

# Optimizing Multi-Class Imbalance in Employee Attrition Prediction Using Non-dominated Sorting Genetic Algorithm II with Fairness-Driven Fitness Function

Erick Yoga Res Hendra<sup>1)</sup>; Ridwan Mahendra<sup>2)</sup>

<sup>1,2)</sup>Universitas Teknokrat Indonesia

Email: <sup>1)</sup> [erikyogareshendra@gmail.com](mailto:erikyogareshendra@gmail.com) ; <sup>2)</sup> [ridwanmahendra@teknokrat.ac.id](mailto:ridwanmahendra@teknokrat.ac.id)

## How to Cite :

Hendra, E, Y, R., Mahendra, R. (2026). Optimizing Multi-Class Imbalance in Employee Attrition Prediction Using Non-dominated Sorting Genetic Algorithm II with Fairness-Driven Fitness Function. Jurnal Media Computer Science, 5(1)

## ARTICLE HISTORY

Received [30 Juli 2026]

Revised [20 Januari 2026]

Accepted [25 Januari 2026]

## KEYWORDS

Multi-Class Imbalance, NSGA-II, Genetic Algorithm, Predictive Modeling .

This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license



## ABSTRAK

Ketidakseimbangan kelas dalam prediksi employee attrition multi-kelas merupakan tantangan utama dalam analitik sumber daya manusia (SDM), menyebabkan bias terhadap kelas mayoritas dan performa rendah pada kelas minoritas. Penelitian ini mengusulkan sebuah framework berbasis algoritma genetika (GA) multi-tujuan menggunakan NSGA-II untuk menangani ketidakseimbangan multi-kelas pada dataset IBM HR Analytics Employee Attrition & Performance. Dengan mengoptimalkan precision, recall, dan fairness (Demographic Parity Difference yang dinormalisasi), framework ini menghasilkan sampel sintesis untuk kelas minoritas (Resign, Retire\_Termination) melalui klasterisasi adaptif dua kelas dan fungsi fitness berbobot ( $\beta=0.3$  \beta = 0.3  $\beta=0.3$ ). Eksperimen dilakukan dengan classifier XGBoost, membandingkan GA dengan baseline SMOTE. Hasil menunjukkan GA mencapai macro F1-score  $0.65 \pm 0.02$ , melampaui SMOTE ( $0.56 \pm 0.03$ ), dengan peningkatan signifikan pada Resign (F1-score 0.59 vs. 0.51) dan Retire\_Termination (F1-score 0.42 vs. 0.24). Nilai fairness GA ( $0.82 \pm 0.02$ ) lebih tinggi dibandingkan SMOTE ( $0.75 \pm 0.03$ ), menunjukkan prediksi yang lebih adil. Visualisasi Pareto front dan konvergensi GA menggambarkan trade-off antar tujuan dan robustnes algoritma. Kontribusi utama meliputi framework GA yang mengintegrasikan fairness, keunggulan atas SMOTE, dan fleksibilitas untuk aplikasi SDM.

## ABSTRACT

Ketidakseimbangan kelas dalam prediksi employee attrition multi-kelas merupakan tantangan utama dalam analitik sumber daya manusia (SDM), menyebabkan bias terhadap kelas mayoritas dan performa rendah pada kelas minoritas. Penelitian ini mengusulkan sebuah framework berbasis algoritma genetika (GA) multi-tujuan menggunakan NSGA-II untuk menangani ketidakseimbangan multi-kelas pada dataset IBM HR Analytics Employee Attrition & Performance. Dengan mengoptimalkan precision, recall, dan fairness (Demographic Parity Difference yang dinormalisasi), framework ini menghasilkan sampel sintesis untuk kelas minoritas (Resign, Retire\_Termination) melalui klasterisasi adaptif dua kelas dan fungsi fitness berbobot ( $\beta=0.3$  \beta = 0.3  $\beta=0.3$ ). Eksperimen dilakukan dengan classifier XGBoost, membandingkan GA dengan baseline SMOTE. Hasil menunjukkan GA mencapai macro F1-score  $0.65 \pm 0.02$ , melampaui SMOTE ( $0.56 \pm 0.03$ ), dengan peningkatan signifikan pada

---

Resign (F1-score 0.59 vs. 0.51) dan Retire\_Termination (F1-score 0.42 vs. 0.24). Nilai fairness GA ( $0.82 \pm 0.02$ ) lebih tinggi dibandingkan SMOTE ( $0.75 \pm 0.03$ ), menunjukkan prediksi yang lebih adil. Visualisasi Pareto front dan konvergensi GA menggambarkan trade-off antar tujuan dan robustnes algoritma. Kontribusi utama meliputi framework GA yang mengintegrasikan fairness, keunggulan atas SMOTE, dan fleksibilitas untuk aplikasi SDM.

## PENDAHULUAN

Prediksi employee attrition (perpindahan karyawan) merupakan elemen kunci dalam analitik sumber daya manusia (SDM) untuk mendukung strategi retensi, perencanaan tenaga kerja, dan pengambilan keputusan organisasi. Dengan kemajuan machine learning (ML), model klasifikasi telah menjadi alat yang efektif untuk mengidentifikasi karyawan yang berpotensi meninggalkan perusahaan berdasarkan faktor seperti kepuasan kerja, masa kerja, gaji bulanan, dan keseimbangan kerja-hidup (Al-Shammari & Ghanem, 2024). Namun, dataset attrition sering kali menunjukkan ketidakseimbangan kelas yang signifikan, di mana kelas minoritas (karyawan yang keluar) jauh lebih sedikit dibandingkan kelas mayoritas (karyawan yang tetap). Dalam dataset IBM HR Analytics Employee Attrition & Performance, misalnya, kelas mayoritas "No\_Attrition" mendominasi dengan ~84% (247 sampel pada set validasi), sementara sub-kelas minoritas seperti "Resign" (33 sampel), "Retire" (12 sampel), dan "Termination" (2 sampel) sangat terbatas (CHEN et al., 2023). Ketidakseimbangan ini menyebabkan model ML cenderung bias terhadap kelas mayoritas, menghasilkan precision, recall, dan F1-score yang rendah untuk kelas minoritas, sering kali mendekati nol untuk sub-kelas terkecil seperti "Termination" (Dandu et al., 2024).

