

PENERAPAN MODEL XGBOOST DENGAN INTERPRETASI MENGGUNAKAN SHAP UNTUK DETEKSI AKTIVITAS PENCUCIAN UANG

Joyce Rosita Firdaus^{1*}, Sofi Defiyanti², Betha Nurina Sari³

^{1,2,3}Informatika, Fakultas Ilmu Komputer, Universitas Singaperbangsa Karawang; Jl. HS. Ronggo Waluyo, Puseurjaya, Telukjambe Timur, Karawang, Jawa Barat 41361; Telp/Fax: (0267) 641177

Keywords:

Pencucian Uang;
XGBoost;
SHAP;
CRISP-DM.

Correspondent Email:

joycerositaf@gmail.com

Abstrak. Deteksi pencucian uang pada data transaksi keuangan sangat kompleks karena ketidakseimbangan kelas yang ekstrem, sehingga diperlukan model yang akurat sekaligus dapat dijelaskan. Penelitian ini menerapkan algoritma *eXtreme Gradient Boosting* (XGBoost) untuk mengklasifikasikan transaksi normal dan transaksi *laundering*, serta menginterpretasikan hasil prediksi dengan *SHapley Additive exPlanations* (SHAP). Metode penelitian yang digunakan adalah CRISP-DM, meliputi *business understanding*, *data understanding*, *data preparation*, *modeling*, *evaluation*, dan *deployment*. Data yang digunakan merupakan dataset transaksi keuangan sintesis sebanyak 9.504.852 transaksi dengan proporsi transaksi *laundering* sebesar 0,10%. *Feature engineering* menghasilkan 25 fitur yang merepresentasikan pola transaksi, hubungan antar akun, frekuensi, dan rasio transaksi. Tiga pendekatan penanganan data tidak seimbang diuji: SMOTE, *scale_pos_weight*, dan kombinasi keduanya. Hasil terbaik diperoleh dengan XGBoost menggunakan *scale_pos_weight*, dengan *accuracy* 0,9996, *precision* 0,7796, *recall* 0,9018, dan *F1-score* 0,8363. Analisis SHAP menunjukkan *receiver_fan_in* dan *sender_fan_out* sebagai fitur paling berpengaruh dengan kontribusi kumulatif sebesar 63,09%, menegaskan bahwa pola hubungan antar akun menjadi indikator utama dalam deteksi pencucian uang.



Copyright © 2026 The Author(s),
Published by Jurnal Informatika
dan Teknik Elektro Terapan. This
is an open-access article
distributed under the terms of the
Creative Commons Attribution-
NonCommercial 4.0 International
License (CC BY-NC 4.0).

Abstract. Money laundering detection in financial transaction data is highly complex due to extreme class imbalance, requiring models that are both accurate and explainable. This study applies the *eXtreme Gradient Boosting* (XGBoost) algorithm to classify normal and laundering transactions, and interprets prediction results using *SHapley Additive exPlanations* (SHAP). The research method follows the CRISP-DM framework, covering business understanding, data understanding, data preparation, modeling, evaluation, and deployment. The dataset consists of 9,504,852 synthetic financial transactions, with laundering transactions accounting for 0.10%. Feature engineering produced 25 features representing transaction patterns, account relationships, frequency, and ratios. Three approaches to handling imbalanced data were tested: SMOTE, *scale_pos_weight*, and a hybrid of both. The best performance was achieved with XGBoost using *scale_pos_weight*, yielding accuracy 0.9996, precision 0.7796, recall 0.9018, and F1-score 0.8363. SHAP analysis identified *receiver_fan_in* and *sender_fan_out* as the most influential features, with a cumulative contribution of 63.09%, confirming that account relationship patterns are the primary indicators in money laundering detection.

1. PENDAHULUAN

Pencucian uang (*money laundering*) merupakan kejahatan finansial yang memiliki implikasi signifikan terhadap stabilitas ekonomi global. Pencucian uang merupakan proses menyembunyikan sumber uang ilegal yang diperoleh dari tindakan terlarang seperti perdagangan narkoba, korupsi, penggelapan, atau perjudian dengan mengubahnya menjadi uang yang dapat digunakan secara hukum [1]. Hal ini mengaburkan jejak kejahatan awal, sehingga memungkinkan pelaku menggunakan hasil kejahatan tanpa terdeteksi oleh pihak berwenang.

Meningkatnya kompleksitas jaringan keuangan dan transaksi digital menuntut adanya sistem *Anti-Money Laundering* (AML) yang mampu menganalisis pola transaksi secara akurat dan secara otomatis mendeteksi perilaku yang tidak biasa. Oleh karena itu, penelitian mengenai pencucian uang menjadi penting karena dapat membantu memahami bagaimana aliran dana ilegal terbentuk, berpindah, dan bertransformasi dalam sistem keuangan.

Studi sebelumnya yang membandingkan beberapa algoritma *machine learning* menunjukkan bahwa XGBoost memberikan performa terbaik dengan *precision* sebesar 0,85, *recall* sebesar 0,84, dan *F1-score* sebesar 0,85 [2]. Hal ini menggambarkan XGBoost merupakan model paling optimal dalam mendeteksi transaksi penipuan, karena mampu memberikan hasil akurasi, presisi, dan konsistensi tertinggi dibandingkan model lainnya.

