabel klasifikasi status gizi berdasarkan WHO-NCHS 2005:

Kategori dan Ambang Batas Status Gizi Anak Berdasarkan Indeks

Indeks	Kategori Status Gizi	Ambang Batas (Z-Score)
Berat Badan menurut Umur (BB/U) Anak Umur 0 – 60 Bulan	Gizi Buruk	< -3 SD
	Gizi Kurang	-3 SD sampai dengan <-2 SD
	Gizi Baik	-2 SD sampai dengan 2 SD
	Gizi Lebih	>2 SD
Panjang Badan menurut Umur (PB/U) atau Tinggi Badan menurut Umur (TB/U) Anak Umur 0 – 60 Bulan	Sangat Pendek	<-3 SD
	Pendek	-3 SD sampai dengan <-2 SD
	Normal	-2 SD sampai dengan 2 SD
Berat Badan menurut Panjang Badan (BB/PB) atau Berat Badan menurut Tinggi Badan (BB/TB) Anak Umur 0 – 60 Bulan	Tinggi	>2 SD
	Sangat Kurus	<-3 SD
	Kurus	-3 SD sampai dengan <-2 SD
Berat Badan menurut Tinggi Badan (BB/TB) atau Berat Badan menurut Panjang Badan (BB/PB) Anak Umur 0 – 60 Bulan	Normal	-2 SD sampai dengan 2 SD
	Gemuk	>2 SD
	Sangat Kurus	<-3 SD
Indeks Massa Tubuh menurut Umur (IMT/U) Anak Umur 0 – 60 Bulan	Kurus	-3 SD sampai dengan <-2 SD
	Normal	-2 SD sampai dengan 2 SD
	Gemuk	>2 SD
Indeks Massa Tubuh menurut Umur (IMT/U) Anak Umur 5 – 18 Tahun	Sangat Kurus	<-3 SD
	Kurus	-3 SD sampai dengan <-2 SD
	Normal	-2 SD sampai dengan 1 SD
	Gemuk	>1 SD sampai dengan 2 SD
	Obesitas	>2 SD

Gambar 2.2. Klasifikasi Status Gizi Menurut WHO-NCHS 2005 (Menteri Kesehatan RI, 2010).

Sesuai dengan baku rujukan klasifikasi status gizi di Indonesia berdasar Keputusan Menteri Kesehatan RI: No 1995/MENKES/SK/XII/2010 tentang Standar Antropometri Penilaian Status Gizi Anak, dapat dijelaskan pengukuran status gizi anak sekolah (6-12 tahun) pada anak laki-laki maupun perempuan dapat dilakukan dengan indeks antropometri dan menggunakan Indeks Massa Tubuh Menurut Umur (IMT/U).

Cara menentukan IMT/U adalah dengan menentukan terlebih dahulu IMT anak dengan rumus berat badan (dalam kilogram) dibagi dengan kuadrat tinggi badan (dalam m). Tahap selanjutnya adalah menentukan tingkatan status gizi anak. Untuk anak-anak pada masa tumbuh kembang, penentuan status gizi ditentukan menggunakan ambang batas dengan menentukan *Z-score* atau standar deviasi (SD) (tabel terlampir).

2.6 Penelitian Sebelumnya

Beberapa penelitian sebelumnya mengenai perbandingan metode regresi logistik dengan *Artificial Neural Network* antara lain: Rezaei Mansour, Zandkarimi Eghbal dan Hashemian

Amirhossein (2013) membandingkan tiga metode sekaligus yakni regresi logistik biner, neural network dan analisis diskriminan untuk kasus pendeteksian penyakit diabetes tipe 2. Dari hasil penelitian yang berjudul “Comparison of Artificial Neural Network, Logistic Regression and Discriminant Analysis Efficiency in Determining Risk Factors of Type 2 Diabetes” tersebut didapatkan hasil bahwa dengan menggunakan neural network (RBF) didapatkan hasil ketepatan klasifikasi yang lebih tinggi yaitu 82,1%, ketepatan klasifikasi menggunakan regresi logistik biner 80,1%, sedangkan dengan menggunakan analisis diskriminan hanya mendapatkan ketepatan klasifikasi sebesar 75 %.

Pada tahun 2012, W ijdani Anindya dan Suhartono melakukan penelitian pemodelan faktor-faktor yang mempengaruhi prestasi mahasiswa pascasarjana ITS dengan regresi logistik dan Neural Network memberikan hasil bahwa jika melibatkan variabel yang signifikan ketepatan klasifikasi yang tertinggi yaitu dengan menggunakan metode Neural Network dengan ketepatan klasifikasinya sebesar 76,23% dan 80,19% untuk masing-masing kategori IPK dan lama tempuh studi. Pada penelitian tersebut disimpulkan bahwa Neural Network merupakan metode yang lebih baik untuk mengklasifikasikan data prestasi mahasiswa pasca sarjana ITS dibanding regresi logistik.

Kajian terkait data obesitas dengan pendekatan Regresi Logistik dan Neural Network juga telah dilakukan oleh Heydari, Ayatollahi, dan Zare pada tahun 2012. Heydari dkk. Melakukan perbandingan antara regresi logistik biner dengan neural network dan menghasilkan performa ketepatan klasifikasi yang hampir sama yaitu 80.2% untuk regresi logistik biner dan 81.2% untuk neural network dengan menggunakan algoritma *backpropagation*.

BAB III

METODOLOGI PENELITIAN

3.1 Sumber Data

Data yang digunakan dalam penelitian ini adalah data sekunder yang diperoleh dari Riset Kesehatan Dasar (Riskesdas) tahun 2010 yang dilaksanakan oleh Badan Penelitian dan Pengembangan Kesehatan (Litbangkes), Kementerian Kesehatan RI tentang Status Gizi Anak Umur 6-12 tahun di Indonesia.

3.2 Variabel Penelitian

Variabel respon yang digunakan adalah klasifikasi apakah seorang anak termasuk obesitas atau tidak. Sedangkan untuk variabel prediktornya adalah lima nutrisi utama (*macronutrients*) yakni energy, protein, lemak, karbohidrat dan serat. Selengkapnya diberikan pada tabel berikut ini:

Tabel 3.1 Variabel Respon dan Prediktor dalam Penelitian

Variabel Respon (Y)	Kategori	Skala
Kriteria Obesitas	0= Tidak Obesitas 1= Obesitas	Nominal
Variabel Prediktor (X)	Kategori	Skala
Konsumsi Energi Per-hari (X_1)		Rasio
Konsumsi Protein Per-hari (X_2)		Rasio
Konsumsi Karbohidrat Per-hari (X_3)		Rasio
Konsumsi Lemak Per-hari (X_4)		Rasio
Konsumsi Serat Per-hari (X_5)		Rasio

3.3 Metode Analisis Data

Langkah-langkah analisis yang digunakan pada penelitian ini adalah sebagai berikut:

1. Membagi data menjadi dua bagian yaitu data *training* dan data *testing*. Data *training* digunakan untuk membentuk model, sedangkan data *testing* digunakan untuk menguji ketepatan model.
2. Pengolahan data dengan menggunakan regresi logistik biner dan Neural Network dengan Fungsi Radial Basis.

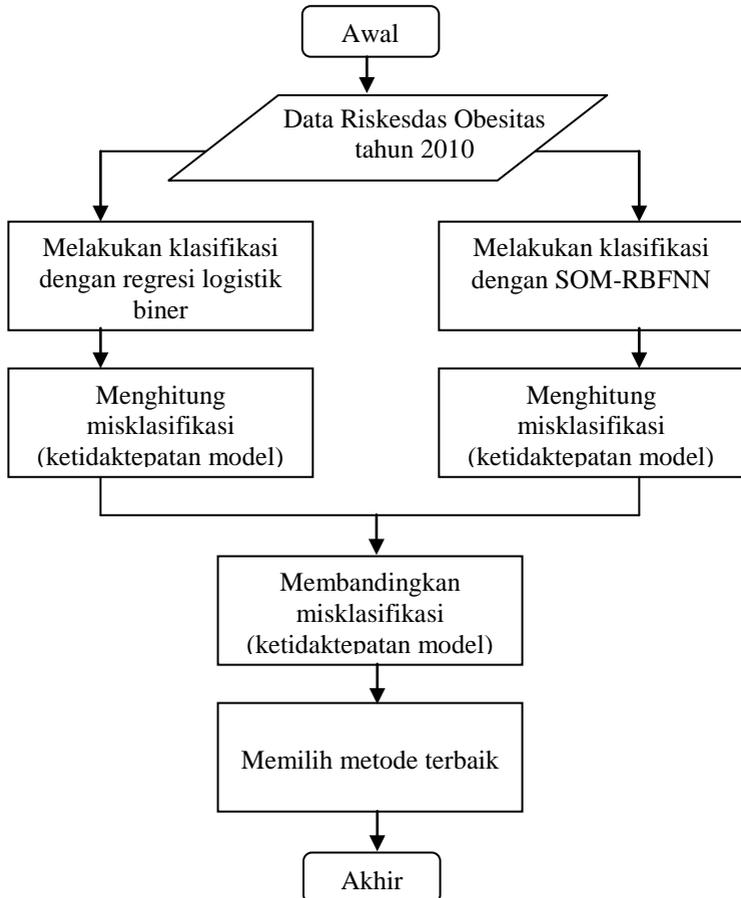
Regresi Logistik biner:

- a. Menyiapkan data penelitian.
- b. Melakukan pemodelan pada seluruh variabel prediktor.
- c. Pengujian parameter model regresi secara serentak dan parsial (individu).
- d. Pengujian hipotesis untuk menentukan kesesuaian model regresi logistik biner.
- e. Mengetahui hasil ketepatan klasifikasi berdasarkan model regresi logistik biner.
- f. Melakukan pemodelan kembali dengan hanya menggunakan variabel-variabel prediktor yang signifikan (melalui langkah b-d).
- g. Membentuk tabel ketepatan klasifikasi.
- h. Menghitung ketepatan klasifikasi.

SOM Radial Basis Function Neural Network (SOM-RBFNN)

- a. Menyiapkan data input .
- b. Penentuan cluster dengan menggunakan SOM untuk menghasilkan nilai *center* dari tiap kelompok data.
- c. Membagi data menjadi data *training* dan data *testing* dengan perbandingan 8:2.
- d. Penentuan bobot pada setiap neuron.
- e. Meneruskan sinyal input ke *hidden layer* dan menghitung nilai fungsi aktivasi pada tiap *hidden layer*.
- f. Menyusun matrik *Gaussian* dari hasil tahap ke-e.
- g. Menghitung bobot baru (W).

- h. Melakukan penghitungan output jaringan dengan metode *Ordinary Least Square* (OLS)
 - i. Menghitung ketepatan klasifikasi.
- Tahapan analisis data selengkapnya disajikan pada Gambar 3 berikut:



Gambar 3.1. Diagram Alir Metode Penelitian

(Halaman ini sengaja dikosongkan)

BAB IV ANALISIS DAN PEMBAHASAN

Pada bagian ini dilakukan analisis data obesitas untuk anak kelompok usia 6-12 tahun di Indonesia. Pembahasan diawali dengan pra-pemrosesan data obesitas. Pada proses ini data dibagi menjadi dua kelompok data yaitu kelompok data laki-laki dan kelompok data perempuan. Dilanjutkan dengan analisis dengan menggunakan analisis regresi logistik biner dan dengan menggunakan *Neural Networks* dengan inialisasi pembobot menggunakan *Self Organizing Maps* (SOM-RBFNN).

