 ISSN: 2830-0408

Prediksi Dinamika Status Top-Tier ESG dengan Algoritma XGBoost: Evaluasi Ketepatan Model

Dean Tirkaamiana[a*], Sinta Dewi[a], Isna Nugraha[a]
[a] Program Studi Teknik Industri, Fakultas Teknik dan Sains, Universitas Pembangunan Nasional "Veteran" Jawa Timur, Jl. Rungkut Madya No.1, 60294 Surabaya Jawa Timur
* Corresponding author: dean.tirkaamiana.ft@upnjatim.ac.id

ABSTRAK

Penelitian ini bertujuan mengembangkan model klasifikasi berbasis XGBoost untuk memprediksi status perusahaan dalam kategori Top-Tier ESG pada periode berikutnya serta mengevaluasi ketepatan prediksi model. Penelitian menggunakan data sekunder dari 1.000 perusahaan global pada periode 2015–2025 yang mencakup skor ESG, indikator lingkungan, karakteristik keuangan, industri, dan wilayah. Data tahun 2016–2022 digunakan sebagai data pelatihan, sedangkan periode 2023–2024 digunakan sebagai data pengujian berbasis waktu. Model XGBoost dikonfigurasi dengan 300 pohon, learning rate 0,03, kedalaman maksimum 4, rasio sampling 0,8, serta pembobotan kelas untuk menangani ketidakseimbangan data. Hasil pengujian menunjukkan akurasi sebesar 93% dan macro F1-score sebesar 0,91. Pada kelas ESG Top-Tier, model menghasilkan precision 78% dan recall 100%. Dari 331 perusahaan yang diprediksi sebagai Top-Tier, sebanyak 251 perusahaan (75,83%) terbukti berada pada kategori tersebut, sedangkan 80 perusahaan (24,17%) merupakan false alarm. Hasil tersebut menunjukkan bahwa XGBoost dapat digunakan untuk memproyeksikan dinamika status ESG satu tahun ke depan dan mendukung identifikasi perusahaan yang berpotensi mempertahankan atau mencapai kategori ESG Top-Tier.
Kata Kunci: ESG, peramalan, *machine learning*, Top-Tier ESG, XGBoost

ABSTRACT

This study developed an XGBoost classification model to predict the dynamics of top-tier Environmental, Social, and Governance status one year ahead and evaluated its predictive accuracy using time-based validation. The analysis used a secondary dataset containing annual Environmental, Social, and Governance scores and financial indicators for 1,000 global companies from 2015 to 2025. Data from 2016–2022 were used for training, while 2023–2024 data were used for testing. The model incorporated historical Environmental, Social, and Governance scores, physical resource-use indicators, financial variables, industry, and region, with class weighting to address the 25% top-tier class proportion. The results showed an accuracy of 93% and a macro F1-score of 0.91. For the top-tier class, recall reached 1.00 and precision reached 0.78. Among 331 companies predicted as top-tier, 251 were correctly classified, corresponding to a precision of 75.83%. The model also produced high predicted probabilities for several companies, exceeding 0.9994. These results indicated that XGBoost provided a useful approach for forecasting one-year changes in top-tier Environmental, Social, and Governance status and supporting prospective sustainability monitoring.

Keywords: ESG, forecasting, machine learning, sustainability prediction, ESG Top-Tier, XGBoost

ISSN: 2830-0408

1. Pendahuluan

Dalam beberapa tahun terakhir, perhatian pada isu ESG (*Environmental, Social, and Governance*) semakin meningkat semakin meningkat seiring dengan tingginya kesadaran global investor terhadap risiko non-keuangan dan keberlanjutan [1] ESG adalah kerangka kerja multidimensional yang digunakan untuk menilai komitmen dan kinerja perusahaan dalam aspek lingkungan, sosial, dan tata kelola internal [2]. Isu ESG dianggap sebagai faktor penting dalam menjalankan sebuah perusahaan oleh pihak internal, regulator, maupun investor [3]. ESG sering dianggap sebagai sinyal bahwa perusahaan tersebut dikelola secara berkelanjutan dan berisiko rendah dalam jangka Panjang [4].

ESG menjadi pertimbangan yang tidak kalah penting dibanding laba perusahaan sebelum investor mengambil keputusan investasi [5]. Perusahaan yang masuk dalam kategori top-tier ESG (kelompok dengan skor tertinggi) biasanya lebih mudah memperoleh pendanaan dan akses modal dari investor [6]. Citra perusahaan dengan skor ESG yang tinggi cenderung lebih tahan terhadap risiko reputasi maupun risiko regulasi di masa depan [7].

Penilaian ESG konvensional yang dilakukan oleh lembaga pemeringkat besar memiliki beberapa keterbatasan, seperti berfokus pada kondisi historis sehingga sulit digunakan untuk memprediksi masa depan [8]. Padahal, informasi mengenai status ESG perusahaan pada periode mendatang memiliki nilai yang lebih tinggi karena investor berorientasi pada kinerja perusahaan di masa depan.