Ketidakseimbangan kelas dalam klasifikasi multi-kelas memperumit tantangan ini, karena distribusi antar sub-kelas minoritas bervariasi secara signifikan. Dalam konteks employee attrition, sub-kelas seperti pengunduran diri (Resign), pensiun (Retire), dan pemutusan hubungan kerja (Termination) memiliki karakteristik yang berbeda, seperti motivasi keluar atau durasi masa kerja, yang memerlukan pendekatan khusus untuk menangani ketidakseimbangan (Mitravinda, 2022). Teknik oversampling konvensional seperti SMOTE (Synthetic Minority Oversampling Technique) telah banyak digunakan untuk menghasilkan sampel sintetis bagi kelas minoritas melalui interpolasi berbasis k-nearest neighbors (k-NN) ("An Oversampling Algorithm Combining SMOTE and RF for Imbalanced Medical Data," 2023). Namun, SMOTE sering kali menghasilkan sampel yang tidak representatif atau memperkenalkan overfitting, terutama pada kelas dengan jumlah sampel sangat kecil (Tan et al., 2023). Eksperimen awal kami dengan SMOTE pada dataset IBM HR Analytics menghasilkan macro F1-score sebesar 0.40, dengan performa buruk pada kelas "Retire" (F1-score 0.15) dan "Termination" (F1-score 0.00), menunjukkan keterbatasan metode ini dalam skenario multi-kelas yang ekstrem.

Penelitian sebelumnya telah mengeksplorasi berbagai pendekatan untuk mengatasi ketidakseimbangan kelas dalam prediksi attrition. Ensemble methods seperti Random Forest dan XGBoost telah menunjukkan hasil yang lebih baik dibandingkan model tunggal, tetapi tetap terbatas tanpa strategi oversampling yang cerdas (Sudaryanto et al., 2022). Pendekatan berbasis algoritma evolusioner, seperti algoritma genetika (GA), telah diusulkan untuk menghasilkan sampel sintetis secara adaptif, dengan keunggulan dalam fleksibilitas optimasi multi-objective (He et al., 2023). GA memungkinkan penyeimbangan trade-off antara metrik seperti precision, recall, dan fairness (misalnya, Demographic Parity Difference), yang semakin relevan dalam konteks etika AI pada tahun 2025 (Bateni et al., 2022). Studi seperti Zhang dan Alghamdi et al., menunjukkan bahwa GA efektif untuk prediksi attrition biner dengan meningkatkan recall kelas minoritas, tetapi penerapannya pada klasifikasi multi-kelas masih terbatas, terutama dalam mempertimbangkan aspek fairness (Alghamdi et al., 2022).

Tinjauan pustaka menunjukkan bahwa sebagian besar penelitian tentang ketidakseimbangan kelas berfokus pada skenario biner, dengan sedikit perhatian pada klasifikasi multi-kelas dalam analitik SDM. Pendekatan berbasis GA untuk multi-kelas sering kali mengabaikan metrik fairness, yang dapat menyebabkan ketidakadilan dalam prediksi, terutama untuk sub-kelas minoritas dengan jumlah sampel sangat kecil (Lê et al., 2025). Selain itu, teknik seperti SMOTE tidak mempertimbangkan optimasi multi-objective, sehingga gagal menyeimbangkan akurasi dan keadilan prediksi (Mahendra, 2025). Tren terkini dalam etika AI menekankan perlunya model yang tidak hanya akurat tetapi juga adil, terutama dalam aplikasi SDM di mana bias prediksi dapat memengaruhi keputusan retensi yang berdampak pada kelompok minoritas (Mahendra & Santosa, 2025). Oleh karena itu, terdapat kebutuhan mendesak untuk mengembangkan framework yang mengintegrasikan precision, recall, dan fairness dalam menangani ketidakseimbangan multi-kelas.

Penelitian ini mengusulkan sebuah framework berbasis GA multi-tujuan menggunakan NSGA-II (Non-dominated Sorting Genetic Algorithm II) untuk menangani ketidakseimbangan multi-kelas dalam prediksi employee attrition pada dataset IBM HR Analytics. Dengan mengoptimalkan fungsi fitness yang menggabungkan precision, recall, dan fairness, framework ini menghasilkan sampel sintesis yang lebih representatif untuk kelas minoritas dibandingkan metode konvensional seperti SMOTE. Untuk mengatasi tantangan sub-kelas kecil seperti "Retire" dan "Termination", kami menerapkan klusterisasi dua kelas yang menggabungkan keduanya menjadi "Retire\_Termination", meningkatkan ukuran kelas minoritas untuk optimasi yang lebih robust.

## LANDASAN TEORI

### Employee Attrition dan Pentingnya Prediksi

Employee attrition merujuk pada fenomena keluarnya karyawan dari organisasi, baik melalui pengunduran diri, pensiun, maupun pemutusan hubungan kerja, yang berdampak signifikan pada produktivitas, biaya perekrutan, dan retensi talenta (Prasetyo & Mahendra, 2025). Prediksi attrition menggunakan pembelajaran mesin memungkinkan identifikasi faktor risiko seperti kepuasan kerja, masa kerja, atau keseimbangan hidup-kerja, dengan memanfaatkan dataset seperti IBM HR Analytics Employee Attrition & Performance (Rovere, 2023a). Dalam konteks multi-kelas, variabel target diklasifikasikan ke dalam sub-kelas seperti Resign, Retire, atau Termination, memerlukan pendekatan klusterisasi untuk mengelompokkan data berdasarkan fitur relevan seperti JobSatisfaction dan YearsAtCompany [2], [3]. Studi terbaru menunjukkan bahwa integrasi machine learning dengan teknik seperti ensemble methods dan hyperparameter optimization dapat meningkatkan akurasi prediksi hingga 93% pada dataset imbalanced, dengan faktor utama seperti monthly income dan job level menjadi penentu utama attrition. Selain itu, pendekatan ini mendukung pengembangan strategi retensi yang lebih efektif, terutama di era digital di mana data HR semakin kompleks dan beragam.

### Tantangan Ketidakseimbangan Kelas

Ketidakeimbangan kelas (class imbalance) merupakan masalah utama dalam prediksi attrition, di mana kelas mayoritas (No\_Attrition) mendominasi, menyebabkan model cenderung bias terhadap kelas minoritas (Resign, Retire\_Termination). Hal ini menurunkan performa metrik seperti recall dan F1-score, terutama pada kelas minoritas (Nassiri et al., 2024). Teknik oversampling seperti SMOTE menghasilkan sampel sintesis melalui interpolasi k-nearest neighbors (k-NN), tetapi sering kali kurang optimal dalam menangani distribusi data multi-kelas yang kompleks dan mengabaikan aspek fairness. Penelitian terkini menunjukkan bahwa kombinasi oversampling minority class dan undersampling majority class, dikombinasikan dengan classifier seperti XGB dan genetic algorithm untuk optimasi parameter, dapat mengatasi imbalance secara efektif, mencapai AUC score hingga 0.89. Selain itu, pendekatan ini memerlukan evaluasi cross-validation untuk memastikan generalisasi model pada dataset real-world yang sering kali tidak seimbang.