Meskipun XGBoost telah menunjukkan performa yang baik dalam berbagai penelitian, sebagian besar penelitian masih berkonsentrasi pada performa klasifikasi dan belum banyak membahas interpretabilitas model. Selain itu, permasalahan data yang sangat tidak seimbang (*highly imbalanced*) masih menjadi tantangan utama dalam deteksi pencucian uang karena dapat menyebabkan model cenderung bias terhadap populasi kelas mayoritas. Oleh karena itu, penelitian ini tidak hanya menerapkan algoritma XGBoost dan interpretasi menggunakan *SHapley Additive exPlanations* (SHAP), tetapi juga membandingkan tiga skenario penanganan *imbalance data*, yaitu SMOTE, *scale_pos_weight*, dan kombinasi SMOTE dengan *scale_pos_weight*. Pendekatan ini dilakukan untuk mengetahui strategi yang

paling efektif dalam meningkatkan kemampuan deteksi transaksi *laundering* sekaligus menjaga keseimbangan antara *precision* dan *recall*.

Penelitian ini bertujuan untuk menerapkan algoritma *eXtreme Gradient Boosting* (XGBoost) dalam mendeteksi aktivitas pencucian uang berdasarkan data transaksi keuangan serta menggunakan pendekatan *SHapley Additive exPlanations* (SHAP) untuk menginterpretasikan hasil prediksi model. Hasil penelitian diharapkan dapat menghasilkan model yang tidak hanya memiliki performa klasifikasi yang baik, tetapi juga mampu menjelaskan faktor-faktor yang memengaruhi keputusan model sehingga dapat mendukung efektivitas sistem *Anti-Money Laundering* (AML).

2. TINJAUAN PUSTAKA

2.1. Money Laundering (Pencucian Uang)

Pencucian uang, menurut Adrian Sutedi, adalah prosedur atau tindakan yang dimaksudkan untuk menyembunyikan atau menyamarkan asset atau sumber uang yang diperoleh dari kegiatan kriminal dan kemudian mengubahnya menjadi aset yang tampaknya diperoleh dari tindakan yang sah [3]. Pencucian uang atau *money laundering* didefinisikan oleh Sutan Remy Sjahdeini sebagai serangkaian tindakan yang dilakukan oleh individu atau organisasi dengan dana haram, yaitu dana yang diperoleh melalui kegiatan kriminal, dengan tujuan menyembunyikan dana dari pemerintah atau lembaga yang berwenang memberantas kejahatan, hal ini dicapai dengan memasukkan uang ke dalam sistem keuangan untuk kemudian ditarik kembali sebagai mata uang yang sah [4].

2.2. CRISP-DM

CRISP-DM adalah kerangka kerja yang secara luas digunakan dalam proses *data mining* karena menawarkan fase yang sistematis dan fleksibel. Tujuan dari metode CRISP-DM adalah melakukan proses analisis strategis untuk memecahkan masalah penelitian atau masalah dari sebuah bisnis atau perusahaan [5]. CRISP-DM terdiri dari enam tahapan utama, yaitu *business understanding*, *data understanding*, *data preparation*, *modeling*, *evaluation*, dan *deployment*.

2.3. Feature Engineering

Feature engineering didefinisikan sebagai seni dan ilmu untuk mengkonversi data mentah menjadi representasi yang lebih baik untuk model *machine learning*. *Feature Engineering* adalah proses untuk mengekstrak atau menciptakan fitur baru dari data yang sudah ada [6]. *Feature engineering* mengubah, memilih, atau membentuk fitur baru dari data mentah untuk meningkatkan kemampuan model *machine learning* dalam mengenali pola pada data. Tujuan utama *Feature Engineering* adalah merencanakan fitur untuk membuat data yang digunakan lebih berkualitas dan representatif terhadap pola yang ingin dianalisis [7].

2.4. Encoding

Encoding merupakan proses mengubah data kategorikal menjadi format numerik yang dapat diproses oleh algoritma *machine learning*. Tujuan proses *encoding* adalah mengonversi atribut kategorikal menjadi representasi numerik agar dapat diproses oleh algoritma *machine learning* [8].

2.5. XGBoost

XGBoost atau *Extreme Gradient Boosting* adalah algoritma *machine learning* yang mengimplementasikan teknik *gradient boosting* untuk menghasilkan model prediksi dengan performa tinggi pada tugas klasifikasi maupun regresi [9]. Algoritma ini merupakan pengembangan dari metode *Gradient Boosting* yang bekerja dengan membangun kumpulan *decision tree* secara bertahap (*sequential boosting*) untuk memperbaiki kesalahan prediksi dari model sebelumnya.

XGBoost memiliki parameter *scale_pos_weight* yang digunakan untuk menyesuaikan rasio kelas positif dan negatif sehingga model dapat lebih efektif mengatasi ketidakseimbangan kelas [11]. *Scale_pos_weight* memberikan bobot yang adil pada kelas minoritas dan meningkatkan keadilan model dalam dataset yang tidak seimbang [12].

2.6. Confusion Matrix

Confusion Matrix adalah metode evaluasi yang digunakan untuk menghitung *performance* atau tingkat kebenaran proses klasifikasi [13]. *Confusion Matrix* menyajikan informasi mengenai perbandingan antara hasil

klasifikasi yang dihasilkan model dengan klasifikasi yang sebenarnya [14]. Matriks ini memiliki kolom yang mewakili kelas hasil prediksi (label prediksi) dan kelas hasil aktual (label aktual) [15]. Pengukuran *Confusion Matrix* memuat nilai *accuracy*, *precision*, *recall*, dan *F1-score*.

2.7. SMOTE

Synthetic Minority Over-sampling Technique (SMOTE) merupakan metode *resampling* dimana data baru (data sintetis) diekstraksi dan dibentuk berdasarkan nilai data kelas minoritas agar tercapai distribusi data yang seimbang antar kelas [16]. SMOTE digunakan untuk menangani ketidakseimbangan data dengan menambah jumlah sampel pada kelas minoritas [17]. SMOTE bekerja dengan cara melakukan *oversampling* terhadap kelas minoritas, bukan dengan menduplikasi data secara langsung, tetapi dengan membuat sampel sintetis baru berdasarkan kesamaan antar data minoritas.