Kemampuan memproyeksikan posisi top-tier ESG suatu perusahaan di tahun-tahun berikutnya sangat relevan dalam menyusun strategi investasi jangka panjang dan manajemen Risiko [9]. Model klasifikasi berbasis XGBoost yang menghasilkan skor probabilitas memungkinkan teridentifikasinya perusahaan yang mengalami penurunan maupun peningkatan status ESG [10]. Prediksi penurunan status dapat menjadi peringatan dini (early warning) bagi investor untuk mengambil langkah mitigasi risiko sebelum informasi tersebut tersebar secara luas di pasa.r Sementara itu, prediksi peningkatan status menuju kategori top-tier ESG dapat membuka peluang investasi lebih awal bagi investor sebelum kinerja tersebut tercermin pada valuasi pasar.

Algoritma XGBoost dipilih karena sangat efektif untuk mengolah data tabular seperti data keuangan dan ESG [11]. Algoritma ini mampu menangani hubungan *non-linear* antarvariabel, tahan terhadap *outlier*, dan secara konsisten unggul dalam berbagai kompetisi *data science* berbasis data terstruktur. Oleh karena itu, penelitian ini memanfaatkan algoritma XGBoost untuk memprediksi status emiten *top-tier ESG* secara prospektif, melakukan evaluasi terhadap ketepatan tebakan model pada data historis, serta menyusun proyeksi dinamika keberlanjutan perusahaan untuk periode tahun 2026."

2. Tinjauan Pustaka

2.1 Konsep, Pengukuran, dan Dinamika Kinerja ESG

Environmental, Social, and Governance (ESG) merupakan kerangka multidimensional untuk menilai pengelolaan perusahaan dalam aspek lingkungan,

ISSN: 2830-0408

sosial, dan tata kelola. Aspek lingkungan mencakup emisi, energi, limbah, serta risiko perubahan iklim; aspek sosial meliputi ketenagakerjaan, keselamatan, hak asasi manusia, dan hubungan dengan masyarakat; sedangkan aspek tata kelola mencakup struktur dewan, perlindungan pemegang saham, etika bisnis, transparansi, dan pengawasan internal. Dengan cakupan tersebut, ESG melengkapi ukuran keuangan dalam menilai kualitas dan keberlanjutan perusahaan.

Kinerja ESG umumnya dinyatakan dalam skor numerik atau peringkat kategoris yang diterbitkan oleh lembaga pemeringkat. Namun, perbedaan indikator, metode pengukuran, dan pembobotan menyebabkan hasil penilaian antarpenyedia data tidak selalu seragam [12], [13]. Oleh karena itu, interpretasi status ESG perlu memperhatikan sumber data dan metodologi pemeringkatan yang digunakan. Dalam penelitian ini, status top-tier ESG mengacu pada kelompok perusahaan dengan skor ESG tertinggi pada suatu periode, baik berdasarkan ambang yang ditetapkan penyedia data maupun posisi relatif, seperti kuartil teratas. Penetapan kriteria dan sumber skor harus dilakukan secara konsisten agar perubahan klasifikasi benar-benar mencerminkan perubahan kinerja perusahaan.

Status ESG bersifat dinamis karena perusahaan dapat mempertahankan, memperoleh, atau kehilangan posisi top-tier dari satu periode ke periode berikutnya. Perubahan tersebut dapat dipengaruhi oleh kebijakan perusahaan, kondisi keuangan, tekanan regulasi, kontroversi, serta perubahan standar penilaian. Taşkın dkk [14] menunjukkan bahwa skor dan peringkat ESG masa lalu dapat digunakan untuk memprediksi kinerja ESG berikutnya. Temuan tersebut memperlihatkan adanya persistensi, tetapi tidak berarti status ESG bersifat tetap. Oleh karena itu, analisis perubahan status antartahun memberikan informasi yang lebih prospektif dibandingkan penilaian yang hanya menggambarkan keadaan pada satu periode.

2.2 Faktor-faktor Prediktif Status ESG

Kinerja ESG dimasa lalu suatu perusahaan merupakan prediktor utama status ESG pada periode berikutnya. Kinerja tersebut dapat berupa skor ESG keseluruhan, skor setiap pilar, perubahan skor, atau status top-tier tahun sebelumnya. Berdasarkan data 6.166 perusahaan dari 73 negara, Chowdhury dkk. [15] menemukan bahwa skor ESG tertunda menjadi prediktor paling dominan, diikuti ukuran perusahaan dan rasio utang terhadap ekuitas. Temuan ini menunjukkan adanya kesinambungan kinerja ESG karena perubahan kebijakan, tata kelola, dan proses operasional perusahaan umumnya berlangsung secara bertahap

Selain skor historis, karakteristik keuangan juga memberikan informasi yang relevan mengenai kemampuan perusahaan menjalankan agenda keberlanjutan. Ukuran perusahaan menunjukkan ketersediaan sumber daya, sedangkan profitabilitas menggambarkan kapasitas internal untuk membiayai program ESG [16], [17]. Sebaliknya, tingkat utang yang tinggi dapat membatasi fleksibilitas perusahaan. Likuiditas, pertumbuhan, efisiensi, dan nilai pasar juga berpotensi menjelaskan variasi kinerja ESG. D'Amato dkk [18] menunjukkan bahwa informasi neraca berperan penting dalam menjelaskan skor ESG perusahaan yang tergabung dalam STOXX Europe 600. Sejalan dengan itu, Cini dan Ferrari [19] menemukan bahwa rasio keuangan dan risiko sistemik pada periode berjalan dapat digunakan untuk memprediksi kelas ESG pada periode berikutnya.

