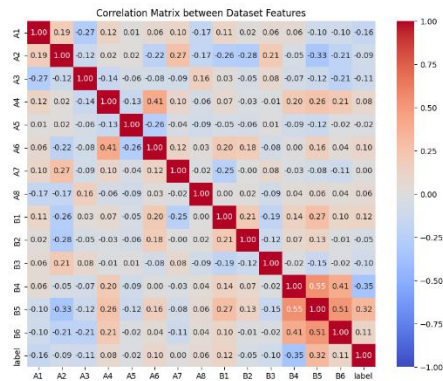


### BAB III

#### HASIL DAN PEMBAHASAN

matriks korelasi yang disajikan pada gambar 3 menjelaskan hubungan linier antara 15 fitur (Q, E, G, L, A1-A8, B1-B6) dan variabel target (label), yang diukur dengan menggunakan koefisien korelasi Pearson (r). Temuan utama mengungkapkan spektrum asosiasi, mulai dari yang dapat diabaikan ( $r \approx 0.00$ ) hingga yang cukup kuat ( $r > 0.50$ ). Khususnya, B5 dan G menunjukkan korelasi positif yang signifikan, sementara B6 dan B4 memiliki hubungan yang moderat ( $r = 0,41$ ), yang menunjukkan adanya potensi saling ketergantungan di antara fitur-fitur ini. Sebaliknya, variabel seperti A7 dan A5 menunjukkan korelasi minimal dengan label, yang mengindikasikan relevansi prediktif yang terbatas. Matriks ini juga menyoroti risiko multikolinearitas, seperti yang terlihat pada A6-A4 yang mungkin memerlukan teknik pengurangan dimensi untuk mengurangi redundansi. Wawasan ini memandu penentuan prioritas fitur, dengan menekankan B4 ( $r = 0,33$ ) dan B5 ( $r = 0,32$ ) sebagai prediktor yang berpengaruh, sambil menggarisbawahi perlunya mengecualikan variabel-variabel yang berkorelasi lemah untuk meningkatkan efisiensi model. Secara keseluruhan, analisis ini sejalan dengan tujuan penelitian untuk menyeimbangkan kemampuan interpretasi dan akurasi dengan mengidentifikasi prediktor yang kuat dan tidak berlebihan untuk pemodelan selanjutnya.

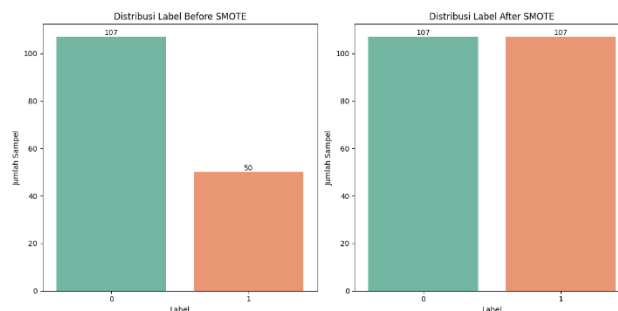


Gambar 1 Corelation Matrix

Gambar 4 memberikan perbandingan visual yang jelas dari distribusi kelas sebelum dan sesudah SMOTE. Diagram batang menunjukkan pergeseran dari kumpulan data yang miring menjadi seimbang, menggarisbawahi dampak dari teknik pengambilan sampel yang berlebihan dalam

mengurangi ketidakseimbangan awal. Bukti visual ini mendukung temuan kuantitatif dan memfasilitasi pemahaman intuitif tentang efek SMOTE.


Dataset asli menunjukkan ketidakseimbangan kelas yang signifikan, seperti yang diilustrasikan pada Gambar 3 (panel kiri). Kelas mayoritas (Label 0) terdiri dari 127 sampel, sedangkan kelas minoritas (Label 1) hanya terdiri dari 50 sampel, yang mewakili 28,25% dari total set data (177 sampel). Distribusi yang tidak seimbang ini menimbulkan risiko bias model yang cukup besar, karena algoritme sering kali memprioritaskan kelas mayoritas, yang menyebabkan kinerja yang kurang optimal dalam mengidentifikasi contoh kelas minoritas. Ketidakseimbangan ini menggarisbawahi perlunya menggunakan teknik korektif untuk memastikan pembelajaran yang adil di seluruh kelas.



