

Implementasi *Chi-Square* dan *Oversampling* Pada Klasifikasi Kesehatan Janin dengan *Support Vector Machine*

Implementation of Chi-Square and Oversampling for Fetal Health Classification Using Support Vector Machine

Sharenada Norisdita Wahyudi¹, Nurissaaidah Ulinnuha^{2*}, Moh. Hafiyusholeh³
^{1,2,3}UIN Sunan Ampel Surabaya

Jl. Dr. Ir. H. Soekarno No.682, Gn. Anyar, Kec. Gn. Anyar, Surabaya, Jawa Timur 60294, (031) 8410298
sharenadaw@gmail.com¹, nuris.ulinnuha@uinsa.ac.id^{2*}, hafiyusholeh@uinsa.ac.id³

Abstrak – Pemantauan kesehatan janin menjadi aspek penting karena hal tersebut merupakan bentuk antisipasi terkait deteksi potensi patologis yang berkemungkinan membahayakan janin maupun ibu hamil. Sebagaimana dilansir dalam website resmi UNICEF, setidaknya terdapat 2,3 juta bayi meninggal pada bulan pertama kelahiran dengan 90% dari total keseluruhan merupakan kasus kematian bayi didalam kandungan pada masa kehamilan diatas 20 minggu. Selain membahayakan bayi, kesehatan janin juga berdampak pada keselamatan ibu hamil. Oleh karena itu, perlu dilakukan suatu usaha mitigasi resiko guna memperkecil potensi kematian janin dengan mendeteksi kesehatan janin dengan melakukan klasifikasi dengan algoritma SVM. Data yang digunakan pada penelitian ini adalah hasil pemeriksaan kandungan berupa data cardiotocography, berisikan 2126 data yang berisikan 21 fitur yang terkategorikan menjadi 3 kelas yaitu 1665 normal, 295 kelas suspect dan 176 kelas pathologic. Berdasarkan perbedaan yang cukup signifikan pada jumlah data ditiap kelas, dilakukan balancing data dengan metode Synthetic Minority Over-Sampling Technique (SMOTE). Selain itu, dilakukan seleksi fitur dengan menggunakan Chi-Square pada 21 fitur yang kemudian didapatkan 12 fitur terpilih untuk diklasifikasikan menggunakan algoritma SVM. Skema klasifikasi dilakukan dengan beberapa tahapan, dan didapatkan bahwa penambahan seleksi fitur Chi-Square dan SMOTE berhasil meningkatkan akurasi klasifikasi menjadi 98%, dengan nilai presicion sebesar 99%, recall 98% dan F-1 Score sebesar 98%.

Kata Kunci: Cardiotocography (CTG), Chi-Square, SMOTE, SVM.

Abstract – Fetal health monitoring is an important aspect because it forms for detect potential pathologies that may endanger fetus and pregnant mother. As reported on UNICEF, at least 2.3 million babies die in the first month of birth with 90% of the total being cases of intrauterus fetal death. In addition to endangering the baby, fetal health also has an impact on pregnant mother. As an effort to minimize the potential and risk of fetal death, is classify the health status of the fetus using the SVM algorithm. The data used in this study are gynecological results in the field of cardiotocography data, containing 2126 data that have been categorized into 3 classes, namely normal, suspect and pathologic classes. Cardiotocography data in this study was included 2,126 observations distributed across 21 features grouped into three categories: 1,665 normal, 295 suspect, and 176 pathological. Given the significant variation in the number of observations across each category, a data balancing technique, known as the Synthetic Minority Over-Sampling Technique (SMOTE), was employed to address this imbalance. Furthermore, a feature selection process was implemented, employing the Chi-Square method on the 21 features. This method identified 12

features that were subsequently classified using the SVM algorithm. The classification scheme was executed in multiple stages, and it was observed that the incorporation of both Chi-Square and SMOTE feature selection led to a substantial enhancement in classification accuracy, reaching 98%, accompanied by a 99% precision value, 98% recall, and an 98% F-1 score.

Keywords: Cardiotocography (CTG), Chi-Square, SMOTE, SVM.

1. Pendahuluan

Kesehatan janin merupakan salah satu prioritas utama dalam dunia medis karena berhubungan dengan kualitas hidup manusia sejak berada dalam kandungan. Hal tersebut dilakukan untuk mengantisipasi hal buruk yang mengkhawatirkan bagi bayi maupun ibu. Sebagaimana dilaporkan pada website resmi *World Health Organization* (WHO), sedikitnya terdapat 7,9 Juta bayi lahir dengan keadaan cacat setiap tahunnya dengan 85% terjadi di negara berkembang seperti Asia Tenggara [1]. Selain itu, United Nation Children's Fund (UNICEF) melaporkan bahwa setidaknya terdapat 2,3 juta kasus bayi meninggal pada bulan pertama kelahirannya dengan 2 juta diantaranya meninggal sejak masih berada dalam kandungan, terjadi pada masa kehamilan di atas 20 minggu.

Tidak hanya berdampak pada keselamatan bayi, kesehatan janin yang terlambat untuk dideteksi dapat membahayakan keselamatan ibu. Seperti yang tercantum dalam panduan profil kesehatan tahun 2022 yang resmi diterbitkan oleh Kementerian kesehatan RI, bahwasanya pada tahun 2021 terdapat 7.138 kasus kematian ibu pada masa sebelum atau pasca persalinan [2]. Angka tersebut menjadikan Indonesia menjadi negara dengan kasus kematian ibu tertinggi di Asia Tenggara. Oleh karena itu, kesehatan janin perlu untuk dideteksi sebagai suatu bentuk usaha mitigasi risiko yang dapat berbahaya bagi bayi dan ibu. Adapun usaha yang dapat dilakukan pada bidang medis dengan melakukan pemeriksaan *cardiotocography* (CTG) maupun melakukan penelitian terkait klasifikasi. Penelitian dalam konteks klasifikasi digunakan untuk mendeteksi kesehatan janin dengan memanfaatkan rekam medis yang sudah ada.