Namun, informasi keuangan belum sepenuhnya mencerminkan aspek ESG yang bersifat spesifik. Struktur kepemilikan, komposisi dewan, sektor industri, usia perusahaan, pengungkapan keberlanjutan, dan kontroversi ESG juga dapat

ISSN: 2830-0408

memengaruhi peluang perusahaan mencapai atau mempertahankan status top-tier. Oleh karena itu, model prediksi perlu menggabungkan riwayat ESG dengan karakteristik keuangan dan nonkeuangan sesuai ketersediaan data.

2.3 Pembelajaran Mesin (Machine Learning) dan Algoritma XGBoost dalam Prediksi Status ESG

Machine Learning semakin banyak digunakan untuk memprediksi kinerja ESG karena mampu mengolah data dalam jumlah besar serta mengenali hubungan nonlinier antarvariabel [20]. Berbagai algoritma telah diterapkan, antara lain regresi logistik, decision tree, k-nearest neighbors, random forest, support vector machine, dan gradient boosting [21]. Chowdhury dkk. [15] menemukan bahwa random forest menghasilkan akurasi tertinggi di antara enam algoritma yang diuji. Sementara itu, Taşkın dkk. [14] menunjukkan bahwa skor ESG historis dapat digunakan oleh beberapa algoritma klasifikasi untuk memperkirakan kinerja ESG periode berikutnya. Hasil tersebut menegaskan bahwa pemilihan algoritma perlu disesuaikan dengan karakteristik data dan dibuktikan melalui evaluasi empiris.

XGBoost (*Extreme Gradient Boosting*) merupakan algoritma berbasis *gradient-boosted decision trees* yang membangun pohon keputusan secara bertahap. Setiap pohon baru memperbaiki kesalahan prediksi dari model sebelumnya. XGBoost juga memiliki regularisasi, pengaturan laju pembelajaran, pengambilan sampel fitur, dan mekanisme penanganan data yang hilang. Karakteristik tersebut menjadikannya sesuai untuk data tabular dengan pola hubungan dan interaksi antarvariabel yang kompleks [23]. Zhang dan Zhao [24] menunjukkan bahwa integrasi XGBoost dengan Shapley additive explanations (SHAP) menghasilkan klasifikasi peringkat ESG yang akurat sekaligus menjelaskan kontribusi setiap prediktor. Karakteristik ini membuat XGBoost sesuai untuk prediksi status ESG karena mampu menangkap hubungan nonlinier dan interaksi kompleks antara skor ESG historis, indikator keuangan, dan karakteristik nonkeuangan perusahaan.

Dalam konteks prediksi *top-tier ESG*, data masukan untuk perusahaan i pada tahun τ dinyatakan sebagai $x_{i,\tau}$, sedangkan variabel target $y_{i,\tau+1}$ menunjukkan status ESG perusahaan pada periode berikutnya. Nilai $y_{i,\tau+1} = 1$menunjukkan bahwa perusahaan termasuk kategori *top-tier*, sedangkan $y_{i,\tau+1} = 0$ menunjukkan status non-*top-tier*. Penggunaan informasi tahun berjalan untuk memprediksi status tahun berikutnya sejalan dengan pendekatan Cini dan Ferrari [19] serta Taskin dkk. [14], yang menempatkan kinerja ESG masa lalu sebagai sumber informasi untuk memprediksi kelas ESG pada periode mendatang. Secara umum, alur kerja XGBoost terdiri atas tahapan berikut:

1. Menetapkan data dan target.
   Tahap pertama adalah menyusun matriks fitur yang memuat seluruh variabel prediktor. Fitur tersebut dapat mencakup skor ESG historis, skor setiap pilar, profitabilitas, ukuran perusahaan, tingkat utang, likuiditas, serta indikator tata kelola. Fitur perusahaan pada tahun τ digunakan untuk memprediksi status *top-tier ESG* pada tahun $\tau + 1$ [19] .
2. Membentuk prediksi awal.
   Sebelum pohon pertama dibangun, XGBoost menetapkan skor dasar F_0 sebagai prediksi awal bagi seluruh observasi. Dalam klasifikasi biner, skor awal umumnya ditentukan berdasarkan proporsi kelas positif dalam data yang diuji. Jika 25% perusahaan berstatus top-tier, model memulai proses dari probabilitas dasar

ISSN: 2830-0408

tersebut. Prediksi awal ini masih bersifat umum karena belum mempertimbangkan perbedaan karakteristik setiap perusahaan.

3. Menghitung kesalahan.
   Prediksi awal dibandingkan dengan status ESG aktual melalui fungsi kerugian. Pada klasifikasi biner, fungsi yang lazim digunakan adalah binary logistic loss. XGBoost kemudian menghitung turunan pertama dan kedua dari fungsi kerugian terhadap prediksi sebelumnya, yaitu:
   $g_i = \frac{\partial l\left(y_i, \hat{y}_i^{(m-1)}\right)}{\partial \hat{y}_i^{(m-1)}}$ dan $h_i = \frac{\partial^2 l\left(y_i, \hat{y}_i^{(m-1)}\right)}{\partial \left(\hat{y}_i^{(m-1)}\right)^2}$ dengan g_i sebagai gradien yang menunjukkan arah koreksi dan h_i sebagai Hessian yang menggambarkan besarnya perubahan gradien.
4. Membentuk pohon koreksi untuk memperbaiki kesalahan .
   Pada iterasi ke-m, XGBoost membangun pohon baru $f_m(\boldsymbol{x}_i)$ untuk mengurangi kesalahan yang tersisa. Fungsi objektif pada tahap ini dirumuskan sebagai:
   $$\mathcal{L}^{(m)} = \sum_{i=1}^{n} l\left(y_i, \hat{y}_i^{(m-1)} + f_m(x_i)\right) + \Omega(f_m).$$
   Komponen pertama mengukur kesalahan prediksi, sedangkan $\Omega(f_m) = \gamma T + \frac{1}{2}\lambda \sum_{j=1}^{T} w_j^2$ merupakan penalti terhadap kompleksitas pohon dengan T sebagai jumlah daun, w_j sebagai bobot daun ke-j, γ sebagai penalti penambahan daun, dan λ sebagai parameter regularisasi bobot.
5. Menentukan pemisahan bobot daun terbaik.
   Model memilih pemisahan dengan nilai *gain* tertinggi:
   $$\text{Gain} = \frac{1}{2}\left[\frac{G_L^2}{H_L + \lambda} + \frac{G_R^2}{H_R + \lambda} - \frac{(G_L + G_R)^2}{H_L + H_R + \lambda}\right] - \gamma$$
   dengan G_L dan G_R sebagai jumlah gradien pada cabang kiri dan kanan, sedangkan H_L dan H_R merupakan jumlah Hessian pada kedua cabang. Pemisahan dilakukan apabila nilai *gain* cukup besar untuk mengimbangi penalti kompleksitas γ. Setelah struktur pohon terbentuk, bobot optimal pada daun ke-j dihitung sebagai:
   $$w_j^* = -\frac{G_j}{H_j + \lambda}$$
   Bobot tersebut menunjukkan arah dan besarnya koreksi yang diberikan oleh suatu daun terhadap prediksi sebelumnya [22, 23].
6. Memperbarui prediksi.
   Koreksi dari pohon baru kemudian ditambahkan ke prediksi sebelumnya dengan mempertimbangkan learning rate:
   $$\hat{y}_i^{(m)} = \hat{y}_i^{(m-1)} + \eta f_m(x_i)$$
   dengan η sebagai *learning rate* yang mengendalikan besarnya kontribusi setiap pohon.
7. Mengulangi proses.
   Tahap 3–6 dilakukan hingga jumlah pohon tercapai atau kinerja validasi tidak meningkat.
8. Menghasilkan probabilitas.
   Setelah seluruh pohon terbentuk, skor akhir perusahaan diperoleh dari penjumlahan skor dasar dan kontribusi setiap pohon:
   $$F_M(\boldsymbol{x}_i) = F_0 + \sum_{m=1}^{M} \eta\, f_m(\boldsymbol{x}_i)$$

 ISSN: 2830-0408

Dalam klasifikasi biner, skor tersebut diubah menjadi probabilitas menggunakan fungsi sigmoid:

$$P(y_i = 1 \mid x_i) = \frac{1}{1 + \exp\left[-F_M(x_i)\right]}$$

9. Menentukan dan menjelaskan kelas. Probabilitas dibandingkan dengan ambang klasifikasi untuk menetapkan status *top-tier* atau non-*top-tier*. Kontribusi setiap prediktor selanjutnya dapat dijelaskan menggunakan SHAP [13]

2.4 Evaluasi Ketepatan dan Kalibrasi Model Prediksi

Ketepatan model klasifikasi dapat dievaluasi melalui *confusion matrix* yang memuat *true positive, true negative, false positive*, dan *false negative*. Komponen tersebut digunakan untuk menghitung *accuracy, precision, recall, specificity*, dan *F1-score*. *Accuracy* menunjukkan proporsi seluruh prediksi yang benar, sedangkan *precision* mengukur ketepatan prediksi kelas *top-tier*. Adapun *recall* menunjukkan kemampuan model mengenali perusahaan yang benar-benar berstatus *top-tier*, sementara *F1-score* menggambarkan keseimbangan antara *precision* dan *recall*.

Penggunaan *accuracy* sebagai satu-satunya ukuran dapat menimbulkan kesimpulan yang keliru ketika distribusi kelas tidak seimbang. Jika perusahaan *top-tier* hanya mencakup 25% observasi, model yang selalu memprediksi kelas non-top-tier tetap dapat menghasilkan akurasi 75%, meskipun gagal mengenali seluruh perusahaan *top-tier*. Dalam kondisi tersebut, PR-AUC lebih informatif karena memperlihatkan keseimbangan antara *precision* dan *recall* pada berbagai ambang klasifikasi [24].