2.8. Grid Search CV

Dalam metode *machine learning*, ada beberapa nilai parameter yang diperkirakan dapat meningkatkan kinerja model yang dikenal sebagai *hyperparameter*. Salah satu metode *hyperparameter* adalah *Grid Search Cross Validation* (*Grid Search CV*). *Cross Validation* merupakan metode yang digunakan untuk mengevaluasi kemampuan model dalam menggeneralisasi data yang belum pernah dilihat sebelumnya atau memeriksa efektivitas model yang dibuat [18]. Sementara itu, *Grid Search* merupakan metode pencarian yang bekerja dengan menguji seluruh kombinasi *hyperparameter* yang telah ditentukan secara sistematis. Setiap kombinasi parameter akan dilatih dan dievaluasi menggunakan teknik *cross validation* sehingga diperoleh kombinasi *hyperparameter* dengan performa terbaik [19].


2.9. SHAP

SHAP digunakan untuk menjelaskan kontribusi setiap fitur terhadap keputusan model [20]. Konsep ini diperkenalkan oleh Lundberg dan Lee pada tahun 2017 dan didasarkan pada konsep *game theory* [21] yang dikembangkan berdasarkan teori nilai *Shapley* (*Shapley Value*). Dalam konteks *game theory*, model dianggap sebagai aturan permainan,

sementara fitur input adalah pemain potensial yang mungkin berpartisipasi dalam permainan (fitur yang diamati) atau tidak (fitur tidak dapat diamati) [22]. Dalam konteks model *machine learning*, pemain yang berpartisipasi adalah fitur input, sedangkan hasilnya adalah keputusan model prediksi [23].

3. METODE PENELITIAN

Penelitian ini menerapkan metode CRISP-DM (*Cross Industry Standard Process for Data Mining*) yang terdiri dari enam tahapan utama, yaitu *business understanding*, *data understanding*, *data preparation*, *modeling*, *evaluation*, dan *deployment*. Tahapan penelitian ditunjukkan pada Gambar 1.



Gambar 1. Tahapan Penelitian CRISP-DM

3.1. Business Understanding

Tahap *business understanding* dilakukan untuk memahami permasalahan pencucian uang serta kebutuhan dalam sistem *Anti-Money Laundering* (AML). Aktivitas pencucian uang merupakan salah satu bentuk kejahatan finansial yang sulit dideteksi karena pelaku berupaya menyamarkan asal-usul dana melalui berbagai transaksi keuangan. Oleh karena itu, penelitian ini bertujuan membangun model

klasifikasi yang mampu membedakan transaksi normal dan transaksi *laundering* menggunakan algoritma XGBoost dan penjelasan faktor-faktor yang memengaruhi prediksi model melalui pendekatan SHAP.

3.2. Data Understanding

Dataset yang digunakan merupakan dataset sintesis *anti-money laundering* yang dikembangkan oleh Oztas dan rekan-rekannya [24]. Dataset terdiri dari 9.504.852 transaksi keuangan dengan label transaksi normal dan *laundering*. Tahap ini dilakukan untuk memahami karakteristik data, struktur atribut, distribusi kelas, serta mengidentifikasi permasalahan yang terdapat pada data. Hasil eksplorasi menunjukkan bahwa dataset memiliki ketidakseimbangan kelas yang tinggi dengan proporsi transaksi *laundering* sebesar sekitar 0,10% dari keseluruhan data.

3.3. Data Preparation

Tahap *data preparation* meliputi *data cleaning*, *data splitting*, dan *data transformation*. *Data cleaning* dilakukan dengan memeriksa *missing value*, duplikasi data, dan konsistensi atribut. Selanjutnya, dilakukan pembagian data menjadi dua bagian, yaitu data latih dan data uji dengan perbandingan 70:30 menggunakan *stratified split* untuk mempertahankan distribusi kelas. Selanjutnya, dilakukan proses transformasi data melalui *feature engineering* yang menghasilkan 25 fitur baru, *feature selection*, dan *encoding* pada atribut kategorikal agar data dapat diproses oleh algoritma *machine learning*.

3.4. Modeling

Pada tahap *modeling* digunakan algoritma *eXtreme Gradient Boosting* (XGBoost) untuk melakukan klasifikasi transaksi normal dan transaksi *laundering*. Proses pemodelan dilakukan menggunakan data latih yang telah melalui tahap *data preparation*. Pada penelitian ini diterapkan tiga skenario eksperimen untuk membandingkan pengaruh metode penanganan imbalanced data terhadap performa model, yaitu XGBoost dengan SMOTE, XGBoost dengan *scale_pos_weight*, XGBoost *Hybrid* SMOTE dan *scale_pos_weight*.

Pada skenario pertama, penanganan ketidakseimbangan kelas dilakukan menggunakan metode SMOTE untuk

meningkatkan jumlah data kelas minoritas secara sintesis. Pada skenario kedua, distribusi data tetap menggunakan kondisi asli dataset dan penanganan *imbalanced data* dilakukan menggunakan parameter *scale_pos_weight* pada algoritma XGBoost. Sementara itu, skenario ketiga mengombinasikan metode SMOTE dan *scale_pos_weight* untuk meningkatkan sensitivitas model terhadap kelas minoritas.

Untuk memperoleh parameter terbaik dilakukan *hyperparameter tuning* menggunakan *Grid Search CV*. Proses *tuning* dilakukan menggunakan *3-fold cross validation* dengan metrik evaluasi *F1-score*. Kombinasi nilai parameter yang diuji ditampilkan pada Tabel 1.

