

MODEL INFERENSI BERBASIS FUZZY NEURAL NETWORK MENGGUNAKAN METODE PEMBELAJARAN DELTA RULE

Sri Kusumadewi¹⁾ Sri Hartati²⁾ Retantyo Wardoyo²⁾ Agus Harjoko²⁾

¹⁾ Jurusan Teknik Informatika Universitas Islam Indonesia Yogyakarta, cicie@fti.uui.ac.id

²⁾ Fakultas MIPA Universitas Gadjah Mada Yogyakarta

ABSTRAK

Aplikasi fuzzy neural network telah banyak diaplikasikan pada beberapa produk komersial. Ada beberapa tipe fuzzy neural network, salah satu diantaranya adalah penggunaan proses pembelajaran jaringan syaraf pada basis pengetahuan yang dibangun dari sekumpulan aturan fuzzy. Model tersebut yang akan diusulkan pada penelitian ini, dengan tujuan utamanya adalah melakukan pembelajaran terhadap aturan-aturan pada basis pengetahuan yang mendukung Clinical Decision Support System (CDSS). Input dan output jaringan merupakan bilangan fuzzy, sedangkan bobot-bobot yang bersesuaian menggunakan bilangan crisp. Arsitektur jaringan menggunakan lapisan tunggal dengan n neuron pada lapisan input, 1 neuron pada lapisan output, dan m pola data pelatihan (m aturan fuzzy). Bilangan fuzzy yang digunakan merupakan bilangan fuzzy trapesium. Konsep himpunan α -level digunakan untuk melakukan diskretisasi terhadap derajat keanggotaan kontinyu. Proses pembelajaran dilakukan dengan menggunakan algoritma pembelajaran delta rule.

Kata kunci: fuzzy neural network, delta rule, bilangan fuzzy

1 Pendahuluan

1.1 Latar Belakang

Proses pembelajaran pada jaringan syaraf tiruan telah banyak dikembangkan, terutama untuk proses pembelajaran tertimbang (*supervised learning*). Konsep pembelajaran terbimbing adalah melakukan pelatihan terhadap sekumpulan pola data pelatihan yang merupakan pasangan input-output untuk mendapatkan bobot-bobot yang tepat. Beberapa aplikasi telah menggunakan model ini, baik untuk keperluan peramalan, pencocokan pola, maupun diagnosis.

Di sisi lain, studi tentang sistem inferensi fuzzy (FIS) telah banyak digunakan pada beberapa sistem pakar. FIS digunakan untuk melakukan inferensi terhadap basis pengetahuan yang dibangun dari sekumpulan aturan. FIS memang sangat cocok apabila digunakan untuk keperluan inferensi, terutama apabila variabel-variabel yang terkait dengan basis pengetahuan mengandung ketidakpastian. Kondisi ini menyebabkan nilai dari suatu variabel tidak dapat diungkapkan secara tegas dengan bilangan *crisp* tertentu.

Apabila dipunyai sekumpulan aturan dalam basis pengetahuan yang disajikan dalam bentuk aturan fuzzy, pada dasarnya dapat dilakukan pelatihan pada sekumpulan aturan

tersebut dengan menggunakan algoritma pembelajaran pada jaringan syaraf. Model ini merupakan bagian dari konsep *fuzzy neural network*.

Beberapa aplikasi telah menggunakan *fuzzy neural network*. Sejak tahun 1991, *fuzzy neural network* telah diaplikasikan untuk mesin cuci, vacuum cleaner, penanak nasi, pencuci piring, pemanggang roti, kulkas, kipas angin, dan fotokopi (Takagi, 1997). NARA merupakan salah satu produk yang menggunakan *fuzzy neural network* yang mampu mengenali karakter tulisan tangan yang diterima dari mesin faksimili (Takagi, 1992). Produk lain yang menggunakan fuzzy neural network adalah kipas angin elektrik yang dikembangkan oleh Sanyo, dengan menggunakan 3 sensor infra merah, kipas angin ini dapat berubah arah secara otomatis tergantung lokasi pengguna (Takagi, 1997). *Fuzzy neural network* juga digunakan oleh Toshiba sebagai *PID controller* untuk melakukan kontrol terhadap udara dan panas pada industri kimia (Ozaki, 1994).


1.2 Tujuan

Penelitian ini bertujuan untuk membangun model inferensi berbasis fuzzy neural network menggunakan algoritma pembelajaran delta rule. Sebagai contoh kasus, model ini akan diaplikasikan pada basis pengetahuan yang mendukung *Clinical Decision Support System* (CDSS). Proses inferensi ditujukan untuk melakukan diagnosis penyakit.

