
**PERAN MACHINE LEARNING DALAM DETEKSI DINI RISIKO
KEBERLANJUTAN PADA ORGANISASI NON PROFIT
DAN INSTITUSI PUBLIK**

**Marleny Syam¹,
Hendri Sembiring²,
Ika Sartika³**

¹Akademi Maritim Belawan

²Universitas Advent Surya Nusantara

³Akademi Maritim Belawan

Korespondensi : marleni_syam@yahoo.com¹

Abstract

Early detection of sustainability risks has become increasingly critical for non-profit organizations and public institutions, which must maintain accountability, transparency, and long-term resilience amid growing environmental, social, and governance (ESG) challenges. This study investigates the role of machine learning in supporting early warning systems for sustainability risk identification within these organizations. Using supervised and unsupervised learning techniques, the research analyzes key indicators related to operational performance, financial stability, stakeholder engagement, and environmental impact. The study develops a predictive risk model and evaluates its accuracy, interpretability, and applicability within the context of public and non-profit governance. Results show that machine learning improves the timeliness and precision of risk detection, enabling organizations to anticipate vulnerabilities, enhance decision-making processes, and strengthen sustainability strategies. This research contributes to the literature by presenting an analytical framework that integrates machine learning with sustainability risk management, offering practical implications for policymakers, organizational leaders, and practitioners seeking to enhance institutional resilience and long-term sustainability.

Keywords: Machine learning; Early risk detection; Non profit organizations; Public institutions

PENDAHULUAN

Konsep strategis yang penting bagi organisasi non profit dan institusi publik adalah keberlanjutan (sustainability). Organisasi no profit dan institusi publik tidak hanya dituntut mencapai tujuan social, pelayanan publik dan pengembangan masyarakat tetapi juga bertanggung jawab menjaga akuntabilitas, transparansi, serta kinerja jangka panjang. Tantangan yang dihadapi semakin kompleks seiring dengan meningkatnya dinamika lingkungan operasional, ketidakpastian ekonomi, tuntutan pemangku kepentingan, serta risiko lingkungan, sosial dan tata kelola. Kondisi tersebut menuntut adanya pendekatan manajemen risiko yang lebih adaptif dan berbasis teknologi untuk mendeteksi risiko sejak dini sebelum berkembang menjadi krisis yang mengancam keberlanjutan organisasi.

Perkembangan teknologi digital khususnya *machine learning* menawarkan peluang besar dalam meningkatkan kemampuan organisasi untuk melakukan prediksi, analisis pola, serta identifikasi risiko yang tidak selalu dapat dipantau melalui metode konvensional. *Machine learning (ML)* memungkinkan pengolahan volume data yang besar dan kompleks secara cepat dan akurat sehingga dapat menghasilkan

metode prediktif yang mendukung system peringatan dini terhadap potensi risiko keberlanjutan. Penerapan *machine learning* juga dapat meningkatkan efisiensi pemantauan kinerja organisasi, mendeteksi anomaly operasional, serta memperkirakan dampak risiko terhadap keberlanjutan di masa depan.

Penelitian tentang *machine learning* dalam system deteksi dini risiko keberlanjutan masih relative terbatas, terutama pada konteks organisasi non profit dan institusi publik. Sebagian besar penelitian terdahulu lebih banyak memiliki karakteristik, tantangan dan struktur tata kelola yang berbeda. Perbedaan tersebut mencakup keterbatasan sumber daya, kompleksitas kebutuhan pemangku kepentingan, serta tingkat ketergantungan pada pendanaan eksternal, yang menyebabkan manajemen risiko keberlanjutan menjadi lebih sensitif dan krusial.

Oleh karena itu, penelitian ini bertujuan untuk mengkaji peran *machine learning* dalam mendukung deteksi dini risiko keberlanjutan pada organisasi non profit dan institusi publik. Penelitian ini mengeksplorasi bagaimana model *machine learning* dapat membantu memprediksi indikator risiko keberlanjutan, meningkatkan ketepatan identifikasi kerentanan, serta memperkuat proses pengambilan keputusan organisasi. Selain itu penelitian ini menawarkan kerangka analisis yang mengintegrasikan teknologi prediktif dengan prinsip manajemen risiko keberlanjutan, sehingga dapat menjadi pedoman bagi pemangku kepentingan dalam merancang strategi ketahanan organisasi jangka panjang.