4.1 Pra-Pemrosesan Data Obesitas Anak Kelompok Usia 6-12 tahun di Indonesia.

Pada tahap ini, data penelitian akan menjadi dua kelompok yaitu data kelompok obesitas anak laki-laki dan anak perempuan. Dari masing-masing data tersebut nantinya akan dibagi lagi menjadi dua bagian yakni data *training* dan data *testing*. Berikut ini adalah ringkasan dari pra-pemrosesan data:

Tabel 4.1. Pra Pemrosesan Data Input

Jenis	TRAINING			TESTING		
	Obesitas	Jumlah	Total	Obesitas	Jumlah	Total
Laki-laki	Ya	1842	13716	Ya	342	3428
		13,4%			10%	
	Tidak	11874		Tidak	3086	
		86,6%			90	

Jenis	TRAINING			TESTING		
	Obesitas	Jumlah	Total	Obesitas	Jumlah	Total
Perempuan	Ya	1259	13026	Ya	214	3256
		9,7%			7%	
	Tidak	11767		Tidak	3042	
		90,3%			93%	

Berdasarkan informasi dari tabel 4.1 dapat dilihat bahwa untuk pembagian data training dan testing adalah dengan proporsi 80:20 untuk training dan testing. Dengan menggunakan proporsi tersebut, kecuali pada pembagian data *testing* untuk jenis kelamin perempuan, didapatkan bahwa persebaran data penderita obesitas yang hampir sama proporsinya yakni 10% dari data keseluruhan.

4.2 Analisis Deskriptif Data

Analisis terhadap konsumsi *macronutrients* anak usia 6-12 tahun di Indonesia dapat dilakukan dengan menggunakan data *pra-processing* sebelumnya yakni setelah data terbagi menjadi dua kelompok yaitu kelompok anak laki-laki dan kelompok anak perempuan.

Tabel 4.2 Statistika Deskriptif Data Konsumsi *Macronutrients*

Variabel	Kelompok	Mean	Standard Deviasi	Minimum	Maksimum
X ₁ (Energi)	Laki-laki	1203,6	520,2	83,0	4849,0
	Perempuan	1183,5	512,0	96,0	5646,0
X ₂ (Protein)	Laki-laki	40,8	22,4	0,9	331,3
	Perempuan	40,2	22,1	0,8	241,4
X ₃ (Lemak)	Laki-laki	35,9	26,8	0,2	284,9
	Perempuan	35,7	26,9	0,2	269,3
X ₄ (Karbohidrat)	Laki-laki	177,3	82,7	19,4	996,8
	Perempuan	173,7	81,9	2,4	1019,6
X ₅ (Serat)	Laki-laki	5,3	3,7	1,0	88,9
	Perempuan	5,3	3,8	1,0	85,8

Berdasarkan analisis statistika deskriptif pada tabel 4.2, rata-rata kebutuhan energi pada kelompok anak laki-laki lebih tinggi daripada rata-rata kebutuhan energi pada kelompok anak perempuan. Kebutuhan energi rata-rata pada kelompok anak laki-laki adalah 1203,6 kalori sedangkan pada kelompok anak perempuan kebutuhan energi rata-rata adalah 1183,5 kalori. Begitu pula pada sumber makronutrien lainnya yaitu protein, lemak dan karbohidrat, kebutuhan rata-rata protein, lemak dan karbohidrat pada anak laki-laki lebih tinggi daripada kelompok anak perempuan. Namun, pada unsur makronutrien yang berasal dari serat, dari analisis statistika deskriptif pada tabel 4.2 dapat

dilihat bahwa rata-rata kebutuhan serat pada kelompok anak laki-laki dan perempuan adalah sama.

4.3 Klasifikasi Menggunakan Regresi Logistik Biner

Untuk mengetahui faktor-faktor *macronutrients* apa saja yang mempengaruhi obesitas anak usia 6-12 tahun dilakukan analisis regresi logistik biner dengan langkah pengerjaan sebagai berikut.

- a. Melakukan koding ulang pada variabel. Variabel respon (Y) dalam penelitian ini adalah status obesitas (obesitas atau tidak obesitas). Variabel respon dalam klasifikasi obesitas responden pada variabel status gizi, yaitu mengganti status gizi 1, 2, 3 dan 4 dengan koding 0 untuk responden yang tidak obesitas dan mengganti status gizi 5 dengan koding 1 untuk responden yang terdeteksi obesitas. Sedangkan Variabel prediktornya adalah variabel faktor-faktor *macronutrients* (energi, protein, lemak, karbohidrat dan serat) yang mempengaruhi seorang anak berusia 6-12 tahun obesitas atau tidak.
- b. Melakukan uji signifikansi tahap 1. Pada proses ini hanya dilakukan dua uji yakni uji signifikansi secara serentak dan parsial. Setelah uji signifikansi secara parsial dan didapatkan variabel mana saja yang signifikan dalam model dan membuang satu variabel yang paling tidak signifikan untuk selanjutnya dari variabel yang didapat tersebut dilanjutkan pada uji signifikansi tahap 2.
- c. Melakukan uji signifikansi tahap 2. Pada tahap ini akan dilakukan uji serentak, parsial, pencarian ketepatan klasifikasi dan penentuan model akhir serta interpretasi *odds ratio*.

Langkah pengerjaan regresi logistik biner dari a-c di atas dilakukan pada masing-masing kelompok yakni kelompok anak laki-laki dan kelompok anak perempuan.

4.3.1 Regresi Logistik Biner Obesitas Kelompok Anak Laki-laki

4.3.1.1 Uji Signifikansi Tahap pertama

a. Uji Signifikansi Secara Serentak

Uji serentak adalah uji yang digunakan untuk mengetahui signifikansi seluruh variabel independen (X) dan variabel dependen (Y). Hipotesis yang digunakan untuk pengujian serentak variabel-variabel adalah sebagai berikut.

$$H_0 : \beta_1 = \beta_2 = \beta_3 = \beta_4 = \beta_5 = 0$$

$$H_1 : \text{Paling tidak terdapat satu } \beta_i \neq 0 ; \quad i = 1, 2, 3, 4, 5$$

Taraf Signifikansi: $\alpha=5\%$

Statistik Uji: Tolak H_0 jika $p\text{-value} < \alpha$

Tabel 4.3. Uji Serentak Variabel Prediktor Tahap Pertama pada Kelompok Anak Laki-laki

Uji serentak	<i>Chi-square</i>	Df	<i>P-value</i>
Model	37,900	3	0,000

Berdasarkan Tabel 4.3 dapat diketahui bahwa dengan menggunakan metode *backward-wald*, nilai *Chi-square* sebesar mode pada step akhir adalah 37,90 dengan derajat bebas 3 dan *P-value* yaitu 0,000 yang kurang dari nilai α yaitu 0,05. Sehingga dapat dikatakan bahwa paling tidak ada satu variabel yang berpengaruh signifikan terhadap model.

b. Uji Signifikansi Secara Parsial

Uji parsial adalah uji yang digunakan untuk mengetahui signifikansi variabel independen (X) dan variabel dependen (Y) secara individu. Hipotesis yang digunakan adalah sebagai berikut.

$$H_0 : \beta_j = 0$$

$$H_1 : \beta_j \neq 0 \text{ dimana } j=0,1,2,3,4,5$$

Taraf Signifikansi: $\alpha=5\%$

Statistik Uji: Statistik Uji: Tolak H_0 jika $p\text{-value} < \alpha$

Tabel 4.4. Uji Parsial Variabel Prediktor Tahap Pertama pada Kelompok Anak Laki-laki

Variabel	<i>P-value</i>	Keputusan
energi	0,000	Tolak H0
protein	0,000	Tolak H0
lemak	0,000	Tolak H0
Constant	0,000	Tolak H0

Berdasarkan tabel 4.4 dapat disimpulkan bahwa dengan menggunakan metode *backward wald*, setelah melalui tiga step, dari 5 variabel prediktor hanya ada 3 variabel yang berpengaruh signifikan terhadap status obesitas. Variabel tersebut adalah variabel energi, protein, dan lemak.

Karena berdasarkan tabel 4.4 terdapat beberapa variabel prediktor untuk menentukan status obesitas anak kelompok usia 6-12 tahun d yang tidak signifikan maka dilakukan pengujian kembali dengan mengeluarkan satu variabel yang paling tidak signifikan (serat) dari model dan hanya mempertahankan tiga variabel yang signifikan (energi, protein, lemak) dan satu variabel yang tidak signifikan yaitu karbohidrat.

4.3.1.2 Uji Signifikansi Tahap Kedua

a. Uji Signifikansi Secara Serentak

Uji serentak adalah uji yang digunakan untuk mengetahui signifikansi seluruh variabel independen (X) dan variabel dependen (Y). Hipotesis yang digunakan untuk pengujian serentak variabel-variabel adalah sebagai berikut.

$$H_0 : \beta_1 = \beta_2 = \beta_3 = \beta_4 = 0$$

$$H_1 : \text{Paling tidak terdapat satu } \beta_i \neq 0 ; \quad i = 1, 2, 3, 4$$

Taraf Signifikansi: $\alpha=5\%$

Statistik Uji: Statistik Uji: Tolak H0 jika $p\text{-value} < \alpha$

Tabel 4.5. Uji Serentak Variabel Prediktor Tahap Kedua pada Kelompok Anak Laki-laki

Uji serentak	<i>Chi-square</i>	df	<i>P-value</i>
Model	37,900	3	0,000

Berdasarkan Tabel 4.5 dapat diketahui bahwa dengan menggunakan metode *backward-wald*, nilai *Chi-square* sebesar

model pada step akhir adalah 37,90 dengan derajat bebas 3 dan *P-value* yaitu 0,000 yang kurang dari nilai α yaitu 0,05. Sehingga dapat dikatakan bahwa paling tidak ada satu variabel yang berpengaruh signifikan terhadap model.

b. Uji Signifikansi Secara Parsial

Uji parsial adalah uji yang digunakan untuk mengetahui signifikansi variabel independen (X) dan variabel dependen (Y) secara individu. Hipotesis yang digunakan adalah sebagai berikut.

$$H_0 : \beta_j = 0$$

$$H_1 : \beta_j \neq 0 \text{ dimana } j=0,1,2,3,4$$

Taraf Signifikansi: $\alpha=5\%$

Statistik Uji: Statistik Uji: Tolak H_0 jika *p-value* $< \alpha$

Tabel 4.6 Uji Parsial Variabel Prediktor Tahap Kedua pada Kelompok Anak Laki-laki

Variabel	<i>P-value</i>	Keputusan
energi	0,000	Tolak H_0
protein	0,000	Tolak H_0
lemak	0,000	Tolak H_0
Constant	0,000	Tolak H_0

Berdasarkan tabel 4.6 dapat disimpulkan bahwa dengan menggunakan metode *backward wald*, setelah melalui dua step, dari 4 variabel prediktor hanya ada 3 variabel yang berpengaruh signifikan terhadap status obesitas. Variabel tersebut adalah variabel energi, protein, dan lemak.

4.3.1.3 Ketepatan Klasifikasi (Akurasi)

Analisis ketepatan klasifikasi (akurasi) dari data faktor yang mempengaruhi status obesitas anak laki-laki usia 6-12 tahun di Indonesia adalah sebagai berikut.

Tabel 4.7. Ketepatan Klasifikasi pada Kelompok Anak Laki-laki

Obesitas	Prediksi			Prosentase benar
	Obesitas			
	0	1		
Tidak	0	11874	0	100,0
Ya	1	1842	0	0,0
Prosentase keseluruhan				86,6

Berdasarkan Tabel 4.7 dapat diketahui bahwa banyaknya observasi yang terklasifikasikan secara tepat dengan menggunakan rerresi logistik biner adalah sebesar 86,6%.

