

Tersedia online di [www.journal.unipdu.ac.id](http://www.journal.unipdu.ac.id)**Unipdu****Terakreditasi S2 – SK No. 34/E/KPT/2018**Halaman jurnal di [www.journal.unipdu.ac.id/index.php/register](http://www.journal.unipdu.ac.id/index.php/register)

## Kombinasi *Synthetic Minority Oversampling Technique (SMOTE)* dan *Neural Network Backpropagation* untuk menangani data tidak seimbang pada prediksi pemakaian alat kontrasepsi implan

### ***Combination of Synthetic Minority Oversampling Technique (SMOTE) and Backpropagation Neural Network to handle imbalanced class in predicting the use of contraceptive implants***

Mustaqim Mustaqim <sup>a</sup>, Budi Warsito <sup>b</sup>, Bayu Surarso <sup>c</sup>

<sup>a</sup> Sistem Informasi, Universitas Diponegoro, Semarang, Indonesia

<sup>b</sup> Statistika, Universitas Diponegoro, Semarang, Indonesia

<sup>c</sup> Matematika, Universitas Diponegoro, Semarang, Indonesia

email: <sup>a</sup> dimasthan@gmail.com, <sup>b</sup> budiwrst2@gmail.com, <sup>c</sup> bayusurarso@yahoo.com

---

#### INFO ARTIKEL

---

**Sejarah artikel:**

Menerima 26 April 2019

Revisi 6 Agustus 2019

Diterima 11 September 2019

Online 12 September 2019

**Kata kunci:**

backpropagation

imbalance class

implan

prediksi

SMOTE

**Keywords:**

backpropagation

imbalance class

implant

predict

SMOTE

---

**Style APA dalam menyajikan artikel ini:**

Mustaqim, M., Warsito, B., &amp; Surarso, B. (2019).

Kombinasi Synthetic Minority Oversampling Technique (SMOTE) dan Neural Network Backpropagation untuk

---

#### ABSTRAK

---

Kegagalan akibat pemakaian alat kontrasepsi implan merupakan terjadinya kehamilan pada wanita saat menggunakan alat kontrasepsi secara benar. Kegagalan pemakaian kontrasepsi implan tahun 2018 secara nasional sejumlah 1.852 pengguna atau 4% dari 41.947 pengguna. Rasio angka kegagalan dan keberhasilan pemakaian kontrasepsi implan yang cenderung tidak seimbang (*imbalance class*) membuatnya sulit diprediksi. Ketidakseimbangan data terjadi jika jumlah data suatu kelas lebih banyak dari data lain. Kelas mayor merupakan jumlah data yang lebih banyak, sedangkan kelas minor jumlahnya lebih sedikit. Algoritma klasifikasi akan mengalami penurunan performa jika menghadapi kelas yang tidak seimbang. *Synthetic Minority Oversampling Technique (SMOTE)* digunakan untuk menyeimbangkan data kegagalan pemakaian kontrasepsi implan. SMOTE menghasilkan akurasi yang baik dan efektif daripada metode *oversampling* lainnya dalam menangani *imbalance class* karena mengurangi *overfitting*. Data yang sudah seimbang kemudian diprediksi dengan *Neural Network Backpropagation*. Sistem prediksi ini digunakan untuk mendeteksi apakah seorang wanita mengalami kehamilan atau tidak jika menggunakan kontrasepsi implan. Penelitian ini menggunakan 300 data, terdiri dari 285 data mayor (tidak hamil) dan 15 data minor (hamil). Dari 300 data dibagi menjadi dua bagian, 270 data latih dan 30 data uji. Dari 270 data latih, terdapat 13 data latih minor dan 257 data latih mayor. Data latih minor pada data latih diduplikasi sebanyak data pada kelas mayor sehingga jumlah data latih menjadi 514, terdiri dari 257 data mayor, 13 data minor asli, dan 244 data minor buatan. Sistem prediksi menghasilkan nilai akurasi sebesar 96,1% pada *epoch* ke-500 dan 1.000. Implementasi kombinasi SMOTE dan *Neural Network Backpropagation* terbukti mampu memprediksi pada *imbalance class* dengan hasil prediksi yang baik.

---

#### ABSTRACT

---

The failed contraceptive implant is one of the sources of unintended pregnancy in women. The number of users experiencing contraceptive-implant failure in 2018 was 1,852 nationally or 4% out of 41,947 users. The ratio between failure and success rates of contraceptive implant, which tended to be unbalanced (*imbalance class*), made it difficult to predict. *Imbalance class* will occur if the amount of data in one class is bigger than that in other classes. Major classes represent a bigger amount of data, while minor classes are

menangani data tidak seimbang pada prediksi pemakaian alat kontrasepsi implan. Register: Jurnal Ilmiah Teknologi Sistem Informasi, 116-127.

*smaller ones. The imbalance class will decrease the performance of the classification algorithm. The Synthetic Minority Oversampling Technique (SMOTE) was used to balance the data of the contraceptive implant failures. SMOTE resulted in better and more effective accuracy than other oversampling methods in handling the imbalance class because it reduced overfitting. The balanced data were then predicted using Backpropagation neural networks. The prediction system was used to detect if a woman using a contraceptive implant was pregnant or not. This study used 300 data, consisting of 285 major data (not pregnant) and 15 minor data (pregnant). Of 300 data, two groups of data were formed: 270 training data and 30 testing data. Of 270 training data, 13 were minor training data and 257 were major training data. The minor training data in the training data were duplicated as much as the number of data in major classes so that the total training data became 514, consisting of 257 major data, 13 original minor data, and 244 artificial minor data. The prediction system resulted in an accuracy of 96.1% on the 500th and 1,000th epochs. The combination of SMOTE and Backpropagation Neural Network was proven to be able to make a good prediction result in imbalance class.*

© 2019 Register: Jurnal Ilmiah Teknologi Sistem Informasi. Semua hak cipta dilindungi undang-undang.

## 1. Pendahuluan

Kegagalan akibat pemakaian alat kontrasepsi implan merupakan terjadinya kehamilan pada wanita saat menggunakan alat kontrasepsi secara benar. Kegagalan pemakaian alat kontrasepsi implan setiap tahunnya cenderung di bawah 5% dari angka keberhasilannya, seperti contoh pada 2018, angka kegagalan secara nasional sejumlah 1.852 pengguna atau 4% dari total pengguna kontrasepsi implan yang berhasil sebanyak 41.947 pengguna (BKKBN, 2013). Rasio angka kegagalan dan keberhasilan pemakaian kontrasepsi implan yang cenderung tidak seimbang membuatnya sulit diprediksi. Penelitian *imbalance class* (kelas tidak seimbang) telah banyak dilakukan, antara lain Mutrofin, Mu'alif, Ginardi, dan Faticah (2019) yang mengusulkan penerapan algoritma k-Nearest Neighbor pada kasus *Educational Data Mining* serta Liu, Li, dan Zhou (2013) yang mengusulkan bahwa mengatasi masalah *multiclass* lebih sulit dari dua kelas.