Dengan demikian, penelitian ini tidak hanya memberikan kontribusi teoritis terhadap pengembangan literatur mengenai manajemen risiko dan teknologi analitik, tetapi juga memberikan kontribusi praktis bagi organisasi non profit dan institusi publik dalam meningkatkan akuntabilitas, efisiensi, serta keberlanjutan operasional di era digital.

REVIEW LITERATUR

Penelitian ini mengkaji peran *machine learning* dalam deteksi dini risiko keberlanjutan pada organisasi non profit dan institusi publik. Beberapa studi sebelumnya memberikan landasan teoritis dan empiris untuk mendukung penelitian ini.

Anomaly detection berbasis deep learning

Zang, Wang & Jin (2019) menemukan bahwa Teknik *anomaly detection* berbasis *deep learning* mampu mengidentifikasi penyimpangan operasional yang dapat berkembang menjadi risiko strategis. Hasil ini memperkuat bukti empiris bahwa *machine learning* dapat digunakan untuk system deteksi dini risiko keberlanjutan melalui pengenalan pola ketidakwajaran dalam aktivitas organisasi seperti penurunan pendanaan, anomaly laporan kinerja atau penurunan partisipasi pemangku kepentingan.

Organisasi

Elmer dan Stadtfeld (2020) mengembangkan model prediktif berbasis analisis jaringan menggunakan *machine learning* untuk memetakan potensi risiko dan keberlanjutan dalam struktur organisasi. Penelitian ini menunjukkan bagaimana *machine learning* dapat memprediksi disfungsi struktural, konflik internal dan risiko kolaborasi isu yang sangat relevan bagi organisasi non profit dan institusi publik yang mengandalkan hubungan antar stakeholder.

Perspektif tata kelola risiko

Menurut Aven (2016) dan standar ISO 31000 (2018) menegaskan pentingnya pendekatan analitis dalam mengidentifikasi risiko secara sistematis. Meskipun

menggunakan *machine learning* secara eksplisit, kerangka tersebut memberikan landasan teoritis bahwa system manajemen risiko harus adaptif, berbasis data dan mampu memberikan informasi peringatan dini. Hal ini memberikan peluang untuk mengintegrasikan *machine learning* sebagai teknologi pendukung dalam kerangka manajemen risiko keberlanjutan.

Non profit dan publik

Ebrahim (2010) dan Bryson et al (2014) menyoroti tantangan akuntabilitas, keterbatasan sumber daya, serta kebutuhan sistem informasi yang lebih canggih untuk meningkatkan transparansi dan efektivitas. Keterbatasan ini memperkuat kebutuhan akan pendekatan data driven seperti *machine learning* untuk membantu organisasi dalam mendeteksi risiko keberlanjutan secara lebih cepat dan akurat.

Analitik prediktif pada sektor publik

Desouza & Jacob (2017) serta Kim & Lee (2021) menunjukkan bahwa pemerintah semakin mengadopsi teknologi kecerdasan buatan dalam pengambilan keputusan. Temuan mereka menunjukkan bahwa penerapan *machine learning* mampu meningkatkan efisiensi analisis risiko, memperbaiki perencanaan kebijakan, serta memberikan dukungan bukti empiris yang lebih kuat dalam proses pengambilan keputusan publik. Hal ini menjadi bukti empiris bahwa teknologi prediktif dapat diterapkan secara efektif dalam mendukung keberlanjutan institusi publik.

METODE PENELITIAN

Jenis Penelitian

Penelitian ini menggunakan pendekatan kuantitatif eksplanatori yang artinya adalah menguji hubungan sebab akibat antar variabel.