4.3.1.4 Model Regresi Logistik Biner dan Interpretasi *Odds Ratio*

Langkah terakhir dari analisis regresi logistik biner adalah menentukan model peluang dan interpretasi *odds ratio*, yaitu sebagai berikut.

Tabel 4.8. *Odds ratio* Kelompok Anak Laki-laki

Variabel	B	Odds Rasio
Energi	-0,005	0,995
Protein	0,006	1,006
Lemak	0,006	1,006
Konstant	-1,772	0,170

Berdasarkan nilai *odds ratio* pada tabel 4.8, untuk variabel energi dapat dikatakan bahwa setiap penurunan nilai energi satu satuan (10 gram) akan menyebabkan peluang untuk obesitas 0,995 kali dibanding dengan yang tidak obesitas.

Untuk variabel protein, setiap kenaikan nilai protein satu satuan (1 gram) akan menyebabkan peluang seorang anak laki-laki berusia 6-12 tahun untuk obesitas 1,006 kali dibanding dengan yang tidak obesitas. Dapat disimpulkan bahwa kenaikan nilai protein juga menyebabkan kenaikan peluang terkena obesitas.

Untuk variabel lemak, didapatkan bahwa setiap kenaikan nilai lemak satu satuan (1 gram) akan menyebabkan peluang seorang anak laki-laki berusia 6-12 tahun untuk obesitas 1,006 kali dibanding dengan yang tidak obesitas. Dapat disimpulkan bahwa kenaikan nilai lemak juga menyebabkan kenaikan peluang terkena obesitas.

Model regresi logistik biner untuk status obesitas anak laki-laki usia 6-12 di Indonesia adalah:

$$\hat{\pi}(X) = \frac{\exp(-1.772 - 0,005X_1 + 0.006X_2 + 0.006X_3)}{1 + \exp(-1.772 - 0,005X_1 + 0.006X_2 + 0.006X_3)}$$

4.3.2 Regresi Logistik Biner Obesitas Kelompok Anak Perempuan

4.3.2.1 Uji Signifikansi Tahap pertama

a. Uji Signifikansi Secara Serentak

Uji serentak adalah uji yang digunakan untuk mengetahui signifikansi seluruh variabel independen (X) dan variabel dependen (Y). Hipotesis yang digunakan adalah sebagai berikut.

$$H_0 : \beta_1 = \beta_2 = \beta_3 = \beta_4 = \beta_5 = 0$$

$$H_1 : \text{Paling tidak terdapat satu } \beta_i \neq 0 ; \quad i = 1, 2, 3, 4, 5$$

Taraf Signifikansi: $\alpha=5\%$

Statistik Uji: Statistik Uji: Tolak H_0 jika $p\text{-value} < \alpha$

Tabel 4.9. Uji Serentak Variabel Prediktor Tahap Pertama pada Kelompok Anak Perempuan

Uji serentak	<i>Chi-square</i>	Df	<i>P-value</i>
Model	14,949	3	0,002

Berdasarkan Tabel 4.9 dapat diketahui bahwa dengan menggunakan metode *backward-wald*, nilai *Chi-square* sebesar mode pada step akhir adalah 14,949 dengan derajat bebas 3 dan *P-value* yaitu 0,002 yang kurang dari nilai α yaitu 0,05. Sehingga dapat dikatakan bahwa paling tidak ada satu variabel yang berpengaruh signifikan terhadap model.

b. Uji Signifikansi Secara Parsial

Uji parsial adalah uji yang digunakan untuk mengetahui signifikansi variabel independen (X) dan variabel dependen (Y) secara individu. Hipotesis yang digunakan adalah sebagai berikut.

$$H_0 : \beta_j = 0$$

$$H_1 : \beta_j \neq 0 \text{ dimana } j=0,1,2,3,4,5$$

Taraf Signifikansi: $\alpha=5\%$

Statistik Uji: Statistik Uji: Tolak H_0 jika $p\text{-value} < \alpha$

Tabel 4.10. Uji Parsial Variabel Prediktor Tahap Pertama pada Kelompok Anak Perempuan

Variabel	<i>P-value</i>	Keputusan
energi	0,002	Tolak H_0
lemak	0,011	Tolak H_0
karbohidrat	0,000	Tolak H_0
Constant	0,000	Tolak H_0

Berdasarkan tabel 4.10 dapat disimpulkan bahwa dengan menggunakan metode *backward wald*, setelah melalui tiga step, dari 5 variabel prediktor hanya ada 3 variabel yang berpengaruh signifikan terhadap status obesitas. Variabel tersebut adalah variabel energi, lemak dan karbohidrat.

Karena berdasarkan tabel 4.109 terdapat beberapa variabel prediktor untuk menentukan status obesitas anak kelompok usia 6-12 tahun yang tidak signifikan maka dilakukan pengujian kembali dengan mengeluarkan satu variabel yang paling tidak signifikan (serat) dari model dan hanya mempertahankan tiga variabel yang signifikan (energi, lemak, karbohidrat) dan satu variabel yang tidak signifikan yaitu protein.

4.3.2.2 Uji Signifikansi Tahap Kedua

a. Uji Signifikansi Secara Serentak

Uji serentak adalah uji yang digunakan untuk mengetahui signifikansi seluruh variabel independen (X) dan variabel dependen (Y). Hipotesis yang digunakan adalah sebagai berikut.

$$H_0 : \beta_1 = \beta_2 = \beta_3 = \beta_4 = 0$$

$$H_1 : \text{Paling tidak terdapat satu } \beta_i \neq 0 ; \quad i = 1, 2, 3, 4$$

Taraf Signifikansi: $\alpha=5\%$

Statistik Uji: Statistik Uji: Tolak H_0 jika $p\text{-value} < \alpha$

Tabel 4.11. Uji Serentak Variabel Prediktor Tahap Kedua pada Kelompok Anak Perempuan

Uji serentak	<i>Chi-square</i>	Df	<i>P-value</i>
Model	14,949	3	0,002

Berdasarkan Tabel 4.11 dapat diketahui bahwa dengan menggunakan metode *backward-wald*, nilai *Chi-square* sebesar mode pada step akhir adalah 14,949 dengan derajat bebas 3 dan *P-value* yaitu 0,002 yang kurang dari nilai α yaitu 0,05. Sehingga dapat dikatakan bahwa paling tidak ada satu variabel yang berpengaruh signifikan terhadap model.

b. Uji Signifikansi Secara Parsial

Uji parsial adalah uji yang digunakan untuk mengetahui signifikansi variabel independen (X) dan variabel dependen (Y) secara individu. Hipotesis yang digunakan adalah sebagai berikut.

$$H_0 : \beta_j = 0$$

$$H_1 : \beta_j \neq 0 \text{ dimana } j=1,2,3,4,5$$

Taraf Signifikansi: $\alpha=5\%$

Statistik Uji: Statistik Uji: Tolak H_0 jika $p\text{-value} < \alpha$

Tabel 4.12. Uji Parsial Variabel Prediktor Tahap Kedua pada Kelompok Anak Perempuan

Variabel	<i>P-value</i>	Keputusan
energi	0,002	Tolak H_0
lemak	0,011	Tolak H_0
karbohidrat	0,000	Tolak H_0
Constant	0,000	Tolak H_0

Berdasarkan tabel 4.12 dapat disimpulkan bahwa dengan menggunakan metode *backward wald*, setelah melalui dua step, dari 4 variabel prediktor hanya ada 3 variabel yang berpengaruh signifikan terhadap status obesitas. Variabel tersebut adalah variabel energi, lemak, dan karbohidrat.

4.3.2.3 Ketepatan Klasifikasi (Akurasi)

Analisis ketepatan klasifikasi (akurasi) dari data faktor yang mempengaruhi status obesitas anak perempuan usia 6-12 tahun di Indonesia adalah sebagai berikut.

Tabel 4.13. Ketepatan Klasifikasi pada Kelompok Anak Perempuan

Obesitas	Prediksi		Prosentase benar
	Obesitas 0	Obesitas 1	
Tidak 0	11767	0	100,0
Ya 1	1259	0	0,0
Prosentase keseluruhan			90,3

Berdasarkan Tabel 4.13 dapat diketahui bahwa banyaknya observasi yang terklasifikasikan secara tepat dengan menggunakan reresi logistik biner adalah sebesar 90,3%.

4.3.2.4 Model Regresi Logistik Biner dan Interpretasi *Odds Ratio*

Langkah terakhir dari analisis regresi logistik biner adalah menentukan model peluang dan interpretasi *odds ratio*, yaitu sebagai berikut.

Tabel 4.14. *Odds ratio* Kelompok Anak Perempuan

Variabel	B	Odds Rasio
Energi	0,011	1,001
Lemak	-0,010	0,990
Karbohidrat	-0,005	0,995
Konstant	-2,204	0,110

Berdasarkan nilai *odds ratio*, untuk variabel energi dapat dikatakan bahwa setiap kenaikan nilai energi satu satuan (10 gram) akan menyebabkan peluang untuk obesitas 1,001 kali dibanding dengan yang tidak obesitas. Hal tersebut berarti bahwa kenaikan energi yang dikonsumsi oleh anak perempuan usia 6-12 tahun menyebabkan kenaikan peluang untuk obesitas.

Untuk variabel lemak, setiap penurunan nilai lemak satu satuan (1 gram) akan menyebabkan peluang seorang anak perempuan berusia 6-12 tahun untuk obesitas 0,990 kali dibanding dengan yang tidak obesitas. Dapat disimpulkan bahwa penurunan nilai lemak juga menyebabkan penurunan peluang terkena obesitas.

Untuk variabel karbohidrat, didapatkan bahwa setiap penurunan nilai karbohidrat satu satuan (1 gram) akan menyebabkan peluang seorang anak perempuan berusia 6-12 tahun untuk obesitas 0,995 kali dibanding dengan yang tidak obesitas. Dapat disimpulkan bahwa penurunan nilai lemak juga menyebabkan penurunan peluang terkena obesitas.