Kelas dikatakan tidak seimbang jika rasio objek suatu kelas data lebih banyak dibandingkan dengan kelas lain. Kelas mayor merupakan jumlah data yang lebih banyak, sedangkan kelas minor yang jumlahnya lebih sedikit. Zhu, Lin, dan Liu (2017) mengusulkan metode *Synthetic Minority Oversampling Technique* (SMOTE) sebagai solusi untuk menangani *imbalance class*. Penerapan algoritma yang mengabaikan *imbalance class* akan menghasilkan prediksi yang baik pada kelas mayor, sedangkan kelas minor diabaikan (Chen, Fang, Shang, & Tang, 2018). Algoritma klasifikasi akan mengalami penurunan performa jika menghadapi *imbalance class* (García, Sánchez, & Mollineda, 2012).

Algoritma klasifikasi yang paling populer digunakan dalam pengklasifikasian ialah *Neural Network* (NN), *Logistic Regression* (LR), *Decision Tree* (DT), dan *Support Vector Machine* (SVM). NN atau Jaringan Saraf Tiruan (JST) merupakan model algoritma komputasi intensif yang mengubah input menjadi *output* menggunakan jaringan sederhana yang saling terhubung dengan elemen proses yang disebut neuron dan unit/*node* (Thammasiri, Delen, Meesad, & Kasap, 2014). Konsep dari LR menguji hubungan linear antara variabel dependen dan independen. DT bekerja dengan mengubah data menjadi pohon dan aturan-aturan keputusan. DT bekerja dengan cara melakukan *break down* keputusan yang kompleks menjadi simple, sehingga menghasilkan keputusan yang menggambarkan solusi dari permasalahan. Prinsip dari SVM merupakan klasifikasi linier, kemudian dikembangkan untuk mengatasi masalah nonlinier dengan cara memasukkan *kernel trick* pada ruang kerja berdimensi tinggi.

Penelitian terkait perbandingan 4 kinerja algoritma klasifikasi dalam menangani *imbalance class* telah dilakukan dengan nilai akurasi: NN dengan SMOTE 85%, DT dengan SMOTE 89%, LR dengan SMOTE 80%, dan SVM 90% (Thammasiri, Delen, Meesad, & Kasap, 2014). *Backpropagation* adalah model yang biasa digunakan untuk memprediksi penyakit dan gejala-gejalanya.

Implementasi NN *Backpropagation* dalam bidang kesehatan, di antaranya deteksi *Tuberculosis* (TBC) (Purnamasari, Dwijanto, & Sugiharti, 2013), demam berdarah (Widodo, Rachman, & Amelia, 2014), kanker serviks (Susanto, 2012) masing-masing dengan tingkat akurasi 100%; 74%; dan 95,14%.

Berdasarkan latar belakang tersebut, penelitian ini menggunakan metode kombinasi *Synthetic Minority Oversampling Technique* (SMOTE) dan *Neural Network Backpropagation* untuk memprediksi keberhasilan pemakaian alat kontrasepsi implan.

## 2. State of the Art

Permasalahan ketidakseimbangan kelas (*imbalance class*) adalah kondisi pada *dataset* kelas dengan perbedaan tinggi. Masalah ini sangat memengaruhi kinerja prediksi model algoritma klasifikasi karena model cenderung memprediksi dengan tingkat akurasi tinggi pada kelas yang lebih besar jumlahnya (Sanguanmak & Hanskunatai, 2016). Model yang dibuat dengan *imbalance class* akan menghasilkan prediksi kelas minor yang rendah. Informasi yang ada pada kelas mayor mendominasi kelas minor, sehingga informasi pada kelas minor cenderung diabaikan dalam sistem klasifikasi (Jian, Gao, & Ao, 2016). Untuk menangani *imbalance class* pada suatu *dataset*, ada dua pendekatan, yaitu level algoritma dan level data. Pada level algoritma, proses berjalan dengan menyesuaikan alur algoritma yang ada melalui pengklasifikasian agar data mayor dan minor seimbang. Pada pendekatan level data, ada macam-macam teknik *resampling* dan duplikasi data untuk menyeimbangkan data kelas minor pada data latih (Zhang, Liu, Gong, & Jin, 2011). Macam-macam teknik *resampling* adalah *undersampling* dan *oversampling*. *Undersampling* merupakan teknik menyeimbangkan kelas dengan mengurangi *instance* pada kelas mayor. *Undersampling* akan mengurangi risiko hilangnya informasi penting dalam pengambilan keputusan dari *machine learning*. *Oversampling* merupakan teknik menyeimbangkan kelas dengan menduplikasi kelas minor secara acak. Kekurangan dari *oversampling* yaitu akan mengalami *overfitting* karena duplikasi kelas minor sama persis (Yap, et al., 2014). Metode SMOTE ditawarkan untuk menangani *overfitting*, yaitu dengan memanfaatkan ketetanggaan terdekat dari jumlah *oversampling* yang dikehendaki.

### 2.1. Imbalance Class

Ketidakseimbangan kelas pada *dataset* kecil sangat merugikan dalam penelitian di *data mining*, karena *machine learning* menghadapi kesulitan saat mengklasifikasikan kelas minoritas dengan benar. Kelas dikatakan tidak seimbang, jika rasio objek suatu kelas data lebih banyak dibandingkan dengan kelas lain. Kelas mayor merupakan kelas yang jumlah datanya lebih banyak, sedangkan kelas minor yang jumlah datanya lebih sedikit. Kebanyakan algoritma berasumsi bahwa distribusi kelas yang diuji sudah seimbang, sehingga salah dalam mengklasifikasi nilai pada tiap kelas. Menurut (Li & Sun, 2012), jika proporsi sampel kelas minoritas kurang dari 35% dari *dataset*, dikategorikan sebagai *imbalance class*. Sementara menurut (He & Ma, 2013), kelas sudah dapat dikatakan *imbalance class*, jika perbandingan data mayor dua kali ditambah satu dari kelas minornya ( $2n + 1$ ).

