

DECISION TREE

(POHON KEPUTUSAN)



RUDY C TARUMINGKENG

Oleh:

[Prof ir Rudy C Tarumingkeng, PhD](#)


Guru Besar Manajemen, NUP: 9903252922

© RUDYCT e-PRESS
rudyct75@gmail.com

Bogor, Indonesia

29 April 2025

Berikut infografik sederhana yang menggambarkan **struktur pohon keputusan (Decision Tree)** dengan komponen utama: Root Node, Internal Nodes, dan Leaf Nodes.



Decision Tree (Pohon Keputusan)

Decision Tree adalah suatu metode pembelajaran mesin (machine learning) dan alat bantu pengambilan keputusan yang memodelkan serangkaian pilihan biner atau multi-kategori secara hierarkis, menyerupai bentuk pohon, di mana setiap "cabang" mewakili suatu kondisi atau pertanyaan, dan setiap "daun" (leaf) mewakili hasil atau keputusan akhir. Di bidang manajemen, decision tree membantu manajer merumuskan dan mengevaluasi berbagai alternatif strategi atau tindakan berdasarkan kriteria yang relevan, sehingga meningkatkan transparansi dan struktur proses pengambilan keputusan.

1. Struktur dan Komponen Utama

1. Root Node

Titik awal pohon yang mewakili keseluruhan populasi data atau masalah yang hendak diputuskan.

2. Internal Nodes

Susunan pertanyaan atau kriteria yang memecah data menjadi subset berdasarkan jawaban (ya/tidak atau kategori tertentu).
Misalnya: "Apakah return on investment (ROI) > 10%?"

3. Branches

Jalur yang menghubungkan antara node dengan sub-node, menggambarkan alternatif jawaban atau kondisi.

4. Leaf Nodes

Hasil akhir setelah rangkaian keputusan—misalnya "Luncurkan Produk A," "Tunda Investasi," atau kategori segmentasi pelanggan.

Secara grafis, decision tree mempermudah pemahaman: cabang kiri biasanya mewakili jawaban "ya" atau kondisi terpenuhi, sedangkan cabang kanan mewakili "tidak" atau kondisi tidak terpenuhi.

2. Langkah-langkah Penyusunan Decision Tree

1. Identifikasi Masalah dan Tujuan

Tentukan dengan jelas keputusan apa yang perlu diambil—misalnya, memilih produk mana yang akan dipasarkan atau menentukan alokasi anggaran.

2. Definisikan Kriteria Keputusan

Pilih variabel yang relevan (misalnya biaya, risiko, waktu, profitabilitas) dan tentukan threshold atau kategori untuk masing-masing.

3. Kumpulkan dan Analisis Data

Data historis atau asumsi kuantitatif diperlukan untuk memperkirakan probabilitas dan nilai payoff setiap alternatif.

4. Bangun Pohon Keputusan

Mulai dari root node, pecahlah data berdasarkan kriteria yang paling informatif—umumnya menggunakan metrik seperti Information Gain atau Gini Index (dalam konteks machine learning).

5. Hitung Ekspektasi Nilai

Untuk setiap cabang, estimasi payoff (misalnya NPV, ROI, atau skor keefektifan), kalikan dengan probabilitasnya, lalu jumlahkan untuk mendapatkan ekspektasi nilai keputusan.

6. Pilih Jalur Optimal

Bandingkan ekspektasi nilai di tiap leaf node, dan pilih keputusan dengan nilai tertinggi atau yang paling sesuai dengan profil risiko organisasi.

3. Contoh Naratif Kasus: Peluncuran Produk Baru

Bayangkan **PT Inovasi Digital** hendak memutuskan apakah akan meluncurkan **Produk X**.

1. **Root:** Data pasar menunjukkan potensi pertumbuhan 15% per tahun, tetapi biaya pengembangan tinggi.
2. **Kriteria 1 (Internal Node):** "Apakah risiko teknis < 20%?"
 - **Ya:** lanjutkan ke kriteria berikutnya.
 - **Tidak:** arus keputusan → **Tunda R&D**.
3. **Kriteria 2:** "Apakah dana investasi tersedia > Rp 5 miliar?"
 - **Ya:** arus keputusan → **Luncurkan Produk X**.
 - **Tidak:** arus keputusan → **Cari Investor Eksternal**.