Tabel 1. Kombinasi parameter *Grid Search CV*

Parameter	Nilai yang diuji
max_depth	4, 6
learning_rate	0.05, 0.1
n_estimators	50, 100

3.5. Evaluation

Evaluasi dilakukan menggunakan metode *Confusion Matrix* yang menghasilkan nilai-nilai *accuracy*, *precision*, *recall*, *F1-score*. Hasil evaluasi tersebut digunakan untuk menilai kinerja model XGBoost dalam mengklasifikasikan transaksi normal dan transaksi *laundering*.


3.6. Deployment

Analisis interpretasi menggunakan *SHapley Additive exPlanations* (SHAP) dilakukan untuk memahami kontribusi setiap variabel terhadap hasil prediksi yang dihasilkan oleh model. Pendekatan ini diterapkan guna memahami kontribusi setiap fitur terhadap hasil prediksi model, sehingga proses klasifikasi transaksi *laundering* tidak hanya menghasilkan performa yang baik, tetapi juga dapat diinterpretasikan secara jelas.

4. HASIL DAN PEMBAHASAN

4.1. Eksplorasi Data

Dataset yang digunakan dalam penelitian ini merupakan dataset transaksi keuangan sintesis sebanyak 9.504.852 transaksi dengan proporsi perbandingan jumlah data antara kelas Normal dan *Laundering* seperti yang terlihat pada Gambar 2.




Gambar 2. Proporsi dataset transaksi

Gambar 2 menunjukkan bahwa sebagian besar transaksi merupakan transaksi normal dengan jumlah 9.494.979 data transaksi atau persentase sebesar 99,90%, sedangkan transaksi yang diklasifikasikan sebagai *laundering* berjumlah 9.873 data transaksi atau hanya sebesar 0,10%. Kondisi ini menunjukkan bahwa dataset memiliki ketidakseimbangan kelas (*imbalanced data*) yang cukup signifikan.

4.2. Data Splitting

Dilakukan pembagian data menggunakan metode *stratified train-test split* dengan proporsi 70% untuk data latih dan 30% untuk data uji seperti yang terlihat pada Gambar 3.



Gambar 3. Proporsi pembagian data

Hasil pembagian data pada Gambar 3 menunjukkan bahwa data latih memiliki proporsi sebesar 70% atau sebanyak 6.653.396 baris, sedangkan data uji sebesar 30% atau sebanyak 2.851.456 baris.

4.3. Data Transformation

4.3.1. Feature Engineering

Proses *feature engineering* membentuk 18 fitur baru, sehingga jumlah atribut meningkat

dari 13 menjadi 31 fitur. Fitur yang dibentuk mencakup beberapa aspek utama, yaitu fitur temporal, fitur geografis dan mata uang, fitur perilaku transaksi pengirim dan penerima, fitur indikator *smurfing*, fitur frekuensi transaksi, serta fitur rasio transaksi.

Setelah proses *feature engineering*, dilakukan *feature selection* dengan menghapus atribut yang tidak relevan. Setelah penghapusan atribut tersebut diperoleh 25 fitur akhir yang digunakan sebagai variabel prediktor pada proses pemodelan seperti yang disajikan pada Tabel 2.

Tabel 2. Daftar seluruh fitur

No.	Fitur
1.	Amount
2.	Payment_currency
3.	Received_currency
4.	Sender_bank_location
5.	Receiver_bank_location
6.	Payment_type
7.	hour
8.	day_of_week
9.	is_weekend
10.	is_cross_border
11.	is_currency_diff
12.	log_amount
13.	sender_txn_count
14.	sender_total_amount
15.	sender_avg_amount
16.	sender_fan_out
17.	receiver_txn_count
18.	receiver_total_amount
19.	receiver_avg_amount
20.	receiver_fan_in
21.	is_small_txn
22.	smurfing_score
23.	avg_txn_per_day
24.	amount_ratio_sender
25.	amount_ratio_receiver

4.3.1. Encoding

Atribut kategorikal ditransformasikan ke dalam bentuk numerik menggunakan metode *Label Encoding*. Proses ini diterapkan pada atribut *Payment_currency*, *Received_currency*, *Sender_bank_location*, *Receiver_bank_location*, dan *Payment_type*.

4.4. Modeling

Pada tahap *modeling* diterapkan tiga skenario eksperimen untuk menganalisis pengaruh strategi penanganan *imbalance* terhadap performa model.

Pada skenario XGBoost dengan SMOTE dilakukan *oversampling* menggunakan metode

SMOTE dengan parameter *sampling_strategy* = 0,1 untuk menambah jumlah data sintetis pada kelas minoritas.

Pada skenario XGBoost dengan *scale_pos_weight*, data latih tetap menggunakan distribusi asli yang *imbalanced*. Penanganan *imbalance* dilakukan melalui pemberian bobot pada kelas minoritas menggunakan parameter *scale_pos_weight* pada XGBoost. Nilai bobot ini dihitung berdasarkan rasio jumlah kelas mayoritas terhadap kelas minoritas pada data latih yang hasilnya sebesar 961,73.

Pada skenario *hybrid* dilakukan kombinasi antara SMOTE dan pemberian bobot kelas menggunakan *scale_pos_weight*. Pada skenario ini, SMOTE diterapkan dengan *sampling_strategy* = 0,1 sehingga jumlah data *laundering* pada data latih ditingkatkan hingga mencapai 10% dari jumlah transaksi normal. Setelah itu, nilai *scale_pos_weight* ditetapkan sebesar 10 berdasarkan rasio kelas setelah SMOTE diterapkan.