Model regresi logistik biner untuk status obesitas anak perempuan usia 6-12 di Indonesia adalah:

$$\hat{\pi}(X) = \frac{\exp(-2.204 + 0.011X_1 - 0.010X_3 - 0.005X_4)}{1 + \exp(-2.204 + 0.011X_1 - 0.010X_3 - 0.005X_4)}$$

4.4. Klasifikasi Menggunakan Neural Network

4.4.1 Klasifikasi Menggunakan Neural Network pada Kelompok Anak Laki-laki

Pembentukan model menggunakan SOM digunakan untuk mendapatkan jumlah node pada *hidden layer* beserta nilai *mean* dan standart deviasi. Pada dasarnya belum ada standart untuk menentukan berapa jumlah kelas yang paling baik, sehingga dalam penelitian ini digunakan jumlah kelas sebanyak 2, 3, 4, 5, dan 10 kelas. *Clustering* menggunakan metode SOM dengan lima kombinasi jumlah *cluster* tersebut, diperoleh nilai *mean* dan standart deviasi sebagai berikut:

Tabel 4.15. Nilai *Mean* dan Standard Deviasi Pada 2 *Cluster*

Prediktor	Mean		Standard Deviasi	
	Cluster 1	Cluster 2	Cluster 1	Cluster 2
X1 (Energi)	973.8343	1880.45	265.3565	423.2628
X2 (Protein)	33.76847	61.43459	15.46857	25.43356
X3 (Lemak)	27.74237	62.92862	16.52422	30.78465
X4 (Karbohidrat)	145.4119	266.0876	45.46374	93.62479

Tabel 4.16. Nilai *Mean* dan Standard Deviasi Pada 3 *Cluster*

Prediktor	Mean			Standard Deviasi		
	Cluster 1	Cluster 2	Cluster 3	Cluster 1	Cluster 2	Cluster 3
X1 (Energi)	833.5052	1407.458	2223.451	195.8829	189.7116	412.7146
X2 (Protein)	28.80518	48.34633	70.42084	12.55821	17.90493	29.08114
X3 (Lemak)	22.3709	44.62229	75.81829	13.36422	20.064	35.10417
X4 (Karbohidrat)	127.5706	200.9764	315.034	36.10345	50.7103	107.7204

Tabel 4.17. Nilai *Mean* dan Standard Deviasi Pada 4 *Cluster*

Prediktor	Mean			Standard Deviasi		
	Cluster 1	...	Cluster 4	Cluster 1	...	Cluster 4
X1 (Energi)	728.9523	...	1669.716	156.1076	...	177.2425
X2 (Protein)	25.05503	...	56.16914	10.94276	...	20.45047
X3 (Lemak)	18.47847	...	54.89192	11.23373	...	23.25107
X4 (Karbohidrat)	114.1096	...	235.9803	30.07684	...	60.28957

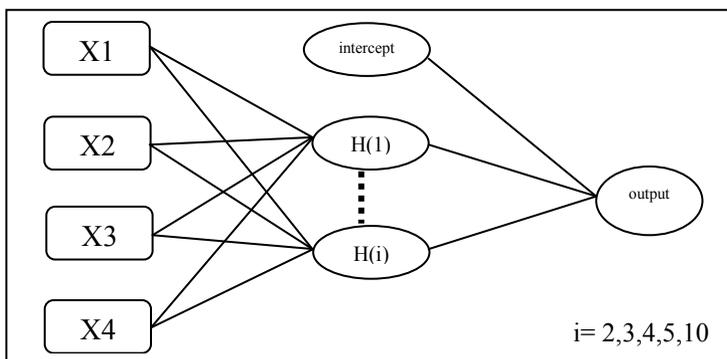
Tabel 4.18. Nilai *Mean* dan Standard Deviasi Pada 5 *Cluster*

Prediktor	Mean			Standard Deviasi		
	Cluster 1	...	Cluster 5	Cluster 1	...	Cluster 5
X1 (Energi)	662.0413	...	1881.987	133.7366	...	174.7275
X2 (Protein)	22.80657	...	62.33145	10.30891	...	23.08715
X3 (Lemak)	15.94107	...	62.75604	9.837012	...	27.05244
X4 (Karbohidrat)	105.4554	...	265.7512	26.2736	...	68.42489

Tabel 4.19. Nilai *Mean* dan Standard Deviasi Pada 10 *Cluster*

Prediktor	Mean			Standard Deviasi		
	Cluster 1	...	Cluster 10	Cluster 1	...	Cluster 10
X1 (Energi)	505.1416	...	2334.023	90.16165	...	142.6512
X2 (Protein)	16.83855	...	73.50033	8.050785	...	27.79829
X3 (Lemak)	9.857247	...	82.19493	6.886529	...	34.29104
X4 (Karbohidrat)	86.09557	...	325.6504	18.93017	...	89.67925

Arsitektur dari model RBF dengan menggunakan lima kombinasi *hidden layer* disajikan pada gambar berikut ini.



Gambar 4.1. Arsitektur Jaringan Syaraf Tiruan Menggunakan Node Hasil *Clustering* SOM pada Kelompok Anak Laki-laki

4.4.2 Klasifikasi Menggunakan Neural Network pada Kelompok Perempuan

Seperti halnya pada pengerjaan dalam kelompok anak laki-laki, pada kelompok anak perempuan pembentukan model menggunakan SOM digunakan untuk mendapatkan jumlah node pada *hidden layer* beserta nilai *mean* dan standart deviasi. Pada dasarnya belum ada standart untuk menentukan berapa jumlah kelas yang paling baik, sehingga dalam penelitian ini digunakan jumlah kelas sebanyak dua. Dengan metode SOM dengan tiga kelas, diperoleh nilai *mean* dan standart deviasi sebagai berikut:

Tabel 4.20. Nilai *Mean* dan Standard Deviasi Pada 2 Cluster

Prediktor	Mean		Standard Deviasi	
	Cluster 1	Cluster 2	Cluster 1	Cluster 2
X1 (Energi)	943.9793	1819.108	248.6348	430.379
X2 (Protein)	32.80081	59.88666	14.47075	25.24209
X3 (Lemak)	27.081	61.28481	16.06981	31.46145
X4 (Karbohidrat)	140.5026	256.0151	42.95204	95.02118

Tabel 4.21. Nilai *Mean* dan Standard Deviasi Pada 3 Cluster

Prediktor	Mean			Standard Deviasi		
	Cluster 1	Cluster 2	Cluster 3	Cluster 1	Cluster 2	Cluster 3
X1 (Energi)	836.2011	1428.565	2300.942	193.844	200.2121	423.5594
X2 (Protein)	29.31263	48.70936	72.09813	12.98136	18.21391	30.26076
X3 (Lemak)	22.66656	46.48611	79.35192	13.29029	21.29761	38.05307
X4 (Karbohidrat)	127.0796	201.9538	325.1681	35.85625	53.51593	117.7794

Tabel 4.22. Nilai *Mean* dan Standard Deviasi Pada 4 Cluster

Prediktor	Mean			Standard Deviasi		
	Cluster 1	...	Cluster 4	Cluster 1	...	Cluster 4
X1 (Energi)	726.824	...	1639.561	151.2375	...	175.6836
X2 (Protein)	25.59669	...	55.62955	11.34766	...	20.74924
X3 (Lemak)	18.71707	...	54.77669	10.97431	...	24.21329
X4 (Karbohidrat)	112.5186	...	229.3249	28.9971	...	61.06831

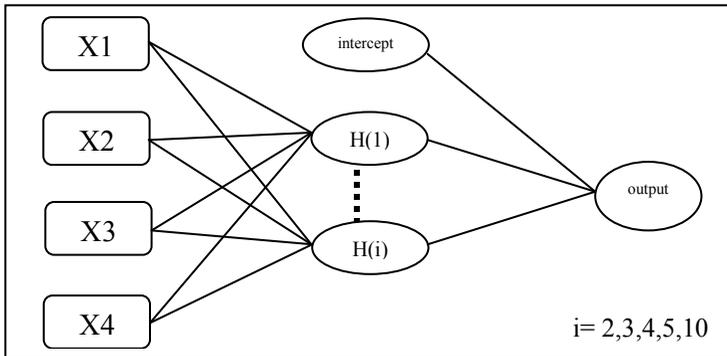
Tabel 4.23. Nilai *Mean* dan Standard Deviasi Pada 5 Cluster

Prediktor	Mean			Standard Deviasi		
	Cluster 1	...	Cluster 5	Cluster 1	...	Cluster 5
X1 (Energi)	667.1727	...	1386.714	131.3251	...	112.8932
X2 (Protein)	23.44731	...	47.35221	10.56074	...	16.7062
X3 (Lemak)	16.45521	...	45.06568	9.755881	...	19.12115
X4 (Karbohidrat)	104.898	...	195.9003	25.39832	...	46.20397

Tabel 4.24. Nilai *Mean* dan Standard Deviasi Pada 10 Cluster

Prediktor	Mean			Standard Deviasi		
	Cluster 1	...	Cluster 10	Cluster 1	...	Cluster 10
X1 (Energi)	514.8406	...	1610.316	91.99092	...	67.59939
X2 (Protein)	17.8383	...	54.56717	8.530283	...	20.00937
X3 (Lemak)	10.48954	...	53.28923	6.872796	...	22.76285
X4 (Karbohidrat)	86.09432	...	226.5338	18.63258	...	56.05411

Arsitektur dari model RBF dengan menggunakan jumlah *node* hasil *clustering* menggunakan SOM disajikan pada gambar berikut ini.



Gambar 4.2. Arsitektur Jaringan Syaraf Tiruan Menggunakan Jumlah *Node* Hasil *Clustering* SOM [pada Kelompok Anak Perempuan](#)

4.4.3 Klasifikasi dengan RBFNN

Dari kombinasi 5 macam *hidden layer*, akan dipilih jumlah *hidden layer* yang memberikan nilai ketepatan klasifikasi paling maksimal. Berdasarkan hasil uji coba didapatkan bahwa semua kombinasi *hidden layer* menghasilkan nilai ketepatan klasifikasi yang sama, oleh karena itu ditambahkan penilaian kebaikan model yang lain yaitu nilai MSE. Berikut ini adalah hasil rekapitulasi dari pemilihan 5 macam *hidden layer*.

Tabel 4.25. Nilai *Performansi* Masing-masing Hidden Layer

Kelompok	Jumlah Hidden Layer	Data	Ketepatan Klasifikasi	SSE	MSE
Anak Laki-laki	2	Training	86.5704	1594.5	0.116277
		Testing	90.0233	311.6324	0.090988
	3	Training	86.5704	1594.6	0.116292
		Testing	90.0233	312.0478	0.091135
	4	Training	86.5704	1594.5	0.116293
		Testing	89.965	445520	130.1548
	5	Training	86.5704	1593.4	0.116222
		Testing	90.0233	312.3198	0.091268
	10	Training	86.5704	1593.1	0.116242
		Testing	90.0233	312.108	0.09134

Kelompok	Jumlah Hidden Layer	Kriteria	Ketepatan Klasifikasi	SSE	MSE
Anak Perempuan	2	Training	90.3347	1137	0.087307
	-	Testing	93.4275	202.7622	0.062331
	3	Training	90.3347	1137.1	0.087321
		Testing	93.4275	202.822	0.062368
	4	Training	90.3347	1136.6	0.08729
		Testing	93.4275	203.1114	0.062477
	5	Training	90.3347	1136.9	0.08732
		Testing	93.4275	202.8748	0.062423
	10	Training	90.3347	1136.6	0.08733
		Testing	93.4275	202.8008	0.062496

Berdasarkan tabel 4.25 diketahui bahwa pada kelompok anak laki-laki maupun kelompok anak perempuan, model yang menghasilkan nilai MSE terkecil pada data training dan testing adalah model dengan *hidden layer 2 node*.

Nilai *mean* dan standard deviasi yang didapat dari proses *clustering* menggunakan SOM digunakan untuk menasir matrik Gaussian (H) dan dilanjutkan dengan menentukan bobot menggunakan metode Ordinary Least Square (OLS). Dengan menggunakan metode RBF didapatkan matrik Gaussian (H) dan nilai bobot taksiran pada masing-masing node di hidden layer.