2 Dasar Teori

2.1 Bilangan fuzzy trapesium

Bentuk linguistik dapat direpresentasikan dengan bilangan fuzzy. Salah satu bilangan fuzzy yang dapat digunakan adalah bentuk trapesium (**Gambar 1**). Bilangan fuzzy trapesium, A memiliki 4 parameter yaitu $A = (a,b,c,d)$, dengan a adalah batas bawah, b adalah batas atas, c-d adalah batas pembentuk derajat keanggotaan 1.



Gambar 1 Bilangan fuzzy trapesium.

Fungsi keanggotaan untuk bilangan fuzzy trapesium adalah:

$$\mu[x] = \begin{cases} 0; & x \leq a \text{ atau } x \geq d \\ \frac{x-a}{b-a}; & a \leq x \leq b \\ 1; & b \leq x \leq c \\ \frac{d-x}{d-c}; & c \leq x \leq d \end{cases} \quad (1)$$

2.2 Representasi bilangan fuzzy dengan himpunan α -level


Suatu bilangan fuzzy dapat direpresentasikan dengan menggunakan sejumlah bilangan terbatas (*finite number*) dari himpunan α -levelnya (Uehara dan Fujise, 1990). Misalkan x adalah variabel fuzzy, dan A_i adalah bilangan fuzzy pada variabel fuzzy x . Dengan mengambil nilai $M \geq 2$ sebagai bilangan bulat positif, diberikan:

$$\alpha_j = \frac{j-1}{M-1}; \quad j=1, \dots, M \quad (2)$$

yang merupakan bagian dari range $[0, 1]$.

$$[A_i]^{\alpha_j} = \{x \mid A_i(x) \geq \alpha_j\} = [a_{ij}^L, a_{ij}^R] \quad (3)$$

dengan $[A_i]^{\alpha_j}$ menunjukkan himpunan α_j -level dari bilangan fuzzy A (**Gambar 2**).



Gambar 2 Representasi bilangan fuzzy dengan himpunan α -level.

2.3 Algoritma pembelajaran *delta rule*.

Misalkan terdapat jaringan syaraf dengan lapisan tunggal, satu neuron pada lapisan output, dengan vektor input x_i , $i=1, \dots, n$; vektor bobot w_i , $i=1, \dots, n$; target output t ; dan output jaringan y . Pasangan input-output yang akan dilatih sebanyak m , dengan pasangan input-output ke- k adalah (x_{ki}, t_k) ; $k=1, \dots, m$; $i=1, \dots, n$. Konsep dasar dari algoritma pembelajaran *delta rule* adalah mengubah bobot w_i dengan formula:

$$w_i = w_i + \eta(t_k - y_k)x_{ki} \quad (4)$$

dengan η adalah laju pembelajaran yang bernilai antara 0 sampai 1. Proses perbaikan bobot ini dilakukan secara berulang sampai tercapai maksimum epoch atau total error

(selisih antara target output dan output jaringan) yang diperoleh sudah kurang dari ξ (nilai yang sangat kecil, mendekati nol)

Algoritma delta rule ini, nantinya akan digunakan untuk mendapatkan bobot-bobot akhir jaringan dengan input pola pelatihan yang berupa bilangan-bilangan fuzzy dalam bentuk interval terdiskretisasi (*fuzzy neural network*), bukan data-data crisp seperti pada kebanyakan pemakaian *delta rule*.

3 Model yang Diusulkan

3.1 Gambaran umum

Proses inferensi akan dilakukan untuk mendapatkan konklusi apabila diberikan fitur-fitur (gejala-gejala, tanda-tanda, atau ukuran-ukuran) tertentu berdasarkan pengetahuan-pengetahuan yang ada pada basis pengetahuan. Pengetahuan direpresentasikan dengan menggunakan aturan yang berbentuk IF – THEN. Anteseden pada setiap aturan berupa pernyataan-pernyataan tentang kondisi setiap fitur, sedangkan konsekuen pada aturan berisi kategori penyakit yang terkait dengan fitur. Baik anteseden maupun konsekuen diberikan dalam bentuk linguistik, dan setiap bentuk linguistik direpresentasikan dengan menggunakan bilangan fuzzy trapesium. Kondisi setiap fitur pada anteseden dihubungkan dengan operator AND. Konsekuen yang merupakan target output berupa tingkat resiko terkait dengan kondisi fitur.

