

Bidang Ilmu: MIPA

**LAPORAN TAHUNAN
PENELITIAN HIBAH BERSAING**



**Optimalisasi Model *Fuzzy* untuk Klasifikasi pada Data Polikotomus
dan Penerapannya di Bidang Kesehatan**

Tahun ke-1 dari Rencana 2 tahun

Ketua:

**Dr. Dhoriva Urwatul Wutsqa, M.S
NIDN: 0031036607**

Anggota:

**Dr. Agus Maman Abadi, M.Si.
NIDN: 0028087003**

**UNIVERSITAS NEGERI YOGYAKARTA
NOVEMBER 2013**

Dibiayai oleh:

**Direktorat Penelitian dan Pengabdian kepada Masyarakat
Direktorat Jenderal Pendidikan Tinggi
Kementerian Pendidikan dan Kebudayaan
Sesuai dengan Surat Perjanjian Pelaksanaan Penugasan Penelitian
Nomor: 447a/HB-Mutitahun/UN34.21/2013 tanggal 13 Mei 2013**

HALAMAN PENGESAHAN

Judul Kegiatan : Optimalisasi Model Fuzzy untuk Klasifikasi pada Data Polikotomus dan Penerapannya di Bidang Kesehatan

Peneliti / Pelaksana

Nama Lengkap : Dr. DHORIVA URWATUL WUTSQA M.S.
NIDN : 0031036607
Jabatan Fungsional :
Program Studi : Matematika
Nomor HP : 08156892990
Surel (e-mail) : dhoriva@yahoo.com

Anggota Peneliti (1)

Nama Lengkap : Dr. AGUS MAMAN ABADI M.Si
NIDN : 0028087003
Perguruan Tinggi : UNIVERSITAS NEGERI YOGYAKARTA

Institusi Mitra (jika ada)

Nama Institusi Mitra :
Alamat :
Penanggung Jawab :
Tahun Pelaksanaan : Tahun ke 1 dari rencana 2 tahun
Biaya Tahun Berjalan : Rp. 50.000.000,00
Biaya Keseluruhan : Rp. 125.000.000,00

Mengetahui
Dekan FMIPA



(Dr. Hartono)

NIP/NIK 196203291987021002

Yogyakarta, 27 - 11 - 2013,
Ketua Peneliti,

(Dr. DHORIVA URWATUL WUTSQA M.S.)

NIP/NIK196603311993032001

Menyetujui,
Ketua LPPM UNY



(Prof. Dr. Anik Ghufron)

NIP/NIK 196211111988031001

Optimalisasi Model *Fuzzy* untuk Klasifikasi pada Data Polikotomus dan Penerapannya di Bidang Kesehatan

Dhoriva Urwatul Wutsqa dan Agus Maman Abadi
Jurusan Pendidikan Matematika FMIPA UNY

RINGKASAN

Penelitian ini bertujuan untuk mengembangkan metode baru dalam pemodelan *fuzzy* dalam klasifikasi data polikotomus dan aplikasinya di bidang kesehatan. Target khusus dalam penelitian ini adalah mendapatkan metode baru dalam pemodelan *fuzzy* yang optimal untuk klasifikasi data polikotomus dengan keakuratan yang tinggi, menghasilkan prosedur pemrograman model *fuzzy* yang optimal untuk data polikotomus, dan menerapkannya untuk permasalahan klasifikasi di bidang kesehatan seperti untuk diagnosa kanker serviks dan kanker payudara.

Pada penelitian tahun pertama, telah diperoleh suatu prosedur baru dalam pembentukan model *fuzzy* yang optimal untuk klasifikasi data polikotomus dengan metode dekomposisi nilai singular. Berdasarkan metode baru yang diperoleh pada penelitian tahun pertama, pada tahun kedua akan dikembangkan prosedur pemrograman dengan MATLAB untuk klasifikasi data polikotomus dan menerapkannya untuk menyelesaikan permasalahan klasifikasi di bidang kesehatan antara lain untuk diagnosa kanker serviks dan kanker payudara.

Kata kunci: optimalisasi, model *fuzzy*, klasifikasi, data polikotomus, dekomposisi nilai singular

Optimization of Fuzzy Model for Classification of Polycotomus Data and Its Application in Health

Dhoriva Urwatul Wutsqa and Agus Maman Abadi

Department of Mathematics Education, Faculty of Mathematics and Sciences

Yogyakarta State University

SUMMARY

The aims of this research are to develop a new method in fuzzy modelling for classification of polycotomus data, to develop a programming procedure of the fuzzy model by using Matlab software, and to apply the method to diagnosis servical cancer and breast cancer.

In first year research, the new prosedure to classification of polycotomus data was developed by using singular value decomposition method. Based on the procedure, in second year, the programming procedure will be developed by using Matlab software. Futhermore, the method will be applied to diagnosis servical cancer and breast cancer.

Keywords: optimization, fuzzy model, classification, polycotomus data, singular value decomposition

PRAKATA

Syukur Alhamdulillah kami panjatkan kehadiran Allah SWT yang telah melimpahkan rahmat dan hidayah-Nya atas selesainya penyusunan laporan hasil penelitian Hibah Bersaing tahun pertama yang berjudul ” Optimalisasi Model *Fuzzy* untuk Klasifikasi pada Data Polikotomus dan Penerapannya di Bidang Kesehatan”. Laporan penelitian ini disusun untuk mempertanggungjawabkan secara tertulis dari kegiatan penelitian yang didanai oleh DP2M Direktorat Jenderal Pendidikan Tinggi, Kementerian Pendidikan dan Kebudayaan.

Selanjutnya peneliti menyampaikan terima kasih yang sebesar-besarnya kepada yang terhormat:

1. Direktur Jenderal Pendidikan Tinggi, Kementerian Pendidikan dan Kebudayaan.
2. Rektor Universitas Negeri Yogyakarta.
3. Ketua Lembaga Penelitian Universitas Negeri Yogyakarta.
4. Dekan FMIPA Universitas Negeri Yogyakarta.
5. Rekan-rekan dosen Jurusan Pendidikan Matematika FMIPA UNY.
6. Ketua Laboratorium Matematika UNY.
7. Semua pihak yang terlibat dalam proses penelitian ini.

Peneliti menyadari bahwa laporan ini masih terdapat kekurangan, oleh karena itu peneliti sangat mengharapkan sumbang saran yang konstruktif dari semua pihak.

Yogyakarta, 25 November 2013

Tim Peneliti

DAFTAR ISI

HALAMAN SAMPUL	i
HALAMAN PENGESAHAN	ii
RINGKASAN	iii
PRAKATA	v
DAFTAR ISI	vi
DAFTAR TABEL	vii
DAFTAR GAMBAR	viii
DAFTAR LAMPIRAN	ix
BAB I. PENDAHULUAN	1
1.1 Latar Belakang Masalah	1
1.2 Rumusan Masalah	2
BAB II. TINJAUAN PUSTAKA	3
2.1 Penelitian pendahuluan	3
2.2 Model Fuzzy	4
2.3 Model Neural Network	6
2.4 Feedforward Neural Network	6
BAB III TUJUAN DAN MANFAAT PENELITIAN	12
3.1 Tujuan Penelitian	12
3.2 Manfaat Penelitian	12
BAB IV METODE PENELITIAN	13
BAB V HASIL DAN PEMBAHASAN	15
BAB VI RENCANA TAHAPAN BERIKUTNYA	20
BAB VII KESIMPULAN DAN SARAN	24
DAFTAR PUSTAKA	25
LAMPIRAN	27

DAFTAR TABEL

	Halaman
Tabel 4.5. Rekapitulasi anggaran penelitian tahun kedua	22
Tabel 4.6. Jadwal Kegiatan Penelitian Tahun Kedua	23

DAFTAR GAMBAR

	Halaman
Gambar 1. Pembentukan sistem <i>fuzzy</i> (Wang, 1997)	5
Gambar 2. Arsitektur FFNN dengan satu lapis tersembunyi, p unit input, q unit di lapis tersembunyi, dan satu unit output.	7
Gambar 3. Arsitektur FFNN dengan satu lapis tersembunyi, p unit input, q unit di lapis tersembunyi, dan m unit output.	9
Gambar 4. Arsitektur model FFNN dengan satu lapis tersembunyi untuk regresi dua respon dengan satu <i>neuron</i> pada lapis output	10
Gambar 5. Bagan penelitian yang akan dilakukan	14
Gambar 6. Prosedur pemodelan fuzzy untuk data polikotomus dengan metode dekomposisi nilai singular	19

DAFTAR LAMPIRAN

1. Dua paper mahasiswa pada seminar nasional MIPA di UNY 18 Mei 2013 dan semnas Matematika dan Pendidikan Matematika, 9 November 2013.
2. Personalia tenaga peneliti
3. Berita acara seminar proposal penelitian Hibah Bersaing
4. Berita acara seminar hasil penelitian Hibah Bersaing
5. Kontrak penelitian

BAB I

PENDAHULUAN

1.1 Latar Belakang Masalah

Kanker Payudara adalah kanker yang terjadi pada jaringan payudara. Kanker jenis ini umumnya terjadi pada wanita. Meski pria juga bisa terkena namun sangat kecil kemungkinannya. Faktor-faktor penyebab kanker payudara adalah faktor reproduksi, penggunaan hormon, obesitas, radiasi, genetik dan faktor keturunan. Pengobatan yang dilakukan untuk kanker payudara ini adalah dengan pembedahan dan dilanjutkan dengan kemoterapi maupun radiasi. Penentuan stadium kanker payudara sangat penting untuk tindakan pengobatan.