Didapatkan nilai matrik Gaussian pada masing-masing node untuk kelompok anak laki-laki dengan jumlah *hidden layer* sebanyak 2 adalah sebagai berikut:

$$H1 = \exp \left[\frac{1}{2} \left\{ \left(\frac{x_1 - 973.834347}{265.3564754} \right)^2 + \left(\frac{x_2 - 33.76846511}{15.46857375} \right)^2 + \left(\frac{x_3 - 27.74236769}{16.52422482} \right)^2 + \left(\frac{x_4 - 145.4118884}{45.46374468} \right)^2 \right\} \right]$$

$$H2 = \exp \left[\frac{1}{2} \left\{ \left(\frac{x_1 - 1880.450311}{423.2627673} \right)^2 + \left(\frac{x_2 - 61.43458879}{125.43356256} \right)^2 + \left(\frac{x_3 - 62.92862391}{30.78464518} \right)^2 + \left(\frac{x_4 - 266.0876448}{93.62479296} \right)^2 \right\} \right]$$

Sedangkan untuk kelompok anak perempuan adalah:

$$H1 = \exp \left[\frac{1}{2} \left\{ \left(\frac{x_1 - 943.9792573}{248.6348393} \right)^2 + \left(\frac{x_2 - 32.80080674}{14.47075444} \right)^2 + \left(\frac{x_3 - 27.08100301}{16.0698086} \right)^2 + \left(\frac{x_4 - 140.5025643}{42.95204155} \right)^2 \right\} \right]$$

$$H2 = \exp \left[\frac{1}{2} \left\{ \left(\frac{x_1 - 1819.108155}{430.3790476} \right)^2 + \left(\frac{x_2 - 59.88666322}{25.24209004} \right)^2 + \left(\frac{x_3 - 61.28480537}{31.46145195} \right)^2 + \left(\frac{x_4 - 256.0150953}{95.02117611} \right)^2 \right\} \right]$$

Dengan matrik $H = [H1 \ H2 \ b]$

Setelah memperoleh matrik Gaussian maka tahapan berikutnya adalah menghitung nilai bobot (w) dengan menggunakan metode Ordinary Least Square (OLS) yaitu dengan mengalikan matrik $(H^T * H)^{-1} * (H^T * Y)$. Berdasarkan perhitungan dengan metode OLS diperoleh nilai taksiran pembobot sebagai berikut:

Tabel 4.26. Nilai Taksiran Pembobot Model RBF

Kelompok anak laki-laki	Kelompok anak Perempuan
-0,0045638	0,0160006
0,0130275	0,0258330
0,1334698	0,0895515

Taksiran nilai pembobot pada tabel 4.26 di atas selanjutnya digunakan untuk mencari taksiran nilai Y pada data training dan testing.

4.4.4 Pemilihan Metode Terbaik

Untuk pemilihan metode terbaik, digunakan nilai ketepatan klasifikasi pada data training dan testing yang disajikan pada tabel 4.27 berikut:

Tabel 4.27. Ketepatan Klasifikasi pada Data Training dan Testing untuk Metode Regresi Logistik Biner dan *Neural Networks*

Metode	Kelompok Anak Laki-laki	
	Ketepatan Data Training (%)	Ketepatan Data Testing (%)
Rgresi Logistik Biner	86,6	90
SOM-RBFNN	86,5704	90,0233

Kelompok Anak Perempuan		
Metode	Ketepatan Data Training (%)	Ketepatan Data Testing (%)
Regresi Logistik Biner	90,3%	93,4
SOM-RBFNN	90,3347	93,4275

Pada tabel 4.27 dapat dilihat bahwa perbedaan antara ketepatan klasifikasi antara kedua metode sangatlah kecil, baik menggunakan regresi logistik biner maupun metode *neural networks* dengan SOM-RBFNN memiliki ketepatan klasifikasi yang hampir sama.

BAB V

PENUTUP

5.1 Kesimpulan

Berdasarkan hasil analisis dan pembahasan pada bab sebelumnya, maka dapat disimpulkan bahwa:

1. Dengan metode regresi logistik biner diketahui variabel yang berpengaruh terhadap respon yaitu variabel untuk kategori anak laki-laki adalah variabel energi, protein, dan lemak. Model logit nya adalah sebagai berikut:

$$\hat{\pi}(X) = \frac{\exp(-1.772 - 0,005X_1 + 0.006X_2 + 0.006X_3)}{1 + \exp(-1.772 - 0,005X_1 + 0.006X_2 + 0.006X_3)}$$

Pada kelompok anak laki-laki, ketepatan klasifikasi data training adalah 86,6 % sedangkan untuk data testing 90%.

Untuk kategori Anak Perempuan, dengan metode regresi logistik biner diketahui variabel yang berpengaruh terhadap respon yaitu variabel energi, lemak, dan karbohidrat. Model logit nya adalah sebagai berikut:

$$\hat{\pi}(X) = \frac{\exp(-2.204 + 0.011X_1 - 0.010X_3 - 0.005X_4)}{1 + \exp(-2.204 + 0.011X_1 - 0.010X_3 - 0.005X_4)}$$

Pada kelompok anak perempuan, ketepatan klasifikasi data training adalah 90,3% sedangkan untuk data testing 93,4%.

2. Jumlah Hidden Layer yang paling optimal adalah 2 hidden layer untuk setiap kelompok. Dengan nilai pembobot:

Tabel 5.1. Nilai taksiran Pembobot Model RBF

Kelompok anak laki-laki	Kelompok anak perempuan
-0,0045638	0,0160006
0,0130275	0,0258330
0,1334698	0,0895515

Pada kelompok anak laki-laki, ketepatan klasifikasi data training adalah 86,574 % sedangkan untuk data testing 90,023%. Sedangkan pada kelompok anak perempuan,

ketepatan klasifikasi data training adalah 90,3347% sedangkan untuk data testing 93,4275%.

3. Berdasarkan kedua perhitungan bisa diambil kesimpulan bahwa secara umum dalam hal ketepatan klasifikasi, metode radial basis function dengan pendekatan SOM dan regresi logistik biner memberikan hasil yang tidak jauh berbeda.

5.2 Saran

Pada penelitian ini kedua metode menghasilkan ketepatan klasifikasi yang hampir sama. Untuk mendapatkan model yang lebih baik, studi tentang variabel yang digunakan bisa lebih diperdalam sehingga akan memberikan hasil yang lebih baik. Disarankan pula untuk mengembangkan metode RBF yang sudah ada dengan mencoba fungsi aktivasi yang lain selain *Gaussian* sehingga diharapkan dapat diperoleh hasil yang lebih optimal.

Selain itu untuk membandingkan kebaikan model tidak cukup hanya dengan prosentase yang benar dan salah mengklasifikasikan saja (ketepatan klasifikasi), akan tetapi diperlukan metode keakuratan klasifikasi lain seperti penggunaan ROC Curve yang dapat mengatasi ketidakmampuan mengklasifikasi secara proporsional (hanya terklasifikasi dalam satu kategori saja).

LAMPIRAN

LAMPIRAN A: Data Obesitas Anak Usia 6-12 Tahun Indonesia (2010)

A1. Kelompok Anak Laki-laki

Energi	Protein	Lemak	Karbohidrat	Serat	Status Obesitas (0=Tidak; 1=Ya)
85,2	39.75	23.92	115.17	2.85	0
131,0	61.11	27.49	198.6	2.55	0
114,6	40.13	23.88	187.08	5.15	0
130,0	42.72	26.91	217.35	7.27	0
96,6	31.98	19.2	163.29	2.85	0
51,4	21.9	3.85	93.66	1.02	0
85,9	31.5	19.2	136.2	2.85	0
64,3	12.85	11.75	120.03	2.71	0
95,6	29.8	14.025	174.915	5.625	0
53,3	18.4	2.4	105.8	3.25	0
91,7	29.8	14.025	164.925	5.625	0
80,4	24.2	2.85	164.45	3.65	0
76,0	29.1	18.8	114.4	1.2	0
89,9	30.71	9.44	169.23	3.92	0
...
...
...
85,6	25.26	15.67	150.43	4.29	0
113,0	54.87	17.67	179.15	2.5	0
104,2	53.78	12.85	171.88	4.08	1
105,7	89.35	15.25	133.91	2.89	0
84,8	37.85	26.1	113.516	4.272	0

A2. Kelompok Anak Perempuan

Energi	Protein	Lemak	Karbohidrat	Serat	Status Obesitas (0=Tidak; 1=Ya)
120,8	45.045	5.236	236.978	4.83	0
114,6	67.09	23.135	159.425	3.175	0
112,9	30.85	30.325	181.575	4.475	0
82,5	30.3	18.9	128.7	1.35	0
93,8	55.975	17.375	133.6	3.45	0
90,6	44.25	21.15	128.7	1.35	0
83,7	31.9	19	130.2	2.75	0
93,2	75	20.95	104.6	1.875	1
102,5	97.6	18.3	108.8	2.95	1
100,6	64.29	26.16	121.95	2.45	0
85,9	31.5	19.2	136.2	2.85	0
96,3	63.54	18.36	128.7	1.35	0
75,3	29.78	8.92	134.3	3.75	0
109,1	76.01	30.04	121.95	2.45	0
91,7	29.8	14.025	164.925	5.625	0
105,9	98.25	20.05	113.15	3.9	0
...
...
...
250,5	80.735	114.685	283.275	5.95	0
131,6	66.9	47.15	150.65	6.35	1
164,9	58.455	52.155	231.86	3.24	1
105,7	54.655	7.245	186.085	4.245	0
60,8	21.08	12.76	100.616	3.722	0

LAMPIRAN B : Tabel Standard Deviasi Penentuan Obesitas

Standar Indeks Massa Tubuh menurut Umur (IMT/U)
Anak Laki-Laki Umur 5-18 Tahun

Umur		Indeks Massa Tubuh (IMT)						
Tahun	Bulan	-3 SD	-2 SD	-1 SD	Median	1 SD	2 SD	3 SD
5	1	12.1	13.0	14.1	15.3	16.6	18.3	20.2
5	2	12.1	13.0	14.1	15.3	16.6	18.3	20.2
5	3	12.1	13.0	14.1	15.3	16.7	18.3	20.2
5	4	12.1	13.0	14.1	15.3	16.7	18.3	20.3
5	5	12.1	13.0	14.1	15.3	16.7	18.3	20.3
5	6	12.1	13.0	14.1	15.3	16.7	18.4	20.4
5	7	12.1	13.0	14.1	15.3	16.7	18.4	20.4
5	8	12.1	13.0	14.1	15.3	16.7	18.4	20.5
5	9	12.1	13.0	14.1	15.3	16.7	18.4	20.5
5	10	12.1	13.0	14.1	15.3	16.7	18.5	20.6
5	11	12.1	13.0	14.1	15.3	16.7	18.5	20.6
6	0	12.1	13.0	14.1	15.3	16.8	18.5	20.7
6	1	12.1	13.0	14.1	15.3	16.8	18.6	20.8
6	2	12.2	13.1	14.1	15.3	16.8	18.6	20.8
6	3	12.2	13.1	14.1	15.3	16.8	18.6	20.9
6	4	12.2	13.1	14.1	15.4	16.8	18.7	21.0
6	5	12.2	13.1	14.1	15.4	16.9	18.7	21.0
6	6	12.2	13.1	14.1	15.4	16.9	18.7	21.1
6	7	12.2	13.1	14.1	15.4	16.9	18.8	21.2
6	8	12.2	13.1	14.2	15.4	16.9	18.8	21.3
6	9	12.2	13.1	14.2	15.4	17.0	18.9	21.3
6	10	12.2	13.1	14.2	15.4	17.0	18.9	21.4
6	11	12.2	13.1	14.2	15.5	17.0	19.0	21.5
7	0	12.3	13.1	14.2	15.5	17.0	19.0	21.6
7	1	12.3	13.2	14.2	15.5	17.1	19.1	21.7
7	2	12.3	13.2	14.2	15.5	17.1	19.1	21.8
7	3	12.3	13.2	14.3	15.5	17.1	19.2	21.9
7	4	12.3	13.2	14.3	15.6	17.2	19.2	22.0
7	5	12.3	13.2	14.3	15.6	17.2	19.3	22.0
7	6	12.3	13.2	14.3	15.6	17.2	19.3	22.1
7	7	12.3	13.2	14.3	15.6	17.3	19.4	22.2
7	8	12.3	13.2	14.3	15.6	17.3	19.4	22.4
7	9	12.4	13.3	14.3	15.7	17.3	19.5	22.5
7	10	12.4	13.3	14.4	15.7	17.4	19.6	22.6
7	11	12.4	13.3	14.4	15.7	17.4	19.6	22.7
8	0	12.4	13.3	14.4	15.7	17.4	19.7	22.8