Aturan ke-k diberikan sebagai:

$$R_k: \text{IF } x_1 \text{ is } A_{k1} \text{ and } \dots \text{ and } x_n \text{ is } A_{kn} \text{ THEN } y \text{ is } B_k$$

dengan:

- x_i , adalah fitur ke-i, $i=1, \dots, n$.
- A_{ki} , adalah bentuk linguistik yang menyatakan kondisi fitur x_i pada aturan ke-k, $i=1, \dots, n$; $k=1, \dots, m$.
- y adalah kategori penyakit;
- A_k , adalah bentuk linguistik yang menyatakan tingkat resiko kategori penyakit y pada aturan ke-k, $k=1, \dots, m$.

Apabila terdapat m aturan, maka akan dipunyai m pasangan pola pelatihan, yaitu $\{(X_1, B_1), \dots, (X_m, B_m)\}$ dengan $X_k = (A_{k1}, \dots, A_{kn})$. Selanjutnya, setiap bilangan fuzzy baik pada anteseden maupun konsekuen akan direpresentasikan dengan menggunakan himpunan α -level, sehingga akan diperoleh versi diskret dari pasangan input-output sebagai berikut (Fullèr, 1995):

$$\left\{ (a_{k11}^L, a_{k11}^R, \dots, a_{k1M}^L, a_{k1M}^R), \dots, (a_{kn1}^L, a_{kn1}^R, \dots, a_{knM}^L, a_{knM}^R), (b_{k1}^L, b_{k1}^R, \dots, b_{kM}^L, b_{kM}^R) \right\}$$

dengan a_{kij}^L adalah batas bawah himpunan α_j -level variabel ke-i pada aturan ke-k; sedangkan a_{kij}^R adalah batas atas himpunan α_j -level variabel ke-i pada aturan ke-k; $i=1, \dots, n$; $j=1, \dots, M$; $k=1, \dots, m$.

Dengan menggunakan jaringan syaraf, m pasangan pola ini dapat dilatih dengan menggunakan algoritma pembelajaran *delta rule* untuk mendapatkan bobot-bobot yang sesuai.

Misalkan diberikan 5 aturan (m=5) untuk menentukan tingkat resiko penyakit meningistis sebagai berikut:

- R₁: IF x₁ is HT and x₂ is HT and x₃ is HT and x₄ is HT and x₅ is HT and x₆ is HT THEN y is R
- R₂: IF x₁ is K and x₂ is K and x₃ is K and x₄ is K and x₅ is K and x₆ is K THEN y is C
- R₃: IF x₁ is HP and x₂ is HP and x₃ is HP and x₄ is HP and x₅ is HP and x₆ is HP THEN y is T
- R₄: IF x₁ is K and x₂ is HP and x₃ is HP and x₄ is HP and x₅ is HP and x₆ is HP THEN y is T
- R₅: IF x₁ is HT and x₂ is HP and x₃ is HT and x₄ is HT and x₅ is HT and x₆ is HP THEN y is T

Dengan (n=6):

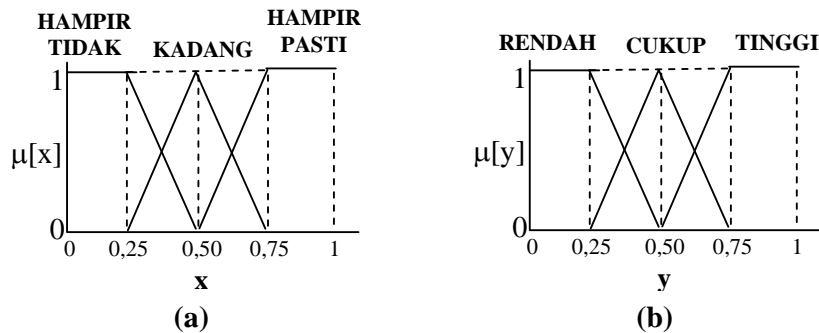
- x₁ = nyeri dirasakan menetap;
- x₂ = nyeri dirasakan di seluruh kepala;
- x₃ = nyeri menjalar sampai ke leher;
- x₄ = demam;
- x₅ = nyeri tenggorokan atau infeksi pernafasan;
- x₆ = leher sulit ditekuk;

Bentuk linguistik yang diberikan pada setiap fitur terlihat pada **Gambar 3.a** dan **Gambar 3.b** untuk bentuk linguistik pada konsekuen. Setiap bentuk linguistik direpresentasikan dengan bilangan fuzzy trapesium. Bentuk-bentuk linguistik pada anteseden adalah:

- Hampir Tidak (HT) = (0; 0; 0,25; 0,5);
- Kadang (K) = (0,25; 0,5; 0,5; 0,75);
- Hampir Pasti (HP) = (0,5; 0,75; 1; 1).