Dilakukan proses *hyperparameter tuning* menggunakan *Grid Search CV* untuk memperoleh kombinasi parameter terbaik pada setiap skenario. Proses *tuning* dilakukan menggunakan *3-fold cross validation* dengan metrik evaluasi *F1-score*. Diperoleh hasil kombinasi parameter yang sama pada setiap skenario seperti yang disajikan pada Tabel 3.

Tabel 3. Kombinasi parameter *Grid Search CV* terbaik setiap skenario

	S1	S2	S3
max_depth	6	6	6
learning_rate	0,10	0,10	0,10
n_estimators	100	100	100
F1-Score	0,9875	0,8878	0,9183

4.5. Evaluasi Model


Evaluasi dilakukan menggunakan metrik *Accuracy*, *Precision*, *Recall*, dan *F1-Score*. Selain itu, analisis *confusion matrix* digunakan untuk melihat distribusi prediksi benar dan salah pada masing-masing kelas transaksi. Ringkasan hasil evaluasi ketiga skenario disajikan pada Tabel 4.

Tabel 4. Hasil Evaluasi Model

	Accuracy	Precision	Recall	F1-Score
S1	0,9992	0,5681	0,9325	0,7060
S2	0,9996	0,7796	0,9018	0,8363
S3	0,9984	0,3951	0,9440	0,5571

Berdasarkan Tabel 4, seluruh skenario menghasilkan nilai *accuracy* yang sangat tinggi, yaitu di atas 99%. Namun, karena proporsi transaksi *laundering* hanya sekitar 0,10% dari keseluruhan data, *accuracy* tidak dapat dijadikan indikator utama dalam menentukan model terbaik. Oleh karena itu, evaluasi lebih difokuskan pada nilai *precision*, *recall*, dan *F1-score* yang lebih representatif dalam mengukur kemampuan model mendeteksi transaksi *laundering*.


Skenario pertama menggunakan pendekatan SMOTE dihasilkan distribusi prediksi melalui visualisasi *Confusion Matrix* pada Gambar 4.



Gambar 4. *Confusion Matrix* S1

Berdasarkan *confusion matrix* pada skenario pertama, dari 2.962 data *laundering*, model hanya mampu memprediksi dengan benar 2.762 data (93,25%), sedangkan 200 data lainnya salah diklasifikasikan sebagai transaksi normal. Hal ini menunjukkan bahwa kemampuan model dalam mendeteksi transaksi *laundering* cukup baik, selaras dengan nilai *recall* kelas *laundering* sebesar 0,9325. Selain itu, terdapat 2.100 data transaksi normal yang salah diprediksi sebagai *laundering*, sehingga menghasilkan *precision* sebesar 0,5681. Hasil tersebut menunjukkan bahwa sebagian besar transaksi normal berhasil diprediksi dengan benar, namun masih terdapat transaksi normal yang salah diklasifikasikan sebagai *laundering*, sehingga model belum memberikan keseimbangan yang optimal antara deteksi *laundering* dan pengurangan *false positive*.


Skenario kedua menggunakan parameter *scale_pos_weight* dihasilkan distribusi prediksi melalui visualisasi *Confusion Matrix* pada Gambar 5.



Gambar 5. *Confusion Matrix* S2

Berdasarkan *confusion matrix* pada skenario kedua, dari 2.962 data *laundering*, model mampu memprediksi dengan benar 2.671 data (90,18%), sedangkan 291 data lainnya salah diklasifikasikan sebagai transaksi normal. Hal ini menunjukkan bahwa kemampuan model dalam mendeteksi transaksi *laundering* cukup baik, selaras dengan nilai *recall* kelas *laundering* sebesar 0,9018. Selain itu, terdapat 755 data transaksi normal yang salah diprediksi sebagai *laundering*, sehingga menghasilkan *precision* sebesar 0,7796. Hasil tersebut menunjukkan bahwa sebagian besar transaksi normal berhasil diprediksi dengan benar, serta model mampu memberikan keseimbangan yang lebih baik antara deteksi *laundering* dan pengurangan *false positive* dibandingkan skenario pertama.

Skenario ketiga yang mengombinasikan SMOTE dan *scale_pos_weight* dihasilkan distribusi prediksi melalui visualisasi *Confusion Matrix* pada Gambar 6.



Gambar 6 *Confusion Matrix* S3


Berdasarkan *confusion matrix* pada skenario ketiga, dari 2.962 data *laundering*, model mampu memprediksi dengan benar 2.796 data (94,40%), sedangkan 166 data lainnya salah

diklasifikasikan sebagai transaksi normal. Hal ini menunjukkan bahwa kemampuan model dalam mendeteksi transaksi *laundering* sangat baik, selaras dengan nilai *recall* kelas *laundering* sebesar 0,9440. Selain itu, terdapat 4.280 data transaksi normal yang salah diprediksi sebagai *laundering*, sehingga menghasilkan *precision* sebesar 0,3951. Hasil tersebut menunjukkan bahwa model sangat sensitif dalam mendeteksi transaksi *laundering*, namun masih terlalu banyak mengklasifikasikan transaksi normal sebagai transaksi mencurigakan, sehingga keseimbangan antara deteksi *laundering* dan pengurangan *false positive* belum optimal.

Secara keseluruhan, terdapat *trade-off* antara *precision* dan *recall* pada ketiga skenario yang diuji. Skenario pertama dan ketiga memiliki kemampuan deteksi *laundering* yang lebih tinggi, tetapi menghasilkan *false positive* yang lebih banyak. Sebaliknya, skenario kedua mampu mempertahankan *recall* yang tetap tinggi sambil menghasilkan *precision* yang lebih baik. Oleh karena itu, skenario kedua menggunakan pendekatan *scale_pos_weight* dipilih sebagai model terbaik dalam penelitian ini karena menghasilkan nilai *F1-score* tertinggi yang merepresentasikan keseimbangan terbaik antara *precision* dan *recall*.