Salah satu algoritma klasifikasi yang dapat ditawarkan adalah *Support Vector Machine* (SVM). SVM dianggap unggul dan dapat mengatasi sistem olah data nonlinear dengan memisahkannya kedalam dimensi lebih tinggi menggunakan bantuan fungsi kernel [3]. Prinsip kerja utama pada SVM adalah memisahkan data kedalam dua kelas dengan *hyperplane* pada jarak *margin* optimal [4]. Dapat ditinjau dari beberapa penelitian diantaranya oleh [5] yang mengklasifikasikan bunga iris dengan SVM menggunakan kernel *polynomial*, mendapatkan hasil akurasi unggul pada nilai 96,7%. Penelitian lain oleh [6] melakukan perbandingan fungsi kernel SVM pada klasifikasi penyakit padi, mendapat hasil optimal dengan kernel linear pada akurasi 89%. Penelitian oleh [7] melakukan perbandingan pada kernel linear dan RBF pada klasifikasi *text-mining* ulasan pelanggan, didapati kernel RBF lebih unggul dengan akurasi tertinggi pada nilai 86,1%.

Beberapa penelitian lain terkait dengan klasifikasi kesehatan janin pernah dilakukan, diantaranya oleh [8] dengan menggunakan algoritma C5.0 dan mendapatkan hasil akurasi sebesar 93,4%. Penelitian [9] membandingkan kinerja algoritma *machine learning* untuk mengklasifikasikan kesehatan janin, didapati terdapat 4 algoritma unggul dengan akurasi diatas 90% diantaranya SVM, XGBoost, Random Forest dan KNN. Berdasarkan beberapa penelitian terkait, perlu dilakukan penelitian dengan kebaruan guna meningkatkan akurasi dan kestabilan klasifikasi. Beberapa metode yang dapat ditawarkan diantaranya adalah *oversampling* untuk mengatasi imbalance pada jumlah data yang dimuat di tiap kelas, juga penambahan seleksi fitur untuk mengurangi fitur-fitur yang dirasa tidak relevan terhadap kelas label.

Metode oversampling yang ditawarkan salah satunya adalah *Synthetic Minority Oversampling Technique* (SMOTE). SMOTE bekerja mengatasi imbalance dataset dengan mengkloning data pada kelas minoritas agar kelas tersebut memiliki jumlah sama dengan data pada kelas mayoritas tanpa mengubah dan menghilangkan karakteristik data yang sudah ada [10]. Beberapa penelitian menyatakan bahwa SMOTE dapat membantu meningkatkan akurasi pada

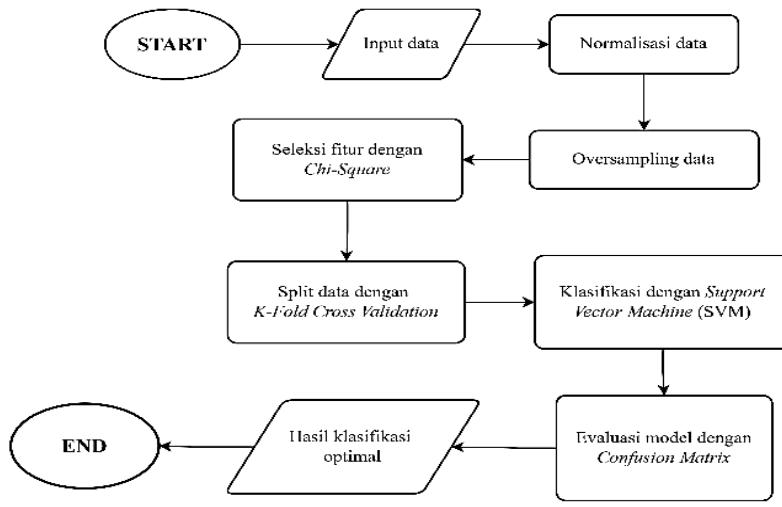
penelitian seperti yang dilakukan oleh [11] yang menggunakan SMOTE untuk menangani *imbalance* data rating acara TV dengan ANN dan mendapat akurasi optimal sebesar 87%. Penelitian [12] melakukan penanganan pada *imbalance* data pada klasifikasi dengan K-NN dan mendapatkan peningkatan akurasi sebelumnya 85% menjadi 97%.

Pemanfaatan seleksi fitur umumnya ditambahkan untuk menstabilkan sekaligus meningkatkan akurasi hasil evaluasi klasifikasi [13]. Salah satu yang dapat digunakan adalah *Chi-Square*, karena pengaplikasian yang sederhana dalam menentukan signifikansi suatu fitur terhadap kelas target [14]. Seleksi fitur *Chi-Square* dapat meningkatkan akurasi hasil evaluasi klasifikasi sebagaimana penelitian yang dilakukan oleh [15] memanfaatkan seleksi fitur *Chi-Square* pada kinerja algoritma Naïve Bayes multinomial dan berhasil meningkatkan akurasi yang awalnya hanya 88% menjadi 95%. Pada penelitian lain yang dilakukan oleh [16] membandingkan dua seleksi fitur yakni Chi-Square dengan Mutual Information, dimana Chi-Square lebih unggul dengan peningkatan akurasi sebesar 3% dengan waktu komputasi lebih singkat. Penggunaan seleksi fitur Chi-Square dinilai cukup unggul dan bisa dimanfaatkan untuk mengoptimalkan hasil evaluasi pada kinerja algoritma klasifikasi dengan waktu komputasi yang efisien.