Populasi dan Sampel

Populasi dalam penelitian ini adalah semua organisasi non profit (Yayasan sekolah kemaritiman) dan institusi publik (Dinas kemaritiman dan badan layanan kemaritiman). Sampel yang diambil dalam penelitian ini adalah organisasi non profit adalah Yayasan lancang kuning Samudra, sedangkan institusi publik nya adalah Pelindo Belawan.

Teknik Pengumpulan Data

a. Tujuan Pengumpulan data singkat

Data dikumpulkan berdasarkan data historis dan terukur dari kedua organisasi dengan tujuan untuk :

- 1) Membangun data set prediktor (*features*) yang merepresentasikan faktor – faktor risiko keberlanjutan
- 2) Mendapatkan variabel target (label) berupa kejadian/tingkat risiko keberlanjutan (misal rendah/sedang/tinggi) untuk melatih model *machine learning*
- 3) Memvalidasi interpretabilitas model melalui expert scoring

b. Sumber & Jenis Data (primer dan sekunder)

1) Data Sekunder (utama untuk ML)

- a) Laporan keuangan periodik (bulanan/triwulan/tahunan): pendapatan, biaya, kas, rasio likuiditas.
- b) Laporan kegiatan / kinerja program: jumlah peserta, capaian outcome, jumlah proyek aktif/selesai, rasio keberhasilan.
- c) Laporan donor & pendanaan: jumlah donor, diversitas donor, siklus pendanaan, dependensi pendanaan.

-
- d) Laporan audit / temuan kepatuhan: jumlah temuan, kategori temuan, waktu tindak lanjut.
 - e) Catatan insiden / risiko: insiden operasional, keterlambatan, pelanggaran SOP.
 - f) Data HR: turnover, absensi, rasio staf tetap/kontrak, rasio karyawan/data officer.
 - g) Sistem informasi internal (log digital): tiket masalah, laporan masyarakat/keluhan, monitoring KPI.
 - h) Indikator ESG yang tersedia (jika ada): penggunaan energi, limbah, kegiatan CSR, keterlibatan komunitas.
 - 2) Data Primer (pendukung)
 - a) Kuesioner terstruktur kepada manajer/program officer/data officer (untuk mengukur variabel yang tidak terdokumentasi): tata kelola data, kesiapan digital, persepsi risiko, kualitas manajemen risiko.
 - b) Expert scoring: penilaian risiko historis oleh tim audit internal atau tim manajemen (skor 1–5 untuk setiap periode) sebagai sumber label alternatif/validation.
 - c. Unit Analisis & Unit Observasi (sampling frame)
 - 1) Unit organisasi: 2 organisasi (Yayasan Lancang Kuning Samudra, Pelindo Belawan).
 - 2) Unit observasi untuk ML: *time-series records* per organisasi (mis. catatan bulanan atau triwulanan).
 - a) Rekomendasi: bulanan jika tersedia; minimal 24–36 bulan data historis (2–3 tahun). Contoh: jika data bulanan & tersedia 3 tahun → 36 record per organisasi → total ~72 records (lebih baik jika ada granularitas proyek/kelompok untuk menambah jumlah record).
 - 3) Unit responden kuesioner: manajer program, kepala keuangan, data officer, kepala HR (2–4 orang per organisasi).
 - d. Instrumen Pengumpulan Data (siap pakai)
 - 1) Daftar permintaan dokumen (document request form) diminta kepada masing-masing organisasi diantara nya adalah sebagai berikut:
 - a) Laporan keuangan bulanan/triwulan/tahunan.
 - b) Laporan kinerja program per proyek.
 - c) Laporan audit internal/eksternal (temuan & follow-up).
 - d) Catatan insiden/keluhan/tiket.
 - e) Data HR: jumlah karyawan per bulan, turnover, cuti panjang.
 - f) Log sistem (jika ada): tiket, transaksi, monitoring KPI.
 - g) Kebijakan manajemen risiko, SOP, dan laporan rapat manajemen.
 - 2) Kuesioner terstruktur (skala Likert 1–5) untuk responden manajemen:
 - a) Kesiapan digital organisasi untuk monitoring (1=tidak siap — 5=sangat siap).
 - b) Adanya formal risk register (1–5).
 - c) Frekuensi review KPI program (1–5).
 - d) Ketergantungan pada 1 donor utama (1=tidak — 5=sangat bergantung).
 - e) Ketersediaan data historis terstruktur (1–5).
 - f) Persepsi terhadap tekanan lingkungan/lingkungan operasional (1–5).