4.6. Analisis SHAP

Interpretasi model dilakukan terhadap model terbaik yang diperoleh pada tahap evaluasi, yaitu XGBoost dengan pendekatan *scale_pos_weight*. Analisis dilakukan menggunakan metode SHAP untuk mengidentifikasi fitur-fitur yang paling berpengaruh terhadap keputusan model dalam mengklasifikasikan transaksi normal dan transaksi *laundering*. Warna pada visualisasi menunjukkan besarnya nilai fitur, di mana warna merah merepresentasikan nilai fitur yang tinggi dan warna biru menunjukkan nilai fitur yang rendah. Sebaran titik ke arah kanan menunjukkan bahwa fitur tersebut meningkatkan probabilitas suatu transaksi diklasifikasikan sebagai *laundering*, sedangkan sebaran ke arah kiri menunjukkan kontribusi terhadap prediksi transaksi normal. Hasil visualisasi SHAP *Summary Plot* ditunjukkan pada Gambar 7.



Gambar 7 SHAP *Summary Plot*

Berdasarkan Gambar 7, terlihat bahwa fitur *receiver_fan_in*, *sender_fan_out*, *receiver_txn_count*, dan *sender_txn_count* merupakan fitur yang memberikan kontribusi terbesar terhadap prediksi model. Posisi fitur pada bagian teratas menunjukkan bahwa keempat fitur tersebut memiliki nilai SHAP rata-rata yang lebih tinggi dibandingkan fitur lainnya sehingga lebih sering digunakan model dalam membedakan transaksi normal dan transaksi *laundering*. Temuan ini mengindikasikan bahwa pola hubungan antar akun menjadi faktor penting dalam mendeteksi aktivitas pencucian uang.

Untuk mengetahui tingkat kontribusi masing-masing fitur secara lebih rinci, dilakukan analisis menggunakan nilai rata-rata absolut SHAP (*mean absolute SHAP value*). Hasil perhitungan tingkat kepentingan fitur disajikan pada Tabel 5.

Tabel 5 Skor *Feature*

	Feature	Mean SHAP	Importance
1	<i>receiver_fan_in</i>	4,39	35,49
2	<i>sender_fan_out</i>	3,41	27,60
3	<i>receiver_txn_count</i>	1,85	14,97
4	<i>sender_txn_count</i>	0,85	6,87
5	<i>sender_total_amount</i>	0,59	4,81
6	<i>avg_txn_per_day</i>	0,39	3,18
7	<i>receiver_avg_amount</i>	0,17	1,40
8	<i>receiver_total_amount</i>	0,12	0,93
9	<i>Payment_type</i>	0,11	0,85
10	<i>sender_avg_amount</i>	0,10	0,80
11	<i>is_currency_diff</i>	0,08	0,61
12	<i>amount_ratio_sender</i>	0,07	0,55

	Feature	Mean SHAP	Importance
13	Amount	0,06	0,49
14	smurfing_score	0,06	0,48
15	Hour	0,05	0,43
16	amount_ratio_receiver	0,02	0,17
17	day_of_week	0,02	0,15
18	is_cross_border	0,01	0,08
19	Payment_currency	0,01	0,05
20	Received_currency	0,01	0,04

Berdasarkan Tabel 5, fitur receiver_fan_in memiliki tingkat kepentingan tertinggi sebesar 35,49%, diikuti oleh sender_fan_out sebesar 27,60%. Kedua fitur tersebut secara kumulatif menyumbang 63,09% terhadap keseluruhan keputusan model. Hasil ini menunjukkan bahwa model sangat bergantung pada pola jaringan transaksi dalam mendeteksi aktivitas *laundering*. Semakin banyak akun pengirim yang mengirim dana ke satu akun penerima (*fan-in*) atau semakin banyak akun tujuan yang menerima dana dari satu akun pengirim (*fan-out*), maka semakin besar kemungkinan transaksi tersebut dikategorikan sebagai *laundering*. Selain itu, fitur receiver_txn_count dan sender_txn_count juga memberikan kontribusi yang cukup besar, masing-masing sebesar 14,97% dan 6,87%. Temuan ini menunjukkan bahwa intensitas transaksi suatu akun menjadi indikator penting dalam proses klasifikasi.

Fitur-fitur hasil *feature engineering* lainnya, seperti sender_total_amount, avg_txn_per_day, dan receiver_avg_amount, juga memberikan kontribusi terhadap keputusan model meskipun dengan tingkat kepentingan yang lebih rendah. Sebaliknya, fitur seperti day_of_week, is_cross_border, Payment_currency, dan Received_currency memiliki pengaruh yang relatif kecil terhadap hasil prediksi. Kondisi ini menunjukkan bahwa model lebih banyak memanfaatkan pola perilaku transaksi dan hubungan antar akun dibandingkan atribut administratif transaksi.

Secara keseluruhan, hasil analisis SHAP menunjukkan bahwa aktivitas *laundering* pada dataset lebih banyak dipengaruhi oleh pola jaringan transaksi dan intensitas aktivitas akun dibandingkan karakteristik transaksi yang bersifat administratif. Temuan ini juga memperkuat bahwa model tidak hanya memiliki performa klasifikasi yang baik, tetapi mampu memberikan interpretasi yang

menjelaskan faktor-faktor utama yang memengaruhi keputusan prediksi.