Standar Indeks Massa Tubuh menurut Umur (IMT/U)
Anak Laki-Laki Umur 5-18 Tahun

Umur		Indeks Massa Tubuh (IMT)						
Tahun	Bulan	-3 SD	-2 SD	-1 SD	Median	1 SD	2 SD	3 SD
8	1	12.4	13.3	14.4	15.8	17.5	19.7	22.9
8	2	12.4	13.3	14.4	15.8	17.5	19.8	23.0
8	3	12.4	13.3	14.4	15.8	17.5	19.9	23.1
8	4	12.4	13.4	14.5	15.8	17.6	19.9	23.3
8	5	12.5	13.4	14.5	15.9	17.6	20.0	23.4
8	6	12.5	13.4	14.5	15.9	17.7	20.1	23.5
8	7	12.5	13.4	14.5	15.9	17.7	20.1	23.6
8	8	12.5	13.4	14.5	15.9	17.7	20.2	23.8
8	9	12.5	13.4	14.6	16.0	17.8	20.3	23.9
8	10	12.5	13.5	14.6	16.0	17.8	20.3	24.0
8	11	12.5	13.5	14.6	16.0	17.9	20.4	24.2
9	0	12.6	13.5	14.6	16.0	17.9	20.5	24.3
9	1	12.6	13.5	14.6	16.1	18.0	20.5	24.4
9	2	12.6	13.5	14.7	16.1	18.0	20.6	24.6
9	3	12.6	13.5	14.7	16.1	18.0	20.7	24.7
9	4	12.6	13.6	14.7	16.2	18.1	20.8	24.9
9	5	12.6	13.6	14.7	16.2	18.1	20.8	25.0
9	6	12.7	13.6	14.8	16.2	18.2	20.9	25.1
9	7	12.7	13.6	14.8	16.3	18.2	21.0	25.3
9	8	12.7	13.6	14.8	16.3	18.3	21.1	25.5
9	9	12.7	13.7	14.8	16.3	18.3	21.2	25.6
9	10	12.7	13.7	14.9	16.4	18.4	21.2	25.8
9	11	12.8	13.7	14.9	16.4	18.4	21.3	25.9
10	0	12.8	13.7	14.9	16.4	18.5	21.4	26.1
10	1	12.8	13.8	15.0	16.5	18.5	21.5	26.2
10	2	12.8	13.8	15.0	16.5	18.6	21.6	26.4
10	3	12.8	13.8	15.0	16.6	18.6	21.7	26.6
10	4	12.9	13.8	15.0	16.6	18.7	21.7	26.7
10	5	12.9	13.9	15.1	16.6	18.8	21.8	26.9
10	6	12.9	13.9	15.1	16.7	18.8	21.9	27.0
10	7	12.9	13.9	15.1	16.7	18.9	22.0	27.2
10	8	13.0	13.9	15.2	16.8	18.9	22.1	27.4
10	9	13.0	14.0	15.2	16.8	19.0	22.2	27.5
10	10	13.0	14.0	15.2	16.9	19.0	22.3	27.7
10	11	13.0	14.0	15.3	16.9	19.1	22.4	27.9
11	0	13.1	14.1	15.3	16.9	19.2	22.5	28.0

Standar Indeks Massa Tubuh menurut Umur (IMT/U)
Anak Laki-Laki Umur 5-18 Tahun

Umur		Indeks Massa Tubuh (IMT)						
Tahun	Bulan	-3 SD	-2 SD	-1 SD	Median	1 SD	2 SD	3 SD
11	1	13.1	14.1	15.3	17.0	19.2	22.5	28.2
11	2	13.1	14.1	15.4	17.0	19.3	22.6	28.4
11	3	13.1	14.1	15.4	17.1	19.3	22.7	28.5
11	4	13.2	14.2	15.5	17.1	19.4	22.8	28.7
11	5	13.2	14.2	15.5	17.2	19.5	22.9	28.8
11	6	13.2	14.2	15.5	17.2	19.5	23.0	29.0
11	7	13.2	14.3	15.6	17.3	19.6	23.1	29.2
11	8	13.3	14.3	15.6	17.3	19.7	23.2	29.3
11	9	13.3	14.3	15.7	17.4	19.7	23.3	29.5
11	10	13.3	14.4	15.7	17.4	19.8	23.4	29.6
11	11	13.4	14.4	15.7	17.5	19.9	23.5	29.8
12	0	13.4	14.5	15.8	17.5	19.9	23.6	30.0
12	1	13.4	14.5	15.8	17.6	20.0	23.7	30.1
12	2	13.5	14.5	15.9	17.6	20.1	23.8	30.3
12	3	13.5	14.6	15.9	17.7	20.2	23.9	30.4
12	4	13.5	14.6	16.0	17.8	20.2	24.0	30.6
12	5	13.6	14.6	16.0	17.8	20.3	24.1	30.7
12	6	13.6	14.7	16.1	17.9	20.4	24.2	30.9
12	7	13.6	14.7	16.1	17.9	20.4	24.3	31.0
12	8	13.7	14.8	16.2	18.0	20.5	24.4	31.1
12	9	13.7	14.8	16.2	18.0	20.6	24.5	31.3
12	10	13.7	14.8	16.3	18.1	20.7	24.6	31.4
12	11	13.8	14.9	16.3	18.2	20.8	24.7	31.6
13	0	13.8	14.9	16.4	18.2	20.8	24.8	31.7
13	1	13.8	15.0	16.4	18.3	20.9	24.9	31.8
13	2	13.9	15.0	16.5	18.4	21.0	25.0	31.9
13	3	13.9	15.1	16.5	18.4	21.1	25.1	32.1
13	4	14.0	15.1	16.6	18.5	21.1	25.2	32.2
13	5	14.0	15.2	16.6	18.6	21.2	25.2	32.3
13	6	14.0	15.2	16.7	18.6	21.3	25.3	32.4
13	7	14.1	15.2	16.7	18.7	21.4	25.4	32.6
13	8	14.1	15.3	16.8	18.7	21.5	25.5	32.7
13	9	14.1	15.3	16.8	18.8	21.5	25.6	32.8
13	10	14.2	15.4	16.9	18.9	21.6	25.7	32.9
13	11	14.2	15.4	17.0	18.9	21.7	25.8	33.0
14	0	14.3	15.5	17.0	19.0	21.8	25.9	33.1

Standar Indeks Massa Tubuh menurut Umur (IMT/U)
Anak Laki-Laki Umur 5-18 Tahun

Umur		Indeks Massa Tubuh (IMT)						
Tahun	Bulan	-3 SD	-2 SD	-1 SD	Median	1 SD	2 SD	3 SD
14	1	14.3	15.5	17.1	19.1	21.8	26.0	33.2
14	2	14.3	15.6	17.1	19.1	21.9	26.1	33.3
14	3	14.4	15.6	17.2	19.2	22.0	26.2	33.4
14	4	14.4	15.7	17.2	19.3	22.1	26.3	33.5
14	5	14.5	15.7	17.3	19.3	22.2	26.4	33.5
14	6	14.5	15.7	17.3	19.4	22.2	26.5	33.6
14	7	14.5	15.8	17.4	19.5	22.3	26.5	33.7
14	8	14.6	15.8	17.4	19.5	22.4	26.6	33.8
14	9	14.6	15.9	17.5	19.6	22.5	26.7	33.9
14	10	14.6	15.9	17.5	19.6	22.5	26.8	33.9
14	11	14.7	16.0	17.6	19.7	22.6	26.9	34.0
15	0	14.7	16.0	17.6	19.8	22.7	27.0	34.1
15	1	14.7	16.1	17.7	19.8	22.8	27.1	34.1
15	2	14.8	16.1	17.8	19.9	22.8	27.1	34.2
15	3	14.8	16.1	17.8	20.0	22.9	27.2	34.3
15	4	14.8	16.2	17.9	20.0	23.0	27.3	34.3
15	5	14.9	16.2	17.9	20.1	23.0	27.4	34.4
15	6	14.9	16.3	18.0	20.1	23.1	27.4	34.5
15	7	15.0	16.3	18.0	20.2	23.2	27.5	34.5
15	8	15.0	16.3	18.1	20.3	23.3	27.6	34.6
15	9	15.0	16.4	18.1	20.3	23.3	27.7	34.6
15	10	15.0	16.4	18.2	20.4	23.4	27.7	34.7
15	11	15.1	16.5	18.2	20.4	23.5	27.8	34.7
16	0	15.1	16.5	18.2	20.5	23.5	27.9	34.8
16	1	15.1	16.5	18.3	20.6	23.6	27.9	34.8
16	2	15.2	16.6	18.3	20.6	23.7	28.0	34.8
16	3	15.2	16.6	18.4	20.7	23.7	28.1	34.9
16	4	15.2	16.7	18.4	20.7	23.8	28.1	34.9
16	5	15.3	16.7	18.5	20.8	23.8	28.2	35.0
16	6	15.3	16.7	18.5	20.8	23.9	28.3	35.0
16	7	15.3	16.8	18.6	20.9	24.0	28.3	35.0
16	8	15.3	16.8	18.6	20.9	24.0	28.4	35.1
16	9	15.4	16.8	18.7	21.0	24.1	28.5	35.1
16	10	15.4	16.9	18.7	21.0	24.2	28.5	35.1
16	11	15.4	16.9	18.7	21.1	24.2	28.6	35.2
17	0	15.4	16.9	18.8	21.1	24.3	28.6	35.2

Standar Indeks Massa Tubuh menurut Umur (IMT/U)
Anak Laki-Laki Umur 5-18 Tahun

Umur		Indeks Massa Tubuh (IMT)						
Tahun	Bulan	-3 SD	-2 SD	-1 SD	Median	1 SD	2 SD	3 SD
17	1	15.5	17.0	18.8	21.2	24.3	28.7	35.2
17	2	15.5	17.0	18.9	21.2	24.4	28.7	35.2
17	3	15.5	17.0	18.9	21.3	24.4	28.8	35.3
17	4	15.5	17.1	18.9	21.3	24.5	28.9	35.3
17	5	15.6	17.1	19.0	21.4	24.5	28.9	35.3
17	6	15.6	17.1	19.0	21.4	24.6	29.0	35.3
17	7	15.6	17.1	19.1	21.5	24.7	29.0	35.4
17	8	15.6	17.2	19.1	21.5	24.7	29.1	35.4
17	9	15.6	17.2	19.1	21.6	24.8	29.1	35.4
17	10	15.7	17.2	19.2	21.6	24.8	29.2	35.4
17	11	15.7	17.3	19.2	21.7	24.9	29.2	35.4
18	0	15.7	17.3	19.2	21.7	24.9	29.2	35.4
18	1	15.7	17.3	19.3	21.8	25.0	29.3	35.4
18	2	15.7	17.3	19.3	21.8	25.0	29.3	35.5
18	3	15.7	17.4	19.3	21.8	25.1	29.4	35.5
18	4	15.8	17.4	19.4	21.9	25.1	29.4	35.5
18	5	15.8	17.4	19.4	21.9	25.1	29.5	35.5
18	6	15.8	17.4	19.4	22.0	25.2	29.5	35.5
18	7	15.8	17.5	19.5	22.0	25.2	29.5	35.5
18	8	15.8	17.5	19.5	22.0	25.3	29.6	35.5
18	9	15.8	17.5	19.5	22.1	25.3	29.6	35.5
18	10	15.8	17.5	19.6	22.1	25.4	29.6	35.5
18	11	15.8	17.5	19.6	22.2	25.4	29.7	35.5
19	0	15.9	17.6	19.6	22.2	25.4	29.7	35.5