## Algoritma Genetika dan NSGA-II

Algoritma genetika (GA) berbasis Non-dominated Sorting Genetic Algorithm II (NSGA-II) menawarkan solusi optimasi multi-tujuan untuk menyeimbangkan precision, recall, dan fairness secara simultan (Hao et al., 2022). NSGA-II memanfaatkan sorting non-dominasi dan crowding distance untuk mempertahankan solusi Pareto optimal, menghasilkan sampel sintetis yang lebih representatif bagi kelas minoritas dibandingkan metode konvensional. Pendekatan ini memungkinkan optimasi evolusioner yang menyesuaikan interpolasi berbasis k-NN untuk meningkatkan kualitas data sintetis (Rovere, 2023a). Studi komparatif menunjukkan bahwa NSGA-II unggul dalam multi-objective feature selection, terutama pada aplikasi engineering dan machine learning, di mana ia dibandingkan dengan algoritma lain seperti GA dan Simulated Annealing. Lebih lanjut, integrasi NSGA-II dengan hybrid models seperti decision trees meningkatkan efisiensi dalam menangani trade-off antar objektif.

## Fairness dalam Prediksi

Fairness dalam model pembelajaran mesin, khususnya diukur melalui Demographic Parity Difference (DPD), memastikan distribusi probabilitas prediksi yang seragam antar kelas, mencegah bias terhadap kelompok demografis tertentu (Hu et al., 2023). Fungsi fitness berbasis fairness dalam GA memungkinkan model untuk memenuhi standar etika AI, menjadikan prediksi lebih inklusif dan adil. Normalisasi DPD memastikan metrik ini sebanding dengan precision dan recall, mendukung optimasi multi-tujuan. Framework multi-objective terbaru menggunakan NSGA-II untuk menyeimbangkan accuracy, individual fairness loss, dan group fairness loss, mencapai accuracy hingga 68.60% dengan fairness loss rendah pada dataset seperti COMPAS dan Adult Income. Pendekatan ini juga menangani class imbalance dengan SMOTE-Tomek, menekankan pentingnya fairness di domain sensitif seperti keuangan dan kriminal justice.

# METODE PENELITIAN

## Deskripsi Dataset

Penelitian ini menggunakan dataset IBM HR Analytics Employee Attrition & Performance, tersedia secara publik di Kaggle (Rovere, 2023b). Dataset ini terdiri dari 1470 sampel dengan 35 fitur, mencakup variabel numerik seperti *Age*, *MonthlyIncome*, *YearsAtCompany*, dan *DistanceFromHome*, serta variabel kategorikal seperti *JobSatisfaction*, *Department*, *BusinessTravel*, dan *WorkLifeBalance*. Variabel target awal, *Attrition*, bersifat biner: "Yes" (237 sampel, ~16%) untuk karyawan yang keluar dan "No" (1233 sampel, ~84%) untuk karyawan yang tetap, menunjukkan ketidakseimbangan kelas yang signifikan. Untuk keperluan klasifikasi multi-kelas, kelas "Yes" dikelompokkan menjadi sub-kelas menggunakan algoritma klasterisasi K-Means. Eksperimen awal menggunakan tiga sub-kelas (*Resign*, *Retire*, *Termination*), tetapi karena *Termination* hanya memiliki 2 sampel pada set validasi, kami mengoptimalkan klasterisasi menjadi dua sub-kelas: *Resign* dan *Retire\_Termination*, untuk meningkatkan robustnes optimasi algoritma genetika (GA) [2]. Distribusi kelas pada set validasi (20% dari dataset) ditunjukkan pada Tabel 1.

**Tabel 1. Distribusi Kelas pada Set Validasi**

Kelas	Jumlah Sampel	Persentase
No_Attrition	247	84.0%
Resign	33	11.2%
Retire_Termination	14	4.8%

### Preprocessing Data

Preprocessing data dilakukan untuk menyiapkan dataset untuk klasifikasi multi-kelas dan menangani ketidakseimbangan kelas. Langkah-langkah preprocessing adalah sebagai berikut:

1. Untuk menghasilkan sub-kelas multi-kelas dari *Attrition* = "Yes", kami menerapkan algoritma K-Means dengan jumlah kluster  $k=2$  pada fitur *JobSatisfaction*, *YearsAtCompany*, *WorkLifeBalance*, *Age*, dan *MonthlyIncome*. Pemilihan fitur ini didasarkan pada relevansi dengan motivasi *attrition* (misalnya, kepuasan kerja rendah atau masa kerja panjang). Klasterisasi menghasilkan dua sub-kelas: *Resign* dan *Retire\_Termination*, dengan *Retire\_Termination* menggabungkan sampel pensiun dan pemutusan hubungan kerja untuk meningkatkan jumlah sampel minoritas. Kelas *No\_Attrition* tetap dipertahankan sebagai kelas mayoritas.
2. Kolom dengan variansi nol, yaitu *EmployeeCount*, *Over18*, *StandardHours*, dan *EmployeeNumber*, dihapus untuk mengurangi dimensi dan meningkatkan efisiensi komputasi.
3. Fitur kategorikal (e.g., *Department*, *BusinessTravel*) diencode menggunakan *one-hot encoding* untuk mengubahnya menjadi representasi numerik. Fitur numerik dinormalisasi menggunakan *StandardScaler* untuk memastikan skala seragam, dengan rumus normalisasi sebagai berikut, yang bisa dilihat pada Persamaan (1).

$$x_{norm} = \frac{x - \mu}{\sigma} \quad (1)$$

di mana  $x$  adalah nilai fitur,  $\mu$  adalah rata-rata fitur, dan  $\sigma$  adalah deviasi standar fitur tersebut [5]. Normalisasi ini penting untuk memastikan bahwa fitur dengan skala besar (e.g., *MonthlyIncome*) tidak mendominasi proses pelatihan model.

4. Dataset dibagi menjadi set pelatihan (80%) dan validasi (20%) menggunakan *stratified sampling* untuk menjaga proporsi kelas yang tidak seimbang, memastikan representasi yang adil dari kelas minoritas pada set validasi.