5. KESIMPULAN

- Implementasi algoritma *eXtreme Gradient Boosting* (XGBoost) berhasil dilakukan untuk mendeteksi aktivitas pencucian uang berdasarkan data transaksi keuangan. Proses implementasi dilakukan melalui tahapan CRISP-DM yang meliputi *data understanding*, *data preparation*, *modeling*, *evaluation*, dan *deployment*. Pada tahap *data preparation* dilakukan *feature engineering* untuk membentuk fitur-fitur yang merepresentasikan pola transaksi, hubungan antar akun, frekuensi transaksi, serta indikator aktivitas mencurigakan. Penelitian ini menggunakan tiga skenario penanganan *imbalanced data*, yaitu SMOTE, scale_pos_weight, dan *hybrid* SMOTE dengan scale_pos_weight. Berdasarkan hasil evaluasi, model terbaik diperoleh pada skenario XGBoost dengan pendekatan scale_pos_weight yang menghasilkan *accuracy* sebesar 0,9996, *precision* sebesar 0,7796, *recall* sebesar 0,9018, dan *F1-score* sebesar 0,8363. Hasil tersebut menunjukkan bahwa algoritma XGBoost mampu mengklasifikasikan transaksi normal dan transaksi *laundering* dengan performa yang sangat baik pada dataset *highly imbalanced*.
- Pendekatan *SHapley Additive exPlanations* (SHAP) berhasil digunakan untuk menginterpretasikan hasil prediksi model XGBoost dengan menunjukkan kontribusi masing-masing fitur terhadap keputusan model. Hasil interpretasi menunjukkan bahwa fitur receiver_fan_in, sender_fan_out, receiver_txn_count, dan sender_txn_count merupakan fitur yang paling berpengaruh dalam mendeteksi aktivitas *laundering*. Fitur receiver_fan_in dan sender_fan_out secara kumulatif memberikan kontribusi sebesar 63,09% terhadap keputusan model, yang menunjukkan bahwa pola hubungan antar akun menjadi indikator utama dalam identifikasi transaksi mencurigakan. Selain itu, visualisasi SHAP *summary plot* mampu memberikan gambaran mengenai arah dan besarnya pengaruh setiap fitur terhadap prediksi model. Dengan demikian,

pendekatan SHAP berhasil meningkatkan transparansi dan interpretabilitas model sehingga hasil prediksi tidak hanya akurat, tetapi juga dapat dijelaskan secara lebih mudah dan informatif.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada pihak-pihak terkait yang telah memberi dukungan terhadap penelitian ini.

DAFTAR PUSTAKA

- [1] R. Dwi Putra, E. Stevany Putri Sinlae, T. Suhaila Syafa, I. Fatika Syahda, and F. Siswajanthi, "Pencegahan dan Pemberantasan Tindak Pidana Pencucian Uang Dalam Perbankan," *Al-Zayn: Jurnal Ilmu Sosial & Hukum*, vol. 2, no. 1, pp. 70–80, Jun. 2024, doi: 10.61104/alz.v2i1.205.
- [2] P. Jing, Y. Gao, and X. Zeng, "A Customer Level Fraudulent Activity Detection Benchmark for Enhancing Machine Learning Model Research and Evaluation," Apr. 2024, [Online]. Available: <http://arxiv.org/abs/2404.14746>
- [3] S. H. Adrian Sutedi, *Hukum Perbankan: Suatu Tinjauan Pencucian Uang, Merger, Likuidasi, dan Kepailitan*. Sinar Grafika, 2023.
- [4] Yunus Achmad, Yusrianto Kadir, and Marten Bunga, "Analisis Yuridis mengenai Pertanggungjawaban Pidana terhadap Pelaku Pembantu (Medeplichtige) dalam Tindak Pidana Pencucian Uang (Money Laundering)," *Bhirawa Law Journal*, vol. 6, no. 1, pp. 115–129, May 2025, doi: 10.26905/blj.v6i1.15567.
- [5] N. C. Sastya and I. Nugraha, "Penerapan Metode CRISP-DM dalam Menganalisis Data untuk Menentukan Customer Behavior di MeatSolution," *UNISTEK*, vol. 10, no. 2, pp. 103–115, Oct. 2023, doi: 10.33592/unistek.v10i2.3079.
- [6] R. Darmawan, I. V. Yut, A. Hernando, R. I. Handayani, R. L. Pratiwi, and E. Widanengsih, "Analisis Peran Feature Engineering Pada Kinerja Model Machine Learning untuk Klasifikasi Potensi Tsunami," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 14, no. 1, Jan. 2026, doi: 10.23960/jitet.v14i1.8303.
- [7] R. Maulana, S. Eka Prastya, M. Zulfadhilah, and R. Noor Pratama, "Eksplorasi Self-disclosure Generasi Z di Second Account Instagram Menggunakan Classification Machine Learning," *Jurnal Teknologi dan Informasi*, vol. 15, no. 2, pp. 147–159, Sep. 2025, doi: 10.34010/jati.v15i2.16847.
- [8] L. N. Wakhidah, A. K. Zyen, and B. B. Wahono, "Evaluation of Telecommunication Customer Churn Classification with SMOTE Using Random Forest and XGBoost Algorithms," *Journal of Applied Informatics and Computing*, vol. 9, no. 1, pp. 89–95, Jan. 2025, doi: 10.30871/jaic.v9i1.8740.
- [9] Diash Firdaus, A. Afin, I. Sumardi, and C. Chazar, "Deteksi Serangan Pada Jaringan Internet Of Things Medis Menggunakan Machine Learning Dengan Algoritma XGBoost," *Cyber Security dan Forensik Digital*, vol. 8, no. 1, pp. 34–42, Jun. 2025, doi: 10.14421/csecurity.2025.8.1.5036.
- [10] D. T. Murdiansyah, "Prediksi Stroke Menggunakan Extreme Gradient Boosting," *JIKO (Jurnal Informatika dan Komputer)*, vol. 8, no. 2, p. 419, Sep. 2024, doi: 10.26798/jiko.v8i2.1295.
- [11] W. Nugraha and M. Syarif, "Teknik Weighting untuk Mengatasi Ketidakseimbangan Kelas Pada Prediksi Churn Menggunakan XGBoost, LightGBM, dan CatBoost," *Techno. com*, vol. 22, no. 1, 2023.
- [12] V. Fu-Zhou, "A Modern Approach to Uplift Marketing: Using Artificial Intelligence to Maximize Marketing Efficiency," 2025.
- [13] A. T. Saragih, D. Afrida, and R. F. Dinara, "Klasifikasi Jumlah Kendaraan di Sumatera Utara Dan Sumatera Barat Menggunakan Algoritma Naive Bayes," *J-Com (Journal of Computer)*, vol. 3, no. 1, pp. 11–16, Mar. 2023, doi: 10.33330/j-com.v3i1.2072.
- [14] A. A. Kurniawan and M. Mustikasari, "Evaluasi Kinerja MLLIB APACHE SPARK pada Klasifikasi Berita Palsu dalam Bahasa Indonesia," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 9, no. 3, p. 489, Jun. 2022, doi: 10.25126/jtiik.2022923538.
- [15] N. Romadoni, A. M. Siregar, D. S. Kusumaningrum, and T. Rohana, "Classification Model of Public Sentiments About Electric Cars Using Machine Learning," *Scientific Journal of Informatics*, vol. 11, no. 2, pp. 303–314, May 2024, doi: 10.15294/sji.v11i2.1309.
- [16] A. A. Nababan, M. Jannah, M. Aulina, and D. Andrian, "Prediksi Kualitas Udara Menggunakan XGBoost dengan Synthetic Minority Oversampling Technique (SMOTE) Berdasarkan Indeks Standar Pencemaran Udara (ISPU)," *JTIK (Jurnal Teknik Informatika Kaputama)*, vol. 7, no. 1, pp. 214–219, Jan. 2023, doi: 10.59697/jtik.v7i1.66.
- [17] F. N. Yahya, M. Anshori, and A. N. Khudori, "Evaluasi Performa XGBoost dengan Oversampling dan Hyperparameter Tuning untuk Prediksi Alzheimer," *Techno.Com*, vol.