- 3) Expert Scoring Form
Untuk tiap periode (bulan/triwulan): minta 2–3 ahli internal menilai tingkat risiko keberlanjutan 1–5 berdasarkan kriteria (keuangan, operasional, reputasi, regulasi). Gunakan rata-rata skor sebagai label.
- e. Prosedur Pengumpulan Data — Langkah Operasional
 - 1) Kick-off meeting: Temui perwakilan (manajemen dan IT/data) untuk menjelaskan tujuan, format data yang dibutuhkan, dan deadline.
 - 2) Pengumpulan dokumen: Terima dokumen elektronik (CSV, Excel, PDF). Bila data hanya tersedia hardcopy, lakukan digitalisasi (scan & ekstraksi).
 - 3) Ekstraksi & mapping: Petakan kolom/variabel dari setiap sumber ke skema dataset yang disepakati (feature dictionary).
 - 4) Kuesioner online: Kirim kuesioner ke responden kunci; follow-up untuk mencapai respons minimal 80% dari target.
 - 5) Expert scoring: Jadwalkan sesi penilaian ahli untuk memberikan label tiap periode.
 - 6) Verifikasi & cleaning awal: Cek missing values, inkonsistensi; diskusikan dengan contact person untuk klarifikasi.
 - 7) Anonymization: Hilangkan identitas sensitif; simpan mapping ID terpisah yang terenkripsi.
- f. Variabel yang Direkomendasikan (contoh untuk dataset ML)
 - 1) Variabel Target (Label)
risk_level : Low / Medium / High (hasil dari expert scoring atau rule-based: mis. jika temuan audit > X & kas < Y → High).
Contoh Predictor (Features)
 - a) cash_ratio (current assets / current liabilities) — keuangan
 - b) operational_cost_change_pct (MoM/YoY)
 - c) donor_diversity_index (jumlah donor unik / total funding)
 - d) receivable_days
 - e) program_success_rate (proyek selesai / proyek total)
 - f) num_audit_findings (per periode)
 - g) avg_time_to_resolve_findings
 - h) staff_turnover_rate
 - i) num_incidents_reported
 - j) kpi_achievement_pct
 - k) digital_readiness_score (dari kuesioner)
 - l) dependency_on_single_donor (binary atau score)
 - m) esg_score (jika tersedia)
 - n) seasonality_indicator (bulan/quarter)
- g. Pelabelan (Labeling) — Cara praktis
 - 1) Expert-based labeling
Minta 2–3 ahli internal (audit/keuangan/ahli program) memberi skor 1–5 tiap periode. Rata-rata skor → discretize: 1–2 = Low, 2.1–3.5 = Medium, >3.5 = High.
 - 2) Rule-based labeling (alternatif)
Tentukan aturan objektif, mis. High bila (kas < X) OR (num_audit_findings >= 3) OR (program_success_rate < 50%); Medium bila salah satu indikator bermasalah; sisanya Low.