Berdasarkan pemaparan diatas, algoritma SVM menunjukkan performa yang baik dalam melakukan klasifikasi. Selain itu, penggunaan seleksi fitur Chi-Square memiliki kinerja yang baik dalam meningkatkan akurasi model pada algoritma yang dijalankan setelahnya. SMOTE juga menunjukkan kestabilan dalam penanganan *imbalance dataset*. Oleh karena itu penelitian dilakukan dengan mengimplementasikan seleksi fitur dengan menambahkan metode *oversampling* pada klasifikasi kesehatan janin. Untuk melihat seberapa baik performa klasifikasi, hasil klasifikasi akan dievaluasi menggunakan *confusion matrix* sebagai pemberi gambaran menyeluruh tentang hasil prediksi model

2. Metode Penelitian

Penelitian ini menggunakan algoritma klasifikasi *Support Vector Machine* (SVM) dengan bantuan *oversampling* SMOTE dan seleksi fitur *Chi-Square*. Sistematis pengolahan data dilakukan bertahap, mulai dari *pre-processing*, seleksi fitur, klasifikasi dan terakhir evaluasi model, sebagaimana disajikan dalam bentuk diagram alir pada Gambar 1.



Gambar 1. Alur Penelitian

Berdasarkan alur penelitian yang ditunjukkan pada Gambar 1, tahapan pengolahan data yang dilakukan dimulai dari input data yang kemudian dilanjutkan normalisasi data, salah satunya dengan metode *MinMax Scaller*. Setelah dilakukan normalisasi pada data, dilakukan tahapan *oversampling* untuk mendapatkan jumlah data yang seimbang. Setelah itu dilakukan seleksi fitur dengan *Chi-Square*, kemudian dilakukan split data testing:training dengan *K-Fold*. Setelahnya dilakukan pengklasifikasian dengan SVM, untuk mengetahui hasil maksimal, dilakukan tahap

evaluasi dengan *confusion matrix*. Setelah didapatkan hasil klasifikasi optimal, maka tahapan pengolahan data telah selesai.

2.1. Sumber Data

Data dalam penelitian ini didapatkan melalui website database Kaggle. Data merupakan hasil pemeriksaan kandungan cardiotocography (CTG) sebanyak 2126 data yang telah diklasifikasikan oleh para dokter ahli kandungan yang menjadikan tiga kategori pada data set kardiotokografi dengan jumlah 1665 normal, 295 suspect, dan 176 pathologic.

2.2. Normalisasi Data

Normalisasi data adalah suatu tahapan dalam preprocessing data yang bertujuan untuk mengubah sebaran data kedalam skala dengan rentang yang sama [17]. Salah satu metode normalisasi yang sering digunakan adalah *MinMax Scaler*. Normalisasi dengan MinMax mengubah rentang data dengan nilai antara 0 sampai dengan 1, dituliskan dengan rumus sebagai berikut [18].

$$X' = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (1)$$

2.3. Balancing Data

Metode balancing yang digunakan pada penelitian ini adalah *Synthetic Minority Over-Sampling Technique* (SMOTE). Metode tersebut menggunakan prinsip oversampling yang menambah data pada kelas minor agar jumlahnya seimbang dengan data dari kelas mayor [19]. Cara kerja SMOTE adalah memilih setiap sampel dari data minoritas secara berurutan sebagai akar sintesis sampel tambahan untuk mensintesis sampel baru dan diulang sebanyak n kali [20].

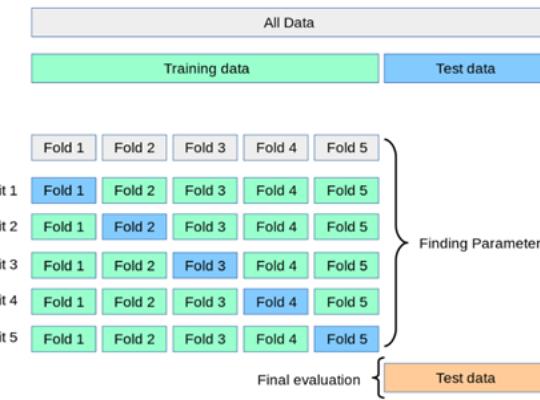
2.4. Seleksi Fitur Chi-Square

Prinsip kerja seleksi fitur Chi-Square adalah dengan mengimplementasikan teori statistika dalam menguji independensi suatu fitur terhadap kelas kategori [21]. Penggunaan seleksi fitur bertujuan untuk mengurangi keberadaan fitur yang kurang relevan [22]. Seleksi fitur Chi-Square dituliskan dengan rumus berikut.

$$\chi^2 = \sum_{i=1}^n \frac{(O_i - E_i)^2}{E_i} \quad (2)$$

2.5. K-Fold Cross Validation

K-Fold Cross Validation merupakan tahapan pembagian data untuk memudahkan proses pengujian dan pelatihan model [23]. Prinsip kerja dari *K-Fold* adalah dengan membagi keseluruhan data kedalam beberapa subset, yang nantinya di tiap subset bergantian untuk menjadi data *train* dan data *test* [24]. Cara kerja split data dengan *K-Fold* divisualisasikan pada Gambar 2 [25].