Penelitian tentang klasifikasi untuk diagnosis kanker payudara terus dilakukan untuk mendapatkan keakuratan hasil. Gupta, S, et.al (2011) menggunakan teknik klasifikasi data mining untuk menentukan diagnosis kanker payudara. You, H dan Rumbe, G. telah melakukan klasifikasi kanker payudara dengan membandingkan metode support vector machine, metode Bayesian dan neural network. Klasifikasi berdasarkan logika fuzzy dengan metode mean dan standar deviasi serta histogram dari nilai atribut telah dilakukan oleh Jain, R dan Abraham, A (2003) . Boyd, N.F., (1995) menggunakan metode klasifikasi kuantitatif mammography untuk klasifikasi kanker payudara. Jelen, L. et al (2008) menggunakan metode support vector machine untuk klasifikasi stadium kanker payudara. Selanjutnya Basha, S.S. dan Prasad, K.S. (2009) telah menggunakan metode operator morfologi dan fuzzy c-mean clustering dalam deteksi kanker payudara. Kemudian Shanti, S dan Bhaskaran, V.M (2011) menentukan klasifikasi kanker payudara dengan metode FCM dan pohon keputusan.

Model NN merupakan alternatif yang banyak menarik perhatian, karena beberapa alasan seperti NN tidak memerlukan asumsi-asumsi pada data yang seringkali sulit dipenuhi. Model NN ini telah banyak digunakan untuk klasifikasi diagnosis kanker payudara. Namun demikian kelemahan model NN adalah prosesnya tidak transparan dalam suatu *black box*.

Kelebihan dari pemodelan *fuzzy* adalah mampu memodelkan data-data yang didasarkan pada gabungan dari data empirik dan pengetahuan ahli dalam bentuk logika

fuzzy. Proses transparansi dalam pemodelan ini dapat dilihat dari logika-logika *fuzzy* yang digunakan dalam pemodelan. Pemodelan *fuzzy* yang optimal untuk data polikotomus masih menjadi **masalah terbuka**. Oleh karena itu perlu dikembangkan suatu pemodelan *fuzzy* yang optimal untuk data polikotomus dan penerapannya untuk diagnosis kanker payudara dan kanker serviks.

1.2 Rumusan Masalah

1. Bagaimana mengembangkan metode baru dalam pemodelan *fuzzy* untuk klasifikasi data polikotomus yang optimal.
2. Bagaimana menentukan prosedur pemrograman dengan MATLAB untuk klasifikasi data polikotomus berdasarkan metode yang dikembangkan.
3. Bagaimana mengaplikasikan metode yang dikembangkan pada diagnosis kanker serviks dan kanker payudara.

BAB II

TINJAUAN PUSTAKA

Keistimewaan dari model *fuzzy* adalah mampu memformulakan pemikiran dan persepsi manusia seperti pada pengambilan keputusan yang faktor manusia mempunyai pengaruh yang besar. Dengan kata lain model *fuzzy* mampu memformulakan suatu permasalahan yang hanya didasarkan pada pengetahuan para ahli di bidangnya atau yang didasarkan pada data empirik.

2.1 Penelitian Pendahuluan

Penelitian tentang klasifikasi untuk diagnosis kanker payudara terus dilakukan untuk mendapatkan keakuratan hasil. Gupta, S, et.al (2011) menggunakan teknik klasifikasi data mining untuk menentukan diagnosis kanker payudara. You, H dan Rumble, G. telah melakukan klasifikasi kanker payudara dengan membandingkan metode support vector machine, metode Bayesian dan neural network. Klasifikasi berdasarkan logika fuzzy dengan metode mean dan standar deviasi serta histogram dari nilai atribut telah dilakukan oleh Jain, R dan Abraham, A (2003) . Boyd, N.F., (1995) menggunakan metode klasifikasi kuantitatif mammography untuk klasifikasi kanker payudara. Jelen, L. et al (2008) menggunakan metode support vector machine untuk klasifikasi stadium kanker payudara. Selanjutnya Basha, S.S. dan Prasad, K.S. (2009) telah menggunakan metode operator morfologi dan fuzzy c-mean clustering dalam deteksi kanker payudara. Kemudian Shanti, S dan Bhaskaran, V.M (2011) menentukan klasifikasi kanker payudara dengan metode FCM dan pohon keputusan.

Model NN merupakan alternatif yang banyak menarik perhatian, karena beberapa alasan. NN tidak memerlukan asumsi-asumsi pada data yang seringkali sulit dipenuhi. Dalam keadaan ini NN dapat dipandang sebagai metode statistik yang non linear dan nonparametrik (Ripley, 1993, Cheng & Titterington, 1994). Berdasarkan hasil training terhadap sampel, NN dapat menyimpulkan bagian populasi yang tidak diketahui. Prinsip ini sesuai dengan peramalan, yaitu melakukan prediksi keadaan yang akan datang dari keadaan masa lalu (sampel). Oleh karena itu NN dapat diaplikasikan untuk peramalan. Menurut Sharda (1994), NN banyak diaplikasikan untuk peramalan data *time series* .

Ada banyak model NN yang telah digunakan dalam pemodelan maupun peramalan data *time series*, diantaranya adalah *Feedforward Neural Network* (FFNN) dan *Recurrent Neural Network*. Yang termasuk dalam kelas FFNN adalah *Backpropagation Neural Network*, *Radial Basis Function Network*, *General Regression Neural Network*. *Backpropagation Neural Network* yang lebih dikenal sebagai FFNN merupakan model yang sangat populer dan banyak digunakan untuk menyelesaikan masalah *time series*, khususnya untuk data finansial.

Penggunaan FFNN untuk analisis data *time series* secara luas telah banyak dilakukan. Hasil-hasil studi empirik di bidang finansial menunjukkan bahwa prediksi data *time series* menggunakan model FFNN memberikan hasil yang lebih akurat dibandingkan model yang diperoleh dari metode statistik. Tkacz (2001) menggunakan model FFNN untuk memprediksi pertumbuhan ekonomi di Canada, Firdaus *et al.* (2005) untuk memprediksi curah hujan di Johor, Malaysia, Chan *et al.* (1999) pada harga saham di Shanghai, dan Chen (2001) pada inflasi di Amerika Serikat. Penerapan NN di bidang finansial dapat dilihat pada Diaz *et al.* (2001), Moody (1995), dan Nikola & Jing Yang (2000), dan Ranaweera & Hubele (1995). Suhartono *et al.* (2005) mengaplikasikan FFNN pada data penumpang pesawat dan memberikan hasil prediksi yang lebih baik dibandingkan dengan prediksi ARIMA dengan pola seasonal. Brodjol Sutijo *et al.* (2005) menggunakan Radial Basis NN untuk peramalan data inflasi dengan hasil cukup memuaskan.

Dalam penerapannya, FFNN mengandung sejumlah parameter (*weight*) yang terbatas. Permasalahan yang masih menjadi perhatian para peneliti adalah bagaimana menentukan model FFNN yang paling baik (jumlah parameter yang optimal) yang meliputi penentuan jumlah unit input dan jumlah unit *hidden* (Zang *et al.*, 1998). Ada beberapa metode yang telah digunakan diantaranya adalah algoritma *pruning*, *network information criteria* (NIC), regulasi, dan *cross-validation*. Namun demikian, metode-metode tersebut belum memberikan jaminan didapatkannya model yang optimal, sehingga masalah ini masih menjadi topik yang terus dikaji.

2.2 Model Fuzzy

Keistimewaan dari model *fuzzy* adalah mampu memformulasikan pemikiran dan persepsi manusia seperti pada pengambilan keputusan yang faktor manusia mempunyai

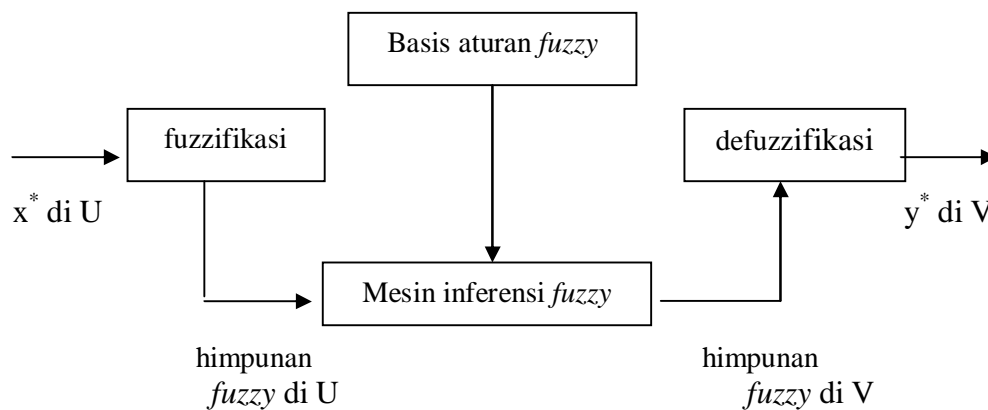
pengaruh yang besar. Dengan kata lain model *fuzzy* mampu memformulakan suatu permasalahan yang hanya didasarkan pada pengetahuan para ahli di bidangnya atau yang didasarkan pada data empirik.