ROC-AUC tetap digunakan untuk menilai kemampuan model membedakan kelas *top-tier* dan *non-top-tier*. Karena XGBoost juga menghasilkan nilai probabilitas, evaluasi perlu dilengkapi dengan *log loss* atau Brier *score* untuk menilai kalibrasi prediksi. Dengan demikian, penilaian model sebaiknya *menggabungkan accuracy, precision, recall, F1-score*, ROC-AUC, PR-AUC, dan ukuran kalibrasi agar kinerjanya dinilai secara menyeluruh.

Penelitian ini mengembangkan model klasifikasi XGBoost untuk mengestimasi probabilitas perusahaan berada dalam kategori top-tier ESG pada periode berikutnya. Berbeda dari penelitian yang hanya memprediksi skor atau kelas ESG, penelitian ini menekankan dinamika perpindahan status, evaluasi ketepatan prediksi berbasis waktu, dan identifikasi perusahaan yang berpotensi mengalami peningkatan maupun penurunan status.

3. Metode Penelitian

3.1 Sumber Data dan Karakteristik Sampel

Data yang digunakan dalam penelitian ini merupakan data sekunder dari repositori publik Kaggle dengan judul "*ESG and Financial Performance Dataset"* oleh Shriyash Jagtap. Dataset ini terdiri dari data Score ESG tahunan (*time-series)* selama 11 tahun, yaitu dari 2015 hingga 2025. Skor ESG tersebut dimiliki oleh 1000 perusahaan global dengan region Asia*, Oceania, Middle East, Europe*, dan *North America*. Variabel-variabel utama yang terdapat dalam dataset, diklasifikasikan ke dalam empat kelompok informasi dalam Tabel 1.

ISSN: 2830-0408

Tabel 1
Penggunaan Variabel

Kelompok Variabel	Nama Kolom Asli	Peran dalam Pemodelan
Identitas & Waktu	CompanyID, Year	Indeks panel untuk pengurutan deret waktu dan operasi pergeseran (*shift/lag*).
Kategori	Industry, Region	Variabel kontrol sektor dan lokasi yang diubah melalui *one-hot encoding*.
Skor ESG	ESG_Overall, ESG_Environmental, ESG_Social, ESG_Governance	Input fitur status kontemporer (t) dan dasar pembentukan label target ($t+1$).
Konsumsi Fisik	CarbonEmissions, EnergyConsumption, WaterUsage	Pembentuk rasio intensitas fisik riil per unit pendapatan (*revenue*).
Finansial	Revenue, MarketCap, ProfitMargin, GrowthRate	Variabel penjelas fundamental korporasi dan skala bisnis (ditransformasi logaritma).

3.2. Skema Validasi Berbasis Waktu

Pada penelitian ini penggunaan data *training* dan *testing* ditetapkan berbasis periode. Data *training* menggunakan data periode 2016 sampai 2022. Data *training* diterapkan untuk mempelajari pola hubungan antara kinerja masa lalu, kondisi finansial, dan pencapaian status Top-Tier. Sedangkan untuk data *testing* menggunakan periode 2023 sampai 2024. Data tersebut digunakan untuk menilai seberapa akurat prediksi model dalam memproyeksikan status emiten di masa depan.

3.3. Pemodelan XGBoost

Klasifikasi dilakukan menggunakan algoritma XGBoost yang membangun *decision trees* secara bertahap dan mengoreksi kesalahan residu dari pohon secara berurutan.

3.1.1 Penyeimbang Kelas

Kelas target *Top-Tier* hanya mencakup 25% dari seluruh populasi data (rasio perbandingan 1:3), sehingga model menggunakan dengan parameter pembobot sebagai berikut,

$$Scale\ Pos\ Weight = \frac{\sum(Y_{train} = 0)}{\sum(Y_{train} = 1)} \approx 3.0 \quad (1)$$

Parameter ini memberikan penalti kerugian tiga kali lipat lebih besar apabila model salah dalam mendeteksi emiten yang sesungguhnya masuk ke dalam kategori *Top-Tier*.

3.1.2 Konfigurasi Hyperparameter

Parameter pada XGBoost harus ditentukan sebelum menjalankan model. Berikut adalah parameter yang digunakan dalam XGBoost pada Tabel 2.

Tabel 2
Parameter XGBoost

Kategori	Jumlah
Jumlah pohon	300
Learning rate	0,03
Batas kedalaman pohon	4
Rasio sampling	0,8
Regularisasi Alpha	0,1
Ragularisasi Lambda	1.0

ISSN: 2830-0408

3.4. Metode Evaluasi Akurasi dan Error Prediksi

Kinerja model diukur menggunakan metrik klasifikasi standar yaitu ROC-AUC Score, Macro F1-Score, dan table Confusion Matrix. Selain itu, evaluasi difokuskan pada akurasi kelompok yang diprediksi menjadi *Top-Tier* keberlanjutan.

4. Hasil dan Pembahasan

4.1 Evaluasi Kinerja Model Klasifikasi XGBoost

Evaluasi ini dilakukan untuk menilai sejauh mana model mampu membedakan emiten yang diproyeksikan masuk ke dalam kelompok 25% teratas (Top-Tier ESG Leader) pada satu tahun mendatang (t+1). Rincian hasil performa model tersebut dapat dulihat di Tabel3.