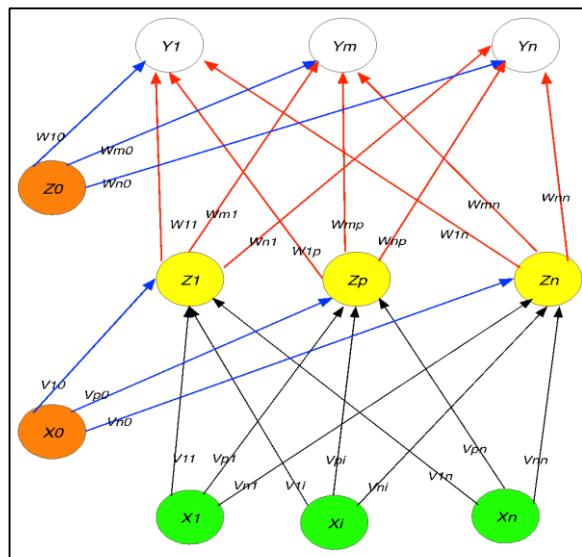
### 2.2. Synthetic Minority Oversampling Technique (SMOTE)

Pendekatan *Synthetic Minority Oversampling Technique* (SMOTE) merupakan teknik untuk menyeimbangkan kelas yang berbeda dengan *oversampling*. Pendekatan SMOTE membuat duplikasi data minor agar seimbang dengan data mayor. Teknik SMOTE mampu mengurangi *overfitting* yang merupakan kelemahan dari teknik *oversampling* (Shen, Lin, & Huang, 2016). Data duplikasi atau sintesis dibuat berdasarkan faktor *k*-tetangga terdekat (*k*-Nearest Neighbor).

### 2.3. Backpropagation

Jaringan Saraf Tiruan (JST) merupakan model *algorithmic* komputasi intensif yang mengubah input menjadi *output* menggunakan jaringan sederhana yang saling terhubung dengan elemen proses yang disebut neuron dan unit/node (Thammasiri, Delen, Meesad, & Kasap, 2014). Pemodelan menggunakan JST dapat menghasilkan analisis lebih baik dan efektif dalam prediksi (Chen, et al., 2014). Hal ini dikarenakan model mampu bekerja dengan baik pada data nonlinier dan data seri. *Backpropagation* merupakan salah satu model JST atau *Neural Network* (NN) *multilayer*. Struktur *Backpropagation* yang umum digunakan adalah *Multilayer Perceptron* (MLP). Dalam jaringan MLP, ada tiga jaringan neuron, yaitu *input*, *hidden*, dan *output* yang dihubungkan oleh bobot. JST *Backpropagation* melatih jaringan untuk memperoleh keseimbangan dalam mengenali pola yang digunakan selama pelatihan dan merespons secara benar terhadap pola masukan yang serupa, tetapi tidak sama dengan pola pelatihan (Gholami, Cai, & Brennan, 2013). Algoritma pelatihan *Backpropagation* dibagi menjadi tiga fase (Sermpinis, Dunis, Laws, & Stasinakis, 2012), yaitu 1) Fase propagasi maju (*feedforward*) pola masukan. Pola masukan dihitung maju dari lapisan (layer) masukan hingga layer keluaran dengan fungsi aktivasi yang ditentukan; 2) Fase propagasi mundur (*Backpropagation*) dimulai dari garis yang berhubungan langsung dengan unit-unit pada layer keluaran; 3) Fase perubahan nilai bobot, perubahan bobot suatu

garis didasarkan pada faktor  $\delta$  neuron di layer atasnya. Ketiga fase tersebut diulang-ulang hingga kondisi penghentian dipenuhi. Umumnya, kondisi penghentian berupa jumlah iterasi (*epoch*) atau kesalahan. Arsitektur standar *Backpropagation* ditunjukkan pada Gambar 1.

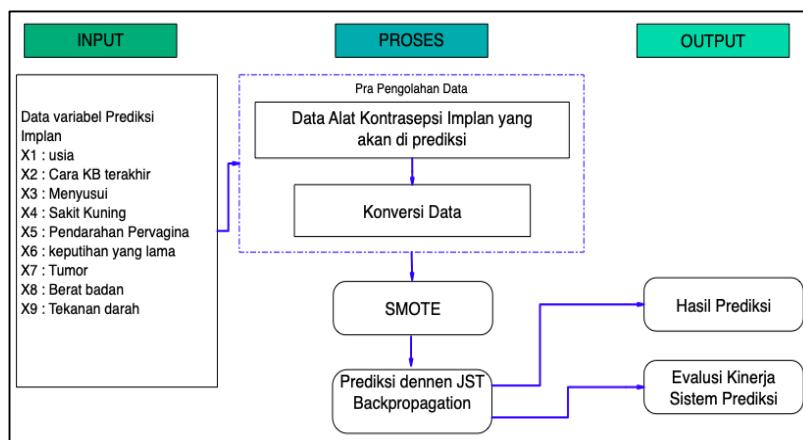


Gambar 1. Arsitektur standar Backpropagation

### 3. Metode Penelitian

#### 3.1. Kerangka Kerja Sistem Prediksi

Penelitian prediksi pemakaian alat kontrasepsi implan menggunakan kombinasi SMOTE dan NN *Backpropagation* dimulai dari input data dari variabel implan  $x_1$  sampai  $x_9$  dilakukan prapengolahan dengan mengonversi data menjadi angka-angka, sehingga memudahkan proses komputasi dalam sistem. Data yang telah dikonversi kemudian dibagi menjadi dua bagian, yaitu data *testing* dan *training*. Pada data *training* dilakukan proses duplikasi data kelas minor untuk menyeimbangkan dengan data kelas mayor melalui metode SMOTE, sedangkan pada data *testing* tidak dilakukan duplikasi data. Setelah data *training* telah seimbang, dilakukan proses *training* dan *testing* dengan NN *Backpropagation* untuk mendapatkan nilai akurasi yang terbaik. *Output* yang dihasilkan berupa hasil prediksi pemakaian alat kontrasepsi implan. Dalam hal ini, sistem akan mendeteksi seorang wanita bila menggunakan kontrasepsi implan dengan ciri-ciri riwayat pemeriksaan medis akan berhasil (tidak hamil) atau gagal (hamil). Evaluasi sistem prediksi menggunakan *confusion matrix* dan *10-fold cross validation*. Konsep kerangka kerja sistem ditunjukkan pada Gambar 2.



Gambar 2. Kerangka kerja sistem prediksi implan

#### 3.2. Data dan Variabel Penelitian

Data penelitian diambil dari kartu status peserta Keluarga Berencana K4/KB yang berasal dari hasil survei Petugas Lapangan Keluarga Berencana (PLKB) Badan Kependudukan dan Keluarga Berencana

Nasional (BKKBN). Dari kartu K4/KB tersebut, diambil 9 variabel penentu, yaitu  $x_1$  sampai  $x_9$ . Data yang digunakan untuk prediksi alat kontrasepsi implan sebanyak 300 data, 285 data berhasil (tidak hamil) dengan target ( $T = 0$ ) dan 15 data gagal (hamil) dengan target ( $T = 1$ ). Variabel  $x_1$  sampai  $x_9$  dengan nilai input dan target prediksi ditunjukkan pada Tabel 1.

