

Klasifikasi Risiko Gagal Ginjal Kronis Menggunakan *Extreme Learning Machine*

Dimas Prenky Dicky Irawan¹, Imam Cholissodin², Edy Santoso³

Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Brawijaya
Email: ¹prenkydimas@gmail.com, ²imamcs@ub.ac.id, ³edy144@ub.ac.id

Abstrak

Ginjal merupakan sebuah organ pada manusia yang mempunyai peranan sangat penting dalam proses mengatur kebutuhan cairan dan elektrolit. Gagal ginjal kronis merupakan sebuah penyakit terhadap ginjal yang terjadi karena infeksi ginjal serta adanya sumbatan yang dikarenakan batu ginjal. Untuk melakukan klasifikasi gagal ginjal kronis tenaga medis masih belum maksimal dalam menanganinya, untuk menangani masalah ini peneliti menggunakan *Extreme Learning Machine* untuk melakukan klasifikasi gagal ginjal kronis. *Extreme Learning Machine* merupakan sebuah algoritme klasifikasi yang mana algoritme ini merupakan bagian dari jaringan saraf tiruan yang memiliki *learning speed* bagus dan juga menurut penelitian yang sudah ada dihasilkan nilai akurasi yang begitu baik apabila dibandingkan menggunakan algoritme lainnya. Penelitian yang dilakukan ini mendapatkan perbandingan nilai data latih serta data uji optimal dengan nilai rasio 70:30, banyak *neuron hidden layer* sebesar 10 dan menggunakan fungsi aktivasi sigmoid bipolar dari parameter tersebut menghasilkan nilai akurasi sebesar 99,13%. Dari hasil akurasi yang didapatkan, menunjukkan bahwa metode *Extreme Learning Machine* cukup baik dipakai untuk proses klasifikasi gagal ginjal kronis.

Kata kunci: ginjal, gagal ginjal kronis, extreme learning machine, jaringan saraf tiruan.

Abstract

Kidney is an organ in humans that have a very important role in the process of managing fluid and electrolyte needs. Chronic renal failure is a disease of kidney that occurs due to kidney infection and the existence of blockage due to kidney stones. To perform the classification of chronic renal failure medical personnel are still not maximally in handling it, to deal with this problem researchers use the Extreme Learning Machine to perform the classification of chronic renal failure. The Extreme Learning Machine is a classification algorithm in which this algorithm is part of a neural network that has a good learning speed and also according to existing research results in a good accuracy value when compared to using other algorithms. This study obtained a comparison of the value of training data as well as the optimal test data with a 70:30 ratio value, many hidden layer neurons of 10 and using the bipolar sigmoid activation function of these parameters resulted in an accuracy of 99.13%. From the results of accuracy obtained, indicating that the method of Extreme Learning Machine is good enough to be used for the process of classification of chronic renal failure.

Keywords: Kidney, Chronic Renal Failure, Extreme Learning Machine, Artificial Neural Network.

1. PENDAHULUAN

Ginjal adalah organ vital yang mempunyai peranan sangat besar dalam proses pengaturan kebutuhan cairan serta elektrolit. Fungsi dari ginjal itu sendiri untuk mengatur air, mengatur konsentrasi jumlah garam pada darah, mengatur keseimbangan antara asam basa pada darah dan mengatur proses pembuangan zat-zat yang berbahaya bagi tubuh (Andriyani, 2015).

Walaupun ginjal mempunyai peran besar untuk menjaga keseimbangan tubuh, bukan berarti ginjal akan terus bekerja secara maksimal. Seseorang apabila tidak menjaga kesehatan ginjal dengan baik tidak menutup kemungkinan kesehatan ginjalnya akan terganggu. Salah satu penyakit yang akan terjadi apabila seseorang tidak menjaga kesehatan ginjalnya dengan baik yaitu penyakit gagal ginjal. Gagal ginjal adalah penyakit yang mana ginjal tidak dapat

melakukan fungsinya dengan semestinya. Gagal ginjal itu sendiri bisa terjadi secara kronis dan akut.

Apabila fungsi dari ginjal telah menurun dengan tiba-tiba tetapi bisa kembali secara normal apabila masalah yang terjadi sudah teratasi itu merupakan gagal ginjal akut. Sedangkan gagal ginjal kronis memiliki gejala yang bertahap dan biasanya gagal ginjal kronis tidak menimbulkan gejala di awal yang jelas. Akibatnya fungsi dari ginjal menurun dan penurunannya tidak bisa teramati, secara tiba-tiba saja sudah pada level yang sulit untuk mendapat pertolongan. Penyakit ini merupakan penyakit yang masuk pada penyakit *silent killer*. Mengapa dikatakan begitu sebab penyakit ini tidak menunjukkan gejala peringatan sebelumnya. Penyakit ini bisa disebabkan dari hal yang sepele seperti dehidrasi, sehingga tubuh mudah terserang infeksi saluran kemih.

Penelitian *Global Burden of Disease* pada tahun 2010, gagal ginjal kronis adalah penyebab angka kematian yang mendapat peringkat 27 pada tahun 1990 serta menjadi peringkat 18 pada tahun 2010. Pada tahun 2013 Indonesia sendiri mempunyai angka penderita kurang lebih 499.800 penduduk mengalami gagal ginjal serta 1.499.400 penduduk mengalami batu ginjal (Rikesda, 2013). Sedangkan menurut Perhimpunan Nefrologi Indonesia (PERNEFRI) serta Kementerian Kesehatan mengatakn bahwa angka pasien gagal ginjal kronis di Indonesia sebesar 25 sampai dengan 30 juta orang (Candra, 2013).

Penyakit gagal ginjal kronis awalnya tidak menunjukkan tanda dan gejala namun dapat berjalan progresif menjadi gagal ginjal. Penyakit ginjal bisa dicegah dan ditanggulangi dan kemungkinan untuk mendapatkan terapi yang efektif akan lebih besar jika diketahui lebih awal. Penyakit gagal ginjal kronis itu sangat sulit dideteksi secara medis sebab para dokter yang ahli di bidangnya ini tidak dapat melakukan pemeriksaan secara visual terhadap pasien. Penyakit gagal ginjal kronis ini dapat di dideteksi dengan melakukan pemeriksaan di laboratorium, salah satunya menggunakan pemeriksaan *Glomerular Filtration Rate* (GFR).

GFR merupakan tes untuk mengetahui jumlah dari darah yang sudah disaring ginjal pada setiap menit. Walaupun penyakit gagal ginjal kronis dapat dideteksi menggunakan GFR tetapi proses untuk melakukannya sangat rumit. Terdapat variabel dan rumusan khusus untuk

pasien dengan usia tertentu. Di Indonesia sendiri masyarakat masih belum sadar kalau mereka telah mengalami penyakit ini padahal kalau masih stadium awal masih dapat di terapi tanpa cuci darah. Selain itu dalam melakukan *check up* membutuhkan waktu yang lama, dikarenakan dalam proses *check up* ada dua tahapan yaitu proses *check lab* dan proses konsultasi dokter. Penelitian ini juga berguna dalam membantu tenaga medis dalam mengklasifikasikan secara cepat antara pasien yang normal dan pasien yang terkena penyakit gagal ginjal kronis.

Klasifikasi merupakan suatu cara dalam mengelompokkan sebuah *dataset* ke dalam suatu kelas. Klasifikasi itu sendiri dapat dilakukan dengan berbagai metode seperti *Extreme Learning Machine* (ELM) serta *Learning Vector Quantization* (LVQ). Pada penelitian Ersu (2016) menerangkan mengenai klasifikasi keadaan mata berdasarkan sinyal EEG menggunakan *Extreme Learning Machine* didapat hasil akurasi sebesar 97,95%. Penelitian selanjutnya klasifikasi gagal ginjal kronis menggunakan C4.5 didapat hasil akurasi sebesar 91,50% (Rianto, 2015).

Berdasarkan penjelasan diatas terbukti metode *Extreme Learning Machine* menghasilkan nilai yang baik dalam hal klasifikasi. Maka dari itu peneliti ingin melakukan penelitian mengenai klasifikasi risiko gagal ginjal kronis menggunakan metode *Extreme Learning Macine*. Penelitian ini nantinya diharapkan bisa membantu mengklasifikasikan risiko gagal ginjal konis untuk selanjutnya dapat menekan angka prevalensi gagal ginjal kronis di Indonesia. Sehingga kita sebagai masyarakat sadar akan pentingnya kesehatan khususnya terhadap penyakit gagal ginjal kronis. Dengan demikian diharapkan masyarakat mau untuk melakukan pola hidup sehat guna menunjang kesehatan bagi diri mereka masing-masing.

2. TINJAUAN PUSTAKA

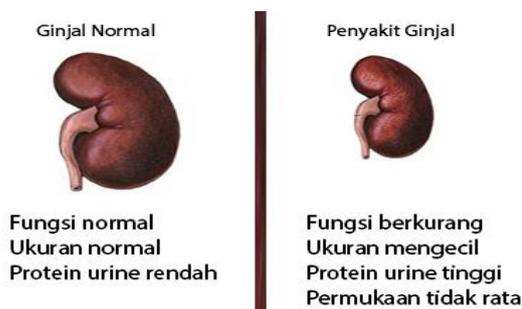
2.1. Klasifikasi

Klasifikasi adalah sebuah aspek pada data mining yang mana banyak digunakan untuk berbagai macam masalah pada sebuah penelitian. Klasifikasi adalah cara untuk melakukan indentifikasi objek ke suatu kelas ataupun kategori tertentu. Dalam hal ini klasifikasi memiliki tujuan dalam membagi sebuah objek masuk ke salah satu kategori yang

biasa disebut dengan kelas.

2.2. Gagal Ginjal Kronis

Ginjal adalah organ vital yang mempunyai peranan sangat besar dalam proses pengaturan kebutuhan cairan serta elektrolit. Fungsi dari ginjal itu sendiri untuk mengatur air, mengatur konsentrasi jumlah garam pada darah, mengatur keseimbangan antara asam basa pada darah dan mengatur proses pembuangan zat-zat yang berbahaya bagi tubuh (Andriyani, 2015). Setiap ginjal mengandung sekitar satu juta nefron. Nefron menggunakan empat proses untuk mengubah plasma darah yang mengalir ke ginjal. Yang meliputi *filtrasi*, *reabsorpsi*, sekresi, dan ekskresi. Gagal ginjal kronis adalah penyakit yang mana ginjal mengalami penurunan fungsi. Sampai saat ini, gagal ginjal kronis masih menjadi perhatian utama pemerintah karena meningkatnya prevalensi gagal ginjal kronis dan banyaknya pasien gagal ginjal kronis yang belum mendapatkan pertolongan medis. Gambar 1 berikut merupakan ginjal normal dan gagal ginjal kronis:



Gambar 1. Ginjal Normal dan Gagal Ginjal Kronis

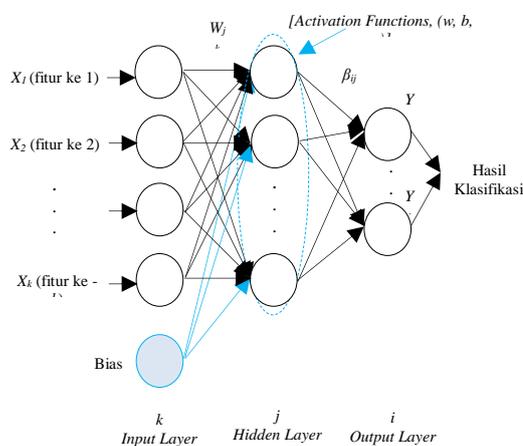
2.3. Extreme Learning Machine

Extreme Learning Machine (ELM) adalah sebuah algoritme pembelajaran pada jaringan saraf tiruan yang berjenis *single hidden layer feedforward network*. Algoritme ini diperkenalkan tahun 2004 oleh Huang. Algoritme ini bisa melakukan proses generalisasi dengan waktu yang cepat di banding *Support Vector Machine* (SVM) dan *Backpropagation* (Huang, et al., 2006).

Menurut Bartlett, *feedforward neural network* bisa melakukan penjangkauan kesalahan pelatihan begitu kecil. Nilai bobot semakin kecil maka proses generalisasi pada jaringan menjadi lebih baik (Huang, et al., 2012). Algoritme *Extreme Learning Machine* diciptakan tujuannya untuk menyempurnakan

kelemahan jaringan saraf tiruan *feedforward* dalam hal *learning speed*. *Extreme Learning Machine* adalah jaringan saraf tiruan yang bisa dilatih untuk melakukan sebuah fungsi kompleks pada berbagai macam bidang, yang paling utama yaitu untuk klasifikasi mengenai hal-hal yang begitu kompleks.

Parameter yang digunakan untuk algoritme *Extreme Learning Machine* seperti halnya nilai *input weight* dan *input bias* dipilih dengan cara *random*, sehingga dengan demikian waktu yang dibutuhkan algoritme *Extreme Learning Machine* dalam pembelajaran sangat kecil dan cepat. Selain waktu pembelajaran yang cepat nilai akurasi yang dihasilkan juga tinggi. Gambar 2. berikut merupakan contoh tentang struktur *Extreme Learning Machine* (ELM):



Gambar 2. Struktur ELM
Sumber: (Yaseen, et al., 2017)

Proses yang pertama dilakukan untuk algoritme *Extreme Learning Machine* yaitu proses *training*. Pada proses *training* akan membutuhkan *input data*. *Input data* ini akan digunakan untuk data *training set* serta *output target* untuk proses klasifikasi (Imam Cholissodin, 2017). Tahapan proses *training* algoritme *Extreme Learning Machine* adalah:

1. Pemilihan secara *random input weight* (W) dengan nilai *range* -1 sampai dengan 1 serta nilai *input bias* (b) dengan nilai *range* 0 sampai dengan 1. Dengan ukuran dari matriks bias $[1 \times j]$.
2. Hitung nilai matriks keluaran *hidden layer* (*Hinit*).

$$H_{init} = (X_{train} \cdot W^T) + b \tag{1}$$

Keterangan:

H_{init} = Keluaran *hidden layer*.

X_{train} = Nilai masukan data *training*.

w = Nilai bobot masukan.

b = Nilai dari bias.

3. Hitung nilai matriks keluaran *hidden layer* dengan menggunakan fungsi aktivasi sigmoid biner (H).

$$H(H_{init}) = \frac{1}{1+e^{-H_{init}}} \quad (2)$$

4. Hitung nilai dari *Moore-Penrose* (H^+).

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

Keterangan:

H^T = *Transpose* matriks H .

5. Hitung nilai *output weight* (β).

$$\beta = H^+ \cdot T \quad (4)$$

Keterangan:

T = Matriks target.

6. Hitung nilai dari *output layer* (Y).

$$Y = H \cdot \beta \quad (5)$$

Setelah proses *training* sudah selesai dan di dapat nilai *output layer*, selanjutnya akan dilanjutkan ke proses *testing*. Tahapan proses *testing* dengan algoritme *Extreme Learning Machine* adalah:

1. Gunakan nilai *input weight* (W) yang nilainya sama dengan proses *training*. Gunakan nilai bias (b) yang didapatkan secara *random* dengan *range* 0 sampai dengan 1. Dengan ukuran dari matriks bias $[1 \times j]$.
2. Hitung nilai matriks keluaran *hidden layer* (H_{init}).

$$H_{init} = (X_{test} \cdot W^T) + b \quad (6)$$

Keterangan:

H_{init} = Keluaran *hidden layer*.

X_{test} = Nilai masukan *testing*.

w = Nilai bobot masukan.

b = Nilai dari bias.

3. Hitung nilai matriks keluaran *hidden layer* dengan menggunakan fungsi aktivasi sigmoid biner (H).

$$H(H_{init}) = \frac{1}{1+e^{-H_{init}}} \quad (7)$$

4. Hitung nilai *output layer* (Y) proses *testing*.

$$Y = H \cdot \beta \quad (8)$$

Keterangan:

β = Bobot keluaran yang didapat pada proses *training*.

2.4. Akurasi Sistem

Akurasi adalah sebuah nilai yang mana nilai ini nantinya akan digunakan dalam proses analisis untuk tingkat keberhasilan dari sebuah sistem dalam menangani masalah. Nilai akurasi biasa diambil dengan cara melakukan perbandingan dari jumlah data yang benar dengan jumlah nilai data keseluruhan yang ada pada sistem. Persamaan 9 berikut ini merupakan persamaan untuk menghitung nilai akurasi pada hasil klasifikasi (Simanjuntak, et al., 2017):

$$Akurasi = \frac{DT}{N} \times 100\% \quad (9)$$

Keterangan:

DT = Jumlah benar pada sistem.

N = Jumlah semua data pada sistem.

2.5. Fungsi Aktivasi

Fungsi aktivasi adalah salah satu fungsi yang memiliki kemampuan untuk memproses sebuah masukan kemudian melakukan transformasi pada masukan tadi supaya menjadi sebuah keluaran tertentu. Pada jaringan saraf tiruan sebuah informasi akan dijadikan menjadi sebuah masukan. Kemudian nilai dari masukan akan diproses melalui suatu fungsi perambatan. Dalam fungsi perambatan nilai dari sejumlah masukan akan dilakukan penjumlahan, hasilnya akan dilakukan proses perbandingan dengan nilai ambang tertentu sesuai fungsi aktivasi yang ada di setiap neuron. Fungsi aktivasi yang digunakan pada algoritme *Extreme Learning Machine* (Srimuang & Intarasothonchun, 2015):

1. Fungsi Aktivasi Sigmoid Biner

$$H = \frac{1}{1+e^{-H_{init}}} \quad (10)$$

2. Fungsi Aktivasi Sin

$$H = \sin(H_{init}) \quad (11)$$

3. Fungsi Aktivasi Radial Basis

$$H = \exp(-(H_{init})^2) \quad (12)$$

4. Fungsi Aktivasi Bipolar

$$H = \frac{1-\exp^{-H_{init}}}{1+\exp^{-H_{init}}} \quad (13)$$

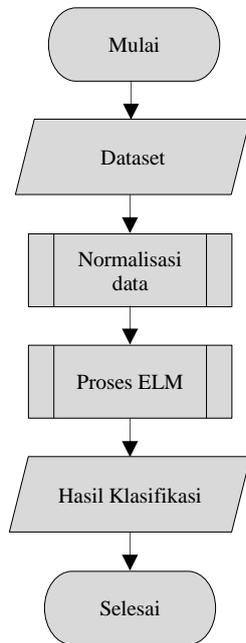
5. Fungsi Aktivasi Linier

$$H = H_{init} \quad (14)$$

3. METODOLOGI

Pada proses klasifikasi risiko gagal ginjal kronis menggunakan *Extreme Learning Machine*

memiliki beberapa tahap dalam melakukan proses klasifikasi. Berikut merupakan rancangan diagram alur dari sistem yang digambarkan pada Gambar 3.



Gambar 3. Diagram Alur Sistem

1. Pada proses pertama yaitu melakukan proses pengambilan *dataset*, yang mana jumlah *dataset* sebesar 155 data. Untuk fitur 1 sampai fitur 24 di ubah menjadi x1 sampai x24. Dalam penelitian ini menggunakan 2 kelas yaitu kelas 1 dan kelas 2, yang mana kelas 1 mewakili penderita gagal ginjal kronis dan kelas 2 mewakili tidak menderita gagal ginjal kronis. Untuk nilai target tergantung dari kelasnya, apabila kelasnya 1 maka nilai target 1 dan -1 sebaliknya apabila kelasnya 2 maka nilai target -1 dan 1. Tabel 1 dibawah ini merupakan *dataset* yang berjumlah 155 data.

Tabel 1. *Dataset*

No	x1	x2	x24	Target	Kelas	
1	48	70	1	1	-1	1
2	53	90	1	1	-1	1
3	63	70	2	1	-1	1
...
145	17	60	2	-1	1	2
155	58	80	2	-1	1	2

2. Kemudian proses kedua yaitu melakukan *normalisasi* pada *dataset* yang berjumlah 155 tadi.
3. Setelah mendapatkan hasil dari proses *normalisasi*, masuk ke proses ELM. Pada

proses ELM nilai *dataset* yang sudah di *normalisasi* akan dibagi untuk dilakukan proses *training* dan proses *testing*. Pada proses *training* didapatkan hasil akhir berupa *output weight*, kemudian nilai dari *output weight* akan menjadi inputan pada proses *testing*.

4. Hasil dari proses *testing* berupa *output layer*. nilai dari *output layer* akan dilakukan klasifikasi.

4. HASIL DAN PEMBAHASAN

4.1. Pengujian Perbandingan Rasio Data Latih dan Data Uji

Pengujian untuk perbandingan rasio antara data latih serta data uji dilakukan bertujuan mengetahui seberapa besar pengaruh rasio antara data latih serta data uji terhadap nilai dari akurasi. Dalam pengujian ini nilai data latih maupun nilai dari data uji sudah ditentukan terlebih dahulu. Nilai data latih dan nilai data uji yang akan digunakan untuk pengujian dan analisis yaitu sebesar 90% : 10% dimana nilainya dibulatkan menjadi 140 data latih dan 15 data uji, 80% : 20% dimana nilainya dibulatkan menjadi 124 data latih dan 31 data uji, 70% : 30% dimana nilainya dibulatkan menjadi 109 data latih dan 46 data uji, 60% : 40% dimana nilainya dibulatkan menjadi 93 data latih dan 62 data uji, dan 50% : 50% dimana nilainya dibulatkan menjadi 78 data latih dan 77 data uji. Parameter pada pengujian ini nantinya akan menggunakan nilai *neuron hidden layer* berjumlah 10, nilai masukan sebanyak 24 buah, dan fungsi aktivasi yang digunakan adalah sigmoid biner. Pengujian akan dilakukan sebanyak 5 kali untuk setiap rasio.

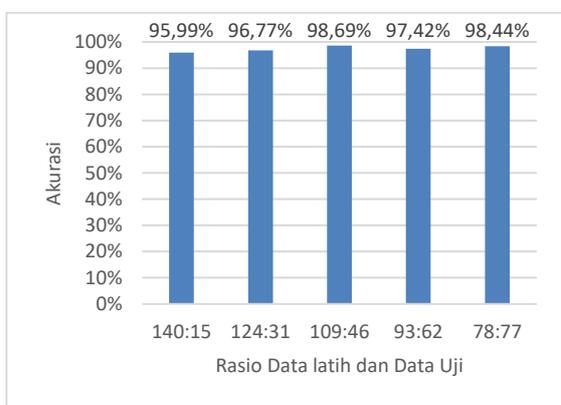
Dalam melakukan proses perhitungan dengan menggunakan algoritme *Extreme Learning Machine* akan menghasilkan nilai yang berbeda dari setiap percobaan. Semua ini terjadi karena nilai dari bobot dan nilai bias yang diinisialisasikan secara random. Sehingga untuk mendapatkan nilai rata-rata keseluruhan harus melakukan 5 kali percobaan setiap rasionya. Tabel 2 dibawah ini merupakan hasil pengujian perbandingan rasio data latih serta data uji.

Tabel 2. Pengujian Perbandingan Data Latih dan Data Uji

No	90%:10%	80%:20%	70%:30%	60%:40%	50%:50%
	%	0%	0%	0%	
	140:15	124:31	109:46	93:62	78:77

1	93,33%	96,77 %	95,65 %	98,39 %	97,40%
2	100%	90,32 %	100%	95,16 %	97,40%
3	100%	100%	100%	98,39 %	98,70%
4	93,33%	96,77 %	100%	96,77 %	100%
5	93,33%	100%	97,83 %	98,39 %	98,70%
Rata-rata	95,99%	96,77 %	98,69 %	97,42 %	98,44%

Dari tabel tersebut dapat digambarkan sebuah grafik hasil pengujian. Gambar 4 merupakan grafik hasil proses pengujian perbandingan rasio data latih dan data uji.



Gambar 4. Grafik Hasil Pengujian Perbandingan Rasio Data Latih dan Data Uji

Hasil pengujian yang di dapat ditampilkan pada Tabel 1 serta Gambar 4. Dapat dilihat bahwa hasil dari pengujian perbandingan rasio antara data latih serta data uji hanya sedikit berpengaruh terhadap setiap nilai akurasi. Nilai akurasi yang didapatkan setiap percobaan sudah baik, sebab *dataset* yang digunakan dalam pengujian nilai datanya sudah memiliki pola sendiri dan akurat. Hasil nilai akurasi yang terbaik yaitu menggunakan perbandingan rasio data sebesar 70% : 30% dimana nilai datanya yaitu 109 untuk data latih serta 46 untuk data uji sehingga mendapatkan nilai rata - rata dari rasio tersebut sebesar 98,69%.

4.2. Pengujian Perbandingan Pengaruh Jumlah Neuron Hidden Layer

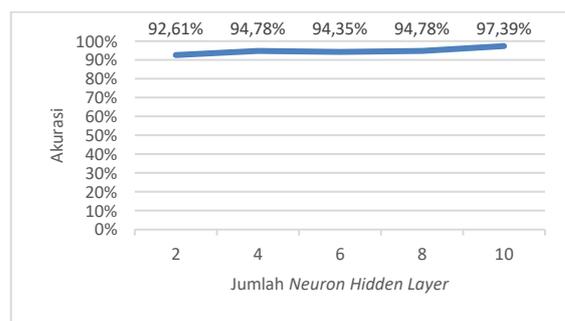
Pengujian untuk pengaruh jumlah nilai *neuron hidden layer* akan digunakan guna mengetahui bagaimana pengaruh dari jumlah nilai *neuron hidden layer* terhadap hasil dari akurasi. Dalam pengujian ini nilai dari jumlah *neuron hidden layer* sudah ditentukan terlebih dahulu. Nilai jumlah *neuron hidden layer* yang

akan digunakan untuk pengujian dan analisis yaitu sebesar 2, 4, 6, 8, 10. Inisialisasi parameter yang akan digunakan dalam pengujian ini adalah jumlah rasio antara data latih dan data uji sebesar 70% : 30% dimana nilainya dibulatkan menjadi 109 data latih dan 46 data uji, jumlah nilai input neuron (*fitur*) sebanyak 24 buah, dan menggunakan fungsi aktivasi sigmoid biner. Pengujian dan analisis pengaruh jumlah *neuron hidden layer* akan dilakukan sebanyak 5 kali percobaan. Pengujian ini akan dihasilkan nilai akurasi yang berbeda-beda. Semua ini terjadi karena nilai dari bobot dan nilai bias yang diinisialisasikan secara random. Tabel 3 merupakan nilai hasil dari pengujian terhadap pengaruh jumlah *neuron hidden layer*.

Tabel 3. Pengujian Perbandingan Pengaruh Jumlah Neuron Hidden Layer

No	2	4	6	8	10
1	95,65%	95,65%	91,30%	89,13%	100%
2	95,65%	93,48%	97,83%	93,48%	95,65%
3	93,48%	97,83%	95,65%	97,83%	97,83%
4	91,30%	97,83%	95,65%	95,65%	95,65%
5	86,96%	89,13%	91,30%	97,83%	97,83%
Rata-rata	92,61%	94,78%	94,35%	94,78%	97,39%

Dari tabel tersebut dapat digambarkan sebuah grafik hasil pengujian. Gambar 5 merupakan grafik hasil proses pengujian perbandingan pengaruh jumlah *neuron hidden layer*.



Gambar 5. Grafik Hasil Pengujian Perbandingan Jumlah Neuron Hidden Layer

Berdasarkan hasil dari pengujian yang telah ditampilkan pada Tabel 3 serta Gambar 5 dapat dilihat bahwa hasil dari pengujian perbandingan jumlah *neuron hidden layer* cenderung memberikan hasil akurasi yang baik. Karena semakin banyak *neuron hidden layer* proses pelatihan akan lebih baik dan juga akan menghasilkan nilai akurasi yang baik pula. Hasil nilai akurasi terbaik yang dihasilkan pada

pengaruh perbandingan jumlah *neuron hidden layer* yaitu menggunakan jumlah *neuron hidden layer* sebanyak 10 dimana nilai rata-rata dari pengujian tersebut sebesar 97,39%.

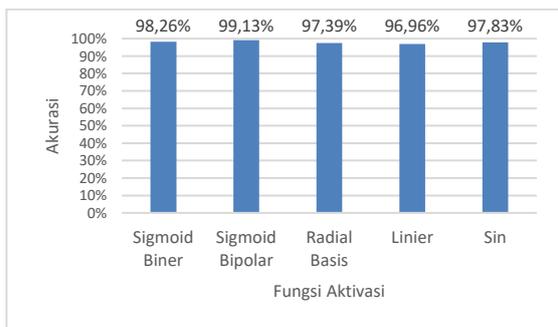
4.3. Pengujian Pengaruh Fungsi Aktivasi

Pengujian fungsi aktivasi bertujuan untuk mengetahui seberapa besar pengaruh dari fungsi aktivasi terhadap hasil dari akurasi. Dalam pengujian ini fungsi aktivasi sudah ditentukan terlebih dahulu. Fungsi aktivasi yang akan digunakan untuk pengujian dan analisis yaitu sigmoid biner, sigmoid bipolar, radial basis, linier, serta sin. Pengujian ini menggunakan parameter jumlah rasio antara data latih dan data uji sebesar 70% : 30% dimana nilainya dibulatkan menjadi 109 data latih dan 46 data uji, jumlah nilai input neuron (*fitur*) sebanyak 24 buah, dan nilai dari jumlah *neuron hidden layer* adalah 10. Pengujian dan analisis pengaruh fungsi aktivasi akan dilakukan sebanyak 5 kali percobaan. Pengujian ini akan dihasilkan nilai akurasi yang berbeda-beda. Semua ini terjadi karena nilai dari bobot dan nilai bias yang diinisialisasikan secara *random*. Tabel 4 merupakan nilai hasil pengujian fungsi aktivasi.

Tabel 4. Pengujian Pengaruh Fungsi Aktivasi

No	Sigmoid biner	Sigmoid bipolar	Radial basis	Linier	sin
1	97,83%	97,83%	95,65%	95,65%	95,65%
2	97,83%	97,83%	100%	97,83%	97,83%
3	97,83%	100%	95,65%	95,65%	97,83%
4	100%	100%	97,83%	100%	100%
5	97,83%	100%	97,83%	95,65%	97,83%
Rata-rata	98,26%	99,13%	97,39%	96,96%	97,83%

Dari tabel tersebut dapat digambarkan sebuah grafik hasil pengujian. Gambar 6 merupakan grafik hasil proses pengujian pengaruh fungsi aktivasi.



Gambar 6. Grafik Hasil Pengujian Pengaruh Fungsi Aktivasi

Hasil pengujian yang di dapat ditampilkan pada Tabel 4 serta Gambar 6. Dapat dilihat hasil dari pengujian perbandingan fungsi aktivasi hanya berpengaruh sedikit terhadap setiap hasil akurasi. Fungsi aktivasi bipolar memiliki nilai rentang 1 sampai -1, ini menguntungkan untuk proses perhitungan ELM sebab nilai rentang 1 sampai -1 lebih berpengaruh dalam mendapatkan nilai *output weight*. Hasil akurasi terbaik yang dihasilkan pada pengaruh perbandingan fungsi aktivasi yaitu menggunakan fungsi aktivasi sigmoid bipolar dengan didapatkan nilai rata-rata dari setiap percobaan sebesar 99,13%.

5. KESIMPULAN DAN SARAN

5.1. Kesimpulan

Berdasarkan proses pengujian serta hasil dari proses analisis mengenai klasifikasi risiko gagal ginjal kronis menggunakan *Extreme Learning Machine* didapatkan kesimpulan bahwa:

1. Dapat dilihat dari nilai proses pengujian, bahwa algoritme *Extreme Learning Machine* bisa digunakan untuk klasifikasi *dataset* gagal ginjal kronis dengan nilai akurasi yang terbaik didapat pada rasio antara data latih serta data uji 70%:30% yang mana perbandingan banyak datanya sebesar 109:46, nilai *neuron hidden layer* berjumlah 10 serta menggunakan sigmoid bipolar.
2. Dari penggunaan ketiga pengujian yaitu pengujian rasio data latih dan data uji, pengujian jumlah *neuron hidden layer* serta pengujian penggunaan fungsi aktivasi untuk klasifikasi risiko gagal ginjal kronis dihasilkan nilai akurasi yang terbaik sebesar 99,13%.

5.2. Saran

Saran mengenai kelanjutan penelitian dalam klasifikasi risiko gagal ginjal kronis menggunakan algoritme *Extreme Learning Machine* yaitu sebagai berikut:

1. Untuk penelitian yang selanjutnya diharapkan untuk melakukan optimasi pada penggunaan nilai *weight* serta bias supaya nilai *weight* serta bias yang di dapat lebih optimal, karena setiap kasus sangat besar kemungkinan memiliki nilai *weight* serta

bias yang berbeda untuk mendapatkan hasil pengujian yang optimal.

2. Untuk penelitian selanjutnya diharapkan untuk mengatasi masalah dengan data yang *outlier* karena data *outlier* akan menimbulkan nilai akurasi menjadi tidak optimal.

DAFTAR PUSTAKA

- Andriyani, R., Triana, A. dan Juliarti, W. 2015. Buku Ajar Biologi Reproduksi dan Perkembangan. Sleman: Deepublish.
- Candra, A., 2013. Rajin Pantau Tensi Turut Sehatkan Ginjal. Tersedia di: <<http://health.kompas.com/read/2013/03/06/18435262/rajin.pantau.tensi.turut.sehatkan.ginjal>> [Diakses 28 Februari 2018].
- Cholissodin, I., Sutrisno, Soebroto, A. A., Hanum, L., Caesar, C. A. 2017. Optimasi Kandungan Gizi Susu Kambing Peranakan Etawa (PE) Menggunakan ELM-PSO di UPT Pembibitan Ternak dan Hijauan Makanan Ternak Singosari Malang.
- Hosten, A.O., 1990. BUN and Creatinine. In: Walker, H.K., Hall, W.D., Hurst, J.W., 3rd eds. Clinical Methods: The History, Physical, and Laboratory Examinations. Boston: Butterworths. p. 874–8.
- Huang, G.B., Zhu, Q.Y. and Siew, C.K., 2006. *Extreme learning machine: theory and applications*. Neurocomputing, 70(1), pp.489-501.
- Humaini, Q. 2015. Jaringan Syaraf Tiruan *Extreme Learning Machine* (ELM) Untuk Memprediksi Kondisi Cuaca di Wilayah Malang. Malang.
- Imanurrahman, M. 2015. Pengklasifikasian Penyakit Ginjal Menggunakan Metode Naive Bayes. Universitas Sumatra Utara.
- Jain, Y.K. and Bhandare, S.K., 2011. Min max normalization based data perturbation method for privacy protection. International Journal of Computer & Communication Technology, 2(8), pp.45-50.
- Kusuma, S. 2003. Artificial Intelligence (Teknik dan Aplikasinya). Yogyakarta: Graha Ilmu.
- Munandar, M. 2016. Faktor-Faktor Risiko Yang Berhubungan Dengan Kejadian Gagal Ginjal Kronis Pada Pasien Rawat Jalan di RSUD Dr Moewardi Surakarta. Surakarta.
- National Kidney Foundation. 2002. K/DOQI Clinical Practice Guidelines for Chronic Kidney Disease: Evaluation, Clasification and Stratification.
- Perdana, J. A., Soeprijanto, A., Wibowo, R. S. 2012. Peramalan Beban Listrik Jangka Pendek Menggunakan *Optimally Pruned Extreme Learning Machine* (OPELM) pada Sistem Kelistrikan Jawa Timur. Surabaya.
- Pranandari, R dan Supadmi, W. 2015. Risk Factors Cronic Renal Failure on Hemodialysis Unit in RSUD Wates Kulon Progo. Wates Kulon Progo.
- Puspitaningrum, D. 2006. Pengantar Jaringan Saraf Tiruan. Yogyakarta: Andi.
- Shahsavari, M.K., Bakhsh, H.R. & Rashidi, H., 2016. Efficient Classification of Parkinson's Disease Using Extreme Learning Machine and Hybrid Particle Swarm Optimization. 2016 4th International Conference on Control, Instrumentation, and Automation (ICCIA). Qazvin Islamic Azad University. Qazvin, Iran, 27-28 January 2016.
- Simanjuntak, T. H., Mahmudy, W. F. & Sutrisno, 2017. Implementasi Modified K-Nearest Neighbor Dengan Otomatisasi Nilai K Pada Pengklasifikasian Penyakit Tanaman Kedelai. Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer, Volume 1, pp. 75-79.
- Siwi, Iga Permata, Imam Cholissodin, and M. Tanzil Furqon, 2016. Peramalan Produksi Gula Pasir Menggunakan *Extreme Learning Machine* (ELM) Pada Pg Candi Baru Sidoarjo.
- Srimuang, W., & Intarasonchun, S., 2015. *Classification Model of Network Intrusion using Weighted Extreme Learning Machine*. 12th International Joint Conference on Computer Science and Software Engineering (JCSSE), 190-194.
- The Renal Association. 2013. CKD Stages. Tersedia di: <<http://www.renal.org/information-resources/the-uk-eckd-guide/ckdstages#sthash.frm4MEB8.dpbs>>. [Diakses pada 28 Februari 2018].
- Wilson, L.M. 2005. Gagal Ginjal Kronik. Dalam: Wilson, L.M., Price, S.A., penyunting. Patofisiologi: konsep klinis

proses-proses penyakit. Edisi ke-6.
Jakarta:ECG. hlm. 912–47.

Yaseen, Z. M., Deo, R. C., Hilal, A., Abd, A. M.,
Bueno, L. C. B., Sanz, S. S. & Nehdi, M. L.
2017. *Predicting Compressive Strength Of
Lightweight Foamed Concrete Using
Extreme Learning Machine Model.*