Sistem *fuzzy* adalah suatu sistem dengan inputnya adalah n-tupel bilangan real dan outputnya adalah bilangan real yang dibentuk dengan menggunakan fuzzifikasi, basis aturan *fuzzy*, mesin inferensi *fuzzy* dan defuzzifikasi. Suatu basis aturan *fuzzy* terdiri dari himpunan aturan **jika-maka** *fuzzy* yang berbentuk:

Jika x_1 adalah A_1^l dan x_2 adalah A_2^l dan ... dan x_n adalah A_n^l , maka y adalah B^l (1)

dengan A_i^l, B^l berturut-turut adalah himpunan *fuzzy* di $U_i \subset \mathbf{R}$ dan $V \subset \mathbf{R}$, (x_1, x_2, \dots, x_n) dan y adalah variabel input output dari sistem *fuzzy* tersebut, $l = 1, 2, \dots, M$ yaitu banyaknya aturan dalam basis aturan *fuzzy*.

Fuzzifikasi adalah suatu pemetaan yang memetakan titik $x^* \in U \subset \mathbf{R}^n$ ke suatu himpunan samar A di U . Ada tiga tipe fuzzifikasi yaitu singleton, Gaussian dan segitiga. Sedangkan defuzzifikasi adalah suatu pemetaan dari himpunan samar B di $V \subset \mathbf{R}$ ke suatu titik bernilai real $y \in V$. Ada tiga tipe defuzzifikasi yaitu *center of gravity*, *center overage* dan maksimum. Kemudian dengan menggunakan logika *fuzzy*, mesin inferensi *fuzzy* mengkombinasikan aturan **jika – maka fuzzy** dengan suatu pemetaan dari himpunan A di U ke suatu himpunan samar B di V . Beberapa bentuk dari mesin inferensi *fuzzy* yang biasa digunakan dalam sistem *fuzzy* adalah mesin inferensi pergandaan, minimum, Lukasiewics, Sadeh, Dienes-Rescher. Mengingat jenis-jenis fuzzifikasi, defuzzifikasi dan mesin inferensi *fuzzy* tersebut, maka ada 45 tipe sistem *fuzzy* yang merupakan kombinasi dari jenis-jenis tersebut.



Gambar 1. Pembentukan sistem *fuzzy*

2.3 Model Neural Network

Neural network adalah suatu model non linear yang telah diaplikasikan dalam berbagai bidang diantaranya *pattern recognition*, *medical diagnostic*, seleksi produk, dan peramalan. Proses komputasi dalam *neural network* dirancang menyerupai sistem kerja *neuron* pada otak manusia yang sangat kompleks.

Neural network terdiri atas elemen-elemen untuk pemrosesan informasi yang disebut dengan *neuron*, unit, sel atau *node*. Setiap *neuron* dihubungkan dengan *neuron* lainnya dengan suatu *connection link*, yang direpresentasikan dengan *weight*/bobot. Metode untuk menentukan nilai *weight* disebut dengan *training*, *learning*, atau algoritma. Setiap *neuron* menggunakan fungsi aktivasi pada net input (jumlah dari input terboboti) untuk menentukan prediksi *output*.

Neuron-neuron dalam *neural network* disusun dalam grup, yang disebut dengan *layer* (lapis) . Susunan *neuron-neuron* dalam lapis dan pola koneksi di dalam dan antar lapis disebut dengan arsitektur jaringan. Arsitektur ini merupakan salah satu karakteristik penting yang membedakan *neural network*.

Secara umum ada tiga lapis yang membentuk *neural network*:

- Lapis input: data diterima oleh *neural network* dalam lapis input. Jumlah *node* atau *neuron* dalam *lapis input* tergantung pada jumlah input dalam model dan setiap input menentukan satu *neuron*.
- Lapis tersembunyi (*hidden layer*): lapis tersembunyi terletak di antara lapis input dan lapis output, yang dapat terdiri atas beberapa lapis tersembunyi.
- Lapis output: setelah melalui proses *training*, *network* merespon input baru untuk menghasilkan output yang merupakan hasil peramalan.

Neural network dengan tiga lapis disebut dengan *multilayer net*, jika hanya terdiri dari lapis input dan lapis output disebut dengan *single layer net*. Tipe NN dibedakan oleh arsitektur, *training*, dan fungsi aktivasi.

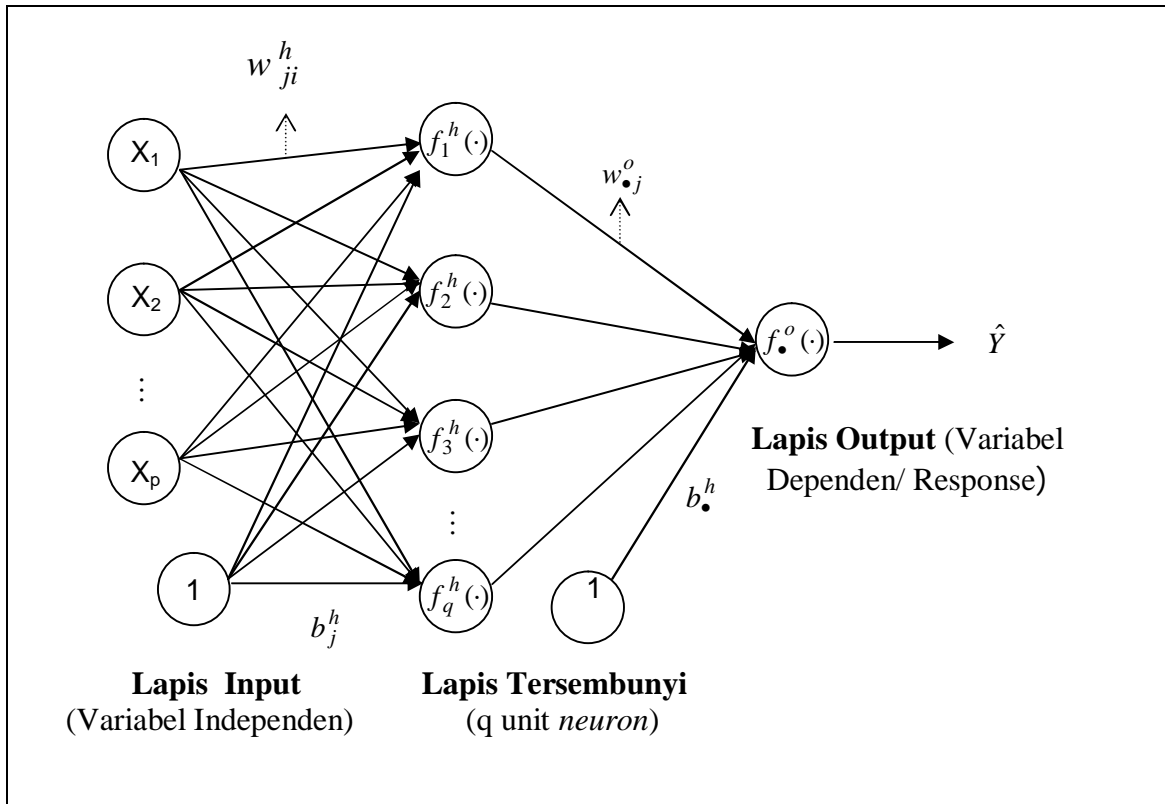
2.4. Feedforward Neural Network

Feedforward neural network merupakan salah satu model *neural network* yang banyak dipakai dalam berbagai bidang, khususnya pada peramalan data *time series*. Model ini biasa disebut dengan *multilayer perceptrons* (MLP). Arsitektur model ini

terdiri atas satu *lapis input*, satu atau lebih lapis tersembunyi, dan *lapis output*. MLP dengan satu lapis tersembunyi

Dalam model ini, perhitungan respon atau output $y(x)$ dilakukan dengan memproses (*propagating*) input x mengalir dari satu lapis maju ke lapis berikutnya secara berurutan. Kompleksitas dari arsitektur FFNN tergantung pada jumlah lapis tersembunyi dan jumlah *neuron* pada masing-masing lapis. FFNN dengan satu lapis tersembunyi merupakan model yang paling sering digunakan, karena ditinjau dari kompleksitas lebih sederhana, tetapi sudah mampu mendekati fungsi kontinyu untuk sembarang derajat akurasi. Hal ini didukung beberapa teorema dari Cybenko (1989), Funahashi (1989), dan Hornik (1989).

Gambar 2 adalah suatu contoh dari bentuk khusus FFNN dengan satu lapis tersembunyi yang terdiri dari q unit *neuron* dan lapis output yang hanya terdiri dari satu unit *neuron*.



