

## Implementasi Extreme Learning Machine Untuk Deteksi Dini Infeksi Menular Seks (IMS) Pada Puskesmas Dinoyo Kota Malang

Fikhi Nugroho<sup>1</sup>, Imam Cholissodin<sup>2</sup>, Suprpto<sup>3</sup>

Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Brawijaya  
Email: <sup>1</sup>fikhi.nugroho@gmail.com, <sup>2</sup>imamcs@ub.ac.id, <sup>3</sup>spttif@ub.ac.id

### Abstrak

Infeksi Menular Seksual (IMS) merupakan masalah kesehatan masyarakat yang cukup besar di dunia. Insiden kasus IMS pada banyak negara berkembang seperti kegagalan dalam mendiagnosis dan memberikan pengobatan pada stadium dini dapat menimbulkan komplikasi serius. Penggunaan sistem cerdas dapat mempermudah mendeteksi dini IMS secara komputasi. Parameter inputan yang diperlukan berupa 39 fitur yang terdiri dari 2 jenis kelamin, 9 faktor resiko, dan 29 gejala. Proses analisa identifikasi gejala dini IMS menggunakan Extreme Learning Machine (ELM). Implementasi ELM tidak memerlukan rule IMS yang terkait dengan aturan melainkan membandingkan hasil penentuan keduanya. Jadi jika terjadi perubahan perhitungan maupun ketentuan identifikasi tidak mempengaruhi perhitungan ELM. Metode ELM digunakan untuk menentukan penyakit IMS menjadi sejumlah 17 kelas. Hasil terbaik dari tiga skenario pengujian tingkat akurasi antara hasil perhitungan ELM dengan hasil diagnosis pakar sebesar 36,36% untuk rasio 90:10, 50% untuk 100 hidden layer, dan 31.82% untuk weight range -1 sampai 0.

**Kata kunci:** Prediksi, Infeksi Menular Seks, artificial neural networks, extreme learning machine

### Abstract

*Sexually Transmitted Infections (STI) is a major public health problem in the world. Incidence of STI cases in many developing countries such as failure in diagnosing and provide treatment at an early stage can lead to serious complications. The required input parameters consist of 39 features consisting of 2 sexes, 9 risk factors, and 29 symptoms. The process of identifying early identification of STI symptoms in this case will implement Extreme Learning Machine (ELM). The implementation of ELM itself does not require IMS rules related to the exact rules but rather compares the results of both determinations. Thus, if there is a change of calculation or identification provisions, it does not affect the calculation of ELM. The ELM method is used to determine STI disease to a number of 17 classes. The best results of the three test scenarios of accuracy between ELM calculations and expert diagnosis results were 36,36% for the 90:10 ratio, 50% for 100 hidden layers, and 31.82% for the weight range of -1 to 0.*

**Keywords:** Prediction, Sexually Transmitted Infections, artificial neural networks, extreme learning machine

### 1. PENDAHULUAN

Infeksi menular seks (IMS) merupakan penyakit atau infeksi yang biasanya ditularkan melalui hubungan seks yang tidak aman (vagina, anus, dan mulut) penularan bisa berupa cairan tubuh dalam. Adapun penularan lainnya ibu yang menyusui bayinya dan penggunaan jarum suntik berulang pada seseorang yang beresiko. IMS tidak selalu menunjukkan gejala, seringkali seseorang terlihat biasa namun sebenarnya telah terinfeksi.

Penanganan pada Poli Penyakit Kulit dan Kelamin Puskesmas Dinoyo sudah baik namun tentunya masih ada kendala. Petugas medis kesulitan untuk melengkapi data pasien karena pasien penderita sendiri tidak tahu pasti akan gejala-gejala yang dialaminya. Ketika tanya jawab pemeriksaan dengan pasien penderita beberapa tidak berkata jujur pada riwayat penyakit IMS sebelumnya ataupun faktor resiko tertular. Dari permasalahan tersebut, penulis membuat suatu sistem cerdas yang mampu untuk menjawab permasalahan sebagai salah satu

sarana pelayanan identifikasi dini IMS.

Berdasarkan penelitian sebelumnya, menggunakan kombinasi metode Rough Set (RS) dan Extreme Learning Machine (ELM). RS digunakan sebagai ekstraksi fitur dan menghapus fitur yang berlebihan. Kemudian dari fitur yang tersisa proses klasifikasi menggunakan metode ELM. Akurasi klasifikasi terbaik dari penelitian ini menggunakan 80% - 20% sebesar 100%. Ini merupakan perolehan yang sangat baik untuk sistem klasifikasi dengan kombinasi dua metode (Kaya dan Uyar, 2013). Selain itu Huang, et al (2006) dalam penelitiannya menyatakan metode ELM memiliki learning speed sangat cepat dan memiliki kinerja lebih bagus dari beberapa pembelajaran berbasis gradient.

Fardani (2015) menggunakan ELM untuk meramalkan jumlah kunjungan pasien rumah sakit. Penelitian menghasilkan akurasi baik dan tingkat error yang kecil yaitu menghasilkan MSE sebesar 0.027. Penelitian Lainnya yaitu prediksi klasifikasi menggunakan Extreme Learning Machine (ELM). ELM digunakan untuk mendiagnosis penyakit diabetes melitus, memakai 3 kelas klasifikasi. Dari segi kecepatan dan akurasi kinerja ELM lebih baik dibandingkan backpropagation. Tingkat akurasi dianalisis menggunakan Mean Square Error (MSE) untuk data testing menghasilkan adalah 0.4036 dan tingkat kesalahan MSE untuk backpropagation pada data testing adalah 0.9425. (Pangaribuan, 2016).

Berdasarkan permasalahan yang dijabarkan di atas dan juga penelitian sebelumnya, maka dalam penelitian ini penulis mengambil judul "Implementasi Extreme Learning Machine untuk Deteksi Dini Infeksi Menular Seks (IMS)". Diharapkan dengan adanya aplikasi ini dapat memudahkan pasien atau masyarakat untuk mendiagnosis awal secara mandiri dengan pengawasan dan tindakan lanjut oleh pihak medis.

**2. INFEKSI MENULAR SEKS**

IMS atau Sexually Transmitted Infection dapat ditularkan dengan kontak hubungan seksual dari seseorang ke orang lainnya. Gaya hidup berganti-ganti pasangan lebih beresiko menularkan IMS. Dalam beberapa penelitian IMS yang sering terjadi adalah Sifilis, Gonorrhoe, Harpes. Bagi penderita infeksi menular seksual yang terkena infeksi saluran reproduksi harus mendapatkan penanganan

sebelum terjadi gejala komplikasi dan dapat membahayakan nyawanya. Bila tidak mendapatkan penanganan dan diobati secara tepat, dapat menjalar dan menyebabkan penderita sakit berkepanjangan, kemandulan sampai kematian (Kesehatan, 2011).


Gejala-gejala IMS yang dapat terjadi ialah:

1. Keluar duh atau nanah dari vagina, penis, atau lubang anus.
2. Rasa panas serta nyeri ketika kencing.
3. Terdapat bintil, benjolan atau luka pada penis, vagina, anus atau mulut.
4. Terjadi Pembengkakan pada pangkal paha.
5. Pendarahan ketika selesai berhubungan seks.
6. Pada perut bawah wanita nyeri.
7. Untuk pria buah pelir terasa nyeri

**3. JARINGAN SARAF TIRUAN**

Jaringan Saraf Tiruan (JST) atau disebut juga Artificial Neural Network memiliki perbedaan pendekatan dari pada metode AI umumnya. Dari struktur otak manusia metode ini didapatkan yaitu melihat cara kerja syaraf otak manusia sehingga dapat diimplementasikan menggunakan pemrograman komputer yang mampu menyelesaikan beberapa proses perhitungan sekaligus ketika proses pembelajaran berjalan.

Umumnya arsitektur JST ini dibagi beberapa layer, yaitu input layer(masukan), hidden layer(tersembunyi), dan output layer(hasil keluaran). Masing-masing lapisan memiliki jumlah node-node atau neuron yang berbeda. Arsitektur JST di gambarkan sesuai dengan gambar berikut:



Gambar 1. Arsitektur JST

#### 4. EXTREME LEARNING MACHINE

Merupakan salah satu Jaringan syaraf tiruan(JST) feedforward dengan satu hidden layer atau lebih dikenal dengan istilah single hidden layer feedforward neural network(SLFN). Kekurangan dari jaringan syaraf feed-forward (feed-forward neural network - FFNN) lebih banyak waktu yang dibutuhkan. Dari Huang et al (2004) alasan dari kekurangan tersebut ialah, masih menggunakan gradien yang lambat untuk algoritma pembelajaran dari pelatihan jaringan syaraf dan kedua terdapat perulangan dari parameter-parameter neuron karena kelemahan algoritma ini. Untuk mengatasi permasalahan tersebut, Huang et al. mengajukan sebuah algoritma pembelajaran baru yang diberi nama extreme learning machine (ELM). Terdapat perbedaan single hidden layer feed-forward (SLFN) dengan jaringan saraf lain yang dapat memilih random bobot input dan bias kemudian menentukan bobot output SLNF. Huang et al. menyatakan “Teoritis, algoritma ini mengedepankan kecepatan pembelajaran yang cepat sangat dan juga generalisasi terbaik”.

Terdapat banyak fungsi aktivasi, menurut Srimuang & Intarasonchun (2015), ada beberapa jenis fungsi aktivasi sebagai berikut:

1. Fungsi Sigmoid Biner

$$H = \frac{1}{1 + \exp(-H_{init})} \tag{1}$$

Dalam perhitungan ini memakai fungsi sigmoid biner karena memiliki rentang nilai 0 sampai 1, sehingga baik digunakan untuk jaringan dengan nilai output pada interval 0 sampai 1 dan juga nilai output 0 atau 1. Fungsi sigmoid biner sangat baik dipakai untuk penyelesaian masalah kompleks dan bersifat non linier.

Langkah-langkah training metode Extreme Learning Machine (ELM) adalah sebagai berikut:

Dalam tahapan ELM proses awal dilakukan ialah training adalah sebagai berikut:

1. Mencari random nilai bobot W(weight) dan bias dengan range tertentu.
2. Menghitung matriks output dari hidden layer memakai fungsi aktivasi sigmoid biner.

$$H = \frac{1}{1 + \exp(-X_{training} \cdot W^T + ones(N_{train},1) * bias)} \tag{2}$$

X adalah matriks data training sedangkan  $W^T$  adalah matrik weight transpose.

3. Mencari nilai matriks Moore-Penrose Generalized Inverse

$$H^+ = (H^T \cdot H)^{-1} \cdot H^T \tag{3}$$

$H^+$  adalah MoorePenrose Generalized invers matrik yang diperoleh dari matriks  $H$ . Sedangkan matriks  $H$  merupakan matriks yang tersusun dari keluaran masing-masing hidden layer.

4. menghitung nilai matriks bobot keluaran training dari inputan hidden layer menggunakan Persamaan.

$$\hat{\beta} = H^+ Y \tag{4}$$

Dimana  $\hat{\beta}$  ialah hasil matriks output bobot,  $H^+$  ialah matriks Moore-Penrose serta  $Y$  merupakan target matrik

Tahapan yang dilakukan pada proses ini adalah lanjutan dari training dan tetap memakai algoritma ELM, prosenya sebagai berikut:

1. Mengambil bobot W dan bias serta  $\hat{\beta}$  yang terdapat dari proses training.
2. Menghitung matriks output hidden layer memakai.

$$H = \frac{1}{1 + \exp(-X_{testing} \cdot W^T + ones(N_{test},1) * bias)} \tag{5}$$

X merupakan data testing matriks sedangkan  $W^T$  adalah transpose matriks bobot yang terdapat pada training.

3. Melakukan perhitungan semua output dengan memakai Persamaan.

$$\hat{Y} = H \cdot \hat{\beta} \tag{6}$$

$\hat{Y}$  adalah target matrik prediksi, H adalah matriks keluaran hidden layer dan  $\hat{\beta}$  merupakan matriks bobot output dari proses training.

Kemudian melakukan kalsifikasi kelas penyakit dengan menghitung jarak  $\hat{Y}$  dengan setiap kelas kemudian mencari nilai minimum yang mendapat nilai minimum jarak berbarti masuk dalam kelas tersebut dan menghasilkan kelas prediksi penyakit.

#### 6. AKURASI

Penelitian ini menghasilkan klasifikasi prediksi penyakit, merupakan suatu penting dan

utama untuk pendukung keputusan yaitu nilai kebenaran. Salah satu cara mengukur tingkat ketepatan antara data aktual dari pakar dengan data prediksi menggunakan akurasi. Untuk mengetahui akurasi tingkat ketepatan dapat menggunakan nilai presentase. Perhitungannya yaitu membagi jumlah data benar dengan jumlah total data kemudian mengalikan dengan 100%.. Persamaan akurasi dapat dilihat dalam persamaan 7.

$$NilaiAkurasi = \frac{y - x}{y} \times 100\% \tag{7}$$

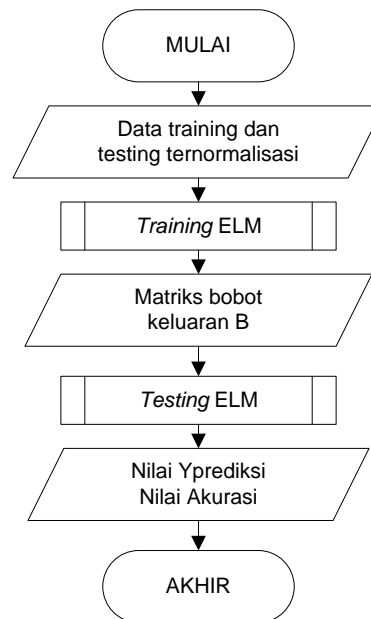
Dimana y adalah jumlah total data dan x merupakan jumlah prediksi testing yang salah.

### 7. IMPLEMENTASI

Permasalahan dari penelitian ini ialah memprediksi klasifikasi infeksi menular seks (IMS) melalui dataset yang diperoleh dari pakar untuk metode pembelajaran Extreme Learning Machine (ELM). Kedua inputan langsung dari pengguna yang akan diproses dengan menggunakan Extreme Learning Machine (ELM). Data yang dipakai adalah 109 data pasien IMS seperti pada Tabel 1 (dataset lengkapnya ada pada lampiran).

Tabel 1 Dataset IMS

N	J	F	F	F	F	G	G	G	G	G	P
O	K	1	2	...	8	9	1	2	3	...	9
1	0	0	0	...	0	0	1	1	0	...	0
2	1	1	0	...	0	0	0	0	0	...	0
3	0	0	0	...	0	0	1	1	0	...	0
4	1	0	0	...	0	0	1	1	0	...	0
5	0	0	1	...	0	0	0	1	0	...	0
6	1	1	0	...	0	0	0	1	0	...	0
7	1	1	0	...	0	0	0	0	0	...	0
...	...	...	...	...	...	...	...	...	...	...	...
1	0	0	0	...	0	0	0	0	0	...	0
9	1	1	0	...	0	0	0	1	0	...	0



Gambar 2 Diagram Alir Algoritma ELM

Menurut tabel diatas terdapat 39 fitur atau input layer dari JK, FR dan G, P adalah kelas target yang kemudian digunakan untuk perhitungan training dan pengujian akurasi. Parameter-parameter yang digunakan variabel pada agoritma ELM yaitu: jumlah hidden layer, range nilai random matriks bobot W, nilai random matriks bias, jumlah input layer, jumlah output layer, jumlah target, rasio jumlah data training dan testing.

Sistem menerima masukan berupa dataset excel yang sudah ternormalisasi yang nantinya akan dibagi sebagai data latih dan data uji untuk proses ELM. Kemudian melakukan proses training dari data masukan dan menghasilkan bobot keluaran  $\hat{\beta}$  untuk selanjutnya dipakai pada proses testing. Proses testing akan menghasilkan matriks prediksi  $\hat{Y}$  dan klasifikasi serta nilai evaluasi akurasi. Dengan dihasilkannya keluaran tersebut menunjukkan bahwa berakhirnya proses ELM.

### 8. PENGUJIAN DAN ANALISIS

#### 8.1 Pengujian Rasio Data

Pengujian perbandingan data latih dan data uji dilakukan untuk mengetahui pengaruh dari rasio jumlah data latih dan jumlah data uji terhadap kemampuan algoritme Extreme Learning Machine dalam mengenali pola data serta nilai Akurasi yang dihasilkan. Pengujian ini terdiri 9 jenis perbandingan data latih dan uji yaitu 90%:10%, 80%:20%, 70%:30%, 60%:40%, 50%:50%, 40%:60%, 30%:70%, 20%:80%, 10%:90%. Parameter yang

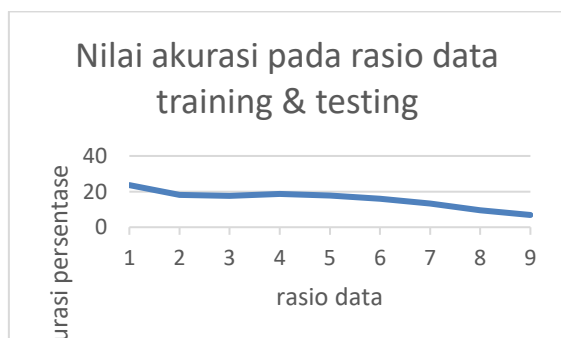
dimasukkan untuk adalah 10 hidden neuron dan -1 sampai 1 range nilai weight random.

Berdasarkan Tabel 2 diketahui bahwa rata-rata tingkat akurasi tertinggi sebesar 23.634% dan akurasi terbaik sebesar 36.36% pada rasio perbandingan 90%:100%. Sehingga tingkat akurasi terbaik dengan rasio perbandingan 90%:10% akan digunakan untuk pengujian selanjutnya. Hasil akurasi pengujian rasio perbandingan data dijelaskan pada Gambar 3.

Analisis dilakukan pada pengujian rasio data yaitu tingkat akurasi terhadap pengaruh rasio perbandingan data. Dari Gambar 6.1 nilai akurasi paling optimal ditunjukkan pada rasio data yang memiliki nilai rata-rata 23.634% pada rasio data 90%:10%. Dibandingkan rasio data lainnya hasil akurasi turun dikarenakan jumlah data latih yang berkurang sehingga pengenalan pola untuk jenis data ini pun semakin sulit karena pengaruh dari noise tiap datanya. Data latih dan data uji yang digunakan dipilih dari setiap kelas secara acak, sehingga minimal ada satu data yang mewakili data latih dan data uji dari setiap kelas. Hal ini menunjukkan bahwa sebaran data latih dan data uji terbaik terdapat pada rasio 90%:10% dan semakin banyak data latih maka tingkat akurasi semakin tinggi.

Tabel 2 Pengujian Rasio Data Latih dan Uji

Percobaan ke- <i>i</i>	Nilai Akurasi Pada Perbandingan Data Latih dan Data Uji								
	90:10	80:20	70:30	60:40	50:50	40:60	30:70	20:80	10:90
1	18	22	18	20	16	22	6.4	7	2
2	36	18	15	15	20	15	14	11	8
3	27	18	18	15	21	16	15	9	9
4	18	13	18	25	12	12	19	6	5
5	18	18	18	15	18	13	10	12	10
Rata-rata Akurasi	23.63	18	17	18	17	16	13	9	6



Gambar 3. Grafik akurasi rasio data


### 8.2 Pengujian Hidden Neuron

Pengujian jumlah hidden neuron dilakukan untuk mengetahui pengaruh jumlah hidden neuron terhadap nilai evaluasi nilai akurasi dalam implementasi algoritma ELM. Jumlah hidden neuron yang akan digunakan pada pengujian ini antara lain 1, 2, 3, 5, 10, 20, 30, 50, 100. Perbandingan data latih dan data uji menggunakan rasio 80%:20% dengan range bobot masukan -1 sampai 1. Rancangan pengujian untuk pengujian jumlah hidden neuron akan ditunjukkan pada Tabel 3.

Berdasarkan Tabel 3 diketahui bahwa rata-rata tingkat akurasi tertinggi sebesar 33.636% dan akurasi terbaik sebesar 50% pada 100 hidden layer. Sehingga tingkat akurasi terbaik dengan 100 hidden layer akan lebih baik. Hasil akurasi pengujian jumlah hidden neuron dijelaskan pada Gambar 4.

Tabel 3 Pengujian Jumlah Hidden Neuron

Percobaan ke- <i>i</i>	Nilai Akurasi Pada Jumlah Hidden Neuron								
	1	2	3	5	10	20	30	50	100
1	18	9	18	18	27	22	16	22	22
2	13	27	9	13	13	16	31	18	18
3	6	2	9	6	6	6	8	1	1
4	4	7	09	4	4	7	2	8	8
5	22	22	18	22	27	31	31	27	27
6	7	7	1	7	2	8	2	7	7
7	3	3	8	3	7	2	2	7	7
8	4	9	9	13	13	22	13	13	13
9	0	55	09	09	6	6	7	6	50
10	1	13	18	22	18	31	27	18	18
11	8	6	1	7	1	8	2	1	50
12	1	4	8	3	8	2	7	8	8
Rata-rata Akurasi	14	17	17	17	22	24	22	33	33



Gambar 4. Grafik akurasi hidden neuron

Analisis dilakukan pada pengujian jumlah



hidden neuron yaitu tingkat akurasi terhadap pengaruh jumlah hidden neuron. Pada Gambar 6.2, nilai akurasi paling optimal ditunjukkan pada 100 hidden layer dengan akurasi 33.636%. Hal ini menunjukkan bahwa 100 hidden layer lebih cocok digunakan untuk jenis data seperti pada penelitian ini. Hal ini karena jumlah data dan input layer yang banyak sehingga jika jumlah hidden neuron kurang cukup maka dalam proses ELM akan terjadi underrate yaitu kurangnya learning.

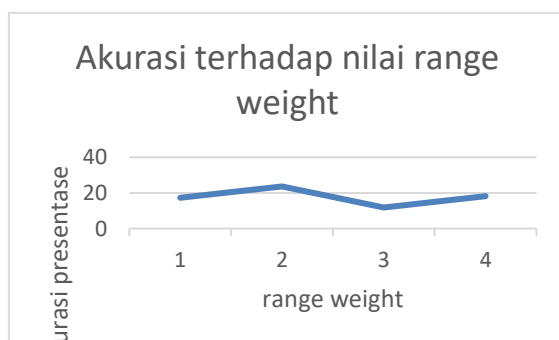
### 8.3 Pengujian dan Analisis Range Weight

Pengujian range nilai weight random dilakukan untuk mengetahui pengaruh rentang weight random terhadap nilai evaluasi akurasi dalam implementasi algoritme ELM. Range nilai yang akan digunakan pada pengujian ini antara lain -1 sampai 1, -1 sampai 0, 0 sampai 1, -0,5 sampai 0,5 dengan nilai bias 0 sampai 1. Pengujian ini memakai 10 hidden layer dan jumlah ratio data 80%:20%.

Berdasarkan Tabel 4 diketahui bahwa rata-rata tingkat akurasi tertinggi sebesar 23.636% dan akurasi terbaik sebesar 31.82% pada nilai range -1 sd 0. Hasil akurasi pengujian range nilai weight random dijelaskan pada Gambar 6.3.

Tabel 4. Pengujian Nilai Weight Random

Percoba-an ke- <i>i</i>	Nilai Akurasi Pada Perbandingan Nilai Weight Random			
	0 sampai 1	-1 sampai 0	-1 sampai 1	-0,5 sampai 0,5
1	22.73	27.27	13.64	18.18
2	18.18	18.18	18.18	22.73
3	13.64	22.73	4.55	13.64
4	18.18	18.18	9.09	18.18
5	13.64	31.82	13.64	18.18
Rata-rata Akurasi	17.274	23.636	11.82	18.182



Gambar 5. Grafik akurasi nilai weight

Analisis dilakukan pada pengujian range nilai weight yaitu tingkat akurasi terhadap pengaruh range nilai weight. Pada skenario ini menunjukkan nilai akurasi paling optimal ditunjukkan pada range nilai weight -1 sd 0 yang memiliki nilai rata-rata 23.636%. Dari Gambar 5 menunjukkan bahwa semakin kecil range nilai weight membuat akurasi menjadi lebih baik, karena setelah nilai range lebar justru mendapatkan akurasi yang jelek. Jadi pengujian ini dapat diperoleh hasil bahwa nilai weight random baik ketika memiliki rentang pendek.

### 9. KESIMPULAN DAN SARAN

Berdasarkan perancangan, implementasi, dan hasil analisis pengujian implementasi algoritma *Extreme Learning Machine* untuk deteksi dini Infeksi Menular Seks (IMS), didapatkan kesimpulan sebagai berikut:

1. Algoritma *Extreme Learning Machine* dapat diimplementasikan pada permasalahan untuk deteksi dini Infeksi Menular Seks (IMS). Proses ELM dibagi menjadi 2 yaitu *training* untuk pembelajaran dan *testing* untuk pengukuran akurasi. Selanjutnya klasifikasi IMS dilakukan dengan cara memasukkan data pasien seperti jenis kelamin, faktor risiko serta gejala penyakit dan mengklasifikasikan berdasarkan parameter *training* terbaik yaitu nilai bobot keluaran, matrik *random weight* dan matrik *random bias*.
2. Nilai Evaluasi prediksi berdasarkan hasil pengujian yang diukur menggunakan *nilai Akurasi* pada implementasi algoritma ELM untuk deteksi dini IMS adalah sebagai berikut:
  - a. Berdasarkan pengujian dan analisis perbandingan jumlah data latih dan data uji berpengaruh terhadap hasil perhitungan ELM. Rata-rata akurasi terbaik sebesar 36.36% pada rasio perbandingan 90%:10%. Hal ini membuktikan bahwa semakin banyak data *training* akan semakin baik nilai akurasinya.
  - b. Pengujian dan analisis perbandingan nilai hidden neuron berpengaruh terhadap hasil perhitungan ELM. nilai akurasi paling optimal ditunjukkan pada 100 *hidden layer* dengan akurasi

terbaik 50%. Hal ini menunjukkan bahwa 100 *hidden layer* lebih cocok digunakan untuk jenis data seperti pada penelitian ini.

- c. Pengujian dan analisis perbandingan jumlah range nilai *weight random* berpengaruh terhadap hasil perhitungan ELM. Akurasi terbaik sebesar 31.82% pada nilai range -1 sampai 0. Hasil pengujian ini bersifat fluktuatif tetapi ketika nilai *range weight* dipersempit pada parameter tertentu dapat meningkatkan akurasi.

Saran Penelitian mengenai implementasi algoritma *Extreme Learning Machine* untuk prediksi dapat dikembangkan dengan beberapa saran sebagai berikut:

1. Menambahkan lebih banyak data pasien dari setiap penyakit dan penambahan parameter lain seperti hasil lab dalam deteksi dini IMS agar perhitungan dalam proses klasifikasi lebih baik.
2. Penggunaan algoritma (*PSO Particle Swarm Optimization*) untuk optimasi parameter ELM atau (*RS Rough Set*) untuk seleksi fitur sehingga menghasilkan prediksi IMS menjadi lebih akurat.

Huang, G.-B., Zhu, Q.-Y. & Siew, C.-K., 2006. *Extreme Learning Machine : Theory and Applications*. Neurocomputing, Volume 70, pp. 489-501.

Kesehatan, K., 2011. Pedoman nasional penanganan infeksi menular seksual 2011. 2011 penyunt. Jakarta: Direktorat Jenderal Pengendalian Penyakit Menular.

Pangaribuan, 2016. "Mendiagnosis Penyakit Diabetes Melitus dengan Menggunakan Metode Extreme Learning Machine". Jurnal ISD Vol.2 No.2 Juli - Desember 2016 ISSN : 2528-5114

Prasetyo, E., 2012. *Data Mining: Konsep dan Aplikasi menggunakan Matlab*. 1st ed. Yogyakarta: Andi Offset.

Srimuang, W. & Intarasothonchun, S., 2015. *Classification Model of Network Intrusion using Weighted Extreme Learning Machine*. International Joint Conference on Computer Science and Software Engineering (JCSSE), Volume 12

Sulistyaningsih, Y., Djunaidy, A. & Kusumawardani, R. P., 2012. Pengklasifikasian Pengaduan Masyarakat pada Laman Kantor Pertanahan Kota Surabaya I dengan Metode Pohon Keputusan.

## DAFTAR PUSTAKA

- Kaya, Y. dan Uyar, M., 2013. "A Hybrid Decision Support System Based on Rough Set and Extreme Learning Machine for Diagnosis of Hepatitis Disease". *Applied Soft Computing* 13 (2013) 3429–3438.
- Fardani, 2015. "Sistem Pendukung Keputusan Peramalan Jumlah Kunjungan Pasien Menggunakan Metode Extreme Learning Machine (Studi Kasus : Poli Gigi Rsu Dr. Wahidin Sudiro Husodo Mojokerto)". *Journal of Information Systems Engineering and Business Intelligence* Vol. 1, No. 1, April 2015
- Huang G-B, Zhu Q-Y, Siew C-K., 2004. "Extreme Learning Machine: A New Learning Scheme of Feedforward Neural Networks". *Proceedings of the International Joint Conference on Neural Networks*: 985-990