Sedangkan bentuk-bentuk linguistik pada konsekuen adalah:

- Rendah (R) = (0; 0; 0,25; 0,5);
- Cukup (C) = (0,25; 0,5; 0,5; 0,75);
- Tinggi (T) = (0,5; 0,75; 1; 1).



Gambar 3 Bilangan fuzzy trapesium untuk (a) anteseden dan (b) konsekuen setiap aturan.

Dengan demikian, untuk setiap aturan diperoleh:

Aturan ke-1 (R_1):

$$X_1 = ((0; 0; 0,25; 0,5); (0; 0; 0,25; 0,5); (0; 0; 0,25; 0,5); (0; 0; 0,25; 0,5); (0; 0; 0,25; 0,5); (0; 0; 0,25; 0,5));$$

$$B_1 = (0; 0; 0,25; 0,5);$$

Aturan ke-2 (R_2):

$$X_2 = ((0,25; 0,5; 0,5; 0,75); (0,25; 0,5; 0,5; 0,75); (0,25; 0,5; 0,5; 0,75); (0,25; 0,5; 0,5; 0,75); (0,25; 0,5; 0,5; 0,75));$$

$$B_2 = (0,25; 0,5; 0,5; 0,75);$$

Aturan ke-3 (R_3):

$$X_3 = ((0,5; 0,75; 1; 1); (0,5; 0,75; 1; 1); (0,5; 0,75; 1; 1); (0,5; 0,75; 1; 1); (0,5; 0,75; 1; 1));$$

$$B_3 = (0,5; 0,75; 1; 1);$$

Aturan ke-4 (R_4):

$$X_4 = ((0,25; 0,5; 0,5; 0,75); (0,5; 0,75; 1; 1); (0,5; 0,75; 1; 1); (0,5; 0,75; 1; 1); (0,5; 0,75; 1; 1));$$

$$B_4 = (0,5; 0,75; 1; 1);$$

Aturan ke-5 (R_5):

$$X_5 = ((0; 0; 0,25; 0,5); (0,5; 0,75; 1; 1); (0; 0; 0,25; 0,5); (0; 0; 0,25; 0,5); (0; 0; 0,25; 0,5));$$

$$B_5 = (0,5; 0,75; 1; 1);$$

Apabila diambil nilai $M=3$, maka berdasarkan persamaan (2), dapat diperoleh:

$$\alpha_1 = \frac{1-1}{3-1} = 0; \quad \alpha_2 = \frac{2-1}{3-1} = 0,5; \quad \alpha_3 = \frac{3-1}{3-1} = 1;$$

Dengan menggunakan persamaan (1), diperoleh $a_{ij}^L = 0$ untuk setiap i dan j ; $a_{3ij}^R = 1$ untuk setiap i dan j ; $b_{ij}^L = 0$ untuk setiap j . Contoh perhitungan yang lainnya:

$$a_{ii}^R = 0,5 - (0)(0,5 - 0,25) = 0,5; \text{ untuk setiap } i.$$

$$a_{ii2}^R = 0,5 - (0,5)(0,5 - 0,25) = 0,375; \text{ untuk setiap } i.$$

$$a_{ii3}^R = 0,5 - (1)(0,5 - 0,25) = 0,25; \text{ untuk setiap } i.$$

$$b_{ii}^R = 0,5 - (0)(0,5 - 0,25) = 0,5.$$

$$\begin{aligned}
b_{12}^R &= 0,5 - (0,5)(0,5 - 0,25) = 0,375 . \\
b_{13}^R &= 0,5 - (1)(0,5 - 0,25) = 0,25 . \\
a_{211}^L &= 0,25 + (0)(0,5 - 0,25) = 0,25 ; \text{ untuk setiap } i . \\
a_{212}^L &= 0,25 + (0,5)(0,5 - 0,25) = 0,375 ; \text{ untuk setiap } i . \\
a_{213}^L &= 0,25 + (1)(0,5 - 0,25) = 0,5 ; \text{ untuk setiap } i . \\
a_{211}^R &= 0,75 - (0)(0,5 - 0,25) = 0,75 ; \text{ untuk setiap } i . \\
a_{212}^R &= 0,75 - (0,5)(0,5 - 0,25) = 0,625 ; \text{ untuk setiap } i . \\
a_{213}^R &= 0,75 - (1)(0,5 - 0,25) = 0,5 ; \text{ untuk setiap } i . \\
b_{21}^L &= 0,25 + (0)(0,5 - 0,25) = 0,25 . \\
b_{22}^L &= 0,25 + (0,5)(0,5 - 0,25) = 0,375 . \\
b_{23}^L &= 0,25 + (1)(0,5 - 0,25) = 0,5 . \\
b_{21}^R &= 0,75 - (0)(0,5 - 0,25) = 0,75 . \\
b_{22}^R &= 0,75 - (0,5)(0,5 - 0,25) = 0,625 . \\
b_{23}^R &= 0,75 - (1)(0,5 - 0,25) = 0,5 .
\end{aligned}$$

Sehingga dengan cara yang sama diperoleh:

Aturan ke-1:

$$\{((0; 0,5); (0; 0,375); (0; 0,25)); ((0; 0,5); (0; 0,375); (0; 0,25)); ((0; 0,5); (0; 0,375); (0; 0,25)); ((0; 0,5); (0; 0,375); (0; 0,25)); ((0; 0,5); (0; 0,375); (0; 0,25)); ((0; 0,5); (0; 0,375); (0; 0,25)); ((0; 0,5); (0; 0,375); (0; 0,25)); ((0; 0,5); (0; 0,375); (0; 0,25))\}$$

Aturan ke-2:

$$\{((0,25; 0,75); (0,375; 0,625); (0,5; 0,5)); ((0,25; 0,75); (0,375; 0,625); (0,5; 0,5)); ((0,25; 0,75); (0,375; 0,625); (0,5; 0,5)); ((0,25; 0,75); (0,375; 0,625); (0,5; 0,5)); ((0,25; 0,75); (0,375; 0,625); (0,5; 0,5)); ((0,25; 0,75); (0,375; 0,625); (0,5; 0,5)); ((0,25; 0,75); (0,375; 0,625); (0,5; 0,5)); ((0,25; 0,75); (0,375; 0,625); (0,5; 0,5))\};$$

Aturan ke-3:

$$\{((0,5; 1); (0,625; 1); (0,75; 1)); ((0,5; 1); (0,625; 1); (0,75; 1)); ((0,5; 1); (0,625; 1); (0,75; 1)); ((0,5; 1); (0,625; 1); (0,75; 1)); ((0,5; 1); (0,625; 1); (0,75; 1)); ((0,5; 1); (0,625; 1); (0,75; 1)); ((0,5; 1); (0,625; 1); (0,75; 1)); ((0,5; 1); (0,625; 1); (0,75; 1))\};$$

Aturan ke-4:


$$\{((0,5; 1); (0,625; 1); (0,75; 1)); ((0,5; 1); (0,625; 1); (0,75; 1)); ((0,5; 1); (0,625; 1); (0,75; 1)); ((0,5; 1); (0,625; 1); (0,75; 1)); ((0,5; 1); (0,625; 1); (0,75; 1)); ((0,5; 1); (0,625; 1); (0,75; 1)); ((0,5; 1); (0,625; 1); (0,75; 1)); ((0,5; 1); (0,625; 1); (0,75; 1))\};$$

Aturan ke-5:

$$\{((0,25; 0,75); (0,375; 0,625); (0,5; 0,5)); ((0,5; 1); (0,625; 1); (0,75; 1)); ((0,25; 0,75); (0,375; 0,625); (0,5; 0,5)); ((0,25; 0,75); (0,375; 0,625); (0,5; 0,5)); ((0,25; 0,75); (0,375; 0,625); (0,5; 0,5)); ((0,25; 0,75); (0,375; 0,625); (0,5; 0,5)); ((0,25; 0,75); (0,375; 0,625); (0,5; 0,5)); ((0,25; 0,75); (0,375; 0,625); (0,5; 0,5))\};$$

3.2 Arsitektur jaringan

Sebanyak m pasangan pola yang terbentuk dari m aturan merupakan pasangan input-output yang keduanya bersifat fuzzy. Pasangan-pasangan pola ini akan dilatih pada jaringan syaraf dengan lapisan tunggal (**Gambar 4**).



Gambar 4 Arsitektur jaringan.