- 24, no. 1, pp. 1–12, Feb. 2025, doi: 10.62411/tc.v24i1.12057.
- [18] Fatmawati and N. A. K. Rifai, “Klasifikasi Penyakit Diabetes Retinopati Menggunakan Support Vector Machine dengan Algoritma Grid Search Cross-validation,” *Jurnal Riset Statistika*, pp. 79–86, Jul. 2023, doi: 10.29313/jrs.v3i1.1945.
- [19] R. Rakarahayu Putri and N. Cahyono, “Analisis Sentimen Komentar Masyarakat Terhadap Pelayanan Publik Pemerintah DKI Jakarta dengan Algoritma Super Vector Machine Dan Naive Bayes,” *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 8, no. 2, pp. 2363–2371, Apr. 2024, doi: 10.36040/jati.v8i2.9472.
- [20] Mubaraqah, A. Puteri, and A. Sumardin, “Comparison of Random Forest and XGBoost for Diabetes Classification with SHAP and LIME Interpretation,” *JTERA (Jurnal Teknologi Rekayasa)*, vol. 9, pp. 121–129, Nov. 2024, doi: 10.31544/jtera.v9.i1.2024.121-130.
- [21] E. Zulfa, H. Amir, R. Ginting, and S. Sudarno, “Analisis Korelasi Kesehatan Mental dan Indeks Prestasi Mahasiswa Jurusan Administrasi Niaga Politeknik Negeri Jakarta dengan Kombinasi Metode XGBoost Dan SHAP,” *Jurnal Administrasi Profesional*, vol. 5, no. 1, pp. 26–37, Jul. 2024, doi: 10.32722/jap.v5i1.6923.
- [22] R. O. Alabi, M. Elmusrati, I. Leivo, A. Almangush, and A. A. Mäkitie, “Machine learning explainability in nasopharyngeal cancer survival using LIME and SHAP,” *Sci. Rep.*, vol. 13, no. 1, p. 8984, Jun. 2023, doi: 10.1038/s41598-023-35795-0.
- [23] E. Mosca, F. Szigeti, S. Tragianni, D. Gallagher, and G. Groh, “SHAP-Based Explanation Methods: A Review for NLP Interpretability,” in *Proceedings of the 29th International Conference on Computational Linguistics*, N. Calzolari, C.-R. Huang, H. Kim, J. Pustejovsky, L. Wanner, K.-S. Choi, P.-M. Ryu, H.-H. Chen, L. Donatelli, H. Ji, S. Kurohashi, P. Paggio, N. Xue, S. Kim, Y. Hahm, Z. He, T. K. Lee, E. Santus, F. Bond, and S.-H. Na, Eds., Gyeongju, Republic of Korea: International Committee on Computational Linguistics, Oct. 2022, pp. 4593–4603. [Online]. Available: <https://aclanthology.org/2022.coling-1.406/>
- [24] B. Oztas, D. Cetinkaya, F. Adedoyin, M. Budka, H. Dogan, and G. Aksu, “Enhancing Anti-Money Laundering: Development of a Synthetic Transaction Monitoring Dataset,” in *2023 IEEE International Conference on e-*
- Business Engineering (ICEBE)*, 2023, pp. 47–54. doi: 10.1109/ICEBE59045.2023.00028.