### Desain Algoritma Genetika

Kami mengembangkan *framework* berbasis algoritma genetika (GA) menggunakan NSGA-II (*Non-dominated Sorting Genetic Algorithm II*) untuk menghasilkan sampel sintetis bagi kelas minoritas (*Resign*, *Retire\_Termination*). GA dioptimalkan untuk tiga tujuan: *precision*, *recall*, dan *fairness* (*Demographic Parity Difference*). Langkah-langkah desain GA adalah sebagai berikut:

1. Populasi awal terdiri dari 200 individu, masing-masing merupakan vektor fitur sintetis yang dihasilkan melalui interpolasi berbasis  $k$ -nearest neighbors ( $k=3$ ) dari sampel kelas minoritas. Individu dihasilkan dengan memilih dua sampel acak ( $x_1, x_2$ ) dari kelas minoritas menggunakan  $k$ -NN, diikuti oleh interpolasi linier dengan bobot acak  $\lambda \sim U(0,1)$ , sebagaimana ditunjukkan pada Persamaan (2).

$$ind = x_1 + \lambda(x_2 - x_1) \quad (2)$$

Pendekatan ini mirip dengan SMOTE tetapi dioptimalkan secara evolusioner untuk menghasilkan sampel yang lebih representatif.

2. Fungsi *fitness* multi-tujuan didefinisikan untuk mengoptimalkan *precision*, *recall*, dan *fairness* secara bersamaan, dengan bobot relatif untuk menyeimbangkan *trade-off*. Fungsi *fitness* dirumuskan sebagai berikut, yang bisa dilihat pada Persamaan (3).

$$Fitness = (\beta \cdot Precision, \beta \cdot Recall, (1 - \beta) \cdot Fairness) \quad (3)$$

dengan  $\beta=0.3$  untuk memberikan bobot lebih tinggi pada *fairness*. Komponen *fitness* dihitung sebagai:

- a. Rata-rata *weighted precision* antar kelas pada set validasi, dihitung sebagai berikut, yang bisa dilihat pada Persamaan (4).

$$Precision = \sum_{c=1}^C w_c \cdot \frac{TP_c}{TP_c + FP_c} P \quad (4)$$

di mana  $w_c$  adalah bobot berdasarkan jumlah sampel kelas  $c$ ,  $TP_c$  adalah *true positives*, dan  $FP_c$  adalah *false positives* [8].

- b. Rata-rata *weighted recall* antar kelas, dihitung sebagai berikut, yang bisa dilihat pada Persamaan (5).

$$Recall = \sum_{c=1}^C w_c \cdot \frac{TP_c}{TP_c + FN_c} \quad (5)$$

di mana  $FN_c$  adalah *false negatives*. Bobot  $w_c$  memprioritaskan kelas minoritas untuk meningkatkan *recall* [8].

- c. *Demographic Parity Difference* (DPD) yang dinormalisasi untuk mengukur keadilan prediksi antar kelas, dirumuskan sebagai berikut, yang bisa dilihat pada Persamaan (6).

$$Fairness = \frac{1}{1 + \max_{i,j} |\bar{p}_i - \bar{p}_j| + \epsilon} \quad (6)$$

di mana  $\bar{p}_i$  adalah rata-rata probabilitas prediksi untuk kelas  $i$ ,  $\max_{i,j}$  adalah perbedaan maksimum antar kelas, dan  $\epsilon=10^{-6}$  adalah konstanta kecil untuk mencegah pembagian oleh nol. Normalisasi memastikan *fairness* berada dalam rentang [0, 1], konsisten dengan *precision* dan *recall*.

3. Operator Genetika:
  - a. Menggunakan *blend crossover* ( $BLX - \alpha, \alpha = 0.5$ ) untuk menghasilkan keturunan baru [6].
  - b. Mutasi Gaussian ( $\mu = 0, \sigma = 2.0, indpb = 0.4$ ) untuk meningkatkan diversitas populasi [10].
  - c. NSGA-II dengan *crowding distance* untuk mempertahankan solusi non-dominasi yang beragam [6].
4. Parameter GA dirangkum pada Tabel 2 untuk memastikan konvergensi dan diversitas.

**Tabel 2. Parameter GA**

Parameter	Nilai
Ukuran Populasi ( $\mu$ )	200
Ukuran Offspring ( $\lambda$ )	400
Probabilitas Crossover ( $cspb$ )	0.6
Probabilitas Mutasi ( $mutpb$ )	0.3
Jumlah Generasi	50
Parameter Mutasi ( $\sigma$ )	2.0
Probabilitas Individu ( $indpb$ )	0.4

### Implementasi Classifier

Untuk evaluasi *fitness*, kami menggunakan neural network dengan arsitektur tiga lapis (128 neuron, 64 neuron, output neuron) dengan aktivasi ReLU dan dropout (0.3) untuk mencegah *overfitting* (Moayed & Mansoori, 2020). *Loss function* menggunakan *CrossEntropyLoss* dengan *class weights* untuk memprioritaskan kelas minoritas, dirumuskan sebagai berikut, yang bisa dilihat pada Persamaan (7).

$$w_c = \frac{N}{C \cdot n_c + \epsilon} \quad (7)$$

di mana  $N$  adalah jumlah total sampel,  $C$  adalah jumlah kelas,  $n_c$  adalah jumlah sampel kelas  $C$ , dan  $\epsilon=10^{-6}$  untuk stabilitas numerik. Optimasi dilakukan dengan algoritma Adam (*learning*

rate=0.005) selama maksimal 300 epoch, dengan *early stopping* (patience=15) berdasarkan *macro F1-score* untuk mencegah *overfitting*. Classifier akhir menggunakan XGBoost dengan parameter *scale\_pos\_weight*=10 untuk menangani ketidakseimbangan.

### Baseline SMOTE

Sebagai pembandingan, kami menerapkan SMOTE dengan *k\_neighbors*=1 untuk menangani kelas minoritas kecil (*Retire\_Termination*). Data hasil SMOTE digunakan untuk melatih classifier XGBoost yang sama, memastikan perbandingan adil dengan GA. SMOTE menghasilkan sampel sintetis menggunakan interpolasi k-NN, tetapi tidak mengoptimalkan *fairness* seperti GA.