Ada n neuron pada lapisan input yang akan menerima sinyal input, A_1, \dots, A_n ; dan 1 neuron pada lapisan output yang akan menghasilkan output jaringan, Y . Besarnya pengaruh sinyal input terhadap neuron pada lapisan output ditentukan dengan bobot, $w_i, i=1, \dots, n$; yang bernilai tegas (*crisp*). Fungsi aktivasi yang digunakan adalah fungsi sigmoid, F (Fausett, 1994):

$$F(y_{in}) = \frac{1}{1 + e^{-y_{in}}} \quad (5)$$

dengan nilai $y_{in} = \sum_{i=1}^n w_i A_i$ (6)

Karena nilai X_i direpresentasikan sebagai himpunan α -level, dan telah dilakukan diskretisasi pada pasangan input-output maka output jaringan pada data pelatihan ke- k akan berbentuk (Fullèr, 1995):

$$[Y_k]^\alpha = \left[F\left(\sum_{i=1}^n w_i A_i \right) \right]^\alpha = \left[F\left(\sum_{i=1}^n [w_i A_{ki}]^L(\alpha) \right), F\left(\sum_{i=1}^n [w_i A_{ki}]^R(\alpha) \right) \right] \quad (7)$$

Demikian pula untuk target output ke- k , B_k diberikan sebagai:

$$[B_k]^\alpha = [B_k^L(\alpha), B_k^R(\alpha)] \quad (8)$$

Pada kasus yang diberikan, ada sebanyak 6 neuron pada lapisan input, yang masing-masing menunjukkan kondisi fitur yang diberikan. Dengan mengambil bobot awal, $w_1 = 0,01$; $w_2 = 0,02$; $w_3 = 0,07$; $w_4 = 0,04$; $w_5 = 0,05$; dan $w_6 = 0,06$; maka untuk pola pelatihan pertama pada α_1 diperoleh $[Y_1]^0 = [0,5; 0,5312]$, berasal dari:

$$F\left(\sum_{i=1}^6 [w_i A_{ii}]^L(0)\right) = F((0,01)(0) + (0,02)(0) + (0,07)(0) + (0,04)(0) + (0,05)(0) + (0,06)(0))$$

$$= \frac{1}{1 + e^0} = 0,5$$

$$F\left(\sum_{i=1}^6 [w_i A_{ii}]^R(0)\right) = F((0,01)(0,5) + (0,02)(0,5) + (0,07)(0,5) + (0,04)(0,5) + (0,05)(0,5) + (0,06)(0,5))$$

$$= \frac{1}{1 + e^{0,125}} = 0,5312$$

3.3 Mekanisme pembelajaran

Proses pembelajaran terhadap pasangan input-output dilakukan dengan menggunakan algoritma pembelajaran *delta rule*. Besarnya *error* antara target output dengan output jaringan untuk setiap himpunan diberikan sebagai:

$$e_k(\alpha) = e_k^L(\alpha) + e_k^R(\alpha) \quad (9)$$

dengan *error* pada sisi sebelah kiri pada himpunan α -level adalah:

$$e_k^L(\alpha) = \frac{1}{2} \left(B_k^L(\alpha) - Y_k^L(\alpha) \right)^2 \quad (10)$$

dan *error* pada sisi sebelah kanan pada himpunan α -level adalah:

$$e_k^R(\alpha) = \frac{1}{2} \left(B_k^R(\alpha) - Y_k^R(\alpha) \right)^2 \quad (11)$$

Total error yang terjadi pada pola pelatihan ke-k adalah

$$e_k = \sum_{\alpha} \alpha e_k(\alpha) \quad (12)$$

Perbaikan bobot untuk proses pembelajaran dengan delta rule pada pola ke-k, variabel ke-i, mengalami modifikasi dengan memperimbangkan α_j , sebagai berikut:

$$w_i = w_i + (\eta)(\alpha_j)(e_k(\alpha_j)) \left(\frac{1}{2} (A_{kij}^L + A_{kij}^R) \right) \quad (13)$$

Pada kasus yang diberikan, apabila ditetapkan maksimum epoch = 10; $\eta = 1$; dan $\xi = 0,009$, akan diperoleh perubahan bobot pada epoch pertama data pertama:

	w_1	w_2	w_3	w_4	w_5	w_6
$\alpha_1 =$	0,0100	0,0200	0,0700	0,0400	0,0500	0,0600
$\alpha_2 =$	0,0228	0,0328	0,0828	0,0528	0,0628	0,0728
$\alpha_3 =$	0,0429	0,0529	0,1029	0,0729	0,0829	0,0929