Gambar 2. Arsitektur FFNN dengan satu lapis tersembunyi, p unit input, q unit di lapis tersembunyi, dan satu unit output.

b_j^h = bias pada *neuron* ke- j pada lapis tersembunyi, ($j=1,2,\dots,q$)

f_j^h = fungsi aktivasi di *neuron* ke- j pada lapis tersembunyi

$w_{\bullet j}^o$ = bobot dari *neuron* ke- j di lapis tersembunyi yang menuju *neuron* pada lapis output

b_{\bullet}^o = bias pada *neuron* di lapis output.

f_{\bullet}^o = fungsi aktivasi pada *neuron* di lapis output.

Dalam arsitektur ini, nilai-nilai respon atau output $y(x)$ dihitung melalui persamaan:

$$\hat{y}_{(k)} = f_{\bullet}^o \left[\sum_{j=1}^q [w_{\bullet j}^o f_j^h (\sum_{i=1}^p w_{ji}^h x_{i(k)} + b_j^h) + b_{\bullet}^o] \right] \quad (2)$$

dengan :

$x_{i(k)}$ = variabel input sebanyak p , ($i=1,2,\dots,p$)

$\hat{y}_{(k)}$ = nilai dugaan dari variabel output

k = indeks pasangan data input-target $(x_{i(k)}, y_{(k)})$, $k=1,2,\dots,n$

w_{ji}^h = bobot dari input ke- i yang menuju *neuron* ke- j pada lapis tersembunyi, ($j=1,2,\dots,q$).

Model FFNN dengan satu lapis tersembunyi untuk data dengan respon lebih dari satu mempunyai bentuk umum sebagaimana pada data dengan respon tunggal. Perbedaan terletak pada bentuk vektor input, vektor output, yang akibatnya vektor *weight* dan biaspun berbeda. Arsitektur untuk data respon ganda diberikan oleh Gambar 3 yaitu suatu bentuk FFNN dengan satu lapis tersembunyi yang terdiri dari q unit *neuron* dan lapis output yang terdiri dari m unit *neuron*. Dalam arsitektur ini, nilai-nilai respon atau *output* \hat{y} dihitung dengan

$$\hat{y}_{r(k)} = f_r^o \left[\sum_{j=1}^q [w_{rj}^o f_j^h (\sum_{i=1}^p w_{ji}^h x_{i(k)} + b_j^h) + b_r^o] \right], \quad (3)$$

dengan :

$x_{i(k)}$ = variabel *input* sebanyak p , ($i=1, 2, \dots, p$)

$\hat{y}_{r(k)}$ = nilai dugaan dari variabel output ke- r , ($r=1, 2, \dots, m$)

k = indeks pasangan data *input-target* ($x_{i(k)}, y_{(k)}$), ($k=1, 2, \dots, n$)

w_{ji}^h = bobot dari *input* ke- i yang menuju *neuron* ke- j pada lapisan tersembunyi,
($j=1, 2, \dots, q$).

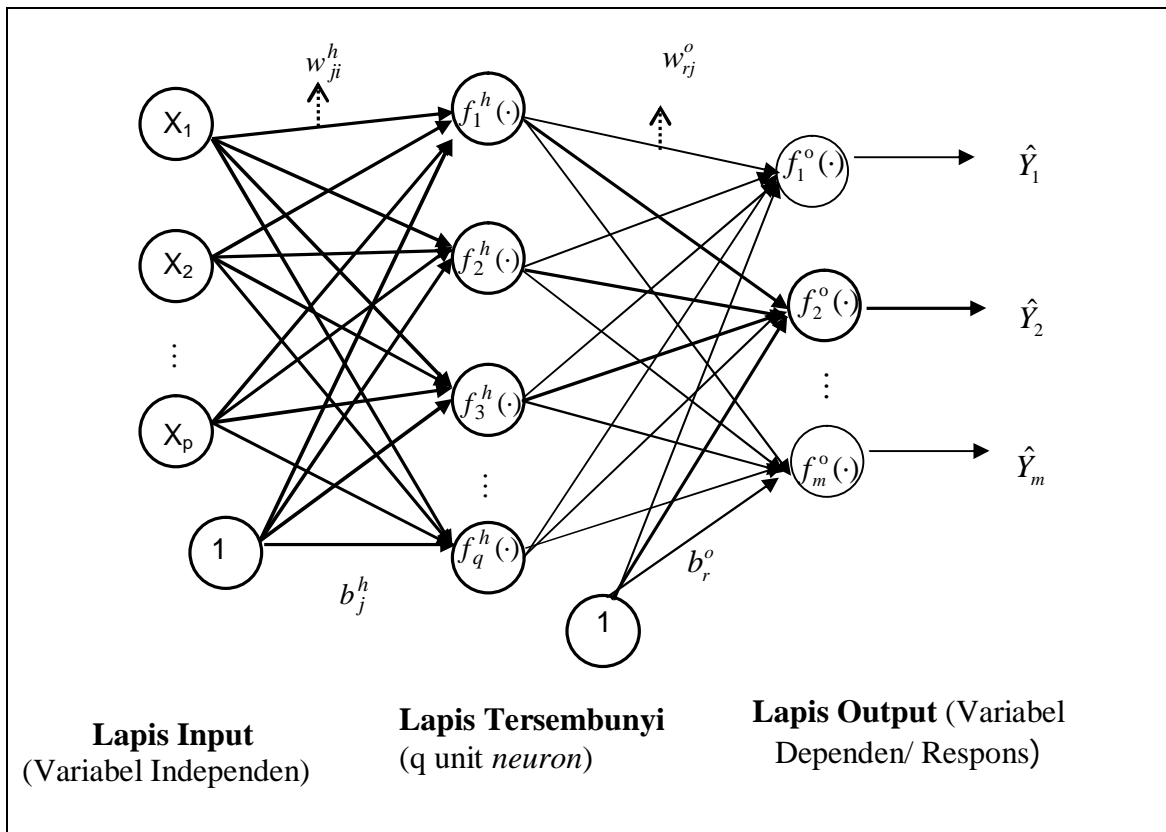
b_j^h = bias pada *neuron* ke- j pada lapisan tersembunyi.

f_j^h = fungsi aktivasi di *neuron* ke- j pada lapisan tersembunyi.

w_{rj}^o = bobot dari *neuron* ke- j di lapisan tersembunyi yang menuju *neuron* ke- r pada lapisan output.

b_r^o = bias pada *neuron* ke- r di lapisan output.

f_r^o = fungsi aktivasi pada *neuron* ke- r di lapisan output.



Gambar 3. Arsitektur FFNN dengan satu lapis tersembunyi, p unit input, q unit di lapis tersembunyi, dan m unit output.

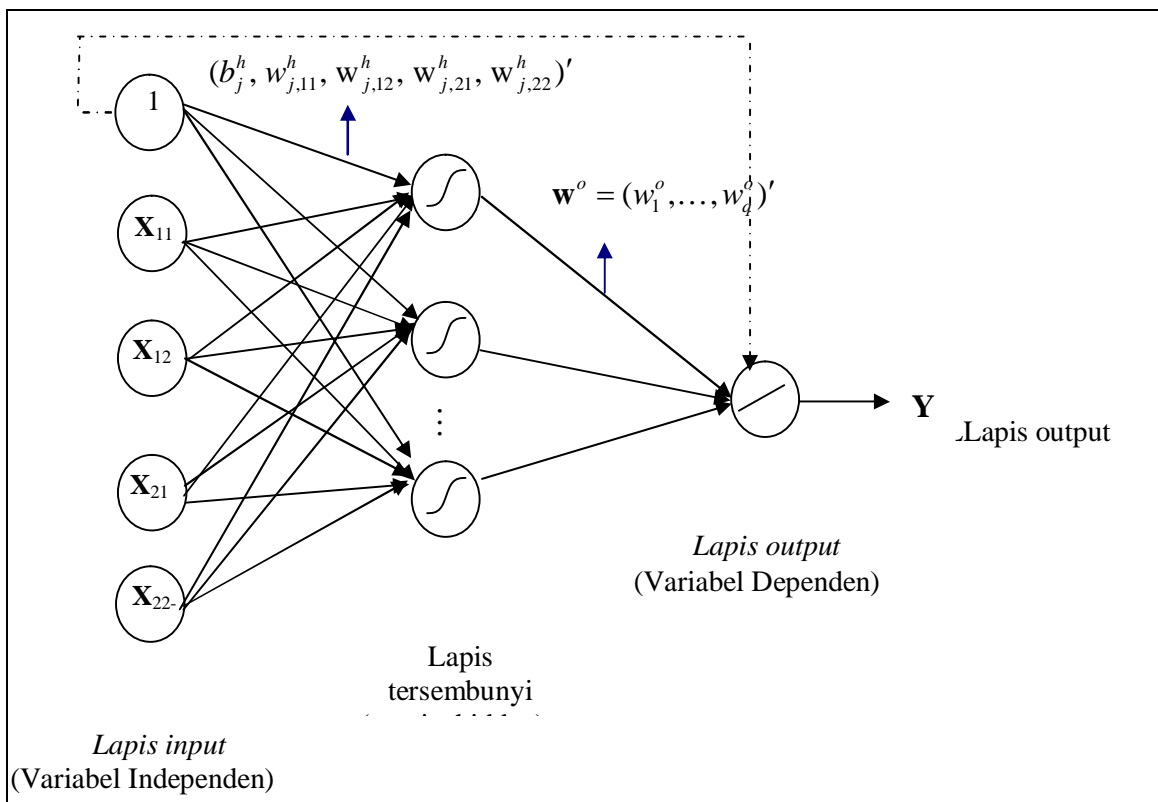
Skema input-output FFNN pada Gambar 3 dapat disajikan dengan arsitektur yang hanya memuat satu *neuron* pada lapis output, tapi tetap dapat merepresentasikan lebih dari satu hubungan fungsional. Sebanyak m persamaan non linear (2) dapat dinyatakan dalam bentuk satu persamaan