Tabel 1. Variabel dan nilai input target prediksi

Variabel	Deskripsi	Kategori	*Nilai input
Usia ( $x_1$ )	Usia saat dipasangi implan	19–30 Tahun	0
		31–40 Tahun	0
		41–49 Tahun	0,5
Cara KB terakhir ( $x_2$ )	Cara KB yang terakhir digunakan	Pil	0
		Suntik	0,3
Menyusui ( $x_3$ )	Saat dipasang kontrasepsi implan	Ya	0
		Tidak	1
Sakit kuning ( $x_4$ )	Riwayat sakit kuning	Ya	1
		Tidak	0
Perdarahan pervaginam ( $x_5$ )	Riwayat perdarahan pervaginam	Ya	0,5
		Tidak	0
Keputihan lama ( $x_6$ )	Riwayat keputihan lama	Ya	0,5
		Tidak	0
Tumor (payudara, rahim) ( $x_7$ )	Riwayat tumor (payudara, rahim, dan indung telur)	Ya	0,5
		Tidak	0
Berat badan ( $x_8$ )	Berat badan pasien saat dipasangi implan	< 40 Kg	0
		40–55 kg	0
		56–64 kg	0
		65–70 kg	0,5
		> 70 kg	1
Tekanan darah ( $x_9$ )	Tekanan darah saat pasien dipasangi kontrasepsi implan	< 90/60 mmHg	0
		90–120/60–70 mmHg	0
		121–139/80–89 mmHg	0
		140–159/90–99 mmHg	0,5
		160–179/100–119 mmHg	1
Target ( $T$ )	Apakah pasien gagal (hamil)/ berhasil (tidak hamil)	>180/120 mmHg	1
		Gagal (hamil)	1
		Berhasil (tidak hamil)	0

\*Sumber: Tim pakar medis yang berkompeten dalam bidang Keluarga Berencana

Data yang digunakan untuk prediksi kontrasepsi implan kemudian dikonversi dengan acuan Tabel 1. Konversi dilakukan untuk mengubah data kualitatif yang terdapat pada variabel menjadi angka untuk memudahkan dalam sistem komputasi. Data yang telah dikonversi kemudian dibagi menjadi dua bagian, yaitu data *testing* dan *training*. Pada data *training*, dilakukan proses duplikasi data minor untuk menyeimbangkan dengan data pada kelas mayor.

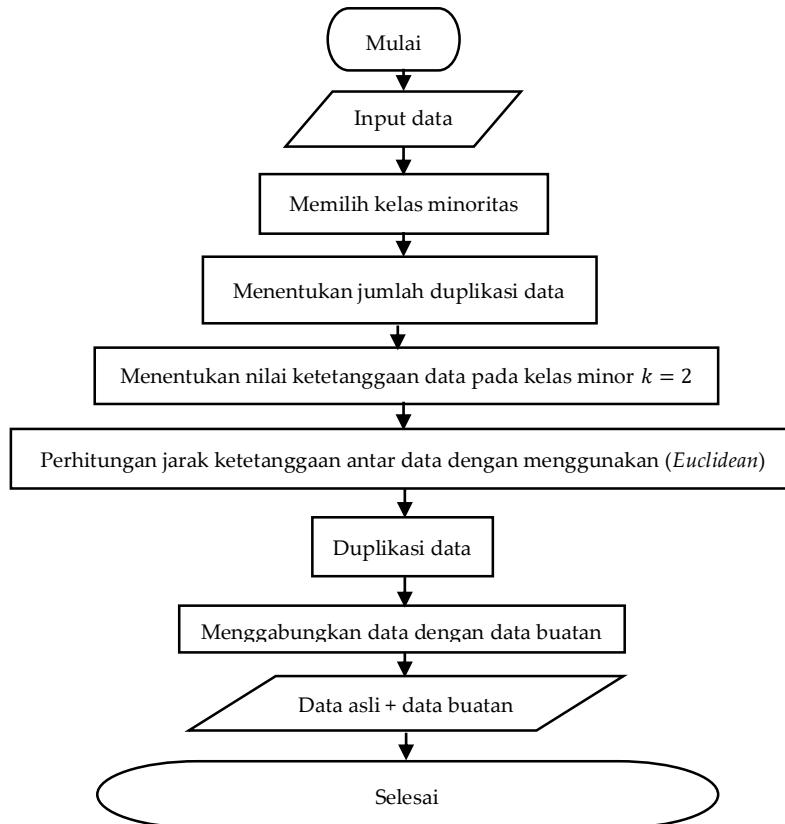
Dari 300 data, 285 data mayor/berhasil ( $T = 0$ ) dan 15 data minor/gagal ( $T = 1$ ). Data kelas mayor dan minor tersebut kemudian sistem secara acak membagi menjadi 2 bagian, yaitu data *training* dan *testing* dengan rincian: data *testing* implan 30 data, 28 data mayor/berhasil ( $T = 0$ ), 2 data minor/gagal ( $T = 1$ ) dan data *training* implan sebanyak 270 data, 257 data mayor ( $T = 0$ ), 13 data minor/gagal ( $T = 1$ ). Data *training* kelas minor sebanyak 13 data dilakukan duplikasi data dengan SMOTE menjadi 244 data minor buatan (*synthetic*), sehingga data kelas minor menjadi 257 data atau setara data kelas mayor, dengan rincian 13 data minor asli dan 244 data minor buatan. Alur proses duplikasi data kelas minor dengan metode SMOTE ditunjukkan pada Gambar 3. Data *testing* dan data *training* yang sudah seimbang kemudian diprediksi dengan menggunakan NN *Backpropagation*.

### 3.3. Algoritma Neural Network Backpropagation

Algoritma pelatihan *Backpropagation* diuraikan sebagai berikut (Budayawan, Yuhandri, & Nurcahyo, 2019):

- Step 0: Tentukan semua nilai bobot dengan bilangan *random* kecil,  $epoch = 1$ ,  $learning rate (\alpha)$ , tentukan jumlah *hidden layer* (Z) dan tentukan kondisi penghentian. Penghentian merupakan maksimum *epoch* dan nilai akurasi.
- Step 1: Jika *epoch* dan nilai akurasi belum sesuai, lakukan Step 2 sampai Step 9.

- c. Step 2: Setiap pasang data latih ( $1 - \alpha$ , di mana  $\alpha$  merupakan jumlah data latih), lakukan Step 3 sampai Step 8.



Gambar 3. Alur proses duplikasi data dengan SMOTE

- d. Fase I: Propagasi maju

Step 3: Tiap unit input menerima sinyal dan meneruskannya ke *hidden layer* di atasnya.