Epoch pertama data kedua:

	w ₁	w ₂	w ₃	w ₄	w ₅	w ₆
$\alpha_1 =$	0,0429	0,0529	0,1029	0,0729	0,0829	0,0929
$\alpha_2 =$	0,0468	0,0568	0,1068	0,0768	0,0868	0,0968
$\alpha_3 =$	0,0485	0,0585	0,1085	0,0785	0,0885	0,0985

dan seterusnya, sehingga diperoleh bobot akhir: $w_1 = 0,6214$; $w_2 = 0,8019$; $w_3 = 0,7317$; $w_4 = 0,7017$; $w_5 = 0,7117$; dan $w_6 = 0,8419$. Proses pembelajaran telah berhenti pada epoch ke-4 pola pelatihan ke-5, dengan *total error* $e_4 = 0,0083$.

3.4 Pengujian

Proses pengujian dilakukan dengan memberikan input berupa bilangan fuzzy. Setelah dilakukan diskretisasi terhadap bilangan-bilangan fuzzy tersebut, selanjutnya dicari nilai output jaringan, $[Y]^\alpha = [Y^L(\alpha), Y^R(\alpha)]$ dengan menggunakan persamaan (7). Kemudian nilai akhir output jaringan Y, ditentukan dengan formula sebagai berikut:

$$Y = \frac{\sum_{j=1}^M (\alpha_j) (Y^L(\alpha_j) + Y^R(\alpha_j))}{2 \sum_{j=1}^M \alpha_j} \quad (14)$$

Misalkan dilakukan pengujian terhadap pola data yang ketiga, yaitu semua fitur Hampir Pasti terjadi, maka diperoleh:

$$X = \{((0,5; 1); (0,625; 1); (0,75; 1)); ((0,5; 1); (0,625; 1); (0,75; 1)); ((0,5; 1); (0,625; 1); (0,75; 1)); ((0,5; 1); (0,625; 1); (0,75; 1)); ((0,5; 1); (0,625; 1); (0,75; 1)); ((0,5; 1); (0,625; 1); (0,75; 1)); ((0,5; 1); (0,625; 1); (0,75; 1))\}$$

Dengan menetapkan $M = 3$ diperoleh: $\alpha_1 = 0$; $\alpha_2 = 0,5$; dan $\alpha_3 = 1$. Output jaringan dapat dihitung sebagai:

$$\begin{aligned} Y^L(0) &= F\left(\sum_{i=1}^6 [w_i A_{li}]^L(0)\right) \\ &= F((0,5)(0,6214 + 0,8019 + 0,7317 + 0,7017 + 0,7117 + 0,8419)) \\ &= \frac{1}{1 + e^{2,2052}} = 0,9007 \end{aligned}$$

$$\begin{aligned} Y^R(0) &= F\left(\sum_{i=1}^6 [w_i A_{li}]^R(0)\right) \\ &= F((1)(0,6214 + 0,8019 + 0,7317 + 0,7017 + 0,7117 + 0,8419)) \\ &= \frac{1}{1 + e^{4,4103}} = 0,988 \end{aligned}$$

$$\begin{aligned}
Y^L(0,5) &= F\left(\sum_{i=1}^6 [w_i A_{ii}]^L(0,5)\right) \\
&= F((0,625)(0,6214 + 0,8019 + 0,7317 + 0,7017 + 0,7117 + 0,8419)) \\
&= \frac{1}{1 + e^{2,7564}} = 0,9403
\end{aligned}$$

$$\begin{aligned}
Y^R(0,5) &= F\left(\sum_{i=1}^6 [w_i A_{ii}]^R(0,5)\right) \\
&= F((1)(0,6214 + 0,8019 + 0,7317 + 0,7017 + 0,7117 + 0,8419)) \\
&= \frac{1}{1 + e^{4,4103}} = 0,988
\end{aligned}$$

$$\begin{aligned}
Y^L(1) &= F\left(\sum_{i=1}^6 [w_i A_{ii}]^L(1)\right) \\
&= F((0,75)(0,6214 + 0,8019 + 0,7317 + 0,7017 + 0,7117 + 0,8419)) \\
&= \frac{1}{1 + e^{3,3077}} = 0,9647
\end{aligned}$$

$$\begin{aligned}
Y^R(1) &= F\left(\sum_{i=1}^6 [w_i A_{ii}]^R(1)\right) \\
&= F((1)(0,6214 + 0,8019 + 0,7317 + 0,7017 + 0,7117 + 0,8419)) \\
&= \frac{1}{1 + e^{4,4103}} = 0,988
\end{aligned}$$