$$\hat{\mathbf{Y}} = f_{\square}^o \left[b^o + \sum_{j=1}^q w_j^o f_j^h (\mathbf{X}w_j^h + b_j^h) \right] \quad (4)$$

dengan vektor output $\mathbf{Y} = \text{vec} \mathbf{Y} = (\mathbf{Y}'_1, \mathbf{Y}'_2, \dots, \mathbf{Y}'_m)'$, matriks input $\mathbf{X} = \text{diag}(\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_m)$, vektor parameter $\mathbf{w}_j^h = (w_{j,1}^h, w_{j,2}^h, \dots, w_{j,m}^h)'$ dengan $\mathbf{w}_{jr}^h = (w_{j,r,1}^h, \dots, w_{j,r,p}^h)$,

$$\mathbf{Y}_r = \begin{pmatrix} Y_{r,1} \\ Y_{r,2} \\ \vdots \\ Y_{r,n} \end{pmatrix}, \text{ dan } \mathbf{X}_r = \begin{pmatrix} X_{1,1} & X_{2,1} & X_{p,1} \\ X_{1,2} & X_{2,2} & X_{p,2} \\ \vdots & \vdots & \vdots \\ X_{1,n} & X_{2,n} & X_{p,n} \end{pmatrix} \quad (5)$$

Arsitektur model (4) disajikan pada Gambar 4, untuk regresi dengan dua respon.



Gambar 4. Arsitektur model FFNN dengan satu lapis tersembunyi untuk regresi dua respon dengan satu *neuron* pada lapis output

Notasi yang digunakan pada Gambar 4 adalah

$$\mathbf{Y} = \begin{pmatrix} \mathbf{X}_1 \\ \mathbf{X}_2 \end{pmatrix}, \mathbf{X}_{11} = \begin{pmatrix} \mathbf{X}_1 \\ \mathbf{0} \end{pmatrix}, \mathbf{X}_{12} = \begin{pmatrix} \mathbf{X}_2 \\ \mathbf{0} \end{pmatrix}, \mathbf{X}_{21} = \begin{pmatrix} \mathbf{0} \\ \mathbf{X}_1 \end{pmatrix}, \text{ dan } \mathbf{X}_{22} = \begin{pmatrix} \mathbf{0} \\ \mathbf{X}_2 \end{pmatrix}$$

Model (4) dapat dijabarkan dalam bentuk

$$\hat{\mathbf{Y}}_r = \sum_{j=1}^q w_j^o f_j^h \left(\sum_{i=1}^p w_{j,ri}^h \mathbf{X}_i + b_j^h \right) + b^o \quad (6)$$

untuk setiap variabel $r = 1, \dots, m$.

Jika dicermati model (3) dan (6), keduanya mencakup beberapa hubungan fungsional antara variabel, tetapi ada perbedaan dari *weight* yang terlibat dalam model. Pada model yang pertama *weight* dari lapis input ke lapis tersembunyi sama, tetapi *weight* dari lapis tersembunyi ke lapis output untuk setiap variabel output berbeda, sedangkan pada model kedua *weight* untuk setiap variabel dari lapis input ke lapis tersembunyi berbeda, tetapi *weight* dari lapis tersembunyi ke lapis output untuk setiap variabel output sama. Jadi model pertama membedakan parameter untuk setiap variabel dari *weight* antara lapis tersembunyi dan lapis output dan model kedua membedakan parameter untuk setiap variabel dari *weight* antara lapis input dan lapis tersembunyi.

BAB III

TUJUAN DAN MANFAAT PENELITIAN

3.1 Tujuan Penelitian

Tujuan khusus penelitian ini adalah:

4. Mendapatkan metode baru dalam pemodelan *fuzzy* untuk data polikotomus yang optimal. (Tahun I)
5. Membuat program dengan MATLAB untuk klasifikasi data polikotomus berdasarkan metode yang dikembangkan. (Tahun II)
6. Mengaplikasikan metode yang dikembangkan pada diagnosis kanker serviks dan kanker payudara. (Tahun II)

3.2 Manfaat Penelitian

Pendekatan baru dalam pemodelan fuzzy yang optimal untuk klasifikasi data polikotomus dapat digunakan untuk mengatasi kelemahan model konvensional dan model fuzzy yang sudah ada dalam klasifikasi data polikotomus. Memberikan sumbangan dalam prosedur baru untuk diagnosis kanker serviks dan kanker payudara.

BAB IV

METODE PENELITIAN

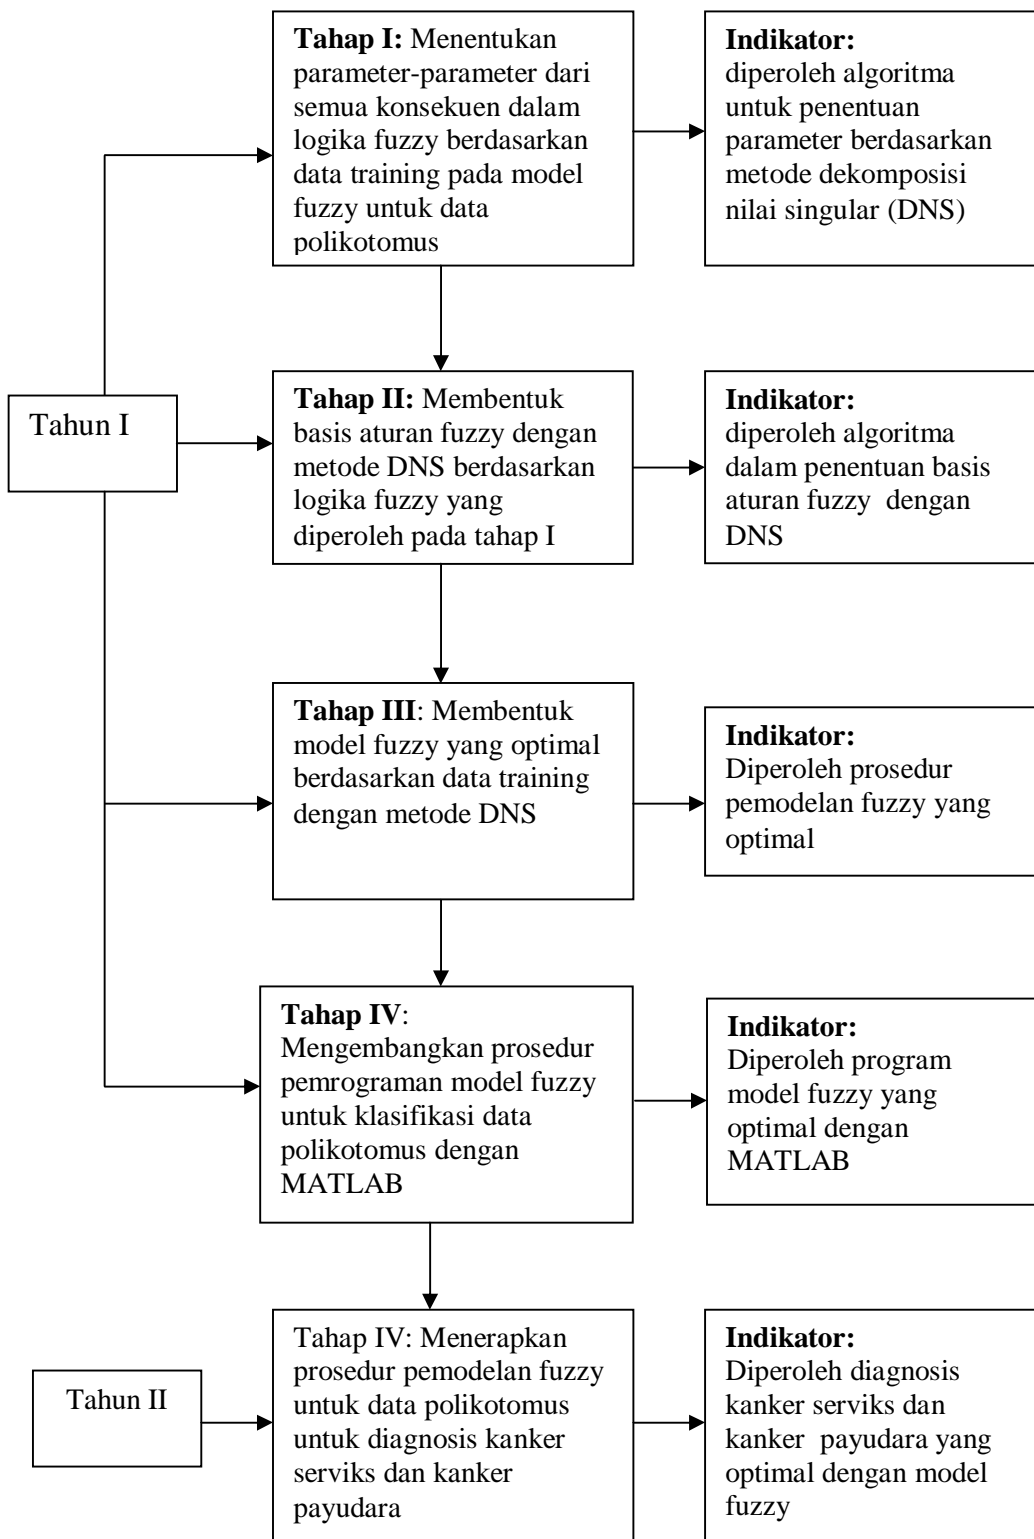
Penelitian ini merupakan penelitian *research and development* yaitu dimulai dari mengkaji dan meneliti model-model yang sudah ada, kemudian mengembangkan metode baru dalam pemodelan dan selanjutnya menerapkan metode tersebut pada permasalahan konkrit. Penelitian ini dilakukan dalam dua tahun. Tahap penelitian pada tahun pertama adalah menentukan metode baru pemodelan *fuzzy* yang optimal untuk klasifikasi data polikotomus dengan cara:

1. Menentukan domain dari input dan output data.
2. Mendefinisikan himpunan *fuzzy* pada domain input-output data dengan fungsi keanggotaan yang normal dan lengkap.
3. Menentukan parameter-parameter dari semua antecedent dalam logika *fuzzy* berdasarkan data training.
4. Menentukan parameter pada bagian konsekuen dengan metode dekomposisi nilai singular.
5. Membentuk basis aturan *fuzzy* berdasarkan aturan *fuzzy* yang diperoleh dari langkah 3 dan 4..
6. Membentuk model *fuzzy* yang optimal untuk klasifikasi data polikotomus yaitu dengan menentukan banyaknya nilai singular yang harus diambil sedemikian sehingga meminimalkan kesalahan klasifikasi data polikotomus.

Adapun tahap-tahap penelitian pada tahun kedua adalah:

1. Menentukan prosedur pemrograman model fuzzy untuk klasifikasi data polikotomus.
2. Mengaplikasikan model *fuzzy* yang dikembangkan pada tahun I untuk diagnosis kanker serviks dan kanker payudara.
3. Menentukan validasi model *fuzzy* untuk diagnosis kanker serviks dan kanker payudara.

Tahap-tahap penelitian beserta indikatornya dapat dilihat pada Gambar 5 berikut ini.



Gambar 5. Bagan penelitian yang akan dilakukan

BAB V HASIL DAN PEMBAHASAN

Prosedur Pemodelan Fuzzy untuk Klasifikasi data Polikotomus dengan Dekomposisi Nilai Singular

Diberikan N data training dari data polikotomus yang dapat dipandang sebagai data dengan n input-satu output $(x_1^k, x_2^k, \dots, x_n^k; d^k)$ untuk $k = 1, 2, \dots, N$. Misalkan suatu aturan *fuzzy* ke- i untuk model TSK order satu ditulis

$$R^i: x_1 \text{ adalah } A_{i1} \text{ dan } \dots \text{ dan } x_n \text{ adalah } A_{in}, \text{ maka } y_i = b_{i0} + b_{i1}x_1 + \dots + b_{in}x_n \quad (5.1)$$

dengan $i = 1, 2, \dots, L$ dan L adalah banyaknya aturan *fuzzy*, A_{ij} adalah himpunan *fuzzy* pada input ke- j , aturan ke- i , y_i adalah output aturan *fuzzy* ke- i , b_{ij} adalah parameter real yang akan dicari. Output model *fuzzy* dengan fuzzifier singleton, mesin inferensi pengandaan dan defuzzifier rata-rata pusat berbentuk:

$$\begin{aligned} y &= \frac{\sum_{i=1}^L y_i (\mu_{i1}(x_1) \mu_{i2}(x_2) \dots \mu_{in}(x_n))}{\sum_{i=1}^L \mu_{i1}(x_1) \mu_{i2}(x_2) \dots \mu_{in}(x_n)} \\ &= \frac{\sum_{i=1}^L (b_{i0} + b_{i1}x_1 + \dots + b_{in}x_n) (\mu_{i1}(x_1) \mu_{i2}(x_2) \dots \mu_{in}(x_n))}{\sum_{i=1}^L \mu_{i1}(x_1) \mu_{i2}(x_2) \dots \mu_{in}(x_n)} \\ &= \sum_{i=1}^L w_i (b_{i0} + b_{i1}x_1 + \dots + b_{in}x_n) \end{aligned} \quad (5.2)$$

dengan $w_i = \frac{\mu_{i1}(x_1) \mu_{i2}(x_2) \dots \mu_{in}(x_n)}{\sum_{i=1}^L \mu_{i1}(x_1) \mu_{i2}(x_2) \dots \mu_{in}(x_n)}$ dan $\mu_{ij}(x_j) = \mu_{A_{ij}}(x_j)$

Selanjutnya akan dibentuk model (5.2) yang meminimumkan fungsi tujuan J dengan

$$J = \sum_{k=1}^N (d(k) - y(k))^2 \quad (5.3)$$

dengan $d(k)$ adalah output sebenarnya untuk pasangan data ke- k , dan $y(k)$ adalah output model TSK untuk pasangan data ke- k . Jadi $y(k)$ adalah nilai y pada persamaan (5.2) untuk data input ke- k $(x_1^k, x_2^k, \dots, x_n^k)$.

Persamaan (5.3) dapat ditulis kembali dalam bentuk: (Yen, dkk., 1998)

$$J = \sum_{k=1}^N (d(k) - y(k))^2 = (d - Xb)^T (d - Xb) \quad (5.4)$$

dengan $d = \begin{bmatrix} d(1) \\ d(2) \\ \vdots \\ d(N) \end{bmatrix}$ dan

$$X = \begin{bmatrix} w_1(1) & w_1(1)x_1(1) & \cdots & w_1(1)x_n(1) & \cdots & w_L(1) & w_L(1)x_1(1) & \cdots & w_L(1)x_n(1) \\ w_1(2) & w_1(2)x_1(2) & \cdots & w_1(2)x_n(2) & \cdots & w_L(2) & w_L(2)x_1(2) & \cdots & w_L(2)x_n(2) \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ w_1(N) & w_1(N)x_1(N) & \cdots & w_1(N)x_n(N) & \cdots & w_L(N) & w_L(N)x_1(N) & \cdots & w_L(N)x_n(N) \end{bmatrix}$$

Jadi X adalah matriks ukuran $N \times [(n+1)L]$

dan $b = \begin{bmatrix} b_{10} \\ b_{11} \\ \vdots \\ b_{1n} \\ \vdots \\ b_{L0} \\ b_{L1} \\ \vdots \\ b_{Ln} \end{bmatrix}$, suatu matriks ukuran $[(n+1)L] \times 1$ (5.5)

Selanjutnya fungsi J pada (5.4) akan mencapai minimum jika $d - Xb = 0$ sehingga diperoleh

$$Xb = d \quad (5.6)$$

Kemudian untuk mencari matriks b , maka diterapkan dekomposisi nilai singular dari matriks X dengan menggunakan Teorema 2.7 dan diperoleh

$$X = U \Sigma V^T \quad (5.7)$$

dengan U dan V adalah matriks ortogonal dan $U = [u_1, \dots, u_N]$ berukuran $N \times N$, $V = [v_1, \dots, v_{(n+1)L}]$ berukuran $[(n+1)L] \times [(n+1)L]$, $\Sigma = \text{diag}(\sigma_1, \dots, \sigma_{(n+1)L})$ matriks ukuran $N \times [(n+1)L]$ dengan nilai singular $\sigma_1 \geq \dots \geq \sigma_{(n+1)L} \geq 0$.

Selanjutnya dengan menggunakan persamaan (2.12), maka penyelesaian dari (5.6) adalah

$$\hat{b} = \sum_{i=1}^r \sigma_i^{-1} \langle d, u_i \rangle v_i = \sum_{i=1}^r \frac{u_i^T d}{\sigma_i} v_i \quad (5.8)$$

dengan r adalah banyaknya nilai singular tak nol.

Jadi parameter-parameter b_{ij} yang merupakan entri-entri matriks b diestimasi dengan entri-entri matriks \hat{b} .

Langkah-langkah pemodelan fuzzy untuk klasifikasi data polikotomus dilakukan sebagai berikut:

Diberikan N data training $(x_1^k, x_2^k, \dots, x_n^k; d^k)$ dari data polikotomus yang dapat dipandang sebagai data dengan n input, $x_1^k, x_2^k, \dots, x_n^k$ dan satu output d^k untuk $k = 1, 2, \dots, N$ (banyaknya data).