Step 4: Hitung semua *output* pada *hidden layer*  $z_p$  ( $p = 1, 2, \dots, n$ ) dengan Persamaan 2,  

$$z_{net,p} = v_{p0} + \sum_{i=1}^n x_i v_{pi} \quad (1)$$

Persamaan 1 digunakan untuk menghitung Persamaan 2,

$$z_p = f(z_{net,p}) = \frac{1}{1+e^{-z_{net,p}}} \quad (2)$$

Step 5: Hitung semua *output* jaringan di unit  $y_m$  ( $m = 1, 2, \dots, n$ ) dengan Persamaan 4,

$$y_{net,m} = w_{m0} + \sum_{p=1}^P z_p w_{mp} \quad (3)$$

Persamaan 3 digunakan untuk menghitung Persamaan 4,

$$y_m = f(y_{net,m}) = \frac{1}{1+e^{-y_{net,m}}} \quad (4)$$

- e. Fase II: Propagasi mundur

Step 6: Hitung faktor  $\delta$  unit keluaran berdasarkan kesalahan di setiap unit keluaran  $\delta_m$  ( $m = 1, 2, \dots, n$ ) menggunakan Persamaan 5,

$$\delta_m = (t_m - y_m) f'(y_{net,m}) = (t_m - y_m) y_m (1 - y_m) \quad (5)$$

Hitung perubahan bobot  $\Delta w_{mp}$  dengan *learning rate* ( $\alpha$ ) dengan Persamaan 6,

$$\Delta w_{mp} = \alpha \delta_m z_p \quad m = 1, 2, \dots, n \text{ dan } p = 0, 1, \dots, n. \quad (6)$$

Step 7: Hitung faktor  $\delta$  unit tersembunyi berdasarkan kesalahan di tiap unit tersembunyi  $\delta_p$  ( $p = 1, 2, \dots, n$ ) dengan Persamaan 8,

$$\delta_{net,p} = \sum_{m=1}^n \delta_m w_{mp} \quad (7)$$

Persamaan 7 digunakan untuk menghitung Persamaan 8,

$$\delta_p = \delta_{net,p} f'(z_{net,p}) = \delta_{net,p} z_p (1 - z_p) \quad (8)$$

Hitung suku perubahan bobot  $v_{pi}$  dengan laju percepatan  $\alpha$  dengan Persamaan 9,

$$\Delta v_{pi} = \alpha \delta_p x_i \quad p = 1, 2, \dots, n; i = 0, 1, \dots, n \quad (9)$$

## f. Fase III: Perubahan bobot

Step 8: Hitung semua perubahan bobot garis yang menuju ke unit keluaran dengan Persamaan 10,

$$w_{mp} (\text{baru}) = w_{mp} (\text{sekarang}) + \Delta w_{mp} \quad m = 1, 2, \dots, n; p = 0, 1, \dots, n \quad (10)$$

Perubahan bobot garis yang menuju ke unit tersembunyi dengan menggunakan Persamaan 11,

$$v_{mp} (\text{baru}) = v_{mp} (\text{sekarang}) + \Delta v_{pi} \quad p = 1, 2, \dots, n; i = 0, 1, \dots, n \quad (11)$$

g. Step 9: Perbaharui nilai *epoch* dengan Persamaan 12,

$$\text{epoch} = \text{epoch} + 1 \quad (12)$$

Hitung nilai akurasi dengan Persamaan 13,

$$\text{akurasi} = \frac{\text{jumlah data latih yang dikenali}}{\text{jumlah seluruh data latih}} \times 100\% \quad (13)$$

**3.4. Evaluasi Sistem Prediksi**

Penelitian ini menggunakan *confusion matrix* dan *10-fold cross validation* untuk evaluasi sistem prediksi. *Confusion matrix* digunakan dalam mengevaluasi kinerja suatu algoritma klasifikasi dengan cara membandingkan hasil prediksi yang dilakukan oleh sistem dengan hasil prediksi yang seharusnya seperti pada Tabel 2. TP (*True Positive*) merupakan data positif yang terdeteksi dengan benar, TN (*True Negative*) merupakan jumlah data negatif yang terdeteksi dengan benar, FP (*False Positive*) merupakan data negatif yang terdeteksi sebagai data positif, dan FN (*False Negative*) merupakan jumlah data kebalikan dari FP. Untuk mengukur kinerja *confusion matrix* digunakan 3 persamaan untuk mencari nilai akurasi dengan menggunakan Persamaan 14, presisi dengan menggunakan Persamaan 15, dan *recall* dengan menggunakan Persamaan 16.

1	2	3	4	5	6	7	8	9	10
1	2	3	4	5	6	7	8	9	10
1	2	3	4	5	6	7	8	9	10
1	2	3	4	5	6	7	8	9	10
1	2	3	4	5	6	7	8	9	10
1	2	3	4	5	6	7	8	9	10
1	2	3	4	5	6	7	8	9	10
1	2	3	4	5	6	7	8	9	10
1	2	3	4	5	6	7	8	9	10
1	2	3	4	5	6	7	8	9	10
		Data Pelatihan							
		Data Pengujian							

Gambar 4. Skema 10-fold cross validation

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FN+FP} \times 100 \% \quad (14)$$

$$\text{Presisi} = \frac{TP}{TP+FP} \times 100 \% \quad (15)$$

$$\text{Recall} = \frac{TP}{TP+FN} \times 100 \% \quad (16)$$

Penelitian ini juga menggunakan metode *10-fold cross validation* untuk evaluasi sistem prediksi. Prinsip evaluasi dengan *10-fold cross validation* dengan membagi *dataset* menjadi 10 bagian, 1 bagian data uji dan 9 bagian lainnya sebagai data latih. *Dataset* yang telah dibagi menjadi 2 bagian tersebut

dilakukan pelatihan sebanyak 10 kali, kemudian hasilnya dihitung nilai rata-rata akurasinya. Gambar 4 merupakan ilustrasi dari *10-fold cross validation*.

Tabel 2. Confusion matrix

		<i>Prediction</i>	
		<i>Positive</i>	<i>Negative</i>
<i>Actual</i>	<i>Positive</i>	TP	FN
	<i>Negative</i>	FP	TN

## 4. Hasil dan Pembahasan

### 4.1. Hasil Pelatihan Sistem Prediksi

Hasil pelatihan sistem prediksi dengan NN *Backpropagation* menggunakan 514 data *training* yang terdiri dari 257 mayor, 13 data minor asli dan 244 data minor buatan. Model NN *Backpropagation* menggunakan arsitektur terbaik berdasarkan hasil latih, yaitu 3 *hidden layer*, *learning rate* ( $\alpha$ ) = **0,1**; Momentum = **0,9** dan data dilakukan 5 kali percobaan *training* pada **10, 50, 100, 500**, dan **1.000 epoch** didapat nilai akurasi terbaik sebesar 96,4% pada **500** dan **1.000 epoch**. Beberapa skenario percobaan *training* untuk mendapatkan akurasi terbaik ditunjukkan pada Tabel 3.