Nilai output jaringan:

$$Y = \frac{(0)(0,9007 + 0,988) + (0,5)(0,9403 + 0,988) + (1)(0,9647 + 0,988)}{(2)(0 + 0,5 + 1)} = 0,9723$$

Nilai Y ini terletak pada range [0,5; 1] yang berarti bahwa tingkat resiko Meningitis termasuk Tinggi (sesuai dengan pola data pelatihan ketiga). Beberapa contoh pengujian yang lain terlihat pada **Tabel 1**.

Tabel 1 Beberapa contoh pengujian.

No	Input						Output	
	x ₁	x ₂	x ₃	x ₄	x ₅	x ₆	Y	Resiko
1	HT	HT	HT	HT	HT	K	0,7046	T
2	K	K	K	K	HP	HP	0,9379	T
3	K	HT	HT	K	K	K	0,7943	T

Pada **Tabel 1**, sebagai contoh, untuk data pengujian pertama, nyeri dirasakan menetap hampir tidak ada (HT), nyeri dirasakan di seluruh kepala hampir tidak ada (HT), nyeri menjalar sampai ke leher hampir tidak ada (HT), demam hampir tidak ada (HT), nyeri tenggorokan atau infeksi pernafasan hampir tidak ada (HT), dan ada sedikit kesulitan menekuk leher (K), maka resiko meningitis adalah 0,7046.

4 Simpulan

Berdasarkan uraian di atas dapat disimpulkan:

1. proses pembelajaran jaringan syaraf pada basis pengetahuan yang berisi aturan-aturan fuzzy memberikan tingkat obyektivitas yang lebih tinggi jika dibandingkan dengan FIS biasa, mengingat proses pembelajaran ini akan menghasilkan bobot-bobot yang tepat sesuai dengan pola data pelatihan yang diberikan.
2. salah satu kelemahan dari model ini adalah adanya proses diskretisasi yang bisa memicu pertumbuhan error, semakin sedikit pendiskretan (semakin kecil nilai M), berakibat besarnya rentang error antara output jaringan dengan target yang diharapkan.

Pustaka

- [1] Fausett, Laurence. 1994. *Fundamentals of Neural Networks (Architectures, Algorithms, and Applications)*. New Jersey: Prentice-Hall.
- [2] Fullèr, Robert. 1995. *Neural Fuzzy Systems*. Åbo.http://facult.petra.ac.id/resmana/basiclab/fuzzy/fuzzy_book.pdf.
- [3] Ozaki, T. 1994. "Recovering Boiler Control at A Pulp Factory" dalam: Takagi, Hideyuki. 1997. "Introduction to Fuzzy Systems, Neural Networks, and Genetic Algorithms" dalam: Ruan, Da. *Intelligent Hybrid Systems: Fuzzy Logic, Neural Networks, and Genetic Algorithms*. Massachusetts: Kluwer Academic Publishers.
- [4] Ruan, Da. 1997. *Intelligent Hybrid Systems: Fuzzy Logic, Neural Networks, and Genetic Algorithms*. Massachusetts: Kluwer Academic Publishers.
- [5] Takagi, H; Suzuki, N; Kouda, T; dan Kojima, Y. 1992. "Neural Network Designed on Aproximate Reasoning Architecture" dalam Takagi, Hideyuki. 1997. "Introduction to Fuzzy Systems, Neural Networks, and Genetic Algorithms" dalam: Ruan, Da. *Intelligent Hybrid Systems: Fuzzy Logic, Neural Networks, and Genetic Algorithms*. Massachusetts: Kluwer Academic Publishers.
- [6] Takagi, Hideyuki. 1997. "Introduction to Fuzzy Systems, Neural Networks, and Genetic Algorithms" dalam: Ruan, Da. *Intelligent Hybrid Systems: Fuzzy Logic, Neural Networks, and Genetic Algorithms*. Massachusetts: Kluwer Academic Publishers.
- [7] Uehara, K; dan Fujise, M. 1990. "Learning of fuzzy inference criteria with artificial Neural Network" dalam: Fullèr, Robert. 1995. *Neural Fuzzy Systems*. Åbo.http://facult.petra.ac.id/resmana/basiclab/fuzzy/fuzzy_book.pdf.

[8] <http://www.medicastore.com/med/>