1. Tentukan domain dari input dan output data.
2. Definisikan himpunan *fuzzy* pada domain input-output data dengan fungsi keanggotaan yang normal dan lengkap.
3. Tentukan parameter-parameter dari semua antecedent dalam logika *fuzzy* berdasarkan data training sehingga diperoleh aturan fuzzy yang berbentuk

$$x_1 \text{ adalah } A_{i1} \text{ dan } \dots \text{ dan } x_n \text{ adalah } A_{in}, \text{ maka } y_i = b_{i0} + b_{i1}x_1 + \dots + b_{in}x_n$$

4. Tentukan parameter pada bagian konsekuen dari aturan pada langkah 3 dengan metode dekomposisi nilai singular yaitu dengan persamaan (5.8).
5. Bentuk basis aturan *fuzzy* berdasarkan aturan *fuzzy* yang diperoleh dari langkah 3 dan 4.
6. Bentuk model *fuzzy* untuk klasifikasi data polikotomus yaitu defuzzifikasi *center average*

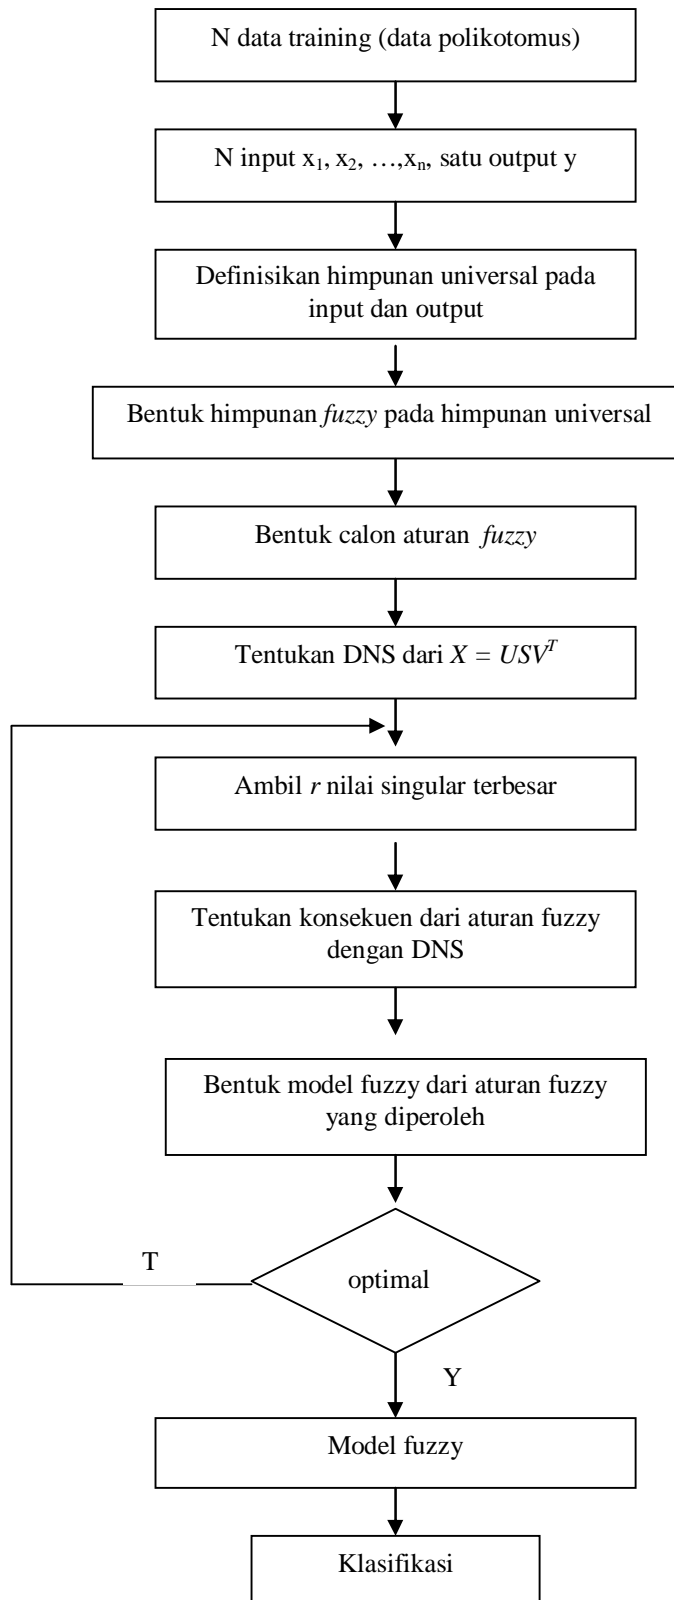
$$y = \frac{\sum_{i=1}^L y_i (\mu_{i1}(x_1) \mu_{i2}(x_2) \dots \mu_{in}(x_n))}{\sum_{i=1}^L \mu_{i1}(x_1) \mu_{i2}(x_2) \dots \mu_{in}(x_n)}$$

7. Hasil defuzzifikasi pada langkah 6 ditransformasi ke jenis klasifikasi yaitu dengan menentukan himpunan fuzzy pada output sedemikian sehingga derajat keanggotaan y

paling besar pada himpunan fuzzy tersebut. Himpunan fuzzy terpilih merupakan jenis klasifikasi yang diperoleh.

8. Model divalidasi dengan data testing yaitu dengan menentukan banyaknya nilai singular yang harus diambil sedemikian sehingga meminimalkan kesalahan klasifikasi data polikotomus.
9. Model fuzzy yang sudah optimal diterapkan untuk klasifikasi data polikotomus.

Secara garis besar prosedur pemodelan fuzzy untuk klasifikasi data polikotomus dengan dekomposisi nilai singular diberikan dalam Gambar 6 berikut.



Gambar 6. Prosedur pemodelan fuzzy untuk data polikotomus dengan metode dekomposisi nilai singular

BAB VI

RENCANA TAHAPAN BERIKUTNYA

4.1 Judul usulan: Optimalisasi Model *Fuzzy* untuk Klasifikasi pada Data Polikotomus dan Penerapannya di Bidang Kesehatan

4.2 Tujuan khusus

Tujuan khusus penelitian ini adalah:

- .1. Membuat program dengan MATLAB untuk klasifikasi data polikotomus berdasarkan metode yang dikembangkan.
2. Mengaplikasikan metode yang dikembangkan pada diagnosis kanker payudara dan kanker serviks.

4.3 Urgensi penelitian

Penelitian tentang klasifikasi untuk diagnosis kanker payudara terus dilakukan untuk mendapatkan keakuratan hasil. Gupta, S, et.al (2011) menggunakan teknik klasifikasi data mining untuk menentukan diagnosis kanker payudara. You, H dan Rumble, G. telah melakukan klasifikasi kanker payudara dengan membandingkan metode support vector machine, metode Bayesian dan neural network. Klasifikasi berdasarkan logika fuzzy dengan metode mean dan standar deviasi serta histogram dari nilai atribut telah dilakukan oleh Jain, R dan Abraham, A (2003) . Boyd, N.F., (1995) menggunakan metode klasifikasi kuantitatif mammography untuk klasifikasi kanker payudara. Jelen, L. et al (2008) menggunakan metode support vector machine untuk klasifikasi stadium kanker payudara. Selanjutnya Basha, S.S. dan Prasad, K.S. (2009) telah menggunakan metode operator morfologi dan fuzzy c-mean clustering dalam deteksi kanker payudara. Kemudian Shanti, S dan Bhaskaran, V.M (2011) menentukan klasifikasi kanker payudara dengan metode FCM dan pohon keputusan.

Dewasa ini telah berkembang suatu pendekatan yang lebih fleksibel untuk memodelkan hubungan linear maupun non linear yang dikenal dengan model *neural network* (NN). Model NN merupakan alternatif yang banyak menarik perhatian, karena beberapa alasan. NN tidak memerlukan asumsi-asumsi pada data yang seringkali sulit

dipenuhi. Ada banyak model NN yang telah digunakan dalam pemodelan maupun peramalan data *time series*, diantaranya adalah *Feedforward Neural Network* (FFNN) dan *Recurrent Neural Network*. Yang termasuk dalam kelas FFNN adalah *Backpropagation Neural Network*, *Radial Basis Function Network*, *General Regression Neural Network*. *Backpropagation Neural Network* yang lebih dikenal sebagai FFNN merupakan model yang sangat populer dan banyak digunakan untuk menyelesaikan masalah *time series*, khususnya untuk data finansial.

Penggunaan FFNN untuk analisis data *time series* secara luas telah banyak dilakukan. Hasil-hasil studi empirik di bidang finansial menunjukkan bahwa prediksi data *time series* menggunakan model FFNN memberikan hasil yang lebih akurat dibandingkan model yang diperoleh dari metode statistik. Tkacz (2001) menggunakan model FFNN untuk memprediksi pertumbuhan ekonomi di Canada, Firdaus *et al.* (2005) untuk memprediksi curah hujan di Johor, Malaysia, Chan *et al.* (1999) pada harga saham di Shanghai, dan Chen (2001) pada inflasi di Amerika Serikat. Penerapan NN di bidang finansial dapat dilihat pada Diaz *et al.* (2001), Moody (1995), dan Nikola & Jing Yang (2000), dan Ranaweera & Hubele (1995). Suhartono *et al.* (2005) mengaplikasikan FFNN pada data penumpang pesawat dan memberikan hasil prediksi yang lebih baik dibandingkan dengan prediksi ARIMA dengan pola seasonal. Brodjol Sutijo *et al.* (2005) menggunakan Radial Basis NN untuk peramalan data inflasi dengan hasil cukup memuaskan.