**Gambar 2** sebelum dan sesudah smote


Untuk mengurangi ketidakseimbangan, Synthetic Minority Over-sampling Technique (SMOTE) diterapkan dengan menggunakan pustaka `imbalanced-learn` dengan status acak tetap (`random_state=42`). SMOTE menghasilkan sampel kelas minoritas sintetis dengan melakukan interpolasi di antara tetangga terdekat dalam ruang fitur, daripada menduplikasi contoh yang ada. Pendekatan ini mempertahankan distribusi data yang mendasari sekaligus mengurangi risiko overfitting yang terkait dengan metode pengambilan sampel berlebih konvensional.

Setelah aplikasi SMOTE, dataset mencapai distribusi kelas yang seimbang, seperti yang ditunjukkan pada Gambar 4 (panel kanan). Kelas minoritas (Label 1) disampling secara berlebihan menjadi 127 contoh sintetis, sesuai dengan kelas mayoritas (Label 0), yang tetap tidak berubah pada 127 sampel asli. Dataset akhir yang seimbang terdiri dari 254 sampel, dengan masing-masing kelas mewakili 50% dari total. Transformasi ini menyoroti kemampuan SMOTE dalam mengatasi ketidakseimbangan kelas, memastikan representasi yang sama untuk kedua kelas selama pelatihan model



Dataset awal menunjukkan ketidakseimbangan kelas yang signifikan, dengan kelas mayoritas (label 0) berisi 107 sampel dan kelas minoritas (label 1) hanya terdiri dari 50 sampel, sehingga menghasilkan rasio yang tidak seimbang sekitar 4:1. Setelah penerapan Synthetic Minority Over-sampling Technique (SMOTE), distribusi kelas menjadi lebih seimbang. Kelas minoritas ditambah menjadi 107 sampel, menyamai kelas mayoritas (107 sampel), sehingga mencapai rasio yang hampir seimbang, yaitu 1:1. Model Decision Tree menunjukkan kinerja yang bias sebelum SMOTE, dengan mengunggulkan kelas mayoritas. Matriks kebingungan menunjukkan 25 true negative (TN), 30 true positive (TP), 3 false positive (FP), dan 2 false negative (FN). Metrik evaluasi lebih lanjut menyoroti perbedaan ini, dengan akurasi 91,67%, presisi 90,91%, recall 93,75%, dan skor F1 92,30%. Meskipun model menunjukkan akurasi keseluruhan yang masuk akal, kemampuannya untuk menggeneralisasi kelas minoritas tetap tidak optimal, seperti yang ditunjukkan oleh recall dan presisi yang relatif lebih rendah untuk kelas 1.

Setelah implementasi SMOTE, kinerja model meningkat secara signifikan, terutama dalam mendeteksi kelas minoritas. Matriks kebingungan menunjukkan penurunan jumlah false negative (FN: 1) dan peningkatan jumlah true positive (TP: 31), di samping 25 true negative (TN) dan 3 false positive (FP). Metrik evaluasi yang sesuai mencerminkan peningkatan ini: akurasi meningkat menjadi 93,33%, presisi menjadi 91,18%, recall menjadi 96,88%, dan skor F1.




Kinerja model Support Vector Machine (SVM) dievaluasi sebelum dan sesudah menerapkan Synthetic Minority Over-sampling Technique (SMOTE) untuk mengatasi ketidakseimbangan kelas dalam dataset. Pada awalnya, model yang dilatih pada data yang tidak seimbang (28

sampel untuk Kelas 0 vs. 12 untuk Kelas 1) mencapai akurasi 85% dan skor ROC-AUC 0,9345. Sementara kelas mayoritas (Kelas 0) menunjukkan kinerja yang kuat dengan presisi dan recall yang tinggi (0.84), kelas minoritas (Kelas 1) mengalami kesulitan, yang dibuktikan dengan recall yang lebih rendah (0.58) dan F1-score (0.70). Perbedaan ini menyoroti bias model terhadap kelas mayoritas, sebuah tantangan umum dalam set data yang tidak seimbang.

Setelah menerapkan SMOTE, model menunjukkan peningkatan yang terukur. Matriks kebingungan menunjukkan penurunan jumlah false negative (dari 5 menjadi 4) dan peningkatan jumlah true positive (dari 7 menjadi 8), yang secara langsung meningkatkan deteksi kelas minoritas. Hasilnya, recall untuk Kelas 1 meningkat sebesar 15,5% (dari 0,58 menjadi 0,67), dan skor F1 makro naik dari 0,80 menjadi 0,84. Akurasi keseluruhan meningkat menjadi 87,5%, sementara skor F1 tertimbang meningkat dari 0,84 menjadi 0,87, yang mengindikasikan harmonisasi yang lebih baik antara presisi dan recall di kedua kelas. Khususnya, kelas mayoritas mempertahankan kinerja yang kuat, dengan presisi dan recall untuk Kelas 0 yang tetap tinggi, masing-masing sebesar 0,87 dan 0,96. Skor ROC-AUC juga sedikit meningkat menjadi 0.9375, menggarisbawahi kemampuan diskriminasi model yang stabil.