**Standar Indeks Massa Tubuh menurut Umur (IMT/U)
Anak Perempuan Umur 5-18 Tahun**

Umur		Indeks Massa Tubuh (IMT)						
Tahun	Bulan	-3 SD	-2 SD	-1 SD	Median	1 SD	2 SD	3 SD
5	1	11.8	12.7	13.9	15.2	16.9	18.9	21.3
5	2	11.8	12.7	13.9	15.2	16.9	18.9	21.4
5	3	11.8	12.7	13.9	15.2	16.9	18.9	21.5
5	4	11.8	12.7	13.9	15.2	16.9	18.9	21.5
5	5	11.7	12.7	13.9	15.2	16.9	19.0	21.6
5	6	11.7	12.7	13.9	15.2	16.9	19.0	21.7
5	7	11.7	12.7	13.9	15.2	16.9	19.0	21.7
5	8	11.7	12.7	13.9	15.3	17.0	19.1	21.8
5	9	11.7	12.7	13.9	15.3	17.0	19.1	21.9
5	10	11.7	12.7	13.9	15.3	17.0	19.1	22.0
5	11	11.7	12.7	13.9	15.3	17.0	19.2	22.1
6	0	11.7	12.7	13.9	15.3	17.0	19.2	22.1
6	1	11.7	12.7	13.9	15.3	17.0	19.3	22.2
6	2	11.7	12.7	13.9	15.3	17.0	19.3	22.3
6	3	11.7	12.7	13.9	15.3	17.1	19.3	22.4
6	4	11.7	12.7	13.9	15.3	17.1	19.4	22.5
6	5	11.7	12.7	13.9	15.3	17.1	19.4	22.6
6	6	11.7	12.7	13.9	15.3	17.1	19.5	22.7
6	7	11.7	12.7	13.9	15.3	17.2	19.5	22.8
6	8	11.7	12.7	13.9	15.3	17.2	19.6	22.9
6	9	11.7	12.7	13.9	15.4	17.2	19.6	23.0
6	10	11.7	12.7	13.9	15.4	17.2	19.7	23.1
6	11	11.7	12.7	13.9	15.4	17.3	19.7	23.2
7	0	11.8	12.7	13.9	15.4	17.3	19.8	23.3
7	1	11.8	12.7	13.9	15.4	17.3	19.8	23.4
7	2	11.8	12.8	14.0	15.4	17.4	19.9	23.5
7	3	11.8	12.8	14.0	15.5	17.4	20.0	23.6
7	4	11.8	12.8	14.0	15.5	17.4	20.0	23.7
7	5	11.8	12.8	14.0	15.5	17.5	20.1	23.9
7	6	11.8	12.8	14.0	15.5	17.5	20.1	24.0
7	7	11.8	12.8	14.0	15.5	17.5	20.2	24.1
7	8	11.8	12.8	14.0	15.6	17.6	20.3	24.2
7	9	11.8	12.8	14.1	15.6	17.6	20.3	24.4
7	10	11.9	12.9	14.1	15.6	17.6	20.4	24.5
7	11	11.9	12.9	14.1	15.7	17.7	20.5	24.6
8	0	11.9	12.9	14.1	15.7	17.7	20.6	24.8

Standar Indeks Massa Tubuh menurut Umur (IMT/U)
Anak Perempuan Umur 5-18 Tahun

Umur		Indeks Massa Tubuh (IMT)						
Tahun	Bulan	-3 SD	-2 SD	-1 SD	Median	1 SD	2 SD	3 SD
8	1	11.9	12.9	14.1	15.7	17.8	20.6	24.9
8	2	11.9	12.9	14.2	15.7	17.8	20.7	25.1
8	3	11.9	12.9	14.2	15.8	17.9	20.8	25.2
8	4	11.9	13.0	14.2	15.8	17.9	20.9	25.3
8	5	12.0	13.0	14.2	15.8	18.0	20.9	25.5
8	6	12.0	13.0	14.3	15.9	18.0	21.0	25.6
8	7	12.0	13.0	14.3	15.9	18.1	21.1	25.8
8	8	12.0	13.0	14.3	15.9	18.1	21.2	25.9
8	9	12.0	13.1	14.3	16.0	18.2	21.3	26.1
8	10	12.1	13.1	14.4	16.0	18.2	21.3	26.2
8	11	12.1	13.1	14.4	16.1	18.3	21.4	26.4
9	0	12.1	13.1	14.4	16.1	18.3	21.5	26.5
9	1	12.1	13.2	14.5	16.1	18.4	21.6	26.7
9	2	12.1	13.2	14.5	16.2	18.4	21.7	26.8
9	3	12.2	13.2	14.5	16.2	18.5	21.8	27.0
9	4	12.2	13.2	14.6	16.3	18.6	21.9	27.2
9	5	12.2	13.3	14.6	16.3	18.6	21.9	27.3
9	6	12.2	13.3	14.6	16.3	18.7	22.0	27.5
9	7	12.3	13.3	14.7	16.4	18.7	22.1	27.6
9	8	12.3	13.4	14.7	16.4	18.8	22.2	27.8
9	9	12.3	13.4	14.7	16.5	18.8	22.3	27.9
9	10	12.3	13.4	14.8	16.5	18.9	22.4	28.1
9	11	12.4	13.4	14.8	16.6	19.0	22.5	28.2
10	0	12.4	13.5	14.8	16.6	19.0	22.6	28.4
10	1	12.4	13.5	14.9	16.7	19.1	22.7	28.5
10	2	12.4	13.5	14.9	16.7	19.2	22.8	28.7
10	3	12.5	13.6	15.0	16.8	19.2	22.8	28.8
10	4	12.5	13.6	15.0	16.8	19.3	22.9	29.0
10	5	12.5	13.6	15.0	16.9	19.4	23.0	29.1
10	6	12.5	13.7	15.1	16.9	19.4	23.1	29.3
10	7	12.6	13.7	15.1	17.0	19.5	23.2	29.4
10	8	12.6	13.7	15.2	17.0	19.6	23.3	29.6
10	9	12.6	13.8	15.2	17.1	19.6	23.4	29.7
10	10	12.7	13.8	15.3	17.1	19.7	23.5	29.9
10	11	12.7	13.8	15.3	17.2	19.8	23.6	30.0
11	0	12.7	13.9	15.3	17.2	19.9	23.7	30.2

Standar Indeks Massa Tubuh menurut Umur (IMT/U)
Anak Perempuan Umur 5-18 Tahun

Umur		Indeks Massa Tubuh (IMT)						
Tahun	Bulan	-3 SD	-2 SD	-1 SD	Median	1 SD	2 SD	3 SD
11	1	12.8	13.9	15.4	17.3	19.9	23.8	30.3
11	2	12.8	14.0	15.4	17.4	20.0	23.9	30.5
11	3	12.8	14.0	15.5	17.4	20.1	24.0	30.6
11	4	12.9	14.0	15.5	17.5	20.2	24.1	30.8
11	5	12.9	14.1	15.6	17.5	20.2	24.2	30.9
11	6	12.9	14.1	15.6	17.6	20.3	24.3	31.1
11	7	13.0	14.2	15.7	17.7	20.4	24.4	31.2
11	8	13.0	14.2	15.7	17.7	20.5	24.5	31.4
11	9	13.0	14.3	15.8	17.8	20.6	24.7	31.5
11	10	13.1	14.3	15.8	17.9	20.6	24.8	31.6
11	11	13.1	14.3	15.9	17.9	20.7	24.9	31.8
12	0	13.2	14.4	16.0	18.0	20.8	25.0	31.9
12	1	13.2	14.4	16.0	18.1	20.9	25.1	32.0
12	2	13.2	14.5	16.1	18.1	21.0	25.2	32.2
12	3	13.3	14.5	16.1	18.2	21.1	25.3	32.3
12	4	13.3	14.6	16.2	18.3	21.1	25.4	32.4
12	5	13.3	14.6	16.2	18.3	21.2	25.5	32.6
12	6	13.4	14.7	16.3	18.4	21.3	25.6	32.7
12	7	13.4	14.7	16.3	18.5	21.4	25.7	32.8
12	8	13.5	14.8	16.4	18.5	21.5	25.8	33.0
12	9	13.5	14.8	16.4	18.6	21.6	25.9	33.1
12	10	13.5	14.8	16.5	18.7	21.6	26.0	33.2
12	11	13.6	14.9	16.6	18.7	21.7	26.1	33.3
13	0	13.6	14.9	16.6	18.8	21.8	26.2	33.4
13	1	13.6	15.0	16.7	18.9	21.9	26.3	33.6
13	2	13.7	15.0	16.7	18.9	22.0	26.4	33.7
13	3	13.7	15.1	16.8	19.0	22.0	26.5	33.8
13	4	13.8	15.1	16.8	19.1	22.1	26.6	33.9
13	5	13.8	15.2	16.9	19.1	22.2	26.7	34.0
13	6	13.8	15.2	16.9	19.2	22.3	26.8	34.1
13	7	13.9	15.2	17.0	19.3	22.4	26.9	34.2
13	8	13.9	15.3	17.0	19.3	22.4	27.0	34.3
13	9	13.9	15.3	17.1	19.4	22.5	27.1	34.4
13	10	14.0	15.4	17.1	19.4	22.6	27.1	34.5
13	11	14.0	15.4	17.2	19.5	22.7	27.2	34.6
14	0	14.0	15.4	17.2	19.6	22.7	27.3	34.7

Standar Indeks Massa Tubuh menurut Umur (IMT/U)
Anak Perempuan Umur 5-18 Tahun

Umur		Indeks Massa Tubuh (IMT)						
Tahun	Bulan	-3 SD	-2 SD	-1 SD	Median	1 SD	2 SD	3 SD
14	1	14.1	15.5	17.3	19.6	22.8	27.4	34.7
14	2	14.1	15.5	17.3	19.7	22.9	27.5	34.8
14	3	14.1	15.6	17.4	19.7	22.9	27.6	34.9
14	4	14.1	15.6	17.4	19.8	23.0	27.7	35.0
14	5	14.2	15.6	17.5	19.9	23.1	27.7	35.1
14	6	14.2	15.7	17.5	19.9	23.1	27.8	35.1
14	7	14.2	15.7	17.6	20.0	23.2	27.9	35.2
14	8	14.3	15.7	17.6	20.0	23.3	28.0	35.3
14	9	14.3	15.8	17.6	20.1	23.3	28.0	35.4
14	10	14.3	15.8	17.7	20.1	23.4	28.1	35.4
14	11	14.3	15.8	17.7	20.2	23.5	28.2	35.5
15	0	14.4	15.9	17.8	20.2	23.5	28.2	35.5
15	1	14.4	15.9	17.8	20.3	23.6	28.3	35.6
15	2	14.4	15.9	17.8	20.3	23.6	28.4	35.7
15	3	14.4	16.0	17.9	20.4	23.7	28.4	35.7
15	4	14.5	16.0	17.9	20.4	23.7	28.5	35.8
15	5	14.5	16.0	17.9	20.4	23.8	28.5	35.8
15	6	14.5	16.0	18.0	20.5	23.8	28.6	35.8
15	7	14.5	16.1	18.0	20.5	23.9	28.6	35.9
15	8	14.5	16.1	18.0	20.6	23.9	28.7	35.9
15	9	14.5	16.1	18.1	20.6	24.0	28.7	36.0
15	10	14.6	16.1	18.1	20.6	24.0	28.8	36.0
15	11	14.6	16.2	18.1	20.7	24.1	28.8	36.0
16	0	14.6	16.2	18.2	20.7	24.1	28.9	36.1
16	1	14.6	16.2	18.2	20.7	24.1	28.9	36.1
16	2	14.6	16.2	18.2	20.8	24.2	29.0	36.1
16	3	14.6	16.2	18.2	20.8	24.2	29.0	36.1
16	4	14.6	16.2	18.3	20.8	24.3	29.0	36.2
16	5	14.6	16.3	18.3	20.9	24.3	29.1	36.2
16	6	14.7	16.3	18.3	20.9	24.3	29.1	36.2
16	7	14.7	16.3	18.3	20.9	24.4	29.1	36.2
16	8	14.7	16.3	18.3	20.9	24.4	29.2	36.2
16	9	14.7	16.3	18.4	21.0	24.4	29.2	36.3
16	10	14.7	16.3	18.4	21.0	24.4	29.2	36.3
16	11	14.7	16.3	18.4	21.0	24.5	29.3	36.3
17	0	14.7	16.4	18.4	21.0	24.5	29.3	36.3