Tabel 3
Metrik Evaluasi Klasifikasi XGBoost

	Precision	Recall	F1-score	Support
Non Top-Tier	1	0,91	0,95	1497
ESG Top-Tier	0,78	1	0,88	503
Accuracy			0,93	2000
Macro Average	0.89	0.95	0.91	2000
Weighted Average	0.95	0.93	0.93	2000

Berdasarkan Tabel 3, model XGBoost menunjukkan performa yang sangat solid dengan tingkat akurasi keseluruhan (Accuracy) mencapai 0,93 (93%). Nilai Macro Average F1-Score sebesar 0,91 dan ROC-AUC Score yang tinggi mengonfirmasi bahwa model mampu mengklasifikasikan kedua kelas secara seimbang tanpa terpengaruh oleh ketimpangan distribusi data (class imbalance).

Pada kelompok target utama, yaitu emiten ESG Top-Tier (1), model menghasilkan nilai Recall sebesar 1,00 (100%). Hal ini mengindikasikan bahwa seluruh emiten (503 perusahaan) yang secara aktual berstatus Top-Tier di masa depan berhasil terdeteksi secara sempurna oleh model tanpa ada satu pun kandidat juara yang luput (zero missed leader). Di sisi lain, nilai Precision untuk kelas Top-Tier tercatat sebesar 0,78 (78%), yang menggambarkan tingkat ketepatan vonis positif model pada pengujian keseluruhan.

4.2. Evaluasi Ketepatan Kelompok Calon ESG Top-Tier

Untuk memberikan gambaran yang lebih mendalam mengenai tingkat sensitivitas dan risiko kesalahan tebakan model, dilakukan evaluasi khusus terhadap seluruh emiten yang diproyeksikan oleh XGBoost akan menjadi ESG Top-Tier pada data pengujian. Hasil audit kelompok calon ESG Top-Tier disajikan pada Tabel 4.

Tabel 4
Metrik Evaluasi Klasifikasi XGBoost

CompanyID	Industry	Region	ESG_Overall	Prob_Leader
884	Consumer Goods	North America	73.3	0.99951
489	Consumer Goods	Asia	72.5	0.999508
451	Consumer Goods	Oceania	85.4	0.999488
376	Technology	Oceania	90	0.999486
176	Healthcare	Oceania	79.3	0.999481
190	Technology	North America	74.4	0.999469

 ISSN: 2830-0408

CompanyID	Industry	Region	ESG_Overall	Prob_Leader
921	Healthcare	Oceania	80.7	0.999451
252	Consumer Goods	North America	71.8	0.999449
133	Consumer Goods	Europe	70.4	0.999441
582	Healthcare	Oceania	80.9	0.999441

Hasil audit pada Tabel 4 menunjukkan bahwa dari total 331 emiten yang diprediksi oleh model akan menduduki posisi Top-Tier, sebanyak 251 perusahaan (75,83%) terbukti secara aktual berstatus Leader (Precision Hit). Sementara itu, sebanyak 80 perusahaan (24,17%) mengalami False Alarm, di mana emiten diproyeksikan masuk ke dalam kelompok Top-Tier namun kenyataannya gagal menembus kuartil teratas pada tahun berikutnya.

Tingginya proporsi tebakan benar (75,83%) mengindikasikan bahwa pembobotan penalti scale_pos_weight = 3,0 berhasil mendorong XGBoost untuk mengenali sinyal-sinyal keberlanjutan secara presisi. Kesalahan prediksi berupa False Alarm umumnya terjadi pada emiten yang berada di batas ambang (borderline) nilai skor ESG, di mana terjadi sedikit penurunan skor pada tahun berikutnya akibat perubahan dinamis dalam konsumsi sumber daya fisik atau indikator keuangan tahunan.

4.2. Evaluasi Ketepatan Kelompok Calon ESG Top-Tier

XGBoost tidak hanya menghasilkan keputusan biner, melainkan juga mengeluarkan nilai probabilitas kontinu (Prob_Top-Tier) yang mencerminkan tingkat keyakinan model terhadap posisi emiten. Tabel 5 menampilkan 10 emiten teratas pada data uji 2024 yang diprediksi paling dominan untuk menjadi ESG Top-Tier.

Tabel 5.
Sampel 10 Emiten Teratas Berdasarkan Probabilitas Keberlanjutan

CompanyID	Industry	Region	ESG_Overall	Prob_Top Tier
884	Consumer Goods	North America	73,3	0,99951
489	Consumer Goods	Asia	72,5	0,99951
451	Consumer Goods	Oceania	85,4	0,99949
376	Technology	Oceania	90,0	0,99949
176	Healthcare	Oceania	79,3	0,99948
190	Technology	North America	74,4	0,99947
921	Healthcare	Oceania	80,7	0,99945
252	Consumer Goods	North America	71,8	0,99945
133	Consumer Goods	Europe	70,4	0,99944
582	Healthcare	Oceania	80,9	0,99944

Sumber: Data Primer Diolah, 2026

Berdasarkan Tabel 5, emiten seperti CompanyID 884, 489, dan 451 mencatatkan tingkat keyakinan probabilitas mendekati sempurna (≥ 0,9994). Temuan ini menunjukkan bahwa model XGBoost mampu mengintegrasikan kombinasi antara tingginya skor ESG berjalan (ESG_Overall) dan rasio efisiensi beban lingkungan terhadap pendapatan (Revenue).