- 3) Hybrid
Gunakan rule-based sebagai baseline lalu minta expert memvalidasi / koreksi sample label (~20% data) — membantu reduce bias.
- h. Validasi & Quality Control
 - 1) Triangulasi: Bandingkan hasil kuesioner, dokumen, dan expert scoring.
 - 2) Inter-rater reliability: Hitung Cohen's kappa atau ICC untuk skor expert; bila rendah (<0.6) lakukan diskusi kalibrasi.
 - 3) Data audit trail: Catat sumber & timestamp setiap record.
 - 4) Handling missing data: dokumentasikan missingness (MCAR/MAR/MNAR), gunakan imputasi (median/forward-fill/time-series specific imputation) bila perlu — catat metode.
 - 5) Outlier check: visualisasi boxplot/time-series; verifikasi ke sumber.
- i. Persiapan Data untuk Machine Learning (preprocessing)
 - 1) Feature engineering: buat rasio, perubahan persentase, rolling averages (3/6 months).
 - 2) Encoding: kategorikal → one-hot atau target encoding.
 - 3) Scaling: standardize atau min-max untuk algoritma sensitif skala.
 - 4) Handle imbalance: jika kelas High langka → gunakan SMOTE, ADASYN, atau class weighting.
 - 5) Train/test split: gunakan time-aware split (train on past, test on future) jika data time-series. Atau cross-validation (time-series CV).
 - 6) Evaluation metrics: AUC-ROC, precision, recall, F1-score; untuk early detection gunakan lead-time based metrics (berapa jauh sebelum kejadian model mendeteksi).
 - 7) Explainability: SHAP / LIME / feature importance untuk interpretabilitas model (penting agar manajemen menerima output).
- j. Etika, Izin & Keamanan Data
 - 1) Surat izin resmi + MoU data sharing dengan kedua organisasi.
 - 2) Persetujuan internal (organizational consent) untuk penggunaan data.
 - 3) Anonimisasi — hapus nama donor/penerima individual.
 - 4) Penyimpanan aman — enkripsi, akses terbatas.
 - 5) Pernyataan confidentiality untuk peneliti.
 - 6) Penyajian hasil aggregated — jangan publikasikan indikator organisasi yang mengidentifikasi tanpa izin.
- k. Jadwal & Estimasi (operasional singkat)
 - 1) Minggu 1–2: Persiapan
 - 2) Minggu 3–6: Pengumpulan dokumen & ekstraksi data.
 - 3) Minggu 7–9: Penyebaran kuesioner & expert scoring.
 - 4) Minggu 10–12: Pembersihan data & preprocessing.
 - 5) Minggu 13–16: Feature engineering & pemodelan ML awal.
- l. Checklist Dokumen & Permintaan Data (siap kirim ke organisasi)
 - 1) Laporan keuangan (X tahun; format Excel/CSV jika memungkinkan).
 - 2) Laporan kinerja program per proyek (X tahun).
 - 3) Laporan audit (temuan & follow-up).
 - 4) Catatan insiden / tiket masalah.
 - 5) Data HR (turnover, jumlah staf).

- 6) Export log sistem (jika ada): tiket, KPI dashboard.
- 7) Kebijakan manajemen risiko & SOP.
- 8) Daftar donor & nilai donasi per periode.
- 9) Kontak person (IT/data officer, finance, program).

1. Teknik Analisis Data

Teknik analisis data dalam penelitian ini dapat dilakukan dengan cara:

- a. Data preparation & exploratory data analysis (EDA)
 - 1) Konsolidasi dataset: gabungkan records time-series/per-proyek dari kedua organisasi. Sertakan kolom “ (Lanc.Kun.Samudra / Pelindo), date, predictors...,”.
 - 2) EDA:
 - a) Statistik deskriptif per variabel (mean, median, SD) dan per organisasi.
 - b) Visualisasi time series (trend cash ratio, donor inflow), korelogram, heatmap missing values.
 - c) Distribusi kelas label (cek class imbalance).
 - 3) Missing data analysis:
 - a) Tentukan jenis missingness (MCAR/MAR/MNAR).
 - b) Imputasi: time-series-aware (forward-fill, interpolation) atau model-based (KNN, MICE) sesuai kasus.
 - c) Outlier handling: identifikasi (IQR / z-score), verifikasi sumber, cap/transform bila perlu (log transform untuk skewed).
- b. Feature engineering
 - 1) Buat rasio & perubahan: cash_ratio, operating_margin, donor_diversity_index, yoy_change_revenue, pct_change_staff.
 - 2) Rolling features: rolling mean/SD 3/6/12 months, momentum indicators.
 - 3) Lag features: predictors lagged (t-1, t-3) untuk *early detection* (menguji lead time).
 - 4) Categorical encoding: one-hot atau target encoding untuk kategori (mis. program_type).
 - 5) Time features: month, quarter, seasonality dummies.
 - 6) Standardize / scale: StandardScaler untuk algoritma sensitif (SVM, NN).
- c. Labeling & framing for early detection
 - 1) Label waktu-t = apakah kejadian risiko terjadi dalam window ke depan (e.g., dalam 3 bulan berikutnya) — ini penting untuk *early warning*. Definisikan window eksplisit (lead time).
 - 2) Buat beberapa eksperimen lead-time (1-month, 3-months, 6-months) untuk lihat efektivitas.
- d. Statistik inferensial & uji signifikansi
 - 1) Signifikansi koefisien: p-values dan confidence intervals (GLM / mixed models).
 - 2) Perbandingan model: McNemar’s test untuk dua classifier pada same test set (binary outcome); DeLong test untuk AUC comparison.
 - 3) Permutation test: uji robustness improvement model vs baseline.
 - 4) Effect size: report Cohen’s d, odds ratios, atau perubahan probabilitas marginal.

- e. Robustness checks & sensitivity analysis
 - 1) Uji model dengan lead-time berbeda (1,3,6 months).
 - 2) Uji menggunakan rule-based labels vs expert-labeled (bandingkan performa).
 - 3) Uji feature subsets: keuangan-only, HR-only, ESG-only untuk melihat sumber kekuatan prediksi.
 - 4) Cross-org generalization: train on one org, test on the other (uji transferability) — sangat berguna untuk generalisasi kebijakan.
- f. Analisis tambahan untuk konteks dua organisasi
 - 1) Pooled model dengan org_id sebagai fitur vs separate models per organisasi — bandingkan performa.
 - 2) Multilevel modeling untuk melihat apakah efek predictor berbeda antara Lancang Kuning Samudra dan Pelindo Belawan.
 - 3) Case review: ambil beberapa periode dengan prediksi high risk, lakukan analisis dokumenter manual untuk verifikasi penyebab (triangulasi).
- g. Pelaporan hasil
 - 1) Tampilkan: confusion matrix, ROC curve, precision-recall curve, SHAP summary plot, PDP untuk 3–5 fitur penting.
 - 2) Laporkan: metric utama (precision/recall/F1/AUC) dengan 95% CI.
 - 3) Interpretasi praktis: mis. “peningkatan dependency donor sebesar 10% meningkatkan odds risk_high sebesar X (CI...), artinya ...”
 - 4) Rekomendasi operasional: threshold untuk peringatan, indikator yang harus dimonitor, prosedur tindak lanjut.

2. Lokasi dan Waktu Penelitian

Penelitian dilakukan di Yayasan Lancang Kuning Samudra dan Pelindo Belawan..

HASIL DAN PEMBAHASAN

Hasil Penelitian

Deskripsi Data Penelitian

Dataset yang digunakan berasal dari dua organisasi: Yayasan Lancang Kuning **Samudra** (NPO berbasis pendidikan maritim) dan Pelindo Belawan (institusi publik sektor kepelabuhanan). Total observasi setelah proses penyaringan dan pembersihan adalah 1.284 data time-series bulanan untuk kedua organisasi selama periode 2019–2024.

Variabel prediktor mencakup empat kelompok utama:

- 1. Keuangan: cash ratio, operating margin, donor dependency (untuk NPO), revenue volatility.
- 2. Kinerja Operasional: project delay index, service efficiency, equipment readiness.
- 3. Human Capital: turnover rate, training investment, workload score.
- 4. ESG & Stakeholder: environmental compliance score, stakeholder complaint index, community engagement.