Standar Indeks Massa Tubuh menurut Umur (IMT/U)
Anak Perempuan Umur 5-18 Tahun

Umur		Indeks Massa Tubuh (IMT)						
Tahun	Bulan	-3 SD	-2 SD	-1 SD	Median	1 SD	2 SD	3 SD
17	1	14.7	16.4	18.4	21.1	24.5	29.3	36.3
17	2	14.7	16.4	18.4	21.1	24.6	29.3	36.3
17	3	14.7	16.4	18.5	21.1	24.6	29.4	36.3
17	4	14.7	16.4	18.5	21.1	24.6	29.4	36.3
17	5	14.7	16.4	18.5	21.1	24.6	29.4	36.3
17	6	14.7	16.4	18.5	21.2	24.6	29.4	36.3
17	7	14.7	16.4	18.5	21.2	24.7	29.4	36.3
17	8	14.7	16.4	18.5	21.2	24.7	29.5	36.3
17	9	14.7	16.4	18.5	21.2	24.7	29.5	36.3
17	10	14.7	16.4	18.5	21.2	24.7	29.5	36.3
17	11	14.7	16.4	18.6	21.2	24.8	29.5	36.3
18	0	14.7	16.4	18.6	21.3	24.8	29.5	36.3
18	1	14.7	16.5	18.6	21.3	24.8	29.5	36.3
18	2	14.7	16.5	18.6	21.3	24.8	29.6	36.3
18	3	14.7	16.5	18.6	21.3	24.8	29.6	36.3
18	4	14.7	16.5	18.6	21.3	24.8	29.6	36.3
18	5	14.7	16.5	18.6	21.3	24.9	29.6	36.2
18	6	14.7	16.5	18.6	21.3	24.9	29.6	36.2
18	7	14.7	16.5	18.6	21.4	24.9	29.6	36.2
18	8	14.7	16.5	18.6	21.4	24.9	29.6	36.2
18	9	14.7	16.5	18.7	21.4	24.9	29.6	36.2
18	10	14.7	16.5	18.7	21.4	24.9	29.6	36.2
18	11	14.7	16.5	18.7	21.4	25.0	29.7	36.2
19	0	14.7	16.5	18.7	21.4	25.0	29.7	36.2



KEMENTERI KESEHATAN RI,

ENDANG RAHAYU SEDYANINGSIH

LAMPIRAN C: Syntax Clustering Menggunakan SOM

```
load f:\SOM\namadata.txt;
X0=namadata;
% Ambil data training
X1=X0(:,1);
X2=X0(:,2);
X3=X0(:,3);
X4=X0(:,4);
X=[X1 X2 X3 X4];
net = newc(X',2);
net=train(net,X');
XX=sim(net,X');
XXX=(vec2ind(XX))';
```

LAMPIRAN D: Tabel Mean dan Standard Deviasi Hasil Clustering Menggunakan SOM

D1. Kelompok Anak Laki-Laki

Prediktor	Mean		Standard Deviasi	
	Cluster 1	Cluster 2	Cluster 1	Cluster 2
X1 (Energi)	973.8343	1880.45	265.3565	423.2628
X2 (Protein)	33.76847	61.43459	15.46857	25.43356
X3 (Lemak)	27.74237	62.92862	16.52422	30.78465
X4 (Karbohidrat)	145.4119	266.0876	45.46374	93.62479

Prediktor	Mean			Standard Deviasi		
	Cluster 1	Cluster 2	Cluster 3	Cluster 1	Cluster 2	Cluster 3
X1 (Energi)	833.5052	1407.458	2223.451	195.8829	189.7116	412.7146
X2 (Protein)	28.80518	48.34633	70.42084	12.55821	17.90493	29.08114
X3 (Lemak)	22.3709	44.62229	75.81829	13.36422	20.064	35.10417
X4 (Karbohidrat)	127.5706	200.9764	315.034	36.10345	50.7103	107.7204

Prediktor	Mean			Standard Deviasi		
	Cluster 1	...	Cluster 4	Cluster 1	...	Cluster 4
X1 (Energi)	728.9523	...	1669.716	156.1076	...	177.2425
X2 (Protein)	25.05503	...	56.16914	10.94276	...	20.45047
X3 (Lemak)	18.47847	...	54.89192	11.23373	...	23.25107
X4 (Karbohidrat)	114.1096	...	235.9803	30.07684	...	60.28957

Prediktor	Mean			Standard Deviasi		
	Cluster 1	...	Cluster 5	Cluster 1	...	Cluster 5
X1 (Energi)	662.0413	...	1881.987	133.7366	...	174.7275
X2 (Protein)	22.80657	...	62.33145	10.30891	...	23.08715

X3 (Lemak)	15.94107	...	62.75604	9.837012	...	27.05244
X4 (Karbohidrat)	105.4554	...	265.7512	26.2736	...	68.42489

Prediktor	Mean			Standard Deviasi		
	Cluster 1	...	Cluster 10	Cluster 1	...	Cluster 10
X1 (Energi)	505.1416	...	2334.023	90.16165	...	142.6512
X2 (Protein)	16.83855	...	73.50033	8.050785	...	27.79829
X3 (Lemak)	9.857247	...	82.19493	6.886529	...	34.29104
X4 (Karbohidrat)	86.09557	...	325.6504	18.93017	...	89.67925

D2. Kelompok Anak Perempuan

Prediktor	Mean		Standard Deviasi	
	Cluster 1	Cluster 2	Cluster 1	Cluster 2
X1 (Energi)	943.9793	1819.108	248.6348	430.379
X2 (Protein)	32.80081	59.88666	14.47075	25.24209
X3 (Lemak)	27.081	61.28481	16.06981	31.46145
X4 (Karbohidrat)	140.5026	256.0151	42.95204	95.02118

Prediktor	Mean			Standard Deviasi		
	Cluster 1	Cluster 2	Cluster 3	Cluster 1	Cluster 2	Cluster 3
X1 (Energi)	836.2011	1428.565	2300.942	193.844	200.2121	423.5594
X2 (Protein)	29.31263	48.70936	72.09813	12.98136	18.21391	30.26076
X3 (Lemak)	22.66656	46.48611	79.35192	13.29029	21.29761	38.05307
X4 (Karbohidrat)	127.0796	201.9538	325.1681	35.85625	53.51593	117.7794

Prediktor	Mean			Standard Deviasi		
	Cluster 1	...	Cluster 4	Cluster 1	...	Cluster 4
X1 (Energi)	726.824	...	1639.561	151.2375	...	175.6836

X2 (Protein)	25.59669	...	55.62955	11.34766	...	20.74924
X3 (Lemak)	18.71707	...	54.77669	10.97431	...	24.21329
X4 (Karbohidrat)	112.5186	...	229.3249	28.9971	...	61.06831

Prediktor	Mean			Standard Deviasi		
	Cluster 1	...	Cluster 5	Cluster 1	...	Cluster 5
X1 (Energi)	667.1727	...	1386.714	131.3251	...	112.8932
X2 (Protein)	23.44731	...	47.35221	10.56074	...	16.7062
X3 (Lemak)	16.45521	...	45.06568	9.755881	...	19.12115
X4 (Karbohidrat)	104.898	...	195.9003	25.39832	...	46.20397

Prediktor	Mean			Standard Deviasi		
	Cluster 1	...	Cluster 10	Cluster 1	...	Cluster 10
X1 (Energi)	514.8406	...	1610.316	91.99092	...	67.59939
X2 (Protein)	17.8383	...	54.56717	8.530283	...	20.00937
X3 (Lemak)	10.48954	...	53.28923	6.872796	...	22.76285
X4 (Karbohidrat)	86.09432	...	226.5338	18.63258	...	56.05411

LAMPIRAN E: *Syntax* Klasifikasi Menggunakan RBFNN

```

%inisialisasi awal
load d:\SOM\allmale.txt;
a=(allmale);

%data training
p=a(1:13716,1:4);
X=p';
t1=a(1:13716,5);

%data testing
pp=a(13717:17144,1:4);
XX=p';
tt1=a(13717:17144,5);

%data mean dan standard deviasi
load d:\SOM\male2cluster.txt;
MS=(male2cluster);
C=MS(:,1:2) ; R=MS(:,3:4);

%mencari matrik gaussian pada data training
H=rbfDesign(X,C,R,'b');

%mencari matrik gaussian pada data testing
HH=rbfDesign(XX,C,R,'b');

%mencari nilai parameter secara OLS (data training)
w1=inv(H' * H) * H' * t1

%mencari taksiran nilai yhat (data training)
yhat=(H * w1);
z1= round (yhat);
z=[z1];
t=[t1];

```

```

SSE=(t1-yhat)'*(t1-yhat)
SSR=(yhat-mean(t1))'*(yhat-mean(t1))
SST=SSE+SSR
rs=SSR/SST

% mencari taksiran nilai yhat (data testing)
yyhat=(HH * w1);
zz1= round (yyhat1);
zz=[zz1];
tt=[t1];
SSEt=(tt1-yyhat)'*(tt1-yyhat)
SSRt=(yyhat-mean(tt1))'*(yyhat-mean(tt1))
SSTt=SSEt+SSRt
rst=SSRt/SSTt

% mencari nilai output untuk data training
n=length(z);
Train=[ ];
for i=1:n
ind=find(z(i,)==1);
if(isempty(ind)==1)
kel=1;
else
kel=ind;
end
Train=[Train kel];
end
Train';
aa=Train';

% mencari nilai output untuk data testing
nn=length(zz);
Test=[ ];
for i=1:nn
ind=find(zz(i,)==1);

```

```

if(isempty(ind)==1)
kel=1;
else
kel=ind;
end
Test=[Test kel];
end
Test';
ab=Test';

% mencari ketepatan klasifikasi total data training
y=a(1:13716,1);
yy=a(13717:17144,1);
f=0;
lz=length(y);
for i=1:lz
if y(i)==aa(i)
f=f+1
end
end

% mencari ketepatan klasifikasi total data testing
ff=0;
lzz=length(yy);
for i=1:lzz
if yy(i)==ab(i)
f=f+1
end
end

% ketepatan klasifikasi data training
j1=0;
l=length(t1);
for i=1:l
if t1(i)==z1(i)

```

```
j1=j1+1
end
end

%ketepatan klasifikasi data testing
jj1=0;
ll=length(tt1);
for i=1:ll
if tt1(i)==zz1(i)
jj1=jj1+1
end
end

%menampilkan ketepatan klasifikasi pada data training
disp('ktepatan klasifikasi training: ');
disp(j1/l*100)

%menampilkan ketepatan klasifikasi pada data testing
disp('ktepatan klasifikasi testing: ');
disp(jj1/ll*100)
```