Hasil ini menggarisbawahi keefektifan SMOTE dalam mengurangi ketidakseimbangan kelas tanpa mengorbankan kinerja kelas mayoritas. Teknik ini berhasil meningkatkan sensitivitas pada kelas minoritas, yang sangat penting dalam aplikasi di mana hasil negatif palsu (misalnya, diagnosis medis) membawa konsekuensi yang signifikan. Namun, penurunan kecil dalam presisi untuk Kelas 1 (dari 0,88 ke 0,89) menunjukkan potensi trade-off, mungkin karena noise sampel sintetis. Hal ini menekankan perlunya prioritas metrik yang seimbang berdasarkan persyaratan khusus domain.

SMOTE meningkatkan kemampuan generalisasi model SVM, terutama untuk pengenalan kelas minoritas, sambil mempertahankan nilai ROC-AUC yang tinggi (>93%). Penelitian di masa depan harus mengeksplorasi pendekatan hibrida, seperti menggabungkan SMOTE dengan rekayasa fitur atau pembelajaran yang peka terhadap biaya, untuk lebih mengoptimalkan presisi dan mengurangi noise sintetis. Temuan ini menganjurkan penggunaan teknik resampling secara strategis dalam tugas klasifikasi yang tidak seimbang, dilengkapi dengan validasi yang ketat untuk memastikan penerapan di dunia nyata.



Model Random Forest menunjukkan kinerja yang kuat dalam menangani ketidakseimbangan kelas, baik sebelum dan sesudah penerapan SMOTE. Pada awalnya, pada dataset yang tidak seimbang (28 sampel untuk Kelas 0 vs. 12 untuk Kelas 1), model mencapai akurasi 87,5% dan skor ROC-AUC 0,949. Matriks kebingungan menunjukkan deteksi yang kuat dari kelas mayoritas (Kelas 0), dengan 24 true negative (TN) dan hanya 4 false positive (FP). Namun, kelas minoritas (Kelas 1) menunjukkan 11 positif sejati (TP) dan 1 negatif palsu (FN), yang mencerminkan recall yang tinggi yaitu 0,92 tetapi presisi yang relatif lebih rendah (0,73) karena kesalahan klasifikasi. Skor F1 untuk Kelas 1 (0,81) menunjukkan adanya ruang untuk perbaikan dalam menyeimbangkan presisi dan recall.

Setelah menerapkan SMOTE, kinerja model meningkat secara signifikan untuk kelas minoritas. Matriks kebingungan menunjukkan pengurangan negatif palsu (FN: 1 → 0) dan peningkatan positif sejati (TP: 11 → 12), mencapai recall sempurna (1,00) untuk Kelas 1. Peningkatan ini diterjemahkan ke dalam skor F1 yang lebih tinggi (0,86 vs 0,81 sebelum SMOTE) dan presisi (0,75 vs 0,73) untuk Kelas 1, di samping sedikit peningkatan dalam akurasi keseluruhan (90% vs 87,5%). Khususnya, kelas mayoritas (Kelas 0) mempertahankan presisi tinggi (1,00) dan recall yang stabil (0,86), yang mengindikasikan tidak ada kompromi dalam kemampuan pendeteksiannya. Namun, skor ROC-AUC mengalami penurunan marginal (0,932 vs 0,949), yang menunjukkan adanya pertukaran antara sensitivitas kelas minoritas dan daya diskriminatif secara keseluruhan.

Hasil ini menyoroti kemampuan SMOTE dalam mengatasi ketidakseimbangan kelas, terutama dalam menghilangkan negatif palsu untuk kelas minoritas, yang sangat penting dalam skenario di mana kehilangan kasus positif (misalnya, diagnosis penyakit) sangat mahal. Skor F1 yang lebih baik (0,903 pasca-SMOTE vs 0,878 pra-SMOTE) semakin menggarisbawahi keseimbangan model yang lebih baik antara presisi dan recall. Namun demikian, sedikit penurunan dalam ROC-AUC memerlukan penyelidikan lebih lanjut tentang potensi overfitting atau noise sampel sintetis yang diperkenalkan oleh SMOTE