Tabel 3. Hasil pelatihan sistem prediksi implan

<i>Epoch</i>	Lr ( $\alpha$ )	Data <i>Training</i>	Jumlah <i>Hidden Layer</i>	Momentum	Akurasi
10	0,1	514	1	0,9	91,5%
50	0,1	514	1	0,9	94%
100	0,1	514	1	0,9	95,3%
500	0,1	514	1	0,9	95,4%
1.000	0,1	514	1	0,9	95,4%
10	0,1	514	2	0,9	92%
50	0,1	514	2	0,9	93%
100	0,1	514	2	0,9	93,3%
500	0,1	514	2	0,9	94,5%
1.000	0,1	524	2	0,9	95,3%
10	0,1	524	3	0,9	92%
50	0,1	524	3	0,9	95%
100	0,1	524	3	0,9	96,3%
500	0,1	524	3	0,9	96,4%
1.000	0,1	524	3	0,9	96,4%
10	0,1	524	4	0,9	90%
50	0,1	524	4	0,9	91%
100	0,1	524	4	0,9	92%
500	0,1	524	4	0,9	94%
1.000	0,1	524	4	0,9	94%

### 4.2. Hasil Pengujian Sistem Prediksi

Hasil pengujian prediksi implan dengan NN *Backpropagation* menggunakan 30 data *testing* yang terdiri dari 28 daya mayor dan 2 data minor. Model NN *Backpropagation* menggunakan arsitektur terbaik berdasarkan hasil pengujian, yaitu 3 *hidden layer*, *learning rate* ( $\alpha$ ) = **0,1**, Momentum = **0,9** dan data dilakukan 5 kali percobaan *testing* pada **10, 50, 100, 500**, dan **1.000 epoch** didapat nilai akurasi terbaik sebesar 96% pada **500** dan **1.000 epoch**. Beberapa skenario percobaan *testing* untuk mendapatkan akurasi terbaik ditunjukkan pada Tabel 4.

### 4.3. Evaluasi Kinerja Sistem Prediksi dengan Metode Confusion Matrix

Evaluasi menggunakan 544 data, yang terdiri dari 30 data *testing* (2 data minor, 28 data mayor) dan 514 data *training* (257 data mayor, 13 data minor asli dan 244 data minor buatan). Evaluasi dilakukan dengan 5 kali percobaan, yaitu 10, 50, 100, 500 dan 1.000 *epoch*. Dari hasil percobaan tersebut, diperoleh nilai akurasi terbaik sebesar 96,1% pada *epoch* 500 dan 1.000. Hasil Evaluasi kinerja sistem prediksi implan ditunjukkan pada Gambar 5.

Dengan menggunakan Persamaan 14, Persamaan 15, dan Persamaan 16, maka nilai akurasi, presisi, dan *recall* ditampilkan pada Tabel 4. Dari hasil percobaan *epoch* 10, 50, 100, 500, dan 1.000 sesuai

dengan Tabel 5 didapat nilai tertinggi dari akurasi, presisi, dan *recall*, yaitu 96,1%, 97,2%, dan 95,5% pada *epoch* 500 dan 1.000.

<i>Epoch = 10</i>		<i>Epoch = 50</i>		<i>Epoch = 100</i>		<i>Epoch = 500</i>		<i>Epoch = 1000</i>	
265	20	277	8	277	8	277	8	277	8
18	241	18	241	16	243	13	246	13	246
<b>Accuracy = 93%</b>					<b>Accuracy = 95,2%</b>				
<b>Accuracy = 95,6%</b>					<b>Accuracy = 96,1%</b>				
<b>Accuracy = 96,1%</b>					<b>Accuracy = 96,1%</b>				

Gambar 5. Pengukuran Kinerja sistem prediksi dengan *confusion matrix*

Tabel 4. Hasil pengujian sistem prediksi implan

<i>Epoch</i>	Lr ( $\alpha$ )	Data Testing	Jumlah Hidden Layer	Momentum	Akurasi
10	0,1	30	1	0,9	90,5%
50	0,1	30	1	0,9	93%
100	0,1	30	1	0,9	94,3%
500	0,1	30	1	0,9	95%
1.000	0,1	30	1	0,9	95%
10	0,1	30	2	0,9	91%
50	0,1	30	2	0,9	93%
100	0,1	30	2	0,9	94,3%
500	0,1	30	2	0,9	94,5%
1.000	0,1	30	2	0,9	95%
10	0,1	30	3	0,9	93%
50	0,1	30	3	0,9	95%
100	0,1	30	3	0,9	95,6%
500	0,1	30	3	0,9	96,0%
1.000	0,1	30	3	0,9	96,0%
10	0,1	30	4	0,9	93%
50	0,1	30	4	0,9	93,3%
100	0,1	30	4	0,9	93,5%
500	0,1	30	4	0,9	95,4%
1.000	0,1	30	4	0,9	95,4%

Tabel 5. Hasil pengujian sistem prediksi implan

<i>Epoch</i>	TP	TN	FP	FN	Jumlah data	Akurasi	Presisi	Recall
10	265	241	20	18	544	93%	93%	93,6%
50	277	241	8	18	544	95,2%	97,2%	93,9%
100	277	243	8	16	544	95,6%	97,2%	94,5%
500	277	246	8	13	544	96,1%	97,2%	95,5%
1.000	277	246	8	13	544	96,1%	97,2%	95,5%

#### 4.4. Evaluasi Kinerja Sistem Prediksi dengan Metode 10-Fold Cross Validation

Evaluasi dengan metode 10-fold cross validation dilakukan dengan 5 kali percobaan, yaitu 10, 50, 100, 500, dan 1.000 *epoch* dengan model 10-fold cross validation berupa *linear sampling*, *shuffle sampling*, dan *stratified sampling*. Dari hasil percobaan tersebut, diperoleh nilai akurasi terbaik sebesar 95% pada *epoch* 500. Hasil evaluasi kinerja sistem dengan 10-fold cross validation ditunjukkan pada Tabel 6.

Dari percobaan dua metode evaluasi, yaitu *confusion matrix* dan 10-fold cross validation, didapat bahwa evaluasi dengan *confusion matrix* menghasilkan nilai akurasi lebih baik, yaitu 96,1% daripada metode 10-fold cross validation dengan nilai akurasi terbaiknya 95%.

Tabel 6. Hasil evaluasi sistem prediksi dengan 10-fold cross validation

Tipe Fold	Nilai akurasi berdasarkan jumlah epoch				
	10	50	100	500	1.000
<i>Linear Sampling</i>	86%	93,6%	93,1%	95%	94,7%
<i>Shuffle Sampling</i>	89,3%	92,4%	92,1%	94,7%	95%
<i>Stratified Sampling</i>	88,3%	93%	93,5%	95%	95%

#### 4.5. Perbandingan Nilai Akurasi Data dengan Teknik SMOTE dan yang Tidak Dilakukan Proses SMOTE dalam Menangani Imbalance Class

Sistem prediksi pemakaian alat kontrasepsi implan menggunakan kombinasi SMOTE dan NN *Backpropagation* pada data *imbalance class* menghasilkan nilai akurasi prediksi yang sangat baik, yaitu 96,1%. Metode SMOTE bekerja dengan baik dalam menangani *imbalance class*. Hal ini terbukti dari kenaikan nilai akurasi yang cukup signifikan, sedangkan data *imbalance class* yang tidak dilakukan proses SMOTE nilai akurasinya cenderung tinggi (100%) pada kelas mayor, tetapi rendah pada kelas minor (0%). Data *imbalance class* yang tidak dilakukan proses SMOTE menghasilkan prediksi 100% pada kelas mayor, tetapi tidak berhasil mendeteksi kelas minor (0%) seperti yang ditunjukkan perbandingan confusion matrix pada Gambar 5 dan Gambar 6.