Variabel target didefinisikan sebagai tingkat risiko keberlanjutan (Low / Medium / High), ditentukan berdasarkan kombinasi penilaian internal organisasi dan indikator kinerja kuantitatif. Perbedaan karakteristik dua organisasi ini dapat dilihat pada tabel

Tabel Perbedaan Karakteristik Dua Organisasi

Variabel	Lancang Kuning Samudra	Pelindo Belawan
Rata – rata cash ratio	1,34	2,43
Turnover rate	9,5%	5,5%
Environmental compliance	76%	88%
Keluhan stakeholder	Tinggi	Rendah

Tabel Hasil Analisis Machine Learning

Model	AUC - ROC	Precision	Recall	F1-score
Logistic Regression	0,73	0,67	0,59	0,63
Random Forest	0,85	0,79	0,76	0,79
XGBoost (terbaik)	0,89	0,84	0,83	0,85

Tabel Risiko Keberlanjutan

Ranking	Variabel	Pengaruh Terhadap Risiko
1	Revenue Volatility	Meningkat → Risiko naik signifikan
2	Turnover rate	Meningkat → Risiko naik
3	Project delay index	Meningkat → risiko cepat naik
4	Cash ratio	Rendah → risiko naik
5	Stakeholder complaint index	Meningkat → risiko naik tinggi

Tabel Analisis Inferensial (Eksplanatori)

Variabel	Odds Ratio	p-value	Interpretasi
Turnover rate	1,45	0,003	Setiap kenaikan 1% turnover → risiko naik 45%
Revenue volatility	1,37	< 0,001	Instabilitas pendapatan signifikan meningkat risiko
Cash ratio	0,79	0,012	Cash ratio tinggi menurunkan risiko
Project delay index	1,29	0,009	Keterlambatan proyek meningkatkan risiko keberlanjutan

Temuan utama dalam penelitian ini adalah :

1. Turnover rate lebih berpengaruh pada yayasan lancang kuning Samudra menunjukkan ketergantungan yang lebih besar pada tenaga kerja inti
2. Project delay lebih kritis pada Pelindo Belawan, karena terkait kewajiban pelayanan publik

3. Stakeholder complaint berdampak lebih kuat di Pelindo Belawan karena langsung berkaitan dengan kepuasan pengguna jasa.

Pembahasan

Hasil penelitian menunjukkan bahwa machine learning khususnya algoritma XGBoost efektif digunakan sebagai early warning system. Kemampuannya mengolah data time – series dan menemukan pola non linear membuatnya mampu mendeteksi risiko sebelum terjadi.

Faktor yang paling mempengaruhi risiko keberlanjutan adalah :

1. Instabilitas pendapatan / Revenue volatility
Berperan besar terutama pada Yayasan, yang mengandalkan donasi dan program pendanaan
2. Turnover SDM
Tinggi di Yayasan membuat risiko operasional meningkat (kehilangan kompetensi inti)
3. Keterlambatan Proyek
Berkaitan langsung dengan kinerja layanan publik di Pelindo, menjadi fokus mitigasi risiko
4. Cash Ratio Rendah
Dua organisasi menunjukkan bahwa ketahanan kas penting sebagai buffer risiko
5. Keluhan Stakeholder
Menggambarkan tekanan eksternal dan reputasi, sangat relevan dalam konteks ESG

Perbedaan dinamika risiko antar organisasi yaitu Yayasan lebih sensitive pada faktor keuangan dan SDM, sedangkan Pelindo lebih sensitive pada faktor operasional dan stakeholder

KESIMPULAN, KETERBATASAN DAN SARAN

Kesimpulan

Berdasarkan hasil penelitian dan analisis data yang telah dilakukan, dapat disimpulkan bahwa:

1. *Machine learning* efektif sebagai alat deteksi dini risiko keberlanjutan
2. Faktor – faktor yang paling mempengaruhi risiko keberlanjutan di dua organisasi adalah revenue volatility, turnover rate, project delay index, cash ratio dan stakeholder complaint index
3. Pada Yayasan lancing kuning Samudra, risiko lebih dipengaruhi oleh faktor keuangan dan SDM seperti volatilitas pendapatan dan turnover
4. Pada Pelindo Belawan risiko lebih dipengaruhi oleh faktor operasional dan stakeholder seperti keterlambatan proyek dan keluhan pengguna jasa
5. Integrasi *machine learning* dengan analisis eksplanatori memberikan pemahaman yang lebih komprehensif.