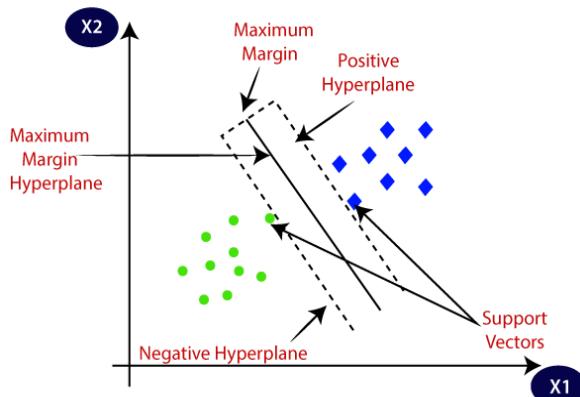


Gambar 2. Sistematis Pembagian K-Fold

Berdasarkan Gambar 2, terlihat sistematis pembagian *K-Fold* yakni dengan membagi data kedalam beberapa *fold* secara sama rata, kemudian 1*fold* menjadi data uji dan *fold* lain merupakan data latih, pengolahan data dilakukan berulang sampai dengan *fold* ke-*K*.

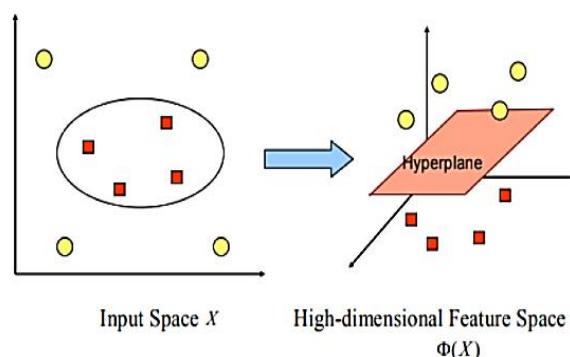
2.6. Klasifikasi *Support Vector Machine* (SVM)

SVM merupakan salah satu algoritma klasifikasi dalam pembelajaran *machine learning* yang bekerja dengan prinsip pemisahan data linear dengan menemukan *hyperplane* optimal [26]. *Hyperplane* terbaik adalah batas yang dapat memaksimalkan pemisahan dua kelas dengan titik jarak paling minimal [27]. Pada dasarnya, SVM merupakan algoritma klasifikasi berbasis *linear separable*, ditunjukkan pada Gambar 3.



Gambar 3. Visualisasi Pemisahan Kelas pada SVM

Gambar 3 menunjukkan data linear pada dimensi bidang dapat dipisah hanya dengan *hyperplane* berupa garis lurus. Hal tersebut jelas berbeda dengan penanganan pada data non-linear, dibutuhkan *hyperplane* pemisah yang lebih kompleks. Dalam mengatasi sistem data nonlinear, SVM dilengkapi dengan fungsi kernel untuk mengubah dimensi data kedalam ruang fitur yang lebih tinggi [28], sebagaimana divisualisasikan pada Gambar 4.



Gambar 4. Visualisasi Dimensi Pada *Hyperplane*

Gambar 4 menjelaskan visualisasi dimensi pada *hyperplane* pada sistem algoritma SVM dimana SVM dilengkapi fungsi kernel untuk mengatasi klasifikasi pada data kompleks. Pemecahan masalah tersebut dilakukan dengan merubah ruang fitur ke dimensi yang lebih tinggi dan membentuk *hyperplane* pemisah. Fungsi kernel yang paling umum ada 3, diantaranya kernel linear, kernel *Radial Basis Function* (RBF) dan kernel *polynomial* yang diketahui berdasarkan yang dituliskan dengan rumus seperti sebagaimana yang tertera pada Tabel 1 [29].

Tabel 1. Fungsi Kernel

| | | |
|-------------------|---|-----|
| Kernel Linear | $K(x_u, x_v) = x_u \cdot x_v$ | (3) |
| Kernel RBF | $K(x_u, x_v) = e^{(-\gamma \ x_u - x_v\ ^2)}$ | (4) |
| Kernel Polinomial | $K(x_u, x_v) = (\gamma(x_u \cdot x_v) + C)^d$ | (5) |

2.7. Confusion Matrix

Confusion Matrix adalah tahapan evaluasi untuk mengetahui kinerja dari sistem klasifikasi dengan memanfaatkan nilai performa pada kesesuaian data aktual dengan hasil prediksi [30]. Evaluasi sistem dilihat dari hasil perhitungan *confusion matrix* yang terdiri dari tingkat akurasi, *recall*, presisi dan F1-score sebagaimana tertera pada persamaan berikut [31].

$$\text{Akurasi} = \frac{TP + TN}{(TP + FP + TN + FN)} \quad (6)$$

$$\text{Recall} = \frac{TP}{(TP + FN)} \quad (7)$$

$$\text{Presisi} = \frac{TP}{(TP + FP)} \quad (8)$$

$$\text{F1-Score} = \frac{2 \times \text{presisi} \times \text{recall}}{\text{presisi} + \text{recall}} \quad (9)$$

Keempat persamaan memiliki fungsi tersendiri dalam melihat seberapa sesuai model hasil klasifikasi dengan data aktual. Semakin mendekati nilai 1 maka dinyatakan semakin baik model dalam mengklasifikasikan data [32].

3. Hasil dan Pembahasan

Tahapan awal pada penelitian ini adalah menginput data hasil pemeriksaan CTG yang diambil dari Website Kaggle. Berikut data CTG dengan jumlah total data sebanyak 2126 dengan 21 variabel independen dan 1 variabel target yang terbagi dalam 3 kategori, sebagaimana sampel data yang ditampilkan pada Tabel 2.