Epoch = 10		Epoch = 50		Epoch = 100		Epoch = 500		Epoch = 1000	
265	20	277	8	277	8	277	8	277	8
18	241	18	241	16	243	13	246	13	246
<b>Accuracy = 93%</b>									
265	20	277	8	277	8	277	8	277	8
18	241	18	241	16	243	13	246	13	246
<b>Accuracy = 95.2%</b>									
265	20	277	8	277	8	277	8	277	8
18	241	18	241	16	243	13	246	13	246
<b>Accuracy = 95.6%</b>									
265	20	277	8	277	8	277	8	277	8
18	241	18	241	16	243	13	246	13	246
<b>Accuracy = 96.1%</b>									
265	20	277	8	277	8	277	8	277	8
18	241	18	241	16	243	13	246	13	246
<b>Accuracy = 96.1%</b>									

Gambar 6. Confusion matrix akurasi prediksi dengan metode SMOTE.

Epoch = 10		Epoch = 50		Epoch = 100		Epoch = 500		Epoch = 1000	
285	0	285	0	285	0	285	0	285	0
15	0	15	0	15	0	15	0	15	0

Gambar 7. Confusion matrix akurasi prediksi dengan tanpa metode SMOTE.

Tabel 7. Nilai akurasi, presisi, dan recall data *imbalance class* dengan teknik SMOTE

Epoch	TP	TN	FP	FN	Jumlah data	Akurasi	Presisi	Recall
10	265	241	20	18	544	93%	93%	93,6%
50	277	241	8	18	544	95,2%	97,2%	93,9%
100	277	243	8	16	544	95,6%	97,2%	94,5%
500	277	246	8	13	544	96,1%	97,2%	95,5%
1.000	277	246	8	13	544	96,1%	97,2%	95,5%

Tabel 8. Nilai akurasi, presisi, dan recall data *imbalance class* tanpa teknik SMOTE

Epoch	TP	TN	FP	FN	Jumlah data	Akurasi	Presisi	Recall
10	285	0	0	15	300	95%	100%	95%
50	285	0	0	15	300	95%	100%	95%
100	285	0	0	15	300	95%	100%	95%
500	285	0	0	15	300	95%	100%	95%
1.000	285	0	0	15	300	95%	100%	95%

Gambar 6 merupakan hasil *confusion matrix* akurasi implan dengan metode SMOTE menggunakan 544 data, yang terdiri dari 30 data *testing* (2 data minor, 28 data mayor) dan 514 data *training* (257 data mayor, 13 data minor asli dan 244 data minor buatan). Pada epoch 10, 50, 100, 500, dan 1.000 dengan nilai akurasi 93%; 95,2%; 95,6%; 96,1%; dan 96,1%, terjadi kenaikan nilai akurasi. Sistem dapat memprediksi kelas minor (target kelas =1) dengan persentase 93% kelas minor pada epoch 10 dan 50, sedangkan pada epoch 100 sistem mampu memprediksi 94% serta 95% pada epoch ke 500 dan 1.000. Gambar 7 merupakan hasil akurasi prediksi implan tanpa menggunakan SMOTE menggunakan 300 data yang terdiri dari 285 data mayor dan 15 data minor. Sistem memprediksi dengan nilai akurasi cenderung tinggi pada kelas mayor 100% (target kelas =0), tetapi tidak mampu memprediksi kelas minor (0%) (target kelas =1). Pada semua epoch 10, 50, 100, 500, dan 1.000 sistem tidak mampu memprediksi kelas minor (0%) (target kelas =1), sedangkan nilai akurasi rata-rata dari keseluruhan data

cenderung tetap, yaitu 95% pada *epoch* 10, 50, 100, 500, dan 1.000. Perbandingan tingkat akurasi data *imbalance* dengan teknik SMOTE dan yang tanpa SMOTE ditunjukkan pada Tabel 7 dan Tabel 8.

Tabel 6 merupakan nilai akurasi, presisi, dan *recall* data *imbalance class* dengan teknik SMOTE. Data dilakukan 5 kali percobaan, yaitu 10, 50, 100, 500 dan 1.000 *epoch*. Diperoleh nilai terbaik dari akurasi, presisi, *recall* pada data *imbalance class* dengan teknik SMOTE sebagai berikut: 96,1%; 97,2%; 95,5% pada 500 dan 1.000 *epoch*. Tabel 6 merupakan nilai akurasi, presisi, dan *recall* pada data *imbalance class* tanpa teknik SMOTE diperoleh nilai akurasi, presisi, dan *recall* berturut-turut 95%, 100%, dan 95% pada semua percobaan (10, 50, 100, 500, dan 1.000 *epoch*). Data *imbalance class* tanpa teknik SMOTE memprediksi data mayor dengan dengan nilai akurasi 100%, tetapi nilai akurasi prediksi pada kelas minor 0%. Hal ini dapat dilihat pada Tabel 7 (nilai ***TN*** = **0** pada semua percobaan *epoch*). Implementasi kombinasi SMOTE dan NN *Backpropagation* mampu memprediksi keberhasilan pemakaian alat kontrasepsi implan dengan nilai akurasi 96,1% sesuai dengan tujuan penelitian ini.

#### 4.6. Perbandingan Nilai Akurasi Algoritma Klasifikasi dalam Menangani Data Tidak Seimbang (*Imbalance Data*)

Perbandingan nilai akurasi algoritma klasifikasi yang mana data penelitian mendapatkan proses SMOTE kemudian diprediksi dengan algoritma klasifikasi, yaitu NN, DT, SVM, dan LR. Metode evaluasi yang digunakan, yaitu *10-fold cross validation* dengan 3 model sampling (*linear sampling*, *shuffle sampling*, dan *stratified sampling*). Perbandingan nilai akurasi algoritma klasifikasi dalam menangani data tidak seimbang disajikan dalam Tabel 9.

Tabel 9. Perbandingan nilai akurasi algoritma klasifikasi dalam menangani *imbalance class*

Model Fold	Perbandingan Nilai Akurasi Algoritma Klasifikasi			
	SMOTE + NN	SMOTE + DT	SMOTE+SVM	SMOTE +LR
<i>Linear Sampling</i>	94,7%	95%	78%	83%
<i>Shuffle Sampling</i>	95%	96,9%	55%	85%
<i>Stratified Sampling</i>	95%	95,4%	49%	85%

Tabel 9 merupakan hasil perbandingan nilai akurasi algoritma klasifikasi dalam menangani *imbalance class*. Kombinasi SMOTE dan NN menghasilkan nilai akurasi yang lebih baik (95%) dari kombinasi SMOTE+SVM (78%), SMOTE+LR (85%), tetapi tidak lebih baik dari kombinasi SMOTE+DT dengan akurasi 96,9%. Selisih hasil akurasi antara kombinasi SMOTE+NN dan SMOTE+DT tidak begitu jauh, yaitu 1%. Hasil akurasi dari perbandingan algoritma klasifikasi dalam menangani *imbalance class* bergantung pada kasus dan jumlah data yang ditangani.