Rudy C Tarumingkeng: **Decision Tree (Pohon Keputusan)**

Dengan menambahkan probabilitas risiko teknis (misalnya 10% gagal) dan payoff finansial (misalnya NPV = Rp 10 miliar jika sukses, -Rp 2 miliar jika gagal), manajer dapat menghitung nilai ekspektasi:

$$EV = (0,9 \times 10) + (0,1 \times -2) = 8,8 \text{ miliar}$$

Karena EV positif, pohon mendukung peluncuran dengan memperhatikan mitigasi risiko teknis.

4. Kelebihan dan Keterbatasan

Kelebihan:

- **Visual dan Intuitif:** Mudah dipahami oleh pemangku kepentingan non-teknis.
- **Terstruktur:** Menyajikan proses keputusan secara sistematis.
- **Fleksibel:** Dapat diadaptasi untuk keputusan strategis, operasional, maupun klasifikasi pelanggan.
- **Integrasi Probabilitas dan Payoff:** Memungkinkan analisis risiko dan keuntungan secara kuantitatif.

Keterbatasan:

- **Overfitting** (dalam konteks machine learning): Pohon yang terlalu kompleks mencerminkan noise, bukan pola nyata.
- **Keputusan Biner Berlebihan:** Realitas seringkali bersifat kontinu dan multi-dimensi, tidak selalu cocok dipecah secara biner.

- **Ketergantungan Data:** Kualitas keputusan sangat bergantung pada akurasi probabilitas dan estimasi payoff.
 - **Bias pada Kriteria dengan Banyak Split:** Metrik seperti Information Gain lebih memilih variabel dengan banyak kategori.
-

5. Diskusi dan Pendapat

Dalam **praktik manajerial**, decision tree tak hanya sekadar alat analitis, tetapi juga **alat komunikasi** yang mempertemukan berbagai pemangku kepentingan—dari tim R&D, keuangan, hingga pemasaran—dalam satu frame berpikir yang sama. Misalnya, saat mempresentasikan *business case* kepada dewan komisaris, diagram pohon mempermudah pemahaman risiko dan imbal hasil, serta memperlihatkan titik-titik kritis (*critical nodes*) yang membutuhkan mitigasi.

Namun, manajer perlu waspada terhadap **asumsi-asumsi implisit** dalam setiap split: estimasi probabilitas kegagalan, skor payoff—jika keliru, keputusan bisa melenceng jauh. Oleh karena itu, sebaiknya decision tree dipadukan dengan **sensitivity analysis**, misalnya dengan memvariasikan nilai probabilitas $\pm 10\%$ untuk melihat stabilitas rekomendasi.

Lebih jauh lagi, dengan kemajuan **data analytics**, decision tree digital (algoritma CART, C4.5) bisa diintegrasikan dalam sistem BI (Business Intelligence) untuk secara otomatis memproses data besar (big data) dan memperbaharui model secara real-time. Hal ini memberi organisasi kemampuan adaptasi yang lebih cepat terhadap perubahan kondisi pasar.

6. Kesimpulan

Decision Tree adalah model keputusan yang sangat berguna dalam manajemen karena strukturnya yang terarah, memungkinkan integrasi kuantitatif antara probabilitas dan payoff, sekaligus memfasilitasi komunikasi dan kolaborasi antar-fungsi. Untuk hasil optimal, pemanfaatannya harus disertai verifikasi data, analisis sensitivitas, dan pemahaman atas keterbatasan metode. Integrasi dengan teknik analytics modern dapat meningkatkan akurasi dan ketepatan waktu pengambilan keputusan.

Referensi untuk pendalaman lebih lanjut:

- Phillips, L. D., & Bana e Costa, C. A. (2007). *Multicriteria Decision Analysis: State of the Art Surveys*. Springer.
- Breiman, L. et al. (1984). *Classification and Regression Trees*. Wadsworth International Group.
- Saaty, T. L. (1988). *Decision Making with the Analytic Hierarchy Process*. McGraw-Hill.

Semoga penjelasan ini memberikan gambaran komprehensif tentang Decision Tree, mulai dari konsep dasar hingga aplikasi dan diskusi kritis dalam konteks manajemen modern.