Tabel 2. Sampel Data *Cardiotocography* (CTG)

| x_1 | x_2 | x_3 | x_4 | x_5 | x_6 | ... | x_{21} | y |
|-------|-------|-------|-------|-------|-------|-----|----------|-----|
| 120 | 0 | 0 | 0 | 0 | 0 | ... | 2 | 2 |
| 132 | 0,006 | 0 | 0,006 | 0,003 | 0 | ... | 1 | 1 |
| 133 | 0,003 | 0 | 0,008 | 0,003 | 0 | ... | 1 | 1 |
| : | : | : | : | : | : | : | : | : |
| 140 | 0,001 | 0 | 0,007 | 0,006 | 0 | ... | 2 | 1 |
| 142 | 0,002 | 0,2 | 0,008 | 0 | 0 | ... | 2 | 1 |

Tabel 2 menunjukkan sampel data yang berisikan 21 fitur yang ditunjukkan dengan x_1 sampai dengan x_{21} yang merupakan data numerik. Kemudian untuk variabel y merupakan variabel target yang berisikan data kategorik dimana 1 menunjukkan kondisi janin normal, 2 menunjukkan kondisi janin *suspect* dan 3 menunjukkan kondisi janin *pathology*. Kategori kelas terdiri dari 1665 data dengan kondisi normal, 296 data dengan kondisi *suspect* dan 176 data merupakan data dengan kondisi *pathology*. Tahapan kedua adalah melakukan normalisasi data

dengan *MinMax Scaler* untuk merubah data kedalam rentang skala yang sama. Hasil normalisasi ditampilkan pada Tabel 3.

Tabel 3. Hasil Normalisasi dengan *MinMax*

| x_1 | x_2 | x_3 | x_4 | x_5 | x_6 | ... | x_{21} |
|-------|-------|-------|-------|-------|-------|-----|----------|
| 0,259 | 0 | 0 | 0 | 0,403 | 0 | ... | 1,05 |
| 0,481 | 0,315 | 0 | 0,4 | 0,577 | 0 | ... | 0,5 |
| 0,500 | 0,157 | 0 | 0,533 | 0,569 | 0 | ... | 0,5 |
| 0,629 | 0,052 | 0 | 0,466 | 0,688 | 0 | .. | 0,5 |
| : | : | : | : | : | : | ... | : |
| 0,666 | 0,026 | 0 | 0,4 | 0,678 | 0 | ... | 1,05 |
| 0,667 | 0,105 | 0,004 | 0,533 | 0,623 | 0 | | 1,05 |

Berdasarkan Tabel 3, hasil normalisasi menggunakan *MinMax* menghasilkan data dengan rentang pada angka 0 sampai dengan 1. Tahapan selanjutnya adalah *balancing* data dengan *Synthetic Minority Over-Sampling Technique* (SMOTE). Data pada kelas 2 (*suspect*) dan kelas 3 (*pathology*) digandakan jumlah data pada kelasnya sehingga memiliki nilai seimbang dengan data pada kelas 1 (*normal*) berjumlah 1665. Hasil *oversampling* data ditampilkan seperti pada Gambar 5.

```
# Menampilkan jumlah sampel per kelas setelah oversampling
print(resampled_data['fetal_health'].value_counts())

Jumlah kelas 1: 1655
fetal_health
2.0    1655
1.0    1655
3.0    1655
```

Gambar 5. Hasil *Over-Sampling* Data

Berdasarkan Gambar 5, ditunjukkan bahwa hasil *oversampling* menjadikan jumlah data pada tiap kelas bernilai sama yakni sejumlah dengan kelas mayoritas sebesar 1655 data. Tahapan setelah dilakukan *oversampling* adalah melakukan seleksi fitur dengan menggunakan *Chi-Square*. Proses seleksi fitur dengan menggunakan *Chi-Square* dilakukan dalam beberapa tahapan inti diantaranya ialah menentukan nilai *alpha* (α) yakni sebesar 0.05%, melakukan pengelompokan value atribut terhadap label (tabel kontingensi), proses perhitungan nilai *Chi-Square* dan yang terakhir adalah penentuan fitur terseleksi berdasarkan perbandingan pada nilai yang ada pada tabel distribusi *Chi-Square*.

Proses seleksi fitur dilakukan dengan membandingkan nilai *Chi-Square* dengan nilai pada tabel distribusi berdasarkan derajat kebebasan dan nilai *alpha*. Fitur dinyatakan signifikan apabila nilai *Chi-Square* lebih besar ($>$) dibandingkan nilai pada tabel distribusi. Begitu juga sebaliknya, apabila nilai pada tabel *Chi-Square* kurang dari ($<$) nilai distribusi tabel *Chi-Square* maka fitur dinyatakan tidak signifikan sehingga dinyatakan tidak lolos seleksi. Berdasarkan ketentuan tersebut, terdapat 12 fitur yang lolos dan dinyatakan signifikan terhadap kelas target, ditampilkan pada Tabel 4.

Tabel 4. Hasil Seleksi Fitur *Chi-Square*

| Fitur | Nilai <i>Chi-Square</i> | Nilai Tabel Distribusi | Keterangan |
|---------------------------------|-------------------------|------------------------|------------|
| <i>Baseline Value</i> | 44,327 | 28,867 | Signifikan |
| <i>Acceleration</i> | 81,968 | 28,867 | Signifikan |
| <i>Uterine Contraction</i> | 42,844 | 28,867 | Signifikan |
| <i>Light Deceleration</i> | 38,933 | 28,869 | Signifikan |
| <i>Severe Deceleration</i> | 55,306 | 28,869 | Signifikan |
| <i>Prolonged Deceleration</i> | 301,166 | 5,991 | Signifikan |
| <i>Abnormal Short Term Var.</i> | 58,506 | 15,507 | Signifikan |
| <i>Time of Long Term Var.</i> | 196,944 | 28,867 | Signifikan |
| <i>Histogram Min.</i> | 29,718 | 28,867 | Signifikan |
| <i>Histogram Mean</i> | 26,849 | 28,867 | Signifikan |
| <i>Histogram Variance</i> | 43,873 | 18,307 | Signifikan |
| <i>Histogram Tendency</i> | 12,090 | 9,488 | Signifikan |

