

# PERANCANGAN JARINGAN SENSOR NIRKABEL UNTUK PENDETEKSI DINI TERJADINYA TANAH LONGSOR DENGAN JARINGAN SYARAF TIRUAN *MULTILAYER PERCEPTRON*

Thariq Hizrian Azka<sup>\*)</sup>, Aghus Sofwan dan Sumardi

Departemen Teknik Elektro, Universitas Diponegoro  
Jl. Prof. Sudharto, SH, Kampus UNDIP Tembalang, Semarang 50275, Indonesia

<sup>\*)</sup>*E-mail: hizrianazka@gmail.com*

## Abstrak

Tanah longsor merupakan salah satu bencana yang sering terjadi di Indonesia. Banyak faktor yang mempengaruhi terjadinya bencana longsor, seperti curah hujan, kemiringan tanah, kelembaban tanah, dan getaran. Dibutuhkan suatu sistem yang dapat mengidentifikasi pengaruh masing-masing faktor tersebut terhadap terjadinya bencana longsor agar bencana longsor yang selanjutnya terjadi dapat diprediksi. Pada penelitian ini dibuatlah perancangan jaringan saraf tiruan dengan metode cascade-forward backpropagation. Jaringan saraf tiruan ini memiliki 5 parameter masukan berupa kemiringan lereng yang dapat diukur dengan sensor MPU 6050, curah hujan yang diukur dengan sensor tipping bucket dengan reed switch, kadar air pada dua kedalaman tanah berbeda dengan sensor kelembaban FC-28, dan getaran tanah yang diukur dengan sensor 801s. Sistem ini memiliki keluaran berupa perhitungan kemungkinan terjadinya bencana longsor pada suatu wilayah dengan kondisi aman, siaga, maupun bahaya. Hasil dari jaringan saraf tiruan ini akan dibandingkan dengan keluaran metode feed-forward backpropagation untuk mengetahui performanya. Dari hasil pengujian jaringan saraf tiruan cascade-forward backpropagation pada kondisi aman, siaga, dan bahaya didapatkan rata-rata error berturut-turut sebesar 0.00664, 0.07825, dan 0.05624 dan rata-rata error pada metode feed-forward backpropagation sebesar 0.03475, 0.07892, dan 0.08702.

*Kata kunci: Jaringan saraf tiruan, cascade-forward backpropagation, Tanah longsor*

## Abstract

Landslide is one of the most frequently happened disasters in Indonesia. Many factors affect the occurrence of landslides, such as rainfall, soil slope, soil moisture, and vibration. A system that can identify the influence of each of these factors on the occurrence of landslides is needed so that the subsequent landslide disaster can be predicted. In this study an artificial neural network design with cascade-forward backpropagation method was made. This artificial neural network has 5 input parameters in the form of slope slope that can be measured with MPU 6050 sensor, the rainfall measured by a sensor tipping bucket with reed switch, moisture content in two different soil depths with FC-28 humidity sensor, and ground vibration measured with 801s sensor. This system has an output in the form of calculated possibility of landslide disasters in an area with safe, alert and hazardous conditions. The results of this artificial neural network will be compared with the output of the feed-forward backpropagation method to determine its performance. From the results of cascade-forward backpropagation neural network testing in safe, standby and hazard conditions, an average error of 0.00664, 0.07825, and 0.05624 respectively were obtained and the average error in the feed-forward backpropagation method output was 0.03475, 0.07892, and 0.08702.

*Keywords: Artificial Neural Network, Cascade-forward backpropagation, Landslide*

## 1. Pendahuluan

Indonesia merupakan salah satu negara dengan tingkat bencana alam yang cukup tinggi. Bencana yang sering terjadi di Indonesia adalah tanah longsor. Efek dari tanah longsor tidak hanya berdampak pada lingkungan, tetapi mengakibatkan timbulnya korban jiwa yang cukup besar. Pada tahun 2017 hingga 2018 sendiri menurut data dari BNPB, telah terjadi sebanyak 1116 kejadian dan

mengakibatkan korban meninggal sebanyak 431 jiwa[1]. Penyebab longsor dapat terjadi karena Indonesia memiliki iklim monsoon tropis, dimana diakibatkan adanya perubahan tekanan udara secara ekstrim di Kawasan daratan India dan Lautan Hindia [2]. Sehingga mengakibatkan curah hujan yang tinggi. Curah hujan yang tinggi ini menyebabkan kandungan air dalam yang meningkat dan akhirnya memicu terjadinya bencana tanah longsor [3]. Terjadinya tanah longsor disebabkan adanya penambahan bobot tanah yang disebabkan peresapan air.

Jika air tersebut terus menerus menebus sampai ke tanah kedap air, maka tanah kedap air yang berfungsi sebagai bidang gelincir akan licin sehingga tanah pelapukan di atasnya akan bergerak mengikuti dan terjun dari lereng. Tidak hanya faktor curah hujan saja yang dapat menyebabkan terjadinya tanah longsor. Ada parameter-parameter lain yang juga menjadi perhitungan terjadinya bencana, seperti kemiringan, getaran tanah, dan lain-lain. Maka dari itu dibutuhkan suatu sistem yang dapat mengidentifikasi berbagai parameter yang menyebabkan tanah longsor secara *real time* sehingga dapat menjadi peringatan akan terjadi tanah longsor. Sistem ini juga dapat dipantau secara langsung di lapangan dan pemantauan data pada server.

Proses pengidentifikasian parameter-parameter penyebab longsor seperti curah hujan, kemiringan tanah, kelembaban tanah, dan getaran diperlukan untuk mengetahui pengaruh masing-masing parameter terhadap terjadinya bencana longsor. Pengenalan pola perubahan nilai dari masing-masing parameter tersebut saat terjadinya longsor akan mempermudah prediksi terjadinya bencana longsor. Proses pengenalan pola dan prediksi ini dapat dilakukan menggunakan jaringan saraf tiruan.

Beberapa penelitian mengenai penggunaan jaringan saraf tiruan untuk mengenali pola data dan peramalan telah dilakukan [4]–[8]. Penggunaan jaringan saraf tiruan dapat dilakukan dalam sistem pendeteksi dini bencana longsor karena jaringan saraf tiruan dapat memodelkan hubungan yang kompleks antara input dan output untuk menemukan pola-pola pada data.

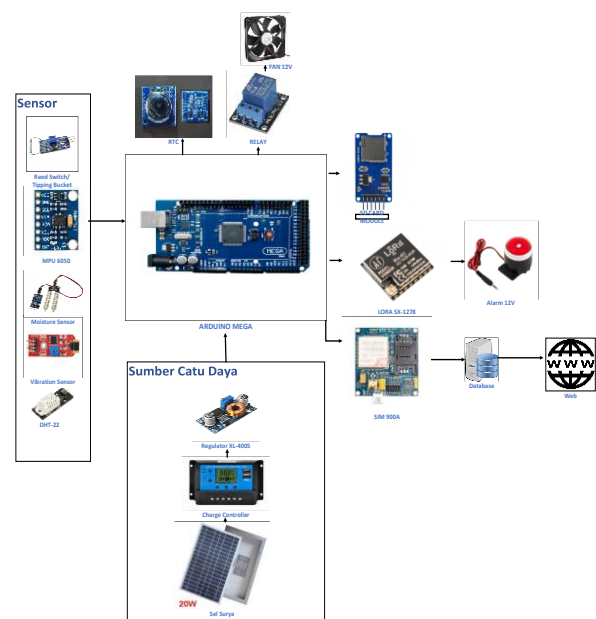
Pada penelitian sebelumnya telah dikembangkan sebuah jaringan sensor nirkabel untuk mendeteksi tanah longsor, yang mana membahas tentang desain, pengembangan, dan implementasi dari jaringan sensor nirkabel yang dapat memantau secara *real time*[9][10]. Sensor yang digunakan adalah kelembaban, kemiringan, dan curah hujan .

Berdasarkan kebutuhan pengidentifikasian parameter tersebut maka pada penelitian ini dibuat jaringan saraf tiruan dengan metode *cascade-forward backpropagation* dengan masukan berupa data curah hujan hasil bacaan sensor tipping bucket, data kemiringan hasil bacaan sensor MPU 6050, data kelembaban tanah hasil bacaan sensor FC-28, dan data getaran hasil bacaan sensor 801s dengan keluaran berupa peringatan kondisi bencana longsor suatu wilayah apakah berstatus aman, siaga, atau bahaya.

## 2. Metode

Perancangan pada penelitian ini terbagi kedalam dua bagian yaitu perancangan perangkat keras dan perancangan perangkat lunak. Perancangan perangkat keras dilakukan dengan merancang *Sensor node* untuk jaringan sensor nirkabel dan merancang tapis pelewat

rendah R-C untuk sensor kelembaban. *Sensor node* ini akan mendeteksi 5 parameter yang dapat menyebabkan terjadinya longsor. Parameter tersebut adalah sudut kemiringan pada alat yang diukur dengan sensor MPU6050, curah hujan yang akan diukur menggunakan *tipping bucket*, kelembaban tanah yang akan diukur dengan sensor kelembaban tanah FC-28, dan getaran tanah. Data yang diterima dari kelima parameter akan dikirim melalui modul GSM SIM900A ke dalam database yang kemudian akan ditampilkan dalam bentuk website. Data yang dikirim juga akan disimpan dalam *SD Card* dengan bentuk data *logger*.



Gambar 1. Perancangan Keseluruhan Alat

### 2.1. Perancangan Jaringan Saraf Tiruan


Pada penelitian ini digunakan 4 parameter dengan 5 nilai yang diukur oleh sensor secara *real-time*, yaitu curah hujan, kemiringan, Kelembaban tanah pada dua kedalaman berbeda, dan getaran. Dikarenakan belum adanya penelitian yang menghitung pengaruh dan pembobotan masing-masing parameter penyebab longsor yang digunakan pada penelitian penelitian ini, maka Peraturan Menteri Pekerjaan Umum No.22/PRT/M/2007 (PMPU No.22/PRT/M/2007) [11] dengan beberapa penyesuaian sebagai dasar perhitungan manual target nilai yang akan dimodelkan oleh JST. Perhitungan manual ini bertujuan sebagai acuan performa JST yang dirancang.

Ada 5 parameter penyebab terjadinya longsor, parameter ini ditunjukkan pada Tabel 1.

Tabel 1. Nilai 5 Parameter Penyebab Longsor


Parameter	Nilai <sub>i</sub>	Bobot	Nilai	Bobot	Nilai	Bobot	Nilai	Bobot
kemiringan[10]	0-20	30%	1	20-40	30%	2	>40	30%
curah hujan/jam[11]	0-30	15%	1	31-70	15%	2	>70	15%
Kelembaban tanah	0-30	22%	1	31-35	22%	2	>36	22%
Getaran	0-2	23%	1	3-5	23%	2	>6	23%
Vegetasi		10%	1	10%	2		10%	3
Total		100%		100%			100%	

Pada penelitian ini dirancang sistem pengambilan keputusan menggunakan jaringan saraf tiruan dengan metode *cascade-forward backpropagation*. Pada sistem ini, terdapat 5 masukan pada input layer, 1 hidden layer yang berisi 5 neuron dan 1 output yang menentukan kondisi peringatan dini. Input layer terdiri dari 5 sensor yaitu MPU6050 sensor yang mengukur kemiringan lereng, sensor kelembaban tanah yang mengukur kadar air dalam tanah, sensor hujan tipping bucket yang mengukur curah hujan yang terjadi, dan sensor getaran untuk mengukur kekuatan gerakan tanah. Struktur JST *cascade-forward backpropagation* (CFBP) dapat dilihat pada Gambar 2.



Gambar 2. JST cascade-forward backpropagation


Dibuat juga Jaringan saraf tiruan dengan metode *feed-forward backpropagation* sebagai pembandingan untuk mengetahui jaringan mana yang memiliki hasil lebih baik saat digunakan sebagai sistem deteksi dini bencana longsor. Jaringan jenis ini telah digunakan pada penelitian sebelumnya[12] Struktur jaringan *feed-forward backpropagation* (FFBP) yang dibuat dapat dilihat pada Gambar 3.



Gambar 3. JST feed-forward backpropagation

### 2.1.1. Penentuan Parameter Terjadinya Longsor

Penelitian ini menggunakan 5 variabel sebagai masukan jaringan saraf tiruan, sebelum data masuk ke JST diperlukan normalisasi data dengan tujuan untuk memperkecil jarak antar nilai data masukan dan mempermudah penghitungan bobot pada JST. Digunakan fungsi *mapminmax* pada MATLAB untuk melakukan normalisasi data seperti pada Gambar 4.



Gambar 4. fungsi *mapminmax*


Pada fungsi ini digunakan rumus :

$$y = \frac{(x-xmin)(ymax-ymin)}{(xmax-xmin)} + ymin$$

Dengan nilai minimal dan maksimal pada masing-masing variable adalah :


1. Curah hujan = 0-150 (mm<sup>3</sup>/jam)
2. Kemiringan = 0-100 (%), dengan 0 mewakili 0 derajat dan 100 mewakili 45 derajat
3. Kelembaban 1 = 0-100 (%)
4. Kelembaban 2 = 0-100 (%)
5. Getaran = 0-7 (skala richter)

Jaringan saraf tiruan yang dirancang memiliki 2 hidden layer, hidden layer 1 memiliki struktur yang dapat dilihat pada Gambar 5.



Gambar 5. hidden layer 1

Pada hidden layer terdapat pemberian bobot (*weighting*) pada masing-masing nilai input yang dapat dilihat pada Gambar 5. pada layer ini juga terjadi penjumlahan antara nilai bobor dan bias yang dilanjutkan dengan fungsi aktivasi *logsig*.



Gambar 6. pembobotan hidden layer 1


Pada Gambar 6 dapat dilihat pembobotan dan penjumlahan pada *hidden layer 1*.

Nilai pembobotan yang didapatkan oleh MATLAB dapat dilihat pada Tabel 2.

Tabel 2. Nilai Bobot dan Bias pada Layer 1

	W					B
	1	2	3	4	5	
1	0.04375	2.20649	-0.08464	-0.02714	-0.0374	-2.74596
2	4.85737	0.01794	0.10916	0.03628	0.0272	0.80508
3	0.01646	0.03791	0.04512	0.00685	-7.2064	5.32141
4	-0.07969	0.04436	15.6592	0.03288	-0.2366	-0.67567
5	0.00834	-0.00474	-0.00055	2.22735	0.0695	3.82336

Fungsi aktifasi yang digunakan adalah log sigmoid yang bias dilihat pada Gambar 7.




Gambar 7. fungsi aktifasi log sigmoid

Fungsi Aktivasi ( $\mu$ ) mendefinisikan nilai output dari sebuah neuron pada level aktivasi tertentu berdasarkan nilai output dari pengombinasi linier. Fungsi ini dipakai untuk menentukan keluaran suatu neuron. Pada hidden sigmoid memiliki rumus sebagai berikut :

$$a = \text{logsig}(n) = 1 / (1 + \exp(-n))$$

Keluaran dari *hidden layer 1* akan masuk ke *hidden layer 2* untuk dikalikan dengan pembobotan kedua pada *hidden layer 2*, Struktur hidden layer 2 dapat dilihat pada Gambar 8.



Gambar 8. hidden layer 2

Karena pada penelitian ini JST dirancang dengan metode *cascade-forward backpropagation* maka pada hidden layer 2 juga dilakukan penjumlahan pembobotan masukan dari *input layer*. Nilai bobot dan bias pada hidden layer 2 dapat dilihat pada Tabel 3.


Tabel 3. Nilai Bobot pada Layer 2 dari layer Input dan layer 1

No.	W		
	I 1	I 2	B2
1	-0.21310	-0.79875	-1.06400
2	0.76419	1.09773	
3	0.29466	0.27832	
4	-0.02179	1.05382	
5	0.25556	0.25286	

Fungsi aktivasi yang digunakan pada *hidden layer 2* adalah fungsi purelin dengan rumus :

$$a = n$$

Pada JST ini memiliki 1 variabel keluaran, karena pada *input layer* digunakan fungsi *mapminmax* untuk melakukan normalisasi data, maka diperlukan proses pengembalian data ke bentuk awal dengan menggunakan fungsi *mapminmax\_reverse* pada MATLAB yang dapat dilihat pada Gambar 9.



Gambar 9. fungsi mapminmax\_reverse

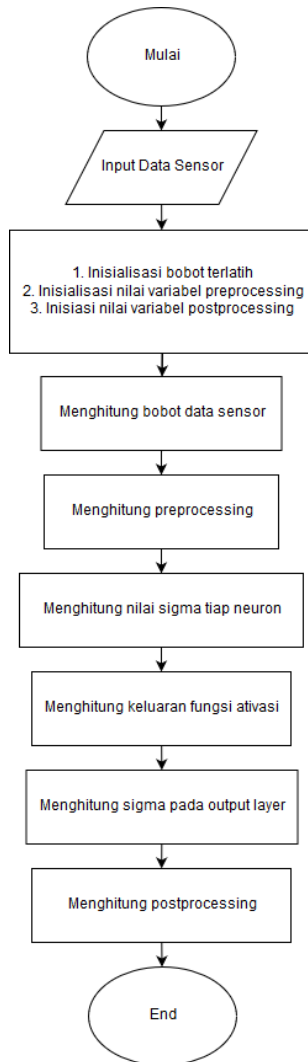
Pada fungsi ini digunakan perhitungan sebagai berikut :

$$y = \frac{(x-ymin)(xmax-xmin)}{(ymax-ymin)} + xmin$$

Dimana  $y$  adalah output *postprocessing*.  $x$  adalah input dari layer 2.  $xmin$  adalah nilai minimal output.  $xmax$  adalah nilai maksimal output.  $ymin$  adalah nilai minimal penskalaan dan  $ymax$  adalah nilai maksimal penskalaan. Berdasarkan data latih yang digunakan,  $xmin$  bernilai 1.1799 dan  $xmax$  bernilai 2.8199 dan  $xmin$  serta  $xmax$  masing-masing bernilai -1 dan 1.

## 2.2. Perancangan Perangkat Lunak

Setelah didapat bobot dan bias pada tiap layer, maka dirancang jaringan saraf tiruan *cascade-forward backpropagation* dengan bahasa C. Algoritma JST *cascade-forward backpropagation* JST dapat dilihat pada Gambar 10.



Gambar 10. Diagram Alir Program JST pada Mikrokontroller

- Inisialisasi bobot tiap neuron yang sudah dilatih
- Inisialisasi variabel pembobotan data sensor, *preprocessing*, dan *postprocessing*
- Menghitung *preprocessing* dengan senarai program berikut:

```

...
Float          i1=(a-Ximin1)*((Yimax-
Yimin)/(Ximax1-Ximin1))+Yimin;
Float          i2=(b-Ximin2)*((Yimax-
Yimin)/(Ximax2-Ximin2))+Yimin;
Float          i3=(c-Ximin3)*((Yimax-
Yimin)/(Ximax3-Ximin3))+Yimin;
  
```

```

Float          i4=(d-Ximin4)*((Yimax-
Yimin)/(Ximax4-Ximin4))+Yimin;
float          i5=(e-Ximin5)*((Yimax-
Yimin)/(Ximax5-Ximin5))+Yimin;
...
  
```

- Menghitung nilai sigma tiap neuron pada *hidden Layer* dengan senarai program berikut:

```

...
Float vxN111 = (i1*vxwh11) + (i2*vxwh12)
+(i3*vxwh13)+(i4*vxwh14) + (i5*vxwh15)+
vxwn1b1;
Float vxN111 = (i1*vxwh21) + (i2*vxwh22)
+(i3*vxwh23)+(i4*vxwh24) + (i5*vxwh25)+
vxwn1b1;
Float vxN111 = (i1*vxwh31) + (i2*vxwh32)
+(i3*vxwh33)+(i4*vxwh34) + (i5*vxwh35)+
vxwn1b1;
Float vxN111 = (i1*vxwh41) + (i2*vxwh42)
+(i3*vxwh43)+(i4*vxwh44) + (i5*vxwh45)+
vxwn1b1;
Float vxN111 = (i1*vxwh51) + (i2*vxwh52)
+(i3*vxwh53)+(i4*vxwh54) + (i5*vxwh55)+
vxwn1b1;
  
```

- Menghitung keluaran fungsi aktivasi tansig dari setiap neuron pada *hidden layer* dengan senarai berikut ini:

```

...
vxN111=(2/(1+exp(-2*vxN111)))-1;
vxN211=(2/(1+exp(-2*vxN211)))-1;
vxN311=(2/(1+exp(-2*vxN311)))-1;
vxN411=(2/(1+exp(-2*vxN411)))-1;
vxN511=(2/(1+exp(-2*vxN511)))-1;
...
  
```

- Menghitung sigma pada *output layer* dengan senarai program berikut:

```

...
float vxN112= (i1*iw1)+ (i2*iw2)+(i3*iw3)
+(i4*iw4)+(i5*iw5) + (vxN111*vxwn21)
+(vxN211*vxwn22)+(vxN311*vxwn2)+
(vxN411*vxwn24)+(vxN511*vxwn25)+
vxwn2b2;
...
  
```

- Menghitung *Postprocessing* dengan rumus *minmax* seperti senarai berikut ini:

```

...
Outputvx = (vxN112-Ymin)*((Xmax-Xmin)/
(Ymax-Ymin)) + Xmin;
...
  
```

### 3. Hasil dan Analisa

#### 3.1. Pengujian Pada Kondisi Aman

Data yang digunakan pada pengujian ini didapatkan secara langsung di lapangan, data diambil mulai tanggal 13 juli 2018 hingga 21 juli 2018 yang berlokasi di pekarangan kampus Teknik Elektro Undip dan diambil 10 sampel untuk menguji keluaran JST. Pengujian dilakukan dengan menganalisa perbedaan nilai keluaran JST *Cascade-forward Backpropagation* dengan keluaran JST *Feed-forward Backpropagation* dan perhitungan manual. Rentangan skor yang menyatakan kondisi aman adalah dari 1-1,69. Data pengujian dapat dilihat pada Tabel 4.

Tabel 4. Data pengujian kondisi aman

No.	Curah Hujan (mm <sup>3</sup> )	Kemiringan (%)	Kelembaban tanah 1 (%)	Kelembaban tanah 2 (%)	Getaran
1	0	1.22	56.07	7.70	0
2	0	1.23	55.17	7.59	0
3	0	1.12	58.38	7.46	0
4	0	0.93	54.57	7.67	0
5	0	0.13	54.13	7.84	0
6	0	0.80	56.12	7.66	0
7	0	0.99	55.82	7.01	0
8	0	0.85	55.06	6.72	0
9	0	0.75	55.24	7.57	0
10	0	0.65	56.42	6.70	0

Tabel 5. Pengujian keluaran JST pada data aman

No.	Manual	Status	CFBP	Status	Error	FFBP	Status	Error
1	1.32	Aman	1.329	Aman	0.009	1.289	Aman	0.030
2	1.32	Aman	1.326	Aman	0.006	1.289	Aman	0.030
3	1.32	Aman	1.336	Aman	0.016	1.288	Aman	0.031
4	1.32	Aman	1.320	Aman	0.000	1.286	Aman	0.033
5	1.32	Aman	1.308	Aman	0.011	1.277	Aman	0.042
6	1.32	Aman	1.324	Aman	0.004	1.284	Aman	0.035
7	1.32	Aman	1.325	Aman	0.005	1.287	Aman	0.033
8	1.32	Aman	1.321	Aman	0.001	1.285	Aman	0.034
9	1.32	Aman	1.313	Aman	0.006	1.281	Aman	0.038
10	1.32	Aman	1.323	Aman	0.003	1.283	Aman	0.036
Rata-rata error					0.00664	0.03475		

Dari Tabel 5 dapat dilihat bahwa bahwa nilai keluaran JST CFBP memiliki rata-rata error 0.00664, lebih kecil dari rata-rata error nilai keluaran JST FFBP yang berjumlah 0.03475.

#### 3.2 Pengujian Pada Kondisi Siaga

Pengujian pada kondisi siaga dilihat dengan menganalisa perbedaan nilai keluaran JST *Cascade-forward Backpropagation* dengan keluaran JST *Feed-forward Backpropagation* dan perhitungan manual. Rentangan skor yang menyatakan kondisi siaga adalah dari 1,7 - 2,39. Pengujian dilakukan dengan 10 kali percobaan dengan mensimulasikan keadaan siaga pada sensor node yang telah dibuat. Data pengujian dapat dilihat pada Tabel 6.

Tabel 6. Data pengujian kondisi siaga

No.	Curah Hujan (mm <sup>3</sup> )	Kemiringan (%)	Kelembaban tanah 1 (%)	Kelembaban tanah 2 (%)	Getaran
1	72.25	16.32	76.32	30.57	5
2	76.50	36.25	56.67	34.48	3
3	30.60	41.70	46.33	13.34	6
4	34.85	51.44	43.37	35.57	2
5	55.25	50.79	83.78	42.37	1
6	56.95	23.06	62.55	31.28	4
7	68.00	40.18	55.39	33.85	7
8	63.75	31.79	41.04	94.69	4
9	64.60	34.32	16.57	60.86	1
10	43.35	16.44	32.11	44.62	3

Tabel 7. Pengujian keluaran JST pada Data Siaga

No.	Manual	Status	CFBP	Status	Error	FFBP	Status	Error
1	2.15	Siaga	2.1974	Siaga	0.0474	2.254	Siaga	0.1042
2	2.03	Siaga	2.0366	Siaga	0.0066	2.028	Siaga	0.0019
3	2.27	Siaga	2.1174	Siaga	0.1449	2.154	Siaga	0.1153
4	2.18	Siaga	2.1151	Siaga	0.0649	2.204	Siaga	0.0248
5	2.29	Siaga	2.2952	Siaga	0.0052	2.286	Siaga	0.0031
6	2.11	Siaga	1.9960	Siaga	0.1140	2.016	Siaga	0.0937
7	2.11	Siaga	2.3532	Siaga	0.3617	2.374	Siaga	0.2647
8	2.22	Siaga	2.1885	Siaga	0.0315	2.270	Siaga	0.0506
9	2.07	Siaga	2.1006	Siaga	0.0949	2.139	Siaga	0.0694
10	1.88	Siaga	1.7935	Siaga	0.0865	1.818	Siaga	0.0615
Rata-rata error					0.07825	0.07892		

Dari Tabel 7. dapat dilihat bahwa bahwa nilai keluaran JST CFBP memiliki rata-rata eror 0.07825, lebih kecil dari rata-rata error nilai keluaran JST FFBP yang berjumlah 0.07892.

#### 3.2 . Pengujian Pada Kondisi Bahaya

Pengujian pada kondisi siaga dilihat dengan menganalisa perbedaan nilai keluaran JST *Cascade-forward Backpropagation* dengan keluaran JST *Feed-forward Backpropagation* dan perhitungan manual. Rentangan skor yang menyatakan kondisi siaga adalah dari 2,4 - 3. Pengujian dilakukan dengan 10 kali percobaan dengan memvariasikan nilai pada tiap sensor. Data pengujian dapat dilihat pada Tabel 8.

Tabel 8. Data pengujian kondisi bahaya

No.	Curah Hujan (mm <sup>3</sup> )	Kemiringan (%)	Kelembaban tanah 1 (%)	Kelembaban tanah 2 (%)	Getaran
1	139.4	81.32	56.42	51.43	5
2	56.95	45.65	75.63	56.33	5
3	99.45	67.07	32.13	32.12	6
4	83.30	72.42	45.96	36.11	4
5	80.75	85.83	56.68	38.11	5
6	111.35	64.13	66.74	68.98	6
7	110.5	81.24	59.73	50.65	5
8	107.95	73.08	33.62	31.67	5
9	76.50	76.52	49.24	48.46	5
10	103.7	68.00	58.42	72.11	6

Tabel 9. Pengujian keluaran JST pada data bahaya

No.	Manual	Status	CFBP	Status	Error	FFBP	Status	Error
1	2.67	Bahaya	2.702	Bahaya	0.0326	2.729	Bahaya	0.083
2	2.52	Bahaya	2.482	Bahaya	0.0378	2.483	Bahaya	0.082
3	2.68	Bahaya	2.561	Bahaya	0.1186	2.518	Bahaya	0.084
4	2.67	Bahaya	2.704	Bahaya	0.0344	2.752	Bahaya	0.086
5	2.67	Bahaya	2.615	Bahaya	0.0547	2.629	Bahaya	0.095
6	2.90	Bahaya	2.829	Bahaya	0.0709	2.779	Bahaya	0.087
7	2.67	Bahaya	2.719	Bahaya	0.0496	2.737	Bahaya	0.085
8	2.45	Bahaya	2.491	Bahaya	0.0417	2.489	Bahaya	0.086
9	2.67	Bahaya	2.633	Bahaya	0.037	2.667	Bahaya	0.088
10	2.90	Bahaya	2.814	Bahaya	0.0851	2.786	Bahaya	0.089
Rata-rata error					0.05624	0.08702		

Dari Tabel 9 dapat dilihat bahwa bahwa nilai keluaran JST CFBP memiliki rata-rata eror 0.05642, lebih kecil dari rata-rata error nilai keluaran JST FFBP yang berjumlah 0.08702.

#### 4. Kesimpulan

Telah dirancang jaringan saraf tiruan dengan metode cascade-forward backpropagation sebagai sistem pendeteksi dini terjadinya tanah longsor. Pada pengujian jaringan saraf tiruan ini dilakukan pada kondisi aman, siaga, dan bahaya memiliki error secara berturut turut sebesar 0.00664, 0.07825, dan 0.05624 dibanding dengan 0.03475, 0.07892, dan 0.08702 pada keluaran jaringan saraf tiruan metode feed-forward backpropagation.

#### Referensi

[1]. Badan Nasional Penanggulangan Bencana, "Indonesia's Disaster Data Information," 2018. [Online]. Available: <http://dibi.bnpb.go.id/dibi/>.

[2]. K. Nakamura, W. A. Noerdjito, and A. Hasyim, "Regional Difference and Seasonity of Rainfall in Java," pp. 93–103, 1994.

[3]. H. L.J and L. X.S, "Study on landslide related to rainfall," *J. Xiangtan Norm. Univ*, vol. 4, no. 22, pp. 55–62, 2002.

[4]. S. Gu, X. Sun, Y. Wu, and Z. Cui, "An Approach to Forecast Red Tide Using Generalized Regression Neural Network," *2012 8th Int. Conf. Nat. Comput. (ICNC 2012)*, no. Icnc, pp. 194–198, 2012.

[5]. A. R. Senthil Kumar, K. P. Sudheer, S. K. Jain, and P. K. Agarwal, "Rainfall-runoff modelling using artificial neural networks: Comparison of network types," *Hydrol. Process.*, vol. 19, no. 6, pp. 1277–1291, 2005.

[6]. C. H. K and A. M., "Generalized regression neural network in modelling river sediment yield," *Adv. Eng. Softw.*, vol. 37, no. 2, pp. 63–68, 2006.

[7]. B. Pradhan and S. Lee, "Regional landslide susceptibility analysis using back-propagation neural network model at Cameron Highland, Malaysia," *Landslides*, vol. 7, no. 1, pp. 13–30, 2010.

[8]. D. Niu, H. Wang, and Z. Gu, "Short-Term Load Forecasting Using General Regression Neural Network," no. August, pp. 18–21, 2005.

[9]. M. V. Ramesh, "Real-time wireless sensor network for landslide detection," *Proc. - 2009 3rd Int. Conf. Sens. Technol. Appl. SENSORCOMM 2009*, pp. 405–409, 2009.

[10]. T. Faisal, F. Gadjah, I. Dwikorita, and K. Gadjah, "Development of Landslide Monitoring and Early Warning System in Indonesia," *2nd Int. Work. Multimodal Sediment Disaster - Asian Cloud Netw. Disaster Res.*, no. Icl, pp. 481–484, 2008.

[11]. *Peraturan Menteri Pekerjaan Umum No.22/PRT/M/2007*. Jakarta, 2007.

[12]. M. Ridho, A. Sofwan, and Sumardi, "Perancangan Prototipe Sensor Node pada Wireless Sensor Network Menggunakan Jaringan Saraf Tiruan sebagai Pengambilan Keputusan pada Sistem Pendeteksi Dini Tanah Longsor," Diponegoro University, 2018.