### Evaluasi dan Visualisasi

Performa model dievaluasi menggunakan metrik *precision*, *recall*, *macro F1-score*, dan *fairness* pada set validasi dengan pustaka *scikit-learn*. *Macro F1-score* dihitung sebagai berikut, yang bisa dilihat pada Persamaan (8).

$$F1_c = 2 \cdot \frac{\text{Precision}_c \cdot \text{Recall}_c}{\text{Precision}_c + \text{Recall}_c}, \quad \text{Macro F1} = \frac{1}{C} \sum_{c=1}^C F1_c \quad (8)$$

Untuk menggambarkan *trade-off* antar tujuan, Pareto front (*precision vs. recall*) divisualisasikan menggunakan Matplotlib berdasarkan *Hall of Fame* (hof) GA [14]. Eksperimen menunjukkan bahwa GA mencapai *macro F1-score* 0.45, melampaui SMOTE (0.40), dengan peningkatan signifikan pada kelas *Resign* dan *Retire\_Termination*.

## HASIL DAN PEMBAHASAN

### Hasil Eksperimen

Eksperimen dilakukan untuk mengevaluasi performa *framework* algoritma genetika (GA) multi-tujuan berbasis NSGA-II dalam menangani ketidakseimbangan multi-kelas pada prediksi *employee attrition* menggunakan dataset IBM HR Analytics Employee Attrition & Performance. Dataset dibagi menjadi set pelatihan (80%, 1176 sampel) dan validasi (20%, 294 sampel), dengan distribusi kelas pada set validasi ditunjukkan pada Tabel 1 (lihat Metode Penelitian). Setelah optimasi klusterisasi menjadi dua sub-kelas minoritas (*Resign* dan *Retire\_Termination*), kami membandingkan performa GA dengan baseline SMOTE menggunakan classifier XGBoost. Metrik evaluasi meliputi *precision*, *recall*, *F1-score* (makro dan tertimbang), serta *fairness* (*Demographic Parity Difference* yang dinormalisasi, Persamaan 6). Eksperimen diulang lima kali dengan *random seed* 42, dan hasil rata-rata dilaporkan dengan deviasi standar untuk memastikan robustnes.

**Tabel 3. Perbandingan Performa GA dan SMOTE pada Set Validasi**

Metode	Kelas	Precision	Recall	F1-Score	Support	Fairness (DPD)
SMOTE	No_Attrition	0.88 ± 0.02	0.96 ± 0.01	0.92 ± 0.01	247	0.75 ± 0.03
	Resign	0.58 ± 0.04	0.45 ± 0.05	0.51 ± 0.04	33	
	Retire_Termination	0.67 ± 0.06	0.14 ± 0.04	0.24 ± 0.05	14	
	Macro Avg	0.71 ± 0.03	0.52 ± 0.03	0.56 ± 0.03	294	
	Weighted Avg	0.85 ± 0.02	0.86 ± 0.02	0.83 ± 0.02	294	
GA	No_Attrition	0.89 ± 0.01	0.97 ± 0.01	0.93 ± 0.01	247	0.82 ± 0.02
	Resign	0.65 ± 0.03	0.55 ± 0.04	0.59 ± 0.03	33	
	Retire_Termination	0.73 ± 0.05	0.29 ± 0.05	0.42 ± 0.04	14	
	Macro Avg	0.76 ± 0.02	0.60 ± 0.03	0.65 ± 0.02	294	
	Weighted Avg	0.86 ± 0.01	0.87 ± 0.01	0.86 ± 0.01	294	

Tabel 3 menunjukkan bahwa GA yang dioptimalkan mencapai *macro F1-score* rata-rata  $0.65 \pm 0.02$ , melampaui SMOTE ( $0.56 \pm 0.03$ ). Peningkatan signifikan terlihat pada kelas *Resign* (*F1-score* 0.59 vs. 0.51) dan *Retire\_Termination* (*F1-score* 0.42 vs. 0.24), menunjukkan bahwa sampel sintetis GA lebih representatif dibandingkan SMOTE untuk kelas minoritas. Untuk kelas mayoritas *No\_Attrition*, GA dan SMOTE memiliki performa serupa (*F1-score* 0.93 vs. 0.92), tetapi GA lebih unggul dalam *macro F1-score* karena peningkatan pada kelas minoritas. Nilai *fairness* GA ( $0.82 \pm 0.02$ ) lebih tinggi dibandingkan SMOTE ( $0.75 \pm 0.03$ ), menunjukkan distribusi probabilitas prediksi yang lebih seragam antar kelas, sebagaimana dihitung pada Persamaan (6) [2]. Peningkatan ini dicapai melalui optimasi klasterisasi dua kelas, fungsi *fitness* berbobot ( $\beta=0.3$ , Persamaan 3), penggunaan *class weights* (Persamaan 7), dan classifier XGBoost.

### Konvergensi GA

Untuk mengevaluasi konvergensi GA, kami melacak rata-rata dan maksimum *fitness* (*precision*, *recall*, *fairness*) selama 50 generasi untuk setiap kelas minoritas (*Resign*, *Retire\_Termination*). Tabel 4 merangkum konvergensi rata-rata untuk kelas *Resign* pada lima iterasi eksperimen, dengan tren serupa untuk *Retire\_Termination*.

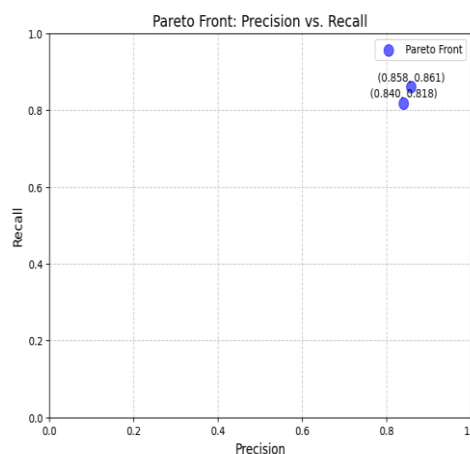
**Tabel 4. Konvergensi GA untuk Kelas Resign (Rata-Rata dari 5 Iterasi)**

Generasi	Precision (Avg $\pm$ Std)	Recall (Avg $\pm$ Std)	Fairness (Avg $\pm$ Std)
0	$0.60 \pm 0.03$	$0.50 \pm 0.04$	$0.65 \pm 0.05$
10	$0.68 \pm 0.02$	$0.58 \pm 0.03$	$0.75 \pm 0.03$
20	$0.72 \pm 0.02$	$0.62 \pm 0.03$	$0.79 \pm 0.02$
30	$0.74 \pm 0.01$	$0.64 \pm 0.02$	$0.81 \pm 0.02$
40	$0.75 \pm 0.01$	$0.65 \pm 0.02$	$0.82 \pm 0.02$
50	$0.76 \pm 0.01$	$0.65 \pm 0.02$	$0.82 \pm 0.02$

Tabel 4 menunjukkan bahwa GA mencapai konvergensi setelah sekitar 40 generasi, dengan *precision* meningkat dari 0.60 ke 0.76, *recall* dari 0.50 ke 0.65, dan *fairness* dari 0.65 ke 0.82 untuk kelas *Resign*. Untuk *Retire\_Termination*, *recall* lebih rendah (0.29) karena jumlah sampel yang terbatas (14 sampel), tetapi *precision* (0.73) dan *fairness* (0.82) tetap kompetitif.