Dalam penerapannya, FFNN mengandung sejumlah parameter (*weight*) yang terbatas. Permasalahan yang masih menjadi perhatian para peneliti adalah bagaimana menentukan model FFNN yang paling baik (jumlah parameter yang optimal) yang meliputi penentuan jumlah unit input dan jumlah unit *hidden* (Zang *et al.*, 1998). Ada beberapa metode yang telah digunakan diantaranya adalah algoritma *pruning*, *network information criteria* (NIC), regulasi, dan *cross-validation*. Namun demikian, metode-metode tersebut belum memberikan jaminan didapatkannya model yang optimal.

Tidak seperti model neural network, model *fuzzy* mempunyai kelebihan yaitu mampu memodelkan data-data yang didasarkan pada gabungan dari data empirik dan pengetahuan ahli dalam bentuk logika *fuzzy*. Proses transparansi dalam pemodelan ini dapat dilihat dari logika-logika *fuzzy* yang digunakan dalam pemodelan. Pemodelan *fuzzy* yang optimal untuk data polikotomus masih terus dikaji. Oleh karena itu perlu

dikembangkan suatu pemodelan *fuzzy* yang optimal untuk data polikotomus dan penerapannya untuk diagnosis kanker payudara.

4.4 Hasil yang ditargetkan pada tahun ke-2:

Target penelitian pada tahun kedua adalah

1. Tersusun program untuk pemodelan *fuzzy* yang optimal untuk klasifikasi data polikotomus dengan software MATLAB.
2. Menerapkan prosedur pemodelan fuzzy yang telah dikembangkan pada tahun I untuk klasifikasi diagnosis kanker payudara dan kanker serviks.
3. Publikasi internasional akan dilakukan pada *Journal of Mathematics and System Sciences*, untuk bulan Februari 2015, David Publishing Company, USA, ISSN 2159-5291 (Print); ISSN 2159-5305 (Online).
4. Seminar internasional pada bulan november 2014 dan Februari 2015.

4.5 Rekapitulasi anggaran penelitian tahun kedua

No	Jenis pengeluaran	Biaya yang diusulkan (Rpx 1000)	Persentase (%)
		Tahun II	
1.	Gaji dan Upah	22.500	30
2.	Bahan habis pakai dan peralatan	26.250	35
3.	Biaya Perjalanan dan lumpsum untuk pemantauan terpusat, seminar internasional dan seminar nasional	18.750	25
4.	Biaya lain-lain		
	4.1 Pertemuan/Lokakarya/ Seminar nasional dan Internasional	5.000	
	4.2 Seminar Proposal/ hasil/ Laporan/ publikasi:	2.500	
	Total biaya lain-lain	7.500	10
	Jumlah	75.000	100

4.6 Jadwal Kegiatan Penelitian Tahun Kedua

No	Jenis Kegiatan	Bulan ke-									
		1	2	3	4	5	6	7	8	9	10
1.	Seminar Proposal dan Persiapan penelitian										
2.	Kajian teori: kanker payudara										
3.	Pembuatan model <i>fuzzy</i> untuk diagnosis kanker payudara										
4.	Validasi dan analisis model										
5.	Penulisan draft laporan										
6.	Seminar hasil penelitian dan penulisan laporan akhir										

BAB VII

KESIMPULAN DAN SARAN

7.1 Kesimpulan

Pada penelitian tahun pertama telah dilakukan pembentukan prosedur baru pemodelan fuzzy untuk klasifikasi data polikotomus. Pada prosedur ini, penentuan parameter pada bagian konsekuen dari aturan fuzzy yang akan dibangun dilakukan dengan metode dekomposisi nilai singular. Selanjutnya aturan fuzzy tersebut digunakan untuk melakukan inferensi dan defuzzifikasi. Kemudian hasil dari defuzzifikasi ini ditransformasi ke jenis klasifikasinya. Model divalidasi dengan data testing yaitu dengan menentukan banyaknya nilai singular yang harus diambil sedemikian sehingga meminimalkan kesalahan klasifikasi data polikotomus. Selanjutnya model fuzzy yang sudah optimal diterapkan untuk klasifikasi data polikotomus.

7.2 Saran

Pada penelitian ini, parameter pada bagian antecedent dari aturan fuzzy ditentukan lebih dahulu. Untuk mendapatkan model fuzzy yang lebih optimal, perlu diteliti bagaimana memilih parameter pada bagian antecedent dari aturan fuzzy.

DAFTAR PUSTAKA

- Basha, S.S., and Prasad, K.S., 2009, Automatic Detection Of Breast Cancer Mass In Mammograms Using Morphological Operators And Fuzzy C –Means Clustering, *Journal of Theoretical and Applied Information Technology*, pp: 704-709
- Boyd, N.F., Byng, J.W., Jong, R.A., Fishell, E.K., Little, L.E., Miller, A.B., Lockwood, G.A., Tritchler, D.L., and Yaffe, M.J., 1995, Quantitative Classification of Mammographic Densities and Breast Cancer Risk: Results From the Canadian National Breast Screening Study, *Journal of The National Cancer Institute*, 87 (9), pp: 670-675
- Brodjol Sutijo. (2005). Radial Basis Function as Statistical Modeling for Financial Data. *Proceedings International Conference on Applied Mathematics*, Bandung.
- Chan M., Wong. C. and Lam C. (1999). Financial Time series Forecasting by using Conjugate Gradient Learning Algorithm and Multiple Linear Regression Weight Initialization. *Working paper*, Department of Computing, The Hongkong Polytechnic University, Hongkong.
- Chen X., Racine J., and Swanson N. R. (2001). Semiparametric ARX Neural-Network Models with an Application to Forecasting Inflation. *IEEE Transaction on Neural Networks*, Vol. 12, No. 4, pp. 674-683.
- Cheng, B. and Titterington, D. M. (1994). Neural networks: A Review from a Statistical Perspective. *Statistical Science*, Vol. 9, pp. 2–54.
- Cybenko, G. (1989). Approximation by Superpositions of a Sigmoidal Function. *Mathematics of Control, Signals and Systems*, Vol. 2, pp. 304–314.
- Firdaus N., Shukor M., Roselina, Azlan, and Nuradibah S. (2005). Backpropagation Neural Network (BPNN) Model as a Solution of Short-Term Rainfall Prediction for Johor Catchment Area. *IRCMSA Proceedings*, Medan, Indonesia.365-375.
- Funahashi, K. (1989). On the approximate realization of continuous mappings by neural networks. *Neural Networks*, 2, 183–192.
- Gupta, S., Kumar, D.M. and Sharma, A., 2011, Data Mining Classification Techniques Applied for breast cancer diagnosis and prognosis, *Indian Journal of Computer Science and Engineering (IJCSE)*, Vol. 2 No. 2, pp: 188-195
- Hornik K. (1989). Multilayer Feedforward Networks are Universal Approximation. *Neural Networks*, 2, 359 – 366.

- Jain, R. and Abraham, A., 2003, A Comparative Study of Fuzzy Classification Methods on Breast Cancer Data, *the 7th International Work Conference on Artificial and Natural Neural Networks, IWANN'03, Spain*.
- Jelen, L., Fevens, T., and Adam Krzyz, AK., 2008, Classification of Breast Cancer Malignancy Using Cytological Images of Fine Needle Aspiration Biopsies, *Int. J. Appl. Math. Comput. Sci.* Vol. 18, No. 1, pp: 75–83
- Moody J. (1995). Economic Forecasting Challenger and *Neural Network Solutions*. In *Proceedings of the International Symposium on Artificial Neural Networks*, Taiwan.
- Nikola G and Jing Yang. (2000).The Application of Artificial Neural Networks to Exchange Rate Forecasting: The Role of Market Microstructure Variables. *Working paper*, Financial Markets Department Bank of Canada.
- Ripley, B. D. (1996). *Pattern Recognition and Neural Networks*. Cambridge University Press, Cambridge.
- Shanti, S., and Bhaskaran, V.M., 2011, Intuitionistic Fuzzy C-Means and Decision Tree Approach for Breast Cancer Detection and Classification, *European Journal of Scientific Research* Vol.66 No.3, pp: 345-351.
- Sharda, R. (1994). Neural Networks for the MS/OR Analyst: An application bibliography. *Interfaces* 24 (2), 116–130.
- Suhartono, Subanar, Sri Rejeki. (2005). Feedforward Neural Networks Model for Forecasting Trend and Seasonal Time series. *IRCMSA Proceedings*. Sumatra Utara Indonesia.
- Tkacz G. (2001). Neural network forecasting of Canadian GDP growth. *International Journal of Forecasting*, 17, 57–69.
- Wang L.X., 1997, *A Course in Fuzzy Systems and Control*, Prentice-Hall, Inc., New Jersey.
- You, H. and Rumba, G., Comparative Study of Classification Techniques on Breast Cancer FNA Biopsy Data, *International Journal of Artificial Intelligence and Interactive Multimedia*, Vol. 1, No. 3.pp:5-12