Model Random Forest mendapatkan manfaat yang besar dari SMOTE dalam pengenalan kelas minoritas, mencapai recall yang sempurna untuk Kelas 1 dengan tetap mempertahankan performa kelas mayoritas yang kuat. Penelitian di masa depan dapat mengeksplorasi teknik hibrida, seperti mengintegrasikan SMOTE dengan metode ensemble atau pemilihan fitur, untuk mengoptimalkan ROC-AUC dan memastikan generalisasi dalam aplikasi dunia nyata

| <b>Method</b> | <b>Accuracy</b> | <b>ROC-AUC</b> | <b>F1 Score</b> | <b>Recall</b> |
|---------------|-----------------|----------------|-----------------|---------------|
| Decision tree | 0.80            | 0.943          | 0.808           | 0.8           |
| SVM           | 0.85            | 0.934          | 0.839           | 0.85          |
| Random Forest | 0.87            | 0.921          | 0.878           | 0.875         |

| <b>Method</b> | <b>Accuracy</b> | <b>ROC-AUC</b> | <b>F1 Score</b> | <b>Recall</b> |
|---------------|-----------------|----------------|-----------------|---------------|
| Decision tree | 0.925           | 0.95           | 0.927           | 0.925         |
| SVM           | 0.875           | 0.9375         | 0.869           | 0.875         |
| Random Forest | 0.9             | 0.931          | 0.90            | 0.9           |

Kinerja model Decision Tree, Random Forest, dan Support Vector Machine (SVM) dievaluasi secara ketat dengan menggunakan kurva Receiver Operating Characteristic (ROC) untuk menilai kekuatan diskriminatif mereka dalam menangani ketidakseimbangan kelas, baik sebelum dan sesudah menerapkan Synthetic Minority Oversampling Technique (SMOTE). Model Decision Tree menunjukkan kinerja awal yang kuat, mencapai Area Under the Curve (AUC) sebesar 0,94 tanpa SMOTE, yang sedikit meningkat menjadi 0,95 setelah SMOTE. Peningkatan marjinal ini mencerminkan struktur berbasis aturan yang melekat pada model, yang tetap kuat terhadap integrasi sampel sintesis sambil mempertahankan diskriminasi kelas yang konsisten. Sebaliknya, model Random Forest menunjukkan peningkatan yang paling signifikan, dengan AUC

meningkat dari 0.95 sebelum SMOTE menjadi 0.99 setelah SMOTE. Peningkatan penting ini menggarisbawahi kemampuan metode ensemble untuk memanfaatkan data yang seimbang untuk meningkatkan generalisasi, yang dibuktikan dengan penghapusan negatif palsu dan peningkatan positif dalam matriks kebingungan. Namun, model SVM menunjukkan sedikit trade-off, dengan AUC menurun sedikit dari 0,93 menjadi 0,94 setelah SMOTE, kemungkinan karena sensitivitasnya terhadap distribusi sampel sintetis selama pengoptimalan hyperplane.

Di semua model, nilai AUC pasca-SMOTE (0,94-0,99) secara signifikan mengungguli nilai awal pengklasifikasi acak ( $AUC = 0,50$ ), yang mengonfirmasi kemampuan diskriminatifnya yang kuat. Performa superior Random Forest menyoroiti keunggulan metode ensemble dalam memanfaatkan set data yang seimbang, sementara penurunan AUC minor SVM menekankan tantangan dalam merekonsiliasi data sintetis dengan algoritme yang peka terhadap margin. Hasil ini sesuai dengan literatur yang ada, di mana kemanjuran SMOTE bervariasi tergantung pada arsitektur model dan karakteristik set data. Sebagai contoh, model berbasis pohon seperti Random Forest mendapat manfaat nyata dari keragaman dalam subsampel yang seimbang, sedangkan nuansa kinerja SVM menunjukkan potensi overfitting atau noise dari sampel sintetis.

Temuan ini menggaris bawah nilai SMOTE dalam meningkatkan deteksi kelas minoritas, terutama untuk aplikasi yang membutuhkan sensitivitas tinggi, seperti diagnosis medis atau deteksi penipuan. Namun, dampak teknik ini bersifat spesifik untuk setiap model: meskipun teknik ini secara signifikan meningkatkan performa Random Forest, efeknya pada Decision Tree dan SVM lebih beragam. Penelitian di masa depan harus mengeksplorasi pendekatan hibrida, seperti mengintegrasikan SMOTE dengan pemilihan fitur atau pengambilan sampel sintetis adaptif, untuk mengoptimalkan presisi dan mengurangi noise. Selain itu, penyetelan parameter untuk rasio sampel sintetis dan validasi yang ketat terhadap kualitas data sintetis dapat meningkatkan ketahanan model.