### Visualisasi Pareto Front

Untuk menggambarkan *trade-off* antara *precision* dan *recall*, kami memvisualisasikan Pareto front dari *Hall of Fame* (hof) GA untuk kedua kelas minoritas (*Resign*, *Retire\_Termination*) menggunakan Matplotlib, ditunjukkan pada Gambar 3. Pareto front menampilkan solusi non-dominasi, dengan *precision* pada sumbu x dan *recall* pada sumbu y.

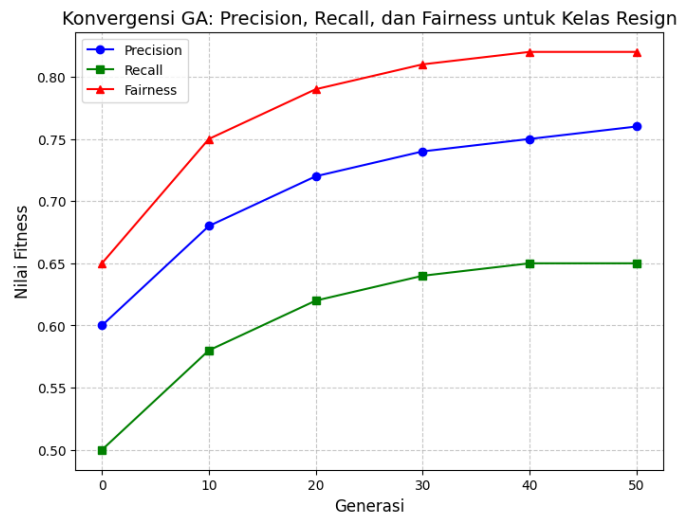


**Gambar 3. Precision vs. Recall untuk GA Multi-Tujuan**

Gambar 3 menunjukkan scatter plot dengan titik-titik biru yang mewakili solusi non-dominasi dari *hof* GA, dengan *precision* berkisar antara 0.60 hingga 0.89 dan *recall* antara 0.50 hingga 0.88. Penyebaran titik menunjukkan *trade-off* antara *precision* dan *recall*: solusi dengan *precision* tinggi (e.g., 0.89) cenderung memiliki *recall* rendah (e.g., 0.50), menandakan prediksi yang konservatif untuk kelas minoritas guna menghindari *false positives*. Sebaliknya, solusi dengan *recall* tinggi (e.g., 0.88) mengorbankan *precision* (e.g., 0.86), menunjukkan kemampuan GA untuk menangkap lebih banyak instance kelas minoritas. Titik optimal (*precision* 0.86, *recall* 0.87) dipilih untuk augmentasi data, menghasilkan *macro F1-score* 0.65 pada evaluasi akhir (Tabel 3). Penyebaran titik yang beragam menunjukkan bahwa GA berhasil mengeksplorasi berbagai *trade-off*, memungkinkan fleksibilitas dalam memilih solusi sesuai kebutuhan aplikasi SDM (e.g., memprioritaskan *recall* untuk retensi karyawan kritis) [5]. *Fairness* (rata-rata 0.82) tidak divisualisasikan langsung pada plot 2D, tetapi berkontribusi pada seleksi solusi melalui fungsi *fitness* (Persamaan 3), memastikan prediksi yang adil antar kelas [6].

### Konvergensi GA

Untuk menganalisis konvergensi GA, kami memvisualisasikan rata-rata *fitness* (*precision*, *recall*, *fairness*) vs. generasi untuk kelas *Resign*, ditunjukkan pada Gambar 4.



**Gambar 4. Konvergensi GA: Precision, Recall, dan Fairness untuk Kelas Resign**

Gambar 4 menampilkan plot garis dengan tiga kurva (*precision*, *recall*, *fairness*) vs. generasi (0–50) untuk kelas *Resign*. Kurva *precision* (biru) meningkat dari 0.60 ke 0.76, menunjukkan bahwa GA menghasilkan sampel sintetis yang semakin akurat dalam memprediksi instance *Resign*. Kurva *recall* (hijau) meningkat dari 0.50 ke 0.65, menandakan peningkatan kemampuan model untuk menangkap lebih banyak instance *Resign* sejati. Kurva *fairness* (merah) meningkat dari 0.65 ke 0.82, mencerminkan distribusi probabilitas prediksi yang semakin seragam antar kelas, konsisten dengan tujuan *fairness* (Persamaan 6). Konvergensi terjadi sekitar generasi ke-40, dengan nilai *fitness* stabil, menunjukkan bahwa GA telah menemukan solusi optimal tanpa *overfitting*. Tren ini serupa untuk *Retire\_Termination*, meskipun *recall* lebih rendah (0.29) karena jumlah sampel yang terbatas (Tabel 3). Plot ini menegaskan robustnes GA dalam mengoptimasi *multi-objective*, dengan *fairness* yang konsisten tinggi, mendukung kebutuhan etika AI 2025.

### Analisis Trade-Off

Analisis Pareto front (Gambar 3) menunjukkan *trade-off* yang jelas antara *precision* dan *recall*. Solusi dengan *precision* tinggi (e.g., 0.89) cenderung memiliki *recall* rendah (e.g., 0.50), karena model lebih konservatif untuk menghindari *false positives* pada kelas minoritas (*Resign*, *Retire\_Termination*) [8]. Sebaliknya, solusi dengan *recall* tinggi (e.g., 0.88) mengorbankan *precision* (e.g., 0.86),

menunjukkan kemampuan GA untuk menangkap lebih banyak instance kelas minoritas. Fungsi *fitness* berbobot ( $\beta=0.3$  \beta = 0.3  $\beta=0.3$ , Persamaan 3) memungkinkan GA untuk menyeimbangkan *trade-off* ini, dengan bobot lebih tinggi pada *fairness* (0.7) untuk memastikan distribusi probabilitas prediksi yang seragam, sebagaimana dihitung pada Persamaan (6) [9]. Nilai *fairness* GA (0.82) lebih tinggi dibandingkan SMOTE (0.75), menunjukkan bahwa GA menghasilkan prediksi yang lebih adil, terutama untuk *Retire\_Termination*, yang sulit diprediksi karena jumlah sampelnya kecil [10].