Memasuki lapisan yang lebih dalam, mari kita gali **Decision Tree** tidak hanya sebagai "diagram" keputusan, tetapi sebagai **kerangka berpikir** yang menggerakkan strategi organisasi secara dinamis. Akan dipaparkan secara naratif proses adopsi, imaji kasus nyata, serta refleksi kritis atas praktik dan inovasi terkini.

A. Kisah Naratif: PT Nusantara Mikrofinancing

1. Latar Belakang

PT Nusantara Mikrofinancing (NM) adalah lembaga multibank yang fokus pada pembiayaan usaha mikro di Jawa Barat. Pada 2023 mereka menghadapi tantangan **tingginya rasio kredit macet (NPL)** sebesar 8 %, padahal target industri di bawah 4 %. Dewan direksi memutuskan memanfaatkan **Decision Tree** untuk menyempurnakan proses persetujuan pinjaman.

2. Merumuskan Masalah

Ali, manajer risiko, bersama tim data-science, mendefinisikan:

- **Tujuan:** Meminimalkan NPL sambil tetap menjaga volume pinjaman.
- **Variabel Utama:**
 - Skor historis peminjam (riwayat cicilan)
 - Lama usaha (tahun beroperasi)
 - Skala bisnis (mikro vs kecil)
 - Lokasi usaha (perkotaan vs pedesaan)
 - Jaminan aset (ada/tidak)

3. Membangun Pohon Keputusan

1. **Root Node** - Semua aplikasi pinjaman (10.000 kasus historis).
2. **Split Pertama:** "Apakah *Skor Historis* ≥ 700 ?"
 - **Ya** → Layanan prioritas
 - **Tidak** → lanjut ke split berikutnya

3. **Split Kedua** (pada cabang "Tidak"): "Apakah *Lama Usaha* ≥ 3 tahun?"

- **Ya** → cabang A
- **Tidak** → cabang B

4. **Split Ketiga** (di cabang B): "Apakah *Jaminan Aset* ada?"

- **Ya** → cabang B1
- **Tidak** → cabang B2 (reject otomatis)

Setiap leaf node kemudian dievaluasi dengan **nilai harapan** (expected loss ratio). Dengan demikian, NM dapat menetapkan kebijakan:

- Cabang A (skor rendah tapi usaha mapan) → persetujuan bersyarat
- Cabang B1 (skor rendah & jaminan) → limit pinjaman lebih kecil
- Cabang B2 → reject

4. Hasil dan Dampak

Dalam enam bulan pertama:

- **NPL menurun** dari 8 % menjadi 4,5 %.
 - **Volume pinjaman** hanya turun 3 %, karena cabang "high-risk but collateralized" masih diberi akses terbatas.
 - **Proses keputusan** menjadi 60 % lebih cepat—karena aplikasi kelas B2 di-reject otomatis tanpa intervensi manual.
-

B. Diskusi Kritis dan Pendapat

1. Interpretabilitas vs. Kompleksitas

Decision Tree unggul dalam **transparansi**: setiap kriteria jelas tertulis. Namun, jika pohon tumbuh terlalu besar—memiliki

puluhan node—maka interpretasi menjadi rumit. Praktik terbaik:

- **Pruning** (pemangkasan) untuk mengeliminasi cabang berpengaruh kecil.
- **Cross-validation** untuk memastikan model tak “menghafal” data (overfitting).

2. Peran Manajer dalam “Memelihara” Model

Model decision tree bukanlah “dibangun sekali pakai.” Ia perlu:

- **Monitoring berkala** atas akurasi: seiring perubahan profil peminjam, threshold mungkin perlu disesuaikan.
- **Review assumptions**: misalnya, pergeseran ekonomi pedesaan pasca-pandemi dapat mengubah signifikansi variabel “lokasi.”

3. Integrasi dengan Kerangka Manajemen Risiko

Decision tree dapat diposisikan sebagai **layer 1** dalam *credit underwriting*.

- **Layer 2** dapat berupa **stress testing** skenario makro (misal: kenaikan suku bunga 200 bps).
- **Layer 3: portofolio review** agregat di tingkat cabang, untuk memetakan konsentrasi risiko.