## 5. Kesimpulan

Berdasarkan hasil penelitian yang dilakukan, dapat diambil beberapa kesimpulan, di antaranya penerapan metode kombinasi SMOTE dan NN *Backpropagation* untuk prediksi pemakaian alat kontrasepsi implan menghasilkan akurasi prediksi 96,1%. Implementasi kombinasi SMOTE dan NN *Backpropagation* mampu memprediksi pada *imbalance class* dengan akurasi 96,1%. Teknik SMOTE mampu memprediksi dengan persentase 93% kelas minor pada *epoch* 10 dan 50, sedangkan pada *epoch* 100, sistem mampu memprediksi 94% serta 95% pada *epoch* ke 500 dan 1.000. Prediksi data *imbalance class* tanpa teknik SMOTE menghasilkan nilai akurasi yang cenderung tinggi pada kelas mayor 100% dan tidak berhasil memprediksi kelas minor 0%. NN *Backpropagation* terbukti mengalami penurunan performa jika menangani *imbalance class*. Oleh karena itu, penelitian ini dapat dijadikan sebagai referensi bagi penelitian ke depan untuk menangani data tidak seimbang. Berdasarkan hal tersebut, sistem yang dirancang dapat digunakan sebagai acuan untuk melakukan prediksi terkait keberhasilan pemakaian alat kontrasepsi implan.

## 7. Referensi

- BKKBN, B. (2013). *Pedoman penggerakan KB dan ayoman komplikasi serta kegagalan kontrasepsi*. Jakarta: Direktorat Bina Kesertaan KB Jalur Pemerintah.
- Budayawan, K., Yuhandri, & Nurcahyo, G. W. (2019). Implementasi Jaringan Syaraf Tiruan dalam Memprediksi Frekuensi Resonansi Atena Mikrostrip. *JTIP: Jurnal Teknologi Informasi dan Pendidikan*, 12(1), 33-40.

- Chen, G., Fu, K., Liang, Z., Sema, T., Li, C., & Tontiwachwuthikul, P. (2014). The genetic algorithm based back propagation neural network for MMP prediction in CO<sub>2</sub>-EOR process. *Fuel*, 126(June), 202-212.
- Chen, L., Fang, B., Shang, Z., & Tang, Y. (2018). Tackling class overlap and imbalance problems in software defect prediction. *Software Quality Journal*, 26(1), 97-125.
- García, V., Sánchez, J. S., & Mollineda, R. A. (2012). On the effectiveness of preprocessing methods when dealing with different levels of class imbalance. *Knowledge-Based Systems*, 25(1), 13-21.
- Gholami, M., Cai, N., & Brennan, R. (2013). An artificial neural network approach to the problem of wireless sensors network localization. *Robotics and Computer-Integrated Manufacturing*, 29(2013), 96–109.
- He, H., & Ma, Y. (2013). *Imbalanced Learning: Foundations, Algorithms, and Applications*. Canada: Wiley.
- Jian, C., Gao, J., & Ao, Y. (2016). A new sampling method for classifying imbalanced data based on support vector machine ensemble. *Neurocomputing*, 193(June), 115-122.
- Li, H., & Sun, J. (2012). Forecasting business failure: The use of nearest-neighbour support vectors and correcting imbalanced samples—Evidence from the Chinese hotel industry. *Tourism Management*, 33(3), 622-634.
- Liu, X.-Y., Li, Q.-Q., & Zhou, Z.-H. (2013). Learning Imbalanced Multi-class Data with Optimal Dichotomy Weights. *IEEE 13th International Conference on Data Mining*. Dallas, TX, USA: IEEE.
- Mutrofin, S., Mu'alif, A., Ginardi, R. V., & Faticahah, C. (2019). Solution of class imbalance of k-nearest neighbor for data of new student admission selection. *International Journal Of Artificial Intelligence Research*, 3(2), 47-55.
- Purnamasari, R. W., Dwijanto, D., & Sugiharti, E. (2013). Implementasi Jaringan Syaraf Tiruan Backpropagation Sebagai Sistem Deteksi Penyakit Tuberculosis (TBC). *Unnes Journal of Mathematics*, 2(2).
- Sanguanmak, Y., & Hanskunatai, A. (2016). Auto-tuning of parameters in hybrid sampling method for class imbalance problem. *2016 International Computer Science and Engineering Conference (ICSEC)*. Chiang Mai, Thailand: IEEE.
- Sermpinis, G., Dunis, C., Laws, J., & Stasinakis, C. (2012). Forecasting and trading the EUR/USD exchange rate with stochastic Neural Network combination and time-varying leverage. *Decision Support Systems*, 54(1).
- Shen, L., Lin, Z., & Huang, Q. (2016). Relay Backpropagation for Effective Learning of Deep Convolutional Neural Networks. *European Conference on Computer Vision (ECCV 2016)* (pp. 467-482). Cham: Springer.
- Susanto, A. T. (2012). *Aplikasi Diagnosa Kanker Serviks dengan Menggunakan Algoritma Backpropagation*. Kupang: STIKOM Uyelindo.
- Thammasiri, D., Delen, D., Meesad, P., & Kasap, N. (2014). A critical assessment of imbalanced class distribution problem: The case of predicting freshmen student attrition. *Expert Systems with Applications*, 41(2), 321-330.
- Widodo, W., Rachman, A., & Amelia, R. (2014). Jaringan Syaraf Tiruan Prediksi Penyakit Demam Berdarah dengan Menggunakan Metode Backpropagation. *Jurnal IPTEK*, 18(1), 64-70.
- Yap, B. W., Rani, K. A., Rahman, H. A., Fong, S., Khairudin, Z., & Abdullah, N. N. (2014). An Application of Oversampling, Undersampling, Bagging and Boosting in Handling Imbalanced Datasets. *Proceedings of the First International Conference on Advanced Data and Information Engineering (DaEng-2013)*. 285, pp. 13-22. Singapore: Springer.
- Zhang, D., Liu, W., Gong, X., & Jin, H. (2011). A Novel Improved SMOTE Resampling Algorithm Based on Fractal. *Journal of Computer information Systems*, 7(6), 2204-2211.
- Zhu, T., Lin, Y., & Liu, Y. (2017). Synthetic minority oversampling technique for multiclass imbalance problems. *Pattern Recognition*, 72(December), 327-340.