Perusahaan di sektor Technology (CompanyID 376) misalnya, berhasil mencapai skor probabilitas 0,99949 berkat kombinasi skor ESG yang sangat tinggi (90,0) serta

 ISSN: 2830-0408

tingkat emisi karbon dan pemakaian air yang relatif rendah dibanding pendapatan yang dihasilkan. Hal ini memverifikasi bahwa XGBoost tidak hanya sekadar melihat besaran angka keuangan, melainkan memperhitungkan interaksi non-linear antara intensitas emisi riil dengan kinerja keberlanjutan korporasi.

4.3 Implikasi Praktis dan Proyeksi Prospektif 2026

Kemampuan model dalam memprediksi status keberlanjutan satu tahun ke depan memberikan dua nilai strategis utama:

- **1. Sistem Peringatan Dini (Early Warning System):** Bagi investor dan pengelola dana (fund manager), model dapat mendeteksi emiten yang berisiko mengalami penurunan kasta dari Top-Tier menuju Non-Leader sebelum informasi tersebut terpublikasi secara resmi di pasar.
- **2. Peluang Investasi Awal (Early Investment Opportunities):** Probabilitas tinggi pada emiten Non-Leader periode berjalan memberi sinyal kandidat perusahaan yang akan mengalami peningkatan kelas (Upgraded Leader), sehingga investor dapat mengambil posisi lebih awal sebelum apresiasi harga aset terjadi di bursa.

5. Kesimpulan

Penelitian ini telah mengembangkan model XGBoost untuk memprediksi status perusahaan dalam kategori Top-Tier ESG pada satu periode berikutnya. Dengan menggunakan data perusahaan global dan validasi berbasis waktu, model menghasilkan akurasi sebesar 93% dan macro F1-score sebesar 0,91. Pada kelas ESG Top-Tier, model mencapai recall sebesar 100% dan precision sebesar 78%, yang menunjukkan bahwa seluruh perusahaan yang secara aktual berada dalam kategori Top-Tier pada data pengujian berhasil teridentifikasi, meskipun masih terdapat prediksi positif yang tidak sesuai. Dari 331 perusahaan yang diprediksi sebagai ESG Top-Tier, sebanyak 251 perusahaan atau 75,83% terbukti berada dalam kategori tersebut, sedangkan 80 perusahaan atau 24,17% merupakan false alarm. Hasil ini menunjukkan bahwa model XGBoost dapat digunakan untuk mengidentifikasi pola status ESG dan memberikan proyeksi mengenai perubahan status perusahaan pada periode berikutnya. Model juga dapat menjadi dasar untuk sistem peringatan dini terhadap potensi perubahan status ESG. Namun, hasil prediksi tetap perlu dipahami sebagai keluaran model berdasarkan variabel dan periode data yang digunakan, sehingga pengujian dengan data yang lebih baru dan variabel tambahan diperlukan untuk meningkatkan validitas proyeksi pada periode mendatang.

ISSN: 2830-0408

Pustaka

[1]. M. Aydoğmuş, G. Gülay, and K. Ergun, "Impact of ESG performance on firm value and profitability," *Borsa Istanbul Review*, vol. 22, pp. S119–S127, Dec. 2022, doi: 10.1016/j.bir.2022.11.006[18].[21]

[2]. N. Manulang and H. Z. Soeratin, "Peran Environmental, Social, and Governance dalam Menarik Investor Milenial dan Gen Z," *Integrative Perspectives of Social and Science Journal (IPSSJ)*, vol. 2, no. 1, pp. 418–427, 2025[3].[14]

[3]. Oktrivina, Nelyumna, Harnovinsah, S. Atikah, and A. P. Sujana, "Pengaruh ESG score terhadap kinerja keuangan," *Jurnal Akuntansi dan Manajemen*, vol. 22, no. 2, pp. 117–134, Jun. 2025, doi: 10.36406/jam.v22i2.186[1].[12]

[4]. D. B. Hariyanto and I. Ghozali, "Pengaruh Environment, Social, Governance (ESG) Disclosure Terhadap Nilai Perusahaan (Studi Empiris pada Perusahaan yang Terdaftar dalam Indeks Kompas 100 Periode 2020-2022)," *Diponegoro Journal of Accounting*, vol. 13, no. 3, pp. 1–13, 2024[5].[16]

[5]. C. Matsali, M. Skordoulis, A. Papagrigoriou, and P. Kalantonis, "ESG Scores as Indicators of Green Business Strategies and Their Impact on Financial Performance in Tourism Services: Evidence

[6]. O. Ferli, E. Wijaya, R. Z. Zahna, and P. M. Sitohang, "Pengaruh Environmental, Social, Governance (ESG) Score Terhadap Financial Performance (Pada Perusahaan yang terdaftar di IDX ESG Leaders Periode 2019-2023)," *Jurnal Administrasi dan Manajemen*, vol. 12, no. 1, pp. 314–324, 2024[2].[13]

[7]. K. Khariroh, A. Eddy S, and N. Endah, "Tinjauan Literatur: Hubungan antara Pengungkapan ESG dan Keputusan Investor pada sektor pertambangan," *YUME: Journal of Management*, vol. 8, no. 2, pp. 254–262, 2025[8].[17]

[8]. D. Tirkaamiana and S. S. A. Basuki, "Enhancing ESG Insights Using Machine Learning: A Case Study of Top Performing Banks in Indonesia," *Journal of Applied Informatics and Computing (JAIC)*, vol. 9, no. 3, pp. 810–818, Jun. 2025[6].[11]

[9]. P. W. Anggraini and T. D. R. Sari, "Pengaruh Environment Social Governance (ESG) Score Terhadap Kinerja Keuangan Perusahaan Yang Terindeks IDX ESG Leader Tahun 2020-2023," *JAFM: Journal of Accounting and Finance Management*, vol. 5, no. 5, 2024, doi: 10.38035/jafm.v5i5

[10]. R. Illaihiyah, G. Abdurrahman, and D Daryanto"Implementasi Algoritma XGBoost Classifier untuk Klasifikasi Kerumunan Jemaah Haji dan Umrah," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 6, no. 1, pp. 106–115, Jan. 2026, doi: 10.57152/malcom.v6i1.2245[9].

[11]. R. Shwartz-Ziv and A. Armon, "Tabular data: Deep learning is not all you need," Information Fusion, vol. 81, pp. 84–90, May 2022, doi: 10.1016/j.inffus.2021.11.011.

[12]. F. Berg, J. F. Kölbel, and R. Rigobon, "Aggregate Confusion: The Divergence of ESG Ratings*," *Rev. Financ.*, vol. 26, no. 6, pp. 1315–1344, Nov. 2022, doi: 10.1093/rof/rfac033.

[13]. [2] L. Widyawati, "A systematic literature review of socially responsible investment and environmental social governance metrics," *Bus. Strateg. Environ.*, vol. 29, no. 2, pp. 619–637, Feb. 2020, doi: 10.1002/bse.2393.

[14]. D. Taskin, G. Sariyer, E. Acar, and E. C. Cagli, "Do past ESG scores efficiently predict future ESG performance?," *Res. Int. Bus. Finance*, vol. 74, Feb. 2025, doi: 10.1016/j.ribaf.2024.102706.

[15]. M. A. F. Chowdhury, M. Abdullah, M. A. K. Azad, Z. Sulong, and M. N. Islam, "Environmental, social and governance (ESG) rating prediction using machine learning approaches," *Ann. Oper. Res.*, 2023, doi: 10.1007/s10479-023-05633-7.

[16]. S. Drempetic, C. Klein, and B. Zwergel, "The Influence of Firm Size on the ESG Score: Corporate Sustainability Ratings Under Review," *J. Bus. Ethics*, vol. 167, no. 2, pp. 333–360, Nov. 2020, doi: 10.1007/s10551-019-04164-1.

[17]. F. Crespi and M. Migliavacca, "The Determinants of ESG Rating in the Financial Industry: The Same Old Story or a Different Tale?," *Sustainability*, vol. 12, no. 16, Art. no. 6398, Aug. 2020, doi: 10.3390/su12166398.

[18]. V. D'Amato, R. D'Ecclesia, and S. Levantesi, "ESG score prediction through random forest algorithm," *Computational Management Science*, vol. 19, no. 2, pp. 347–373, Jun. 2022, doi: 10.1007/s10287-021-00419-3.

[19]. F. Cini and A. Ferrari, "Towards the estimation of ESG ratings: A machine learning approach using balance sheet ratios," *Res. Int. Bus. Finance*, vol. 73, Jan. 2025, doi: 10.1016/j.ribaf.2024.102653.

ISSN: 2830-0408

[20]. T. Lim, "Environmental, social, and governance (ESG) and artificial intelligence in finance: State-of-the-art and research takeaways," *Artif. Intell. Rev.*, vol. 57, Art. no. 76, Feb. 2024, doi: 10.1007/s10462-024-10708-3.

[21]. R. Y. C. Seow, "Transforming ESG Analytics With Machine Learning: A Systematic Literature Review Using TCCM Framework," *Corp. Soc. Responsib. Environ. Manag.*, vol. 32, no. 6, pp. 7358–7389, Nov. 2025, doi: 10.1002/csr.70089.

[22]. T. Chen and C. Guestrin, "XGBoost: A scalable tree boosting system," in *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, Association for Computing Machinery, Aug. 2016, pp. 785–794. doi: 10.1145/2939672.2939785.

[23]. J. Zhang and Z. Zhao, "Corporate ESG rating prediction based on XGBoost-SHAP interpretable machine learning model," *Expert Syst. Appl.*, vol. 295, Jan. 2026, doi: 10.1016/j.eswa.2025.128809.

[24]. T. Saito and M. Rehmsmeier, "The precision-recall plot is more informative than the ROC plot when evaluating binary classifiers on imbalanced datasets," *PLoS One*, vol. 10, no. 3, Mar. 2015, doi: 10.1371/journal.pone.0118432.