4. Perbandingan dengan Metode Lain

- **Scorecard tradisional** (logistic regression) sering lebih stabil, tetapi memerlukan asumsi linearitas. Decision tree menyesuaikan diri pada **non-linear relationships** tanpa perlu transformasi variabel.
- **Ensemble methods** seperti **Random Forest** atau **Gradient Boosting** meningkatkan akurasi, tetapi mengorbankan **explainability**—sehingga untuk keputusan kritikal (regulasi OJK), interpretasi pohon tunggal sering dipilih.

5. Konteks Revolusi Industri 4.0

Dengan **Internet of Things (IoT)** dan **big data**, variabel keputusan dapat meluas ke:

- **Data transaksi real-time** (misal: arus kas harian digital).
- **Analisis sentimen** (feedback pelanggan atau reputasi digital usaha).

Decision tree dapat diperluas ke "streaming decision tree" yang **memperbarui** sendiri saat aliran data masuk.

6. Etika dan Governance

Penggunaan decision tree untuk otomatisasi keputusan kredit memiliki implikasi:

- **Bias data historis** (misal under-serve wilayah terpencil).
- **Kepatuhan terhadap prinsip fair lending**: pohon harus diaudit untuk memastikan tidak mengalami **disparate impact**.

C. Rekomendasi Praktis

1. Framework Adopsi

- **Kick-off Workshop**: Libatkan pemangku kepentingan (risiko, keuangan, operasional) untuk menetapkan variabel penting.
- **Prototyping**: Bangun pohon sederhana, uji pada subset data, kemudian iterasi.
- **Governance Process**: Bentuk komite review model untuk update tahunan.

2. Pengembangan Kapabilitas

- Latih tim manajer risiko untuk “membaca” pohon keputusan, agar mereka dapat mengidentifikasi **anomalies** atau **shift pattern** sejak dini.
- Gunakan **visualisasi interaktif** (dashboard BI) sehingga setiap level organisasi dapat memahami kriteria dan hasil akhir.

3. Sensitivitas dan Scenario Analysis

Sebelum implementasi penuh, jalankan simulasi:

- **Scenarios:** misal 20 % peningkatan gagal bayar.
- **Stress test:** NPL target 2 %—apa kombinasi kriteria yang bisa dipangkas atau dipertahankan?

Kesimpulan Naratif

Decision Tree, dalam praktik manajerial, bergerak melampaui “diagram” menjadi **instrument strategis**: menyelaraskan analisis kuantitatif dengan kebijakan perusahaan, memacu efisiensi proses, sekaligus tetap menjaga nilai transparansi bagi pemangku kepentingan. Namun, kekuatan ini datang bersama tanggung jawab—manajer harus aktif mengelola, memonitor, dan memastikan model tetap **adil, tepat, dan selaras** dengan tujuan jangka panjang organisasi.

Selain aspek-aspek yang telah dibahas, masih ada beberapa **dimensi lanjutan** dan **praktik terbaik** yang patut diperhatikan ketika menerapkan Decision Tree dalam konteks manajerial:

1. Varian Algoritma dan Pengaturan Hyperparameter

Di luar algoritma CART klasik, terdapat berbagai **varian decision tree** yang menawarkan keunggulan tertentu:

- **C4.5 / C5.0**: Memperkenalkan metode pembobotan cabang (pruning pasca-pemisahan) dan dukungan untuk atribut kontinu, sehingga pohon menjadi lebih ringkas dan tahan noise.
- **CHAID (Chi-square Automatic Interaction Detection)**: Cocok untuk variabel kategorikal, menggunakan uji chi-square untuk memilih split, berguna dalam analisis survey pelanggan atau demografi.

Hyperparameter tuning—seperti kedalaman maksimum (`max_depth`), jumlah sampel minimal di internal node (`min_samples_split`), atau minimal leaf node (`min_samples_leaf`)—sangat memengaruhi trade-off **bias-variance**.

- **Tree too deep** → low bias, high variance (overfitting).
- **Tree too shallow** → high bias, low variance (underfitting).

Praktik terbaik:

1. **Grid Search** atau **Random Search** pada hyperparameter melalui cross-validation,
 2. **Pruning** dengan memotong cabang yang kontribusi informasinya rendah,
 3. **Early stopping**—berhenti menumbuhkan pohon ketika perbaikan impurity di bawah threshold.
-

2. Cost-Sