

Penentuan Waktu Terakhir Penggunaan Ganja dengan Metode *Radial Basis Function Neural Network (RBFNN)*

Sukma Fardhia Anggraini¹, Sigit Adinugroho², Randy Cahya Wihandika³

Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Brawijaya
Email: ¹sukmafardhia@gmail.com, ²sigit.adinu@ub.ac.id, ³rendicahya@ub.ac.id

Abstrak

Pada tahun 2017, jumlah penyalahguna ganja di Indonesia mencapai 1.742.285 orang. Ketika seorang pecandu ganja ingin menghentikan pemakaian secara mendadak, maka dapat menimbulkan gejala sakau. Untuk mengantisipasi gejala sakau maka dapat dilakukan langkah rehabilitasi, sehingga pecandu bisa mendapatkan perawatan yang komprehensif. Penentuan jenis rehabilitasi yang sesuai dapat menjadikan perawatan lebih efektif. Sehingga dengan mengetahui waktu terakhir penggunaan ganja, diharapkan dapat memberi informasi pendukung untuk menentukan program rehabilitasi yang sesuai untuk pecandu ganja. Salah satu teknik dalam *data mining* yang dapat digunakan untuk menyelesaikan permasalahan ini adalah dengan teknik klasifikasi. Pada penelitian ini, metode klasifikasi yang digunakan adalah metode *Radial Basis Function Neural Network (RBFNN)* dengan *K-Means*. Tahapan yang dilakukan meliputi tahap normalisasi data, metode *K-means* untuk menentukan nilai *center* dan *spread* pada fungsi aktivasi *Gaussian*, tahap *training RBFNN* dan tahap *testing RBFNN*. Penelitian ini menggunakan 627 data pengguna ganja yang dipublikasikan di *UCI Machine Learning* pada tahun 2016. Berdasarkan hasil pengujian dari penelitian yang telah dilakukan, didapatkan parameter optimal diantaranya 7 *hidden neuron* dan batas maksimal iterasi *K-Means* adalah 100. Dengan menggunakan parameter tersebut, didapatkan hasil akurasi sebesar 35,908%.

Kata kunci: ganja, *Radial Basis Function Neural Network*, *K-Means*, klasifikasi, *clustering*

Abstract

In 2017, there are 1,742,285 cannabis (popular as marijuana) abusers in Indonesia. If a marijuana addict suddenly wants to stop using marijuana, it can cause symptoms of "sakau". To anticipate the symptoms of "sakau", rehabilitation treatment can be taken, so that marijuana addicts can get comprehensive treatment. Determining the appropriate type of rehabilitation, can make it useful. Then knowing the last time abusers had consumption the marijuana, be expected to provide supporting information to determine the appropriate rehabilitation program for marijuana addicts. One technique in data mining that can be used to solve this problem is classification techniques. In this study using Radial Radial Basis Function Neural Network (RBFNN) with K-Means as the classification method. The steps taken included data normalization, K-Means to found the value of centers and spread for Gaussian activation function, training and testing RBFNN. This study using 627 marijuana abuser data which was published on the UCI Machine Learning in 2016. The results of the research showed the optimal parameters involves 7 hidden neurons and 100 as the maximum limit of K-Means iterations. By using these parameters, the classification result achieved accuracy of 35,908%.

Keywords: *cannabis, marijuana, Radial Basis Function Neural Network, K-Means, classification, clustering*

1. PENDAHULUAN

Merujuk pada Undang-Undang No. 35 Tahun 2009 tentang Narkotika pada Pasal 1 angka 1, Narkotika adalah zat atau obat yang dapat memberikan efek penurunan atau perubahan kesadaran, mengurangi atau menghilangkan rasa nyeri dan memiliki sifat yang adiktif serta berasal dari tanaman maupun

bukan tanaman. Jenis narkoba yang paling banyak dikonsumsi oleh penyalahguna narkoba di Indonesia adalah ganja atau yang memiliki nama ilmiah *cannabis*, dengan jumlah penyalahguna mencapai 1.742.285 orang (Badan Narkotika Nasional, 2017). Menurut Humas BNN (2011), ganja merupakan tumbuhan berserat dengan kandungan zat narkotika tetrahidrokanabinol (THC) pada bijinya. Dengan

adanya kandungan THC pada biji ganja, menyebabkan penggunaanya dapat merasa gembira berlebihan tanpa sebab setelah mengonsumsinya. Konsumsi ganja dengan jangka panjang dapat memberikan dampak buruk terhadap kesehatan fisik maupun psikis.

Dampak lain yang dapat terjadi ketika penyalahguna telah mengalami kecanduan ganja adalah sakau. Menurut Yayasan Pelita Ilmu (2017) jalan terbaik untuk menanggulangi gejala sakau adalah dengan rehabilitasi. Menurut Partodiharjo (2006), rehabilitasi narkoba adalah suatu metode pemulihan terhadap kesehatan jiwa maupun raga pecandu narkoba, sehingga dapat terbebas dari rasa candu terhadap narkoba dan terhindar dari dampak buruk yang ditimbulkan dari penyalahgunaan narkoba. Mengutip pernyataan dr. Diah Setia Utami SpKJ, Ma, yang merupakan Deputi Rehabilitasi BNN, salah satu yang menentukan program rehabilitasi yang sebaiknya dilakukan terhadap pecandu adalah tingkat penggunaan narkoba. Menurut BNN Baddoka Makassar (2017), terdapat tiga program rehabilitasi, diantaranya rehabilitasi rawat jalan, rehabilitasi rawat inap 4 bulan dan rehabilitasi rawat inap 6 bulan. Program rehabilitasi rawat jalan dapat dilakukan dengan syarat tingkat penggunaan masih pada tahap ringan hingga sedang. Program rehabilitasi rawat inap 4 bulan dapat dilakukan dengan syarat tingkat penggunaan pada tahap teratur pakai. Bagi pengguna yang telah memasuki tahap ketergantungan, diharuskan menjalani program rehabilitasi rawat inap 6 bulan. Sehingga dengan mengetahui waktu terakhir penggunaan ganja, diharapkan dapat memberi informasi pendukung untuk menentukan program rehabilitasi yang sesuai untuk pecandu ganja.

Fehrman et al (2017) dalam penelitiannya menyebutkan bahwa terdapat beberapa faktor yang dapat dijadikan landasan untuk mengetahui waktu terakhir penggunaan ganja, diantaranya adalah umur, tingkat pendidikan yang terakhir ditempuh, *openness to experience* atau tingkat keterbukaan terhadap orang lain, *agreeableness* atau tingkat kemufakatan dengan orang lain, *conscientiousness* atau tingkat kesungguhan untuk mencapai tujuan dan *impulsivity*.

Metode yang dapat digunakan untuk mengetahui waktu terakhir pemakaian narkoba jenis ganja adalah dengan klasifikasi menggunakan Jaringan Saraf Tiruan. Salah satu jenis Jaringan Saraf Tiruan untuk klasifikasi adalah dengan *Radial Basis Function*. Pada

penelitian yang dilakukan oleh Mirawanti et al (2012) dengan menggunakan objek Rumahtangga miskin Kota Pasuruan untuk melakukan perbandingan terhadap Metode Regresi Logistik Ordinal dengan Jaringan Saraf Tiruan Fungsi Radial, memberikan hasil akurasi klasifikasi sebesar 67,08% terhadap metode RBFNN dengan *K-Means* dan hanya 38% terhadap metode Regresi Logistic Ordinal. Selain itu, penelitian yang dilakukan oleh Dillak (2012) menggunakan Jaringan RBF pada obyek *medical prescription* penyakit jantung, mampu memberikan hasil ketepatan diagnosa dan kesesuaian jenis obat sebesar 85%. Dan penelitian yang terkait dengan klasifikasi durasi pemakaian narkoba pernah dilakukan sebelumnya oleh Fehrman et al (2017). Pada penelitian tersebut metode klasifikasi yang digunakan adalah Decision Tree, Random Forest, KNN, Linear Discriminant Analysis, *Gaussian Mixture*, Probability Density Function Estimation, Regresi Logistic dan Naïve Bayes. Hasil yang didapatkan pada penelitian tersebut memiliki nilai rata-rata sensitivitas dan spesifisitas hingga 75% untuk narkoba jenis ganja.

Berdasarkan pada masalah-masalah yang dipaparkan di atas dan penelitian terdahulu yang relevan, maka penulis mengusulkan untuk melakukan penelitian dengan judul Klasifikasi Waktu Terakhir Penggunaan Ganja dengan Metode *Radial Basis Function Neural Network* (RBFNN). Dengan dilakukannya penelitian ini diharapkan dapat memberi manfaat untuk alat bantu pendukung keputusan jenis rehabilitas yang sesuai untuk pemakai ganja.

2. DASAR TEORI

2.1. Penjelasan Dataset

Pada penelitian ini data yang digunakan adalah data sekunder dari *UCI Machine Learning* dengan judul *Drug Consumption* yang diterbitkan pada tahun 2016 (Fehrman et al., 2016) sebanyak 627 data. Dalam data tersebut terdapat 6 fitur, diantaranya: umur, pendidikan terakhir, *Oscore*, *Ascore*, *Cscore* dan *Impulsivity* (BIS-11). Kemudian terdapat 7 kelas waktu terakhir penggunaan ganja, diantaranya: CL0 (tidak pernah menggunakan), CL1 (menggunakan di atas 10 tahun lalu), CL2 (menggunakan pada 10 tahun terakhir), CL3 (menggunakan pada 1 tahun terakhir), CL4 (menggunakan pada 1 bulan terakhir), CL5

(menggunakan pada 1 minggu terakhir) dan CL6 (menggunakan pada 1 hari sebelumnya).

2.2. Ganja

Ganja atau yang memiliki nama ilmiah *cannabis sativa*, merupakan salah satu jenis tumbuhan narkoba. Ganja digolongkan sebagai narkoba karena mampu memberikan efek euphoria atau rasa senang tanpa sebab kepada pemakainya karena terdapat kandungan zat Tetrahidrokanabinol (THC) di dalamnya. Penyalahgunaan ganja dapat menyebabkan berbagai efek berbahaya bagi tubuh pemakainya, baik secara fisik maupun secara psikis. Dan penyalahgunaan ganja dengan dosis tinggi dapat memberikan dampak berupa peradangan pada paru-paru, iritasi hingga pembengkakan saluran nafas (Humas BNN, 2011).

Beberapa faktor yang dapat berpengaruh untuk mengetahui waktu terakhir penggunaan ganja diantaranya:

1. Umur
2. Pendidikan yang terakhir ditempuh
3. *Openness to experience* (Oscore)

Oscore merupakan tingkat keterbukaan seseorang terhadap orang lain. Orang dengan nilai oscore yang tinggi cenderung memiliki pemikiran yang imajinatif (Friedman dan Schustack, 2012).

4. *Agreeableness* (Ascore)

Ascore merupakan tingkat kemufakatan seseorang terhadap orang lain. Seseorang dengan nilai ascore yang tinggi akan cenderung mudah mempercayai orang lain, murah hati, mudah menerima pendapat orang lain, mudah mengalah dan menghindari konflik (Feist dan Feist, 2009).

5. *Conscientiousness* (Cscore)

Cscore merupakan tingkat keseungguhan seseorang terhadap tujuan yang ingin dicapai. Seseorang dengan nilai cscore yang tinggi cenderung dapat diandalkan, teratur, fokus terhadap tujuan dan bertanggung jawab. Sebaliknya, jika nilai cscore seseorang rendah, maka ia cenderung ceroboh, berantakan, tidak terarah, mudah teralih perhatiannya dan tidak dapat diandalkan (Friedman dan Schustack, 2012).

6. *Impulsivity*

Merupakan tingkat dorongan dalam diri untuk melakukan tindakan untuk kepuasan yang ingin dicapai, baik secara sadar maupun tidak sadar. Salah satu metode

yang dapat digunakan untuk mengukur tingkat impulsivity seseorang adalah dengan BIS-11 (Patton et al, 1995).

2.3. K-Means

Normalisasi Menurut Kuntjoro et al (2018), *clustering* adalah pengelompokan data yang bertujuan untuk mencari data dengan karakteristik yang sama untuk dijadikan satu klaster dan memisahkan klaster untuk data dengan karakteristik yang berbeda. *Clustering* juga disebut sebagai *unsupervised classification* karena mengelompokkan tidak berdasarkan klas yang sudah ada, tetapi berdasarkan kesamaan karakteristik data. Salah satu metode yang menerapkan konsep *clustering* adalah *K-Means*. Langkah-langkah dari metode *K-Means* adalah sebagai berikut.

1. Inisialisasi jumlah klaster, fungsi obyektif awal, *threshold*, batas iterasi maksimum dan klaster awal.
2. Hitung *centroid* setiap klaster.

$$C_{kj} = \frac{1}{N_k} \sum_{i=0}^{N_k} X_{ij} \quad (1)$$

Keterangan:

C_{kj} = *centroid* atau nilai *mean* klaster ke- k untuk fitur ke- j

N_k = jumlah data pada klaster ke- k

X_{ij} = nilai data ke- i untuk fitur ke- j

3. Hitung jarak data dengan *centroid*.

$$d_{ik} = \sqrt{\sum_{j=1}^p (X_{ij} - C_{kj})^2} \quad (2)$$

Keterangan:

d_{ik} = jarak antara data ke- i dengan klaster ke- k

P = jumlah fitur

X_{ij} = nilai data ke- i pada fitur ke- j

C_{kj} = nilai *centroid* klaster ke- k pada fitur ke- j

4. Perbarui klaster setiap data dengan mencari jarak maksimum data terhadap *centroid*.

5. Hitung fungsi obyektif.

$$F_t = \sum_{i=0}^n d_{min}^{ik} \quad (3)$$

Keterangan:

F_t = nilai fungsi obyektif iterasi ke- t

n = jumlah data

d_{min}^{ik} = jarak minimum data ke- i ke semua klaster k

6. Hitung perubahan fungsi obyektif.

$$\Delta F_t = |F_t - F_{t-1}| \quad (4)$$


Keterangan:

ΔF_t = delta fungsi obyektif pada iterasi ke- t

- F_t = nilai fungsi objektif pada iterasi ke- t
 F_{t-1} = nilai fungsi objektif pada iterasi ke- $(t - 1)$
7. Ulangi langkah 4-6 jika kriteria berhenti berikut belum terpenuhi.
 - a. Jika nilai iterasi sama dengan nilai maksimum iterasi
 - b. Jika nilai *threshold* lebih besar dari delta fungsi obyektif

2.4. Radial Basis Function Neural Network (RBFNN)

Menurut Azmi (2016), pada jaringan RBF, *hidden layer* bersifat non-linier dengan menggunakan fungsi aktivasi *Gaussian* dan output layer bersifat linier sehingga menggunakan fungsi aktivasi linier. Pada jaringan RBF, dari *input layer* ke *hidden layer* tidak menerapkan operasi perkalian matriks antara data *input* dengan bobot, tetapi dengan menghitung jarak antara data input dengan nilai center dari setiap *hidden neuron*. Nilai *center* dari *hidden neuron* dapat ditentukan salah satunya dengan metode *unsupervised* seperti algoritme *K-means* (Santosa, 2016). Arsitektur jaringan *Radial Basis Function* ditunjukkan pada Gambar 1.



Gambar 1. Aritektural Jaringan Radial basis Function

Pada metode RBFNN dengan *K-Means*, dilakukan dua langkah utama. Langkah pertama adalah *clustering* data dengan *K-Means*. Pada langkah pertama bertujuan untuk mendapatkan nilai *mean* tiap atribut pada tiap kluster atau *hidden neuron*. Setelah mendapatkan hasil *training* maka langkah kedua adalah melakukan klasifikasi dengan RBFNN (Mirawanti et al., 2012). Pada RBFNN terdapat dua fase utama, yaitu fase *training* dan fase *testing*. Berikut langkah-langkah dalam metode RBFNN.

A. Fase Training

1. Inisialisasi nilai *centroid* dari hasil

clustering dengan *K-Means*.

2. Hitung nilai *spread*. Pada penelitian ini nilai *spread* untuk seluruh *hidden neuron* dibuat sama. Menurut Haykin (2009) nilai *spread* untuk fungsi Gaussian adalah seperti pada Persamaan 5.

$$\sigma_j = \frac{d_{max}}{\sqrt{2K}} \tag{5}$$

Keterangan:

σ_j = nilai *spread hidden neuron* ke- j
 d_{max} = jarak maksimum dari pusat kluster yang terbentuk

3. Meneruskan sinyal dari *input layer* ke *hidden layer* dengan fungsi aktivasi *Gaussian*.

$$\phi_j = \exp\left(-\frac{\|X_i - C_j\|^2}{2\sigma_j^2}\right) \tag{6}$$

Keterangan:

ϕ_j = fungsi *Gaussian* pada *hidden neuron* ke- j

$\|X_i - C_j\|^2$ = jarak antara data ke- i dengan nilai *centroid* dari *hidden neuron* ke- j

σ_j^2 = nilai *spread hidden neuron* ke- j

4. Membangun matriks *Gaussian* dari langkah 3. Kemudian mengisi kolom terakhir dengan nilai bias, yaitu 1.

$$G = [\phi_1 \dots \phi_j \ b] \tag{7}$$

Keterangan:

G = matriks *Gaussian*

j = indeks *hidden neuron*

b = bias

5. Perbarui bobot dan bias dengan *pseudoinverse* dari matriks *Gaussian* dan mengalikannya dengan target.

$$W = (G^T G)^{-1} G^T t \tag{8}$$

Keterangan:

W = matriks bobot dari *hidden neuron* ke *output neuron*

G^T = *transpose* dari matrik G

$(G^T G)^{-1}$ = *inverse* dari perkalian G^T dan G

t = matriks target

6. Simpan hasil dari proses *training* yang berupa matrik *centroid*, *spread*, bobot dan bias.

B. Fase Testing

1. Hitung matriks *Gaussian* untuk data uji menggunakan Persamaan 7 dan 8 dengan nilai *centroid* dan *spread* yang didapat dari fase *training*.

2. Hitung *output* RBFNN dengan bobot dan bias yang didapatkan dari fase *training*.

$$y_k = \sum_{j=1}^m \phi_{ij} w_{jk} + b_k \tag{9}$$

Keterangan:

y_k = nilai keluaran pada *output neuron* ke- k
 w_{jk} = bobot dari *hidden neuron* ke- j ke *output neuron* ke- k
 φ_{ij} = fungsi aktivasi *Gaussian* data ke- i *hidden neuron* ke- j
 b_k = bobot bias untuk *output neuron* ke- k

3. Tentukan kelas setiap data dari indeks *output neuron* yang memiliki nilai y_k maksimum untuk data tersebut.


2.6. Evaluasi

Pada penelitian ini, metode evaluasi data yang digunakan adalah *K-Fold Cross Validation*. Pada *k-fold cross validation*, terdapat dua jenis data untuk dilakukan evaluasi, yaitu data latih dan data uji. Data akan dibagi menjadi beberapa lipatan atau *fold*, kemudian setiap *fold* secara bergantian akan menjadi data latih dan data uji. Ketika satu *fold* menjadi data uji, maka sisa *fold* yang lain akan menjadi data latih, begitu seterusnya hingga semua *fold* telah menjadi data uji maupun data latih (Rafaeilzadeh et al., 2009). Kemudian hitung rata-rata akurasi dari 5 *fold* tersebut, untuk menghitung akurasi hasil klasifikasi menggunakan Persamaan 10.

$$akurasi = \frac{jumlah\ data\ benar}{jumlah\ data} \times 100\% \quad (10)$$

3. PERANCANGAN

Pada penelitian ini, metode yang dilakukan terdiri dari beberapa proses, diantaranya adalah normalisasi data, pengelompokan dengan *K-Means* untuk menemukan nilai *center* dan *spread* fungsi *Gaussian* serta *training* dan *testing* RBFNN. Rancangan metode secara umum yang dilakukan pada penelitian ini ditunjukkan pada Gambar 2.



Gambar 2. Diagram Alir RBFNN dengan *K-Means*

4. PENGUJIAN DAN ANALISIS

4.1. Pengujian dan Analisis Maksimum Iterasi *K-Means*

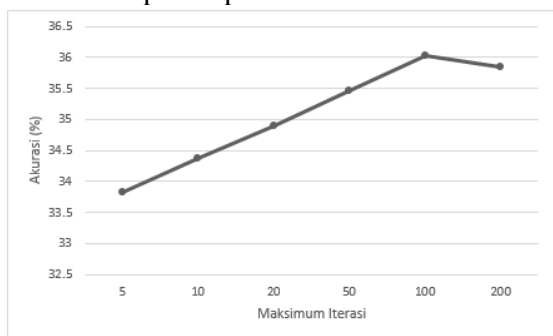
Pada metode *K-Means*, salah satu kriteria berhenti adalah ketika jumlah iterasi telah mencapai batas maksimum iterasi. Pengujian batas maksimum iterasi *K-Means* bertujuan untuk mengetahui pengaruh batas maksimum iterasi dengan akurasi sistem klasifikasi. Akurasi dari hasil klasifikasi, didapatkan dengan menggunakan metode *K-Fold Cross Validation* dengan 5 *fold*. Karena pada *K-Means* inialisasi kluster dilakukan secara acak, maka setiap pengujian dilakukan sebanyak 5 percobaan. Jumlah maksimum iterasi yang diujikan adalah 5, 10, 20, 50, 100 dan 200. Jumlah *hidden neuron* yang digunakan pada pengujian ini adalah 10. Hasil dari pengujian maksimum iterasi *K-Means* ditampilkan pada Tabel 1.

Tabel 1. Hasil Pengujian Maksimum Iterasi

K-Means

Maks. Iterasi	Akurasi Percobaan (%)					Rata-Rata (%)
	1	2	3	4	5	
5	33,38	34,01	35,13	33,53	33,06	33,82
10	35,14	33,85	34,81	34,18	34,34	34,46
20	34,49	34,49	35,61	34,65	35,28	34,91
250	35,46	35,14	35,45	35,61	35,61	35,45
100	37,05	35,94	35,45	35,45	36,25	36,03
200	35,94	35,62	36,66	35,93	36,09	35,85

Dari hasil pengujian batas maksimum iterasi pada Tabel 1, kemudian divisualisasikan dalam grafik untuk mengetahui lebih jelas mengenai hasil pengujian. Grafik rata-rata akurasi dari hasil pengujian batas maksimum iterasi ditampilkan pada Gambar 3.



Gambar 3. Grafik Pengujian Maksimum Iterasi

K-Means

Dari hasil pengujian pada Gambar 2, rata-rata akurasi dari lima percobaan setiap jumlah iterasi pengujian menunjukkan bahwa semakin banyak jumlah maksimum iterasi, maka nilai akurasi juga semakin meningkat hingga batas maksimum iterasi bernilai 100, setelah itu mengalami penurunan 0,18% ketika batas maksimum iterasi bernilai 200. Pada pengujian batas maksimum iterasi bernilai 5, rata-rata akurasi yang dihasilkan memiliki nilai terendah yaitu 33,82%. Sedangkan rata-rata akurasi tertinggi terjadi ketika maksimum iterasi bernilai 100 yaitu 36,03%. Hal ini dapat terjadi karena, apabila iterasi *clustering K-Means* dihentikan ketika masih banyak data yang berada pada kluster yang belum tepat, maka kualitas kluster yang terbentuk juga semakin rendah. Kualitas kluster yang rendah akan berpengaruh terhadap *centroid* yang terbentuk. Sehingga apabila *centroid* tidak membentuk pola data rata-rata kelas dengan baik, maka hasil akurasi klasifikasi juga akan rendah.


4.2. Pengujian dan Analisis Banyak *Hidden Neuron*

Pada RBFNN, banyak *hidden neuron* merepresentasikan banyak kluster yang dibentuk dari proses *K-Means*. Pengujian banyak *hidden neuron* bertujuan untuk mengetahui banyak *hidden neuron* terbaik untuk hasil klasifikasi dan mengetahui pengaruh banyak *hidden neuron* dengan akurasi sistem klasifikasi. Karena pada metode RBFNN terdapat proses *clustering* dengan *K-Means* yang mana inialisasi kluster dilakukan secara acak, maka setiap program dijalankan akan memberikan hasil yang berbeda. Sehingga pengujian banyak *hidden neuron* dilakukan percobaan sebanyak 5 percobaan. Parameter lain yaitu batas iterasi maksimum *K-Means* yang digunakan pada pengujian ini adalah 100 dan evaluasi hasil akurasi menggunakan metode *K-Fold* sebanyak 5 *fold*. Hasil dari pengujian banyak *hidden neuron* ditampilkan pada Tabel 2.

Tabel 2. Hasil Pengujian Banyak *Hidden Neuron*

<i>Hidden Neuron</i>	Akurasi Percobaan (%)					Rata-Rata (%)
	1	2	3	4	5	
2	33,07	33,06	33,38	33,71	33,22	33,29
3	33,85	33,53	33,85	34,16	33,54	33,79
4	34,02	34,33	34,5	33,85	34,64	34,27
5	34,65	34,18	34,49	35,3	35,13	34,75
6	34,97	34,81	35,12	34,97	35,14	35
7	35,77	36,3	36,26	35,61	35,61	35,91
8	36,08	35,45	35,28	35,76	35,61	35,64
9	34,96	35,77	35,14	35,3	35,12	35,26
10	34,82	34,96	34,49	34,5	35,3	34,81
20	33,68	33,7	33,21	33,21	33,84	33,53
50	32,42	32,42	32,42	32,42	32,42	32,42

Dari hasil pengujian batas maksimum iterasi pada Tabel 2, kemudian divisualisasikan dalam grafik untuk mengetahui lebih jelas mengenai hasil pengujian. Grafik rata-rata akurasi dari hasil pengujian batas maksimum iterasi ditampilkan pada Gambar 4.



Gambar 4. Grafik Pengujian Banyak *Hidden Neuron*

Dari hasil pengujian pada Gambar 4, rata-rata akurasi dari lima percobaan setiap jumlah *hidden neuron* menunjukkan bahwa jumlah *hidden neuron* yang memiliki hasil tertinggi yaitu 7 *hidden neuron* dengan rata-rata akurasi sebesar 35,908%. Dari grafik menunjukkan bahwa akurasi akan naik hingga mencapai puncaknya yaitu ketika *hidden neuron* berjumlah 7, setelah itu terus menurun hingga yang terendah ketika jumlah *hidden neuron* 50 dengan akurasi 32,423%. Hal ini terjadi karena dengan jumlah *hidden neuron* 7, menunjukkan bahwa dengan 7 kluster yang terbentuk maka kualitas kluster paling optimal dibandingkan dengan jumlah kluster kurang atau lebih dari 7. Sehingga nilai rata-rata setiap kluster atau *centroid* kluster merepresentasikan nilai yang sesuai dengan rata-rata dari 7 kelas data latih dengan baik. Apabila banyaknya *hidden neuron* terlalu sedikit, maka akan terjadi *underfitting*, yaitu keadaan dimana terlalu sedikit pola data yang dikenali. Sedangkan apabila banyaknya *hidden neuron* terlalu banyak, maka akan terjadi *overfitting*, yaitu keadaan dimana pola data yang dikenali terlalu banyak, sehingga ketika dilakukan pengujian dengan data uji yang belum pernah dikenali polanya, akan diklasifikasikan dengan tidak benar.

4.3. Analisis Global

Pada penelitian ini, terdapat dua jenis pengujian yang dilakukan terkait dengan metode RBFNN. Yang pertama adalah pengujian mengenai pengaruh batas maksimum iterasi pada *K-Means* terhadap akurasi klasifikasi RBFNN. Pada pengujian tersebut menunjukkan bahwa akurasi klasifikasi terus meningkat seiring dengan bertambahnya batas iterasi maksimum untuk metode *K-Means* hingga mencapai puncaknya yaitu dengan batas 100 iterasi. Kemudian dengan melakukan pengujian batas maksimum iterasi di atas 100, yaitu 200, ternyata hasil akurasi menurun sebesar 0,18%. Kemudian pengujian kedua mengenai pengaruh jumlah *hidden neuron* pada jaringan RBF terhadap akurasi klasifikasi. Pada pengujian tersebut menunjukkan bahwa jumlah *hidden neuron* sebanyak 7 menjadi jumlah yang paling optimal. Sedangkan jika *hidden neuron* sejumlah 50, maka akurasi yang dicapai jauh menurun sebesar 3,483%.

Dari dua pengujian yang telah dilakukan, hasil akurasi rata-rata jika parameter yang digunakan adalah parameter optimal dari dua

pengujian, yaitu batas iterasi maksimum sebanyak 100 dan *hidden neuron* sebanyak 7, hanya sebesar 35,908%. Hasil yang didapat ini masih rendah untuk akurasi suatu metode klasifikasi. Faktor yang dapat menyebabkan rendahnya akurasi klasifikasi pada penelitian ini adalah nilai rata-rata fitur pada beberapa kelas cenderung mirip.

Pada penelitian ini data yang digunakan memiliki 7 kelas untuk klasifikasi. Dari ketujuh kelas tersebut, terdapat beberapa kelas yang memiliki karakteristik data yang hampir mirip, terutama pada nilai fitur Oscore, Ascore dan Cscore. Hal ini dapat dibuktikan dengan menghitung nilai rata-rata fitur Oscore, Ascore dan Cscore pada setiap kelas. Hasil rata-rata fitur tersebut pada setiap kelas ditampilkan pada Tabel 3.

Tabel 3. Rata-Rata Fitur Oscore, Ascore dan Cscore

Kelas	Fitur		
	Oscore	Ascore	Cscore
CL0	41,7	44,45	45,23
CL1	43,4	43,92	43,37
CL2	43,97	42,34	41,75
CL3	45,76	42,5	41,56
CL4	46,04	40,88	40,25
CL5	45,45	42,24	38,79
CL6	47,43	42,11	40,64

Dari Tabel 3, pada kolom untuk fitur Oscore, kelas CL1 dan CL2 memiliki nilai rata-rata Oscore yang hampir sama, keduanya memiliki selisih nilai hanya sebesar 0,57. Kemudian untuk kelas CL3, CL4 dan CL5 memiliki nilai rata-rata Oscore yang hampir sama juga, ketiganya memiliki selisih nilai yang tidak lebih dari 0,6. Selanjutnya pada kolom untuk fitur Ascore, kelas CL0 dan CL1 memiliki nilai rata-rata Ascore dengan selisih nilai hanya sebesar 0,53. Kemudian untuk kelas CL2, CL3, CL5 dan CL6 juga memiliki nilai rata-rata Ascore yang hampir sama, keempatnya memiliki selisih nilai tidak lebih dari 0,4. Selanjutnya pada kolom Cscore, kelas CL2 dan CL3 memiliki nilai rata-rata Cscore dengan selisih sebesar 0,19. Kemudian untuk CL4 dan CL6 memiliki selisih nilai hanya sebesar 0,39.

Selanjutnya, dilakukan analisis terhadap rata-rata fitur usia, pendidikan dan *impulsivity* dari setiap kelas, untuk mengetahui keterkaitan ketiga fitur ini dengan perbedaan karakteristik antar kelas. Hasil rata-rata fitur usia, pendidikan dan *impulsivity* setiap kelas ditampilkan pada

Tabel 4.

Tabel 4. Rata-Rata Fitur Usia, Pendidikan dan *Impulsivity*

Kelas	Fitur		
	Usia	Pendidikan	Impulsivity
CL0	3,315	6,094	4,468
CL1	3,522	6,391	5,365
CL2	2,754	6,246	5,861
CL3	2,519	6,13	6,759
CL4	2,375	5,958	7,167
CL5	2,414	5,276	6,759
CL6	2,563	5,25	7,35

Dari hasil rata-rata fitur pada Tabel 4, dapat ditunjukkan bahwa kelas CL0 dan CL1 memiliki nilai yang dekat untuk rata-rata fitur usia yaitu dengan perbedaan 0,207, sedangkan untuk kelas lainnya berada pada rentang yang sama yaitu memiliki rata-rata di bawah 3. Kemudian untuk fitur pendidikan, kelas CL0, CL1, CL2 dan CL3 memiliki kemiripan rata-rata nilai fitur dengan bernilai lebih dari 6. Sedangkan kelas sisanya memiliki rata-rata fitur bernilai kurang dari 6. Untuk fitur *impulsivity* kelas CL0 dan CL1 memiliki nilai rata-rata kurang dari 5,5, sedangkan untuk kelas sisanya memiliki nilai rata-rata di atas 5,5. Dari hasil Tabel 4 dapat ditunjukkan bahwa kelas CL0 dan CL1 memiliki kemiripan terhadap ketiga fitur tersebut begitupula dengan kelas CL2, CL3, CL4, CL5 dan CL6 yang memiliki kemiripan. Dari hasil analisis tersebut, dapat disimpulkan bahwa jumlah kelas yang banyak dan rata-rata nilai atribut setiap kelas hampir sama atau tidak unik, menyebabkan pembentukan model klasifikasi menjadi kurang baik. Sehingga ketika dilakukan pengujian, maka banyak data yang dikelompokkan ke kelas yang tidak sesuai dengan kelas aktual melainkan ke kelas yang memiliki nilai atribut hampir mirip dengan kelas aktualnya. Terlebih lagi, jumlah data setiap kelas tidak merata. Sehingga kelas yang memiliki jumlah data lebih sedikit tidak terklasifikasikan dengan baik. Sebaliknya, kelas yang memiliki jumlah data lebih banyak akan mendominasi hasil klasifikasi.

Berikutnya, dilakukan pengujian dengan mengklasifikasikan data menjadi dua kelas, yaitu CL0 dan CL1 menjadi kelas *Non-user* dan sisanya menjadi kelas *User*. Karena menurut penelitian yang dilakukan oleh Fehrman (2015), pengguna narkoba yang tidak mengonsumsi narkoba dalam sepuluh tahun terakhir dapat

dikategorikan sebagai bukan pemakai atau *non-user*, sedangkan yang masih mengonsumsi narkoba dalam kurun waktu sepuluh tahun terakhir dikategorikan sebagai pemakai atau *user*. Selain itu, terdapat kemiripan terhadap rata-rata nilai fitur untuk kelas CL0 dan CL1 serta CL2, CL3, CL4, CL5 dan CL6 seperti ditampilkan pada Tabel 3 dan Tabel 4. Pengujian ini dilakukan untuk membuktikan pengaruh jumlah kelas dan kemiripan karakteristik tiap kelas yang terlalu dekat dapat memengaruhi hasil akurasi. Hasil pengujian dengan menggunakan dua kelas, *hidden neuron* sebanyak 7 dan batas maksimum iterasi *K-Means* sebanyak 100 ditampilkan pada Tabel 5.

Tabel 5. Hasil Pengujian 2 Kelas

Percobaan	Akurasi
1	70,88%
2	70,73%
3	71,63%
4	72,36%
5	70,99%
Rata-rata	71,32%

Dari hasil percobaan menggunakan dua kelas pada Tabel 5, menunjukkan bahwa rata-rata akurasi yang didapatkan jauh lebih baik dibandingkan dengan menggunakan 7 kelas yaitu dengan rata-rata akurasi sebesar 71,32%. Hal ini mengindikasikan bahwa ketika kriteria data antar kelas memiliki nilai yang jauh berbeda, maka proses *training* menjadi lebih efektif. Proses *training* yang efektif akan menghasilkan pola klasifikasi yang baik sehingga data dapat diklasifikasikan dengan baik pula.

5. KESIMPULAN

Dari hasil penelitian yang telah dilakukan bertahap mulai dari proses perancangan, implementasi, serta pengujian dan analisis mengenai Penentuan Waktu Terakhir Penggunaan Ganja dengan Metode *Radial Basis Function Neural Network* (RBFNN) dapat disimpulkan beberapa hal, diantaranya:

1. Setelah melakukan pengujian terhadap metode RBFNN dengan *K-Means*, didapatkan parameter optimal yang menghasilkan akurasi paling tinggi. Parameter tersebut diantaranya adalah jumlah *hidden neuron* sebanyak 7 *neuron* dan batas iterasi maksimum untuk metode *K-Means* adalah sejumlah 100.

2. Dengan menggunakan dua parameter optimal yaitu 7 *hidden neuron* dan batas iterasi maksimum *K-Means* sebanyak 100, hasil akurasi yang dihasilkan adalah sebesar 35,908%. Hasil akurasi yang rendah ini disebabkan karena jumlah kelas yang banyak tetapi karakteristik data setiap kelas yang hampir sama dan jumlah data setiap kelas yang tidak merata, sehingga proses *training* menjadi tidak efektif. Akibatnya ketika dilakukan pengujian menggunakan data uji, banyak data yang diklasifikasikan cenderung ke kelas yang memiliki data paling banyak atau ke kelas yang memiliki karakteristik yang hampir sama dengan data uji tersebut. Penggabungan kelas yang memiliki karakteristik data yang sama yaitu kelas CL0 dan CL1 menjadi kelompok *non-user* dan CL2, CL3, CL4, CL5, CL6 menjadi kelompok *user*, terbukti mampu memberikan hasil akurasi yang jauh lebih baik, yakni sebesar 71,32%.

6. DAFTAR PUSTAKA

- Azmi, Fadhilah, 2016. Analisis Learning Jaringan RBF (Radial Basis Function Network) pada Pengenalan Pola Alfanumerik. *Jurnal TIMES*, 5(2), p.32-34.
- Badan Narkotika Nasional Baddoka Makassar, 2017. *Rehabilitasi*. [online] Badan Narkotika Nasional Baddoka Makassar. Tersedia di: <<http://rehabbaddoka.com/>> [Diakses 30 September 2018]
- Badan Narkotika Nasional Republik Indonesia, 2017. *Data Pendukung Press Release Akhir Tahun 2017*. [pdf] Badan Narkotika Nasional Republik Indonesia. Tersedia di: <http://www.bnn.go.id/_multimedia/document/20180208/lampiran_press_releas_e_akhir_tahun_2017_fin-20180208110343.pdf> [Diakses 18 Juli 2018]
- Chamidah, N., Wiharto, Salamah, U., 2012. Pengaruh Normalisasi Data pada Jaringan Syaraf Tiruan Backpropagasi Gradient Descent Adaptive Gain (BPGDAG) untuk Klasifikasi. *Jurnal ITSMAR*, 1(1), p.28-33.
- Dillak, R. Y., Bintiri, M. G., Sina, D. R., 2012. *Penerapan Jaringan Saraf Tiruan Radial Basis Function pada Diagnosa dan Medical Prescription Penyakit Jantung*. Dalam: Seminar Nasional Informatika, 2012. Yogyakarta, 30 Juni 2012.
- Fehrman, E., Muhammad, A.K., Mirkes, E.M., Egan, V. & Gorban, A.N., 2017. *The Five Factor Model of Personality and Evaluation of Drug Consumption Risk*. Cornell University [online] Tersedia melalui: Cornell University Library <<https://arxiv.org/abs/1506.06297>> [Diakses 12 Juli 2018]
- Fehrman, E., Muhammad, A.K., Mirkes, E.M., Egan, V. & Gorban, A.N., 2017. *Drug Consumption (Quantified) Dataset*. UCI Machine Learning [online] Tersedia melalui: UCI Machine Learning Repository <[https://archive.ics.uci.edu/ml/datasets/Drug+consumption+\(quantified\)](https://archive.ics.uci.edu/ml/datasets/Drug+consumption+(quantified))> [Diakses 12 Juli 2018]
- Feist, J., Feist, G.J., 2009. *Theories of Personality*. New York: Plenum Press.
- Friedman, H.S., Schustack, M.W., 2012. *Personality: Classic Theories and Modern Research*. Boston: Pearson.
- Humas Badan Narkotika Nasional, 2011. *Ulasan Tentang Ganja*. [online] DEDI Humas BNN. Tersedia di: <<http://dedihumas.bnn.go.id/read/section/artikel/2012/04/02/354/ulasan-tentang-ganja>> [Diakses 15 Agustus 2018]
- Kuntjoro, Dwi A., Setiawan, Budi D., Perdana, Rizal S., 2018. *Algoritme Genetika untuk Optimasi K-Means Clustering dalam Pengelompokan Data Tsunami*. S1. Universitas Brawijaya.
- Mirawanti, Y., Ulama, Brodjol S. S., 2012. *Perbandingan Metode Regresi Logistik Ordinal dengan Jaringan Saraf Tiruan Fungsi Radial Basis Studi Kasus Klasifikasi Rumahtangga Miskin Kota Pasuruan Tahun 2008*. S2. Institut Teknologi Sepuluh Nopember.
- Partodiharjo, Subagyo, 2006. *Kenali Narkoba dan Musuhi Penyalahgunaannya*. Jakarta: Erlangga.
- Patton, J.H., Stanford, M.S., Barrat, E.S., 1995. Factor Structure of The Barrat Impulsiveness Scale. *Journal of Clinical Psychology*, 51, p.764-768.
- Rafaeilzadeh, P., Tang, L., Liu, H., 2009. Cross-

Validation. *Encyclopedia of Database Systems*, p.532-538.

Santosa, S., Widjanarko, A., Supriyanto, C.,
2016. Model Prediksi Ginjal Kronik
Menggunakan Radial Basis Function.
Jurnal Pseudocode, 3(2), p.163-170.