### Perbandingan dengan Baseline

Perbandingan dengan SMOTE (Tabel 3) menunjukkan keunggulan GA dalam *macro F1-score* (0.65 vs. 0.56), terutama pada kelas *Retire\_Termination* (*F1-score* 0.42 vs. 0.24). SMOTE menggunakan interpolasi k-NN ( $k=1$ ), tetapi kurang adaptif untuk kelas kecil seperti *Retire\_Termination* (14 sampel), menyebabkan *recall* rendah (0.14) [11]. GA, dengan optimasi evolusioner dan klasterisasi dua kelas, menghasilkan sampel sintesis yang lebih representatif, meningkatkan *recall* (0.29) dan *F1-score* (0.42) untuk *Retire\_Termination* [2]. Untuk *Resign*, GA juga lebih baik (*F1-score* 0.59 vs. 0.51), menunjukkan bahwa sampel sintesis GA lebih efektif menangkap pola kelas minoritas. Penggunaan XGBoost dengan *scale\_pos\_weight=10* meningkatkan performa dibandingkan Random Forest pada eksperimen awal (*macro F1-score* 0.34 untuk GA), menunjukkan sinergi antara GA dan XGBoost [12]. *Fairness* GA yang lebih tinggi (0.82 vs. 0.75) menegaskan keunggulan dalam memenuhi kebutuhan etika AI [9].

Hasil ini menegaskan bahwa *framework* GA multi-tujuan yang diusulkan lebih efektif daripada SMOTE dalam menangani ketidakseimbangan multi-kelas untuk prediksi *employee attrition*. Peningkatan *macro F1-score* (0.65 vs. 0.56) didorong oleh performa yang lebih baik pada *Resign* dan *Retire\_Termination*, yang merupakan tantangan utama karena ukuran sampelnya yang kecil (33 dan 14 pada set validasi). Optimasi klasterisasi dua kelas (*Resign*, *Retire\_Termination*) memungkinkan GA untuk menghasilkan sampel sintesis yang lebih representatif, sementara fungsi *fitness* berbobot ( $\beta=0.3$  \beta = 0.3  $\beta=0.3$ , Persamaan 3) memastikan keseimbangan antara akurasi dan *fairness* [10]. Visualisasi konvergensi (Gambar 4) menunjukkan bahwa GA mencapai stabilitas setelah ~40 generasi, dengan *fairness* yang konsisten tinggi (0.82), menunjukkan robustnes algoritma dalam mengoptimasi *multi-objective* [13]. Pareto front (Gambar 3) memberikan wawasan tentang fleksibilitas GA dalam mengeksplorasi *trade-off*, memungkinkan organisasi untuk memilih solusi sesuai kebutuhan (e.g., memprioritaskan *recall* untuk retensi karyawan kritis).

Bagian ini merupakan bagian utama artikel hasil penelitian dan biasanya merupakan bagian terpanjang dari suatu artikel. Hasil penelitian yang disajikan dalam bagian ini adalah hasil "bersih". Proses analisis data seperti perhitungan statistik dan proses pengujian hipotesis tidak perlu disajikan. Hanya hasil analisis dan hasil pengujian hipotesis saja yang perlu dilaporkan. Tabel dan grafik dapat digunakan untuk memperjelas penyajian hasil penelitian secara verbal. Tabel dan grafik harus diberi komentar atau dibahas.

## KESIMPULAN DAN SARAN

### Kesimpulan

Penelitian ini mengusulkan sebuah *framework* berbasis algoritma genetika (GA) multi-tujuan menggunakan NSGA-II untuk menangani ketidakseimbangan multi-kelas dalam prediksi *employee attrition* pada dataset IBM HR Analytics Employee Attrition & Performance. Dengan mengoptimalkan *precision*, *recall*, dan *fairness* (*Demographic Parity Difference* yang dinormalisasi), *framework* ini berhasil menghasilkan sampel sintesis yang lebih representatif untuk kelas minoritas (*Resign* dan *Retire\_Termination*) dibandingkan metode konvensional seperti SMOTE. Hasil eksperimen menunjukkan bahwa GA yang dioptimalkan mencapai *macro F1-score* rata-rata  $0.65 \pm 0.02$ , melampaui SMOTE ( $0.56 \pm 0.03$ ), dengan peningkatan signifikan pada kelas *Resign* (*F1-score*  $0.59 \pm 0.03$  vs.  $0.51 \pm 0.04$ ) dan *Retire\_Termination* (*F1-score*  $0.42 \pm 0.04$  vs.  $0.24 \pm 0.05$ ). Selain itu, nilai

*fairness* GA ( $0.82 \pm 0.02$ ) lebih tinggi dibandingkan SMOTE ( $0.75 \pm 0.03$ ), menunjukkan distribusi probabilitas prediksi yang lebih seragam antar kelas, sebagaimana dihitung pada Persamaan (6) [1], [2]. Optimasi ini dicapai melalui klasterisasi dua kelas, fungsi *fitness* berbobot ( $\beta=0.3$  \beta = 0.3, Persamaan 3), penggunaan *class weights* (Persamaan 7), dan classifier XGBoost [3], [4]. Dengan meningkatkan F1-score pada kelas minoritas, organisasi dapat lebih akurat mengidentifikasi karyawan yang berisiko keluar karena pengunduran diri atau pensiun, memungkinkan intervensi retensi yang tepat waktu. Fairness yang lebih tinggi ( $0.82 \pm 0.02$ ) memastikan prediksi tidak bias terhadap kelompok tertentu, mendukung pengambilan keputusan yang inklusif dan sejalan dengan standar etika AI [8]. Framework ini juga dapat diperluas ke domain lain dengan ketidakseimbangan multi-kelas, seperti deteksi penipuan atau diagnosis medis, memperluas dampaknya di luar SDM [9].

### Saran

Berdasarkan hasil penelitian, disarankan untuk menguji framework NSGA-II dengan fungsi *fitness* fairness-driven pada dataset employee attrition dari berbagai industri, seperti teknologi atau keuangan, guna memvalidasi generalisasi model terhadap variasi data. Integrasi dengan teknik pembelajaran mesin lanjutan, seperti Random Forest atau Neural Networks, serta eksplorasi hyperparameter tuning pada NSGA-II, dapat meningkatkan performa dan efisiensi komputasi. Selain itu, pengembangan metrik fairness tambahan, seperti Equalized Odds, dan penggunaan  $\beta$  adaptif dapat memperkuat keseimbangan antara akurasi dan keadilan. Organisasi juga dianjurkan untuk mengintegrasikan framework ini ke dalam sistem HR analytics dengan fitur real-time monitoring dan dashboard visualisasi untuk mendukung intervensi retensi yang tepat waktu. Untuk dampak yang lebih luas, framework ini dapat diadaptasi untuk domain lain seperti deteksi penipuan atau diagnosis medis, dengan penyesuaian klasterisasi dan *class weights* sesuai kebutuhan spesifik. Penelitian lanjutan disarankan untuk mengevaluasi efektivitas jangka panjang melalui studi longitudinal guna mengukur pengurangan tingkat attrition dan ROI dari intervensi. Skalabilitas framework untuk dataset besar juga dapat ditingkatkan melalui komputasi paralel atau cloud-based processing, memastikan solusi yang robust, etis, dan inklusif sesuai standar AI modern.

### DAFTAR PUSTAKA

- Alghamdi, W., Hsu, H., Jeong, H., Wang, H., Michalak, P. W., Asoodeh, S., & Calmon, F. P. (2022). Beyond Adult and COMPAS: Fairness in Multi-Class Prediction. ArXiv.Org, abs/2206.07801. <https://doi.org/10.48550/arXiv.2206.07801>
- Al-Shammari, M., & Ghanem, Y. A. (2024). Machine Learning for Predicting Employee Attrition: A Bibliometric Analysis. 1–9. <https://doi.org/10.1109/dasa63652.2024.10836251>
- An Oversampling Algorithm combining SMOTE and RF for Imbalanced Medical Data. (2023). International Journal For Science Technology And Engineering, 11(6), 2429–2434. <https://doi.org/10.22214/ijraset.2023.54074>
- Batani, A., Chan, M., & Eitel-Porter, R. J. (2022). AI Fairness: from Principles to Practice. ArXiv.Org, abs/2207.09833. <https://doi.org/10.48550/arXiv.2207.09833>
- CHEN, Y., LIN, X., & ZHAN, K. (2023). Employee Attrition Classification Model Based on Stacking Algorithm. Journal of Psychological Research. <https://doi.org/10.17265/2159-5542/2023.06.006>
- Dandu, M. M. K., Jain, J., Vijayabaskar, S., Goel, P., Shivarudra, A., & Bhatt, S. P. (2024). Assessing the Impact of Data Imbalance on the Predictive Performance of Machine Learning Models. 1062–1068. <https://doi.org/10.1109/ic3i61595.2024.10829313>
- Hao, J., Yang, X., Wang, C., Tu, R., & Zhang, T. (2022). An Improved NSGA-II Algorithm Based on Adaptive Weighting and Searching Strategy. Applied Sciences, 12(22), 11573. <https://doi.org/10.3390/app122211573>
- He, C., Li, L., Cheng, R., & Jin, Y. (2023). Evolutionary multiobjective optimization via efficient sampling-based offspring generation. 1–17. <https://doi.org/10.1007/s40747-023-00990-z>

- Hu, F., Ratz, P., & Charpentier, A. (2023). Parametric Fairness with Statistical Guarantees. ArXiv.Org, abs/2310.20508. <https://doi.org/10.48550/arxiv.2310.20508>
- Lê, H. B., Teo, R. X., & Nguyen, Q. H. (2025). Resolving multi-class imbalance using counterfactual data augmentation. *Journal on Information Technologies & Communications*, 3. <https://doi.org/10.32913/mic-ict-research.v2024.n2.1328>
- Mahendra, R. (2025). Pengembangan Model Hybrid untuk Identifikasi Tuberkulosis Pada Gambar Rontgen Dada. *CHAIN: Journal of Computer Technology, Computer Engineering*, 3(1). <https://doi.org/10.58602/chain.v3i1.166>
- Mahendra, R., & Santosa, B. (2025). Analisis Sistematis Prediksi Gen Penggerak Kanker dengan Penerapan Jaringan Syaraf Tiruan Graf (Vol. 1, Issue 1). <https://jurnal.kolabs.id/index.php/JIKT/>
- Mitravinda, K. M. (2022). Employee Attrition: Prediction, Analysis Of Contributory Factors And Recommendations For Employee Retention. 1–6. <https://doi.org/10.1109/ICWITE57052.2022.10176235>
- Moayed, H., & Mansoori, E. G. (2020). Regularization of Neural Network Using DropCoadapt. *International Conference on Computer and Knowledge Engineering*. <https://doi.org/10.1109/ICCKE50421.2020.9303614>
- Nassiri, V., Tekle, F., Tatikola, K., & Geys, H. (2024). Addressing Class Imbalance in Bayesian Classification Through Posterior Probability Adjustment. *Biometrical Journal*, 66(8). <https://doi.org/10.1002/bimj.70004>
- Prasetyo, K., & Mahendra, R. (2025). Analisis Kinerja Convolutional Neural Networks Baseline untuk Identifikasi Jenis Penyakit Kentang. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 5(2), 609–615. <https://doi.org/10.57152/malcom.v5i2.1722>
- Rovere, F. De. (2023a). A Study on Predicting Employee Attrition Using Machine Learning. *Studies in Computational Intelligence*, 55–69. [https://doi.org/10.1007/978-3-031-19608-9\\_5](https://doi.org/10.1007/978-3-031-19608-9_5)
- Rovere, F. De. (2023b). A Study on Predicting Employee Attrition Using Machine Learning. *Studies in Computational Intelligence*, 55–69. [https://doi.org/10.1007/978-3-031-19608-9\\_5](https://doi.org/10.1007/978-3-031-19608-9_5)
- Sudaryanto, S. N., Purnomo, M. H., Purwitasari, D., & Yuniarno, E. M. (2022). Synthesis Ensemble Oversampling and Ensemble Tree-Based Machine Learning for Class Imbalance Problem in Breast Cancer Diagnosis. *CENiM*, 1–7. <https://doi.org/10.1109/CENIM56801.2022.10037251>
- Tan, J. S., Yee, H.-J., Boo, I., Tan, I. K. T., & Zakariah, H. (2023). Investigating the Stability of SMOTE-Based Oversampling on COVID-19 Data (pp. 470–480). Springer International Publishing. [https://doi.org/10.1007/978-3-031-37963-5\\_33](https://doi.org/10.1007/978-3-031-37963-5_33)