Tabel 4 menunjukkan fitur-fitur hasil seleksi dengan menggunakan *Chi-Square*. Berdasarkan tabel tersebut, terdapat 12 fitur yang dinyatakan signifikan karena memiliki nilai *Chi-Square* yang lebih besar dibandingkan dengan nilai pada tabel distribusi *Chi-Square*. Fitur-fitur tersebut selanjutnya akan diproses untuk melakukan klasifikasi dengan algoritma *Support Vector Machine* (SVM). Tahapan klasifikasi dilakukan dengan beberapa skema uji coba. Uji coba dilakukan kedalam 3 tahapan, yang pertama klasifikasi SVM tanpa dilakukan *Oversampling* SMOTE dan seleksi fitur *Chi-Square*, kedua melakukan klasifikasi SVM dengan seleksi fitur *Chi-Square* tanpa *Oversampling* SMOTE, dan pengujian terakhir adalah melakukan ketiga tahapan yakni klasifikasi SVM dengan menambahkan metode *Oversampling* SMOTE dan seleksi fitur *Chi-Square*.

Pengujian dilakukan dengan tiga kernel yakni kernel linear, RBF dan polynomial. Selain uji coba kernel, dilakukan pengujian nilai pada parameter kernel berupa nilai Cost (C), γ (γ), dan derajat (d). Hal tersebut dilakukan untuk mencari hasil paling optimal pada sistem klasifikasi data rekam medis kesehatan janin. Berdasarkan hasil uji coba tersebut, didapatkan hasil-hasil optimal dari rangkaian tahapan pada tiap klasifikasi, yang ditampilkan dalam Tabel 5.

Tabel 5. Hasil Klasifikasi

| Tahapan Uji Coba | Nilai Akurasi | Kernel | Parameter Kernel |
|-----------------------------|---------------|------------|---------------------------|
| SVM | 0,9213 | RBF | $C = 10$ $\gamma = 10$ |
| SVM <i>Chi-Square</i> | 0,9496 | Polinomial | $C = 1$ $d = 3$ |
| SVM SMOTE <i>Chi-Square</i> | 0,9838 | RBF | $C = 10$ $\gamma = 10$ |

Tabel 5 menunjukkan bahwa hasil optimal dari evaluasi berdasarkan akurasi pada tiap klasifikasi menunjukkan peningkatan setelah ditambahkan beberapa metode penunjang seperti seleksi fitur dan dilakukan *balancing* data. Berdasarkan hasil pengujian, terjadi peningkatan yang cukup signifikan, yang awalnya 0,9213 atau 92,1% meningkat menjadi 0,9496 atau 94,9% sampai dengan 0,9838 atau 98,3% pada percobaan klasifikasi. Dapat dilihat bahwasanya penambahan metode SMOTE dan seleksi fitur memiliki tingkat akurasi tertinggi dengan nilai sebesar 0,9838 atau 98,38% dengan memanfaatkan kernel RBF pada parameter Cost (C) =10

dan nilai *gamma* (γ) = 10. Selain meninjau akurasi, beberapa aspek seperti *Recall*, spesifisitas dll perlu diperhatikan untuk memastikan keakuratan model dalam melakukan klasifikasi seperti pada Gambar 6.

| | precision | recall | f1-score |
|--------------|-----------|--------|----------|
| 1.0 | 0.99 | 0.97 | 0.98 |
| 2.0 | 0.97 | 0.99 | 0.98 |
| 3.0 | 0.99 | 0.99 | 0.99 |
| accuracy | | | 0.98 |
| macro avg | 0.98 | 0.98 | 0.98 |
| weighted avg | 0.98 | 0.98 | 0.98 |

Gambar 6. Evaluasi Klasifikasi Optimal

Gambar 6 merupakan evaluasi klasifikasi pada tahapan uji coba SVM dengan ditambahkan SMOTE dan seleksi fitur Chi-Square. Terlihat bahwasanya tidak hanya akurasi yang unggul, namun hasil *recall* presisi dan F-1 Score pada masing-masing kelas. Nilai *recall* pada kelas 1 sebesar 0,97 kelas 2 dan 3 sebesar 0,99. Untuk nilai presisi, ditunjukkan bahwa pada kelas 1 dan 3 memiliki presisi pada angka 0,99 dan kelas 2 sebesar 0,97. Begitu juga pada nilai performa F-1 Score pada kelas 1 dan 2 berada pada angka 0,98 sedangkan pada kelas 3 memiliki nilai sebesar 0,99. Dari hasil evaluasi tersebut, menunjukkan bahwa hasil klasifikasi seimbang dan optimal dengan capaian rata-rata nilai mendekati data aktual yakni pada nilai 0,97 sampai 0,99.

4. Kesimpulan

Dapat disimpulkan berdasarkan beberapa tahapan percobaan sebagaimana yang ada pada Tabel 5 bahwasanya hasil optimal pada klasifikasi status kesehatan janin ialah dengan menggunakan algoritma SVM yang telah ditambahkan beberapa metode penunjang. Penambahan SMOTE untuk menyeimbangkan kelas data dan seleksi fitur *Chi-Square* untuk mengurangi fitur yang dianggap tidak relevan berhasil meningkatkan akurasi klasifikasi sampai dengan 98% dengan rata-rata nilai *recall*, presisi dan F-1 Score adalah 98,3%. Penambahan metode SMOTE dan *Chi-Square* pada klasifikasi kesehatan janin dengan algoritma *Support Vector Machine* (SVM) dinyatakan optimal dengan nilai mendekati data aktual.

Referensi

- [1] WHO, “World Birth Defects Day: Many birth defects, one voice,” WHO. Accessed: Dec. 11, 2024. [Online]. Available: <https://www.who.int/southeastasia/news/detail/02-03-2023-world-birth-defects-day-many-birth-defects-one-voice>
- [2] KEMENKES, *Profil Kesehatan Indonesia* 2022. Jakarta, 2022. Accessed: Jan. 01, 2025. [Online]. Available: <https://kemkes.go.id/id/profil-kesehatan-indonesia-2022>
- [3] F. Pamungkas and I. Kharisudin, “Analisis Sentimen dengan SVM, NAIVE BAYES dan KNN untuk Studi Tanggapan Masyarakat Indonesia Terhadap Pandemi Covid-19 pada Media Sosial Twitter”, prisma, vol. 4, pp. 628-634, Feb. 2021.
- [4] N. G. Ramadhan and A. Khoirunnisa, “Klasifikasi Data Malaria Menggunakan Metode Support Vector Machine,” *Jurnal Media Informatika Budidarma*, vol. 5, no. 4, p. 1580, 2021, doi: 10.30865/mib.v5i4.3347.
- [5] A. Desiani *et al.*, “Penerapan Metode Support Vector Machine Dalam Klasifikasi Bunga Iris,” *Indonesian Journal of Applied Informatics*, vol. 7, no. 1, p. 12, Apr. 2023, doi: 10.20961/ijai.v7i1.61486.
- [6] D. Margarita, H. Maulana, E.P.Madyartha, “Klasifikasi Penyakit Daun Padi Menggunakan Support Vector Machine Berdasarkan Fitur Mendalam (Deep Feature),” *JIPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, vol. 9, no. 4, pp. 2256–2270, 2024, doi: 10.29100/jipi.v9i4.5634.

- [7] E. Rizqi Mar'atus Sholihah, I. G. Susrama Mas Diyasa, and E. Yulia Puspaningrum, "Perbandingan Kinerja Kernel Linear dan RBF Support Vector Machine Untuk Analisis Sentimen Ulasan Pengguna KAI Acces Pada Google Play Store," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 8, no. 1, pp. 728–733, Mar. 2024, doi: 10.36040/jati.v8i1.8800.
- [8] M. R. Santoso and P. Musa, "Rekomendasi Kesehatan Janin Dengan Penerapan Algoritma C5.0 Menggunakan Classifying Cardiotocography Dataset," *Jurnal Simantec*, vol. 9, no. 2, pp. 65–76, Jun. 2021, doi: 10.21107/simantec.v9i2.10730.
- [9] N. Rahmayanti, H. Pradani, M. Pahlawan, and R. Vinarti, "Comparison Of Machine Learning Algorithms To Classify Fetal Health Using Cardiotocogram Data," *Procedia Comput Sci*, vol. 197, pp. 162–171, 2022, doi: 10.1016/j.procs.2021.12.130.
- [10] D. Elreedy, A. F. Atiya, and F. Kamalov, "A Theoretical Distribution Analysis Of Synthetic Minority Oversampling Technique (SMOTE) For Imbalanced Learning," *Mach Learn*, vol. 113, no. 7, pp. 4903–4923, Jul. 2024, doi: 10.1007/s10994-022-06296-4.
- [11] E. Sutoyo, M. Asri Fadlurrahman, J. Telekomunikasi JI Terusan Buah Batu, K. Dayeuhkolot, K. Bandung, and J. Barat, "Penerapan SMOTE untuk Mengatasi Imbalance Class dalam Klasifikasi Television Advertisement Performance Rating Menggunakan Artificial Neural Network," *JEPIN (Jurnal Edukasi dan Penelitian Informatika)*, vol. 6, pp. 379–385, Dec. 2020.
- [12] O. Siboro, Y. Pricilia Banjarnahor, A. Gultom, N. Antonius Siagian, and P. D. Silitonga, "Penanganan Data Ketidakseimbangan dalam Pendekatan SMOTE Guna Meningkatkan akurasi Algoritma K-NN in SNISTIK :Seminar Nasional Inovasi Sains Teknologi Informasi Komputer, Medan, 2024.
- [13] O. Somantri, W. E. Nugroho, and A. R. Supriyono, "Penerapan Feature Selection Pada Algoritma Decision Tree Untuk Menentukan Pola Rekomendasi Dini Konseling," *Jurnal Sistem Komputer dan Informatika (JSON)*, vol. 4, no. 2, p. 272, Dec. 2022, doi: 10.30865/json.v4i2.5267.
- [14] W. B. Santosa, A. Syukur, and P. Purwanto, "Pemilihan Fitur Menggunakan Algoritma Chi-Square Dan Particle Swarm Optimization (PSO) Untuk Meningkatkan Kinerja Deep Neural Network Pada Deteksi Penyakit Diabetes," *Jurnal Media Informatika Budidarma*, vol. 8, no. 1, p. 488, Jan. 2024, doi: 10.30865/mib.v8i1.7277.
- [15] T. Ernayanti, M. Mustafid, A. Rusgiyono, and A. R. Hakim, "Penggunaan Seleksi Fitur Chi-Square dan Algoritma Multinomial Naive Bayes Untuk Analisis Sentimen Pelanggan Tokopedia," *Jurnal Gaussian*, vol. 11, no. 4, pp. 562–571, Feb. 2023, doi: 10.14710/j.gauss.11.4.562-571.
- [16] A. Rahmadeyan and M. Mustakim, "Seleksi Fitur pada Supervised Learning: Klasifikasi Prestasi Belajar Mahasiswa Saat dan Pasca Pandemi COVID-19," *Jurnal Nasional Teknologi dan Sistem Informasi*, vol. 9, no. 1, pp. 21–32, May 2023, doi: 10.25077/teknosi.v9i1.2023.21-32.
- [17] M. Sholeh, D. Andayati, and Rr. Y. Rachmawati, "Data Mining Model Klasifikasi Menggunakan Algoritma K-Nearest Neighbor Dengan Normalisasi Untuk Prediksi Penyakit Diabetes," *TeIKA*, vol. 12, no. 02, pp. 77–87, Oct. 2022, doi: 10.36342/teika.v12i02.2911.
- [18] V. Putri, "Normalisasi Data Dengan Menggunakan Model Min Max Untuk Klasifikasi Nasabah Potensial Pada Bidang Pembelian Properti Menggunakan Algoritma K-Nearest Neighbor," *Informasi dan Teknologi Ilmiah (INTI)*, pp. 111–119, Jun. 2024.
- [19] C. Agustina and E. Rahmawati, "Optimalisasi Algoritma Random Forest Menggunakan SMOTE untuk Prediksi Pembatalan Tamu Hotel," *Jurnal Sains dan Manajemen*, vol. 12, no. 2, 2024.
- [20] A. A. Arifiyanti and E. D. Wahyuni, "Smote: Metode Penyeimbang Kelas Pada Klasifikasi Data Mining," *SCAN - Jurnal Teknologi Informasi dan Komunikasi*, vol. 15, no. 1, pp. 34–39, 2020, doi: 10.33005/scan.v15i1.1850.
- [21] C. Chairunnisa, I. Ernawati, and M. M. Santoni, "Klasifikasi Sentimen Ulasan Pengguna Aplikasi PeduliLindungi di Google Play Menggunakan Algoritma Support Vector Machine dengan Seleksi Fitur Chi-Square," *Informatik : Jurnal Ilmu Komputer*, vol. 18, no. 1, p. 69, Aug. 2022, doi: 10.52958/iftk.v17i4.4594.
- [22] S. Taliki, I. C. R. Drajana, and A. Bode, "Support Vector Machine Berbasis Chi Square Untuk Prediksi Harga Beras Ecer Kabupaten Pohuwato," *Journal Of Science And Social Research*, vol. 5, no. 2, p. 436, Jul. 2022, doi: 10.54314/jssr.v5i2.899.