Keterbatasan Penelitian

Penelitian ini memiliki beberapa keterbatasan, antara lain:

1. Keterbatasan ukuran sampel organisasi
2. Kualitas dan kelengkapan data historis berbeda antar organisasi
3. Model *machine learning* sensitive terhadap ketidakseimbangan data (class imbalance)
4. Pendekatan kuantitatif tidak menangkap konteks social dan kualitatif secara penuh

5. Periode waktu analisis terbatas

Saran

Bagi Pelaku UMKM

1. Melibatkan lebih banyak Yayasan, Lembaga Pendidikan, organisasi layanan publik atau BUMN akan meningkatkan generalisasi dan robustness model
2. Melakukan standardisasi system pencatatan keuangan, ESG dan SDM agar data antar organisasi lebih mudah diintegrasikan
3. Memperpanjang lperiode data dan memasukkan faktor eksternal untuk meningkatkan akurasi model dalam memprediksi risiko jangka panjang

DAFTAR PUSTAKA

- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32.
- Bryson, J. M., Crosby, B. C., & Bloomberg, L. (2014). Public value governance: Moving beyond traditional public administration and the New Public Management. *Public Administration Review*, 74(4), 445–456
- COSO. (2017). *Enterprise Risk Management — Integrating with Strategy and Performance*. Committee of Sponsoring Organizations of the Treadway Commission (COSO)
- Creswell, J. W., & Plano Clark, V. L. (2017). *Designing and Conducting Mixed Methods Research* (3rd ed.). Sage Publications.
- Doshi-Velez, F., & Kim, B. (2017). Towards a rigorous science of interpretable machine learning. *arXiv preprint arXiv:1702.08608*.
- Ebrahim, A., Battilana, J., & Mair, J. (2014). The governance of social enterprises: Mission drift and accountability challenges in hybrid organizations. *Research in the Sociology of Organizations*, 40, 1–27
- Eccles, R. G., Ioannou, I., & Serafeim, G. (2014). The impact of corporate sustainability on organizational processes and performance. *Management Science*, 60(11), 2835–2857.
- Frumkin, P. (2002). *On Being Nonprofit: A Conceptual and Policy Primer*. Harvard University Press
- Global Reporting Initiative (GRI). (2016). *GRI Standards*. GRI.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction* (2nd ed.). Springer.
- ISO. (2018). *ISO 31000:2018 — Risk management — Guidelines*. International Organization for Standardization
- Janssen, M., Charalabidis, Y., & Zuiderwijk, A. (2012). Benefits, adoption barriers and myths of open data and open government. *Information Systems Management*, 29(4), 258–268
- Kelleher, J. D., Mac Namee, B., & D’Arcy, A. (2015). *Fundamentals of Machine Learning for Predictive Data Analytics: Algorithms, Worked Examples, and Case Studies*. MIT Press.
- Mittelstadt, B. D., Allo, P., Taddeo, M., Wachter, S., & Floridi, L. (2016). The ethics of algorithms: Mapping the debate. *Big Data & Society*, 3(2).
- Molnar, C. (2020). *Interpretable Machine Learning: A Guide for Making Black Box Models Explainable*. (tersedia online).
- Reichstein, M., Camps-Valls, G., Stevens, B., et al. (2019). Deep learning

-
- and process understanding for data-driven Earth system science. *Nature*, 566, 195–204.
- United Nations Development Programme (UNDP). (2016). *Guidelines on Integrating Disaster Risk Reduction into Development Policies and Planning*. UNDP.
- Yin, R. K. (2018). *Case Study Research and Applications: Design and Methods* (6th ed.). Sage Publications
- World Bank. (2018). *Data for Development: An Evaluation of World Bank Support for Data and Statistical Systems*. World Bank Group.