- [23] K. Pal and Biraj. V. Patel, "Data Classification with k-fold Cross Validation and Holdout Accuracy Estimation Methods with 5 Different Machine Learning Techniques," in *2020 Fourth International Conference on Computing Methodologies and Communication (ICCMC)*, IEEE, Mar. 2020, pp. 83–87. doi: 10.1109/ICCMC48092.2020.ICCMC-00016.
- [24] S. N. Aisah, Dian Candra Rini Novitasari, and Y. Farida, "Perbandingan Metode Extreme Learning Machine (ELM) dan Kernel Extreme Learning Machine (KELM) Pada Klasifikasi Penyakit Cedera Panggul," *Jurnal Fourier*, vol. 12, no. 2, pp. 69–78, Oct. 2023, doi: 10.14421/fourier.2023.122.69-78.
- [25] Y. Widyaningsih, G. P. Arum, and K. Prawira, "Aplikasi K-Fold Cross Validation Dalam Penentuan Model Regresi Binomial Negatif Terbaik," *BAREKENG: Jurnal Ilmu Matematika dan Terapan*, vol. 15, no. 2, pp. 315–322, Jun. 2021, doi: 10.30598/barekengvol15iss2pp315-322.
- [26] S. Rahayu and Y. Yamasari, "Klasifikasi Penyakit Stroke dengan Metode Support Vector Machine (SVM)," *Journal of Informatics and Computer Science*, vol. 05, 2024.
- [27] Z. Lai, X. Chen, J. Zhang, H. Kong, and J. Wen, "Maximal Margin Support Vector Machine for Feature Representation and Classification," *IEEE Trans Cybern*, vol. 53, no. 10, pp. 6700–6713, Oct. 2023, doi: 10.1109/TCYB.2022.3232800.
- [28] S. Rabbani, D. Safitri, N. Rahmadhani, A. A. F. Sani, and M. K. Anam, "Perbandingan Evaluasi Kernel SVM untuk Klasifikasi Sentimen dalam Analisis Kenaikan Harga BBM," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 3, no. 2, pp. 153–160, Oct. 2023, doi: 10.57152/malcom.v3i2.897.
- [29] N. Pratiwi and Y. Setyawan, "Analisis Akurasi Dari Perbedaan Fungsi Kernel Dan Cost Pada Support Vector Machine Studi Kasus Klasifikasi Curah Hujan Di Jakarta," *Journal of Fundamental Mathematics and Applications (JFMA)*, vol. 4, no. 2, pp. 203–212, Nov. 2021, doi: 10.14710/jfma.v4i2.11691.
- [30] R. Nurhidayat and K. E. Dewi, "Penerapan Algoritma K-Nearest Neighbor Dan Fitur Ekstraksi N-Gram Dalam Analisis Sentimen Berbasis Aspek," *KOMPUTA : Jurnal Ilmiah Komputer dan Informatika*, vol. 12, no. 1, 2023.
- [31] M. Azhari, Z. Situmorang, and R. Rosnelly, "Perbandingan Akurasi, Recall, dan Presisi Klasifikasi pada Algoritma C4.5, Random Forest, SVM dan Naive Bayes," *Jurnal Media Informatika Budidarma*, vol. 5, no. 2, p. 640, Apr. 2021, doi: 10.30865/mib.v5i2.2937.
- [32] A. Pangestu, Y. T. Arifin, and R. A. Safitri, "Analisis Sentimen Review Publik Pengguna Game Online Pada Platform Steam Menggunakan Algoritma Naïve Bayes," *Jurnal Mahasiswa Teknik Informatika*, vol. 7, no. 6, pp. 3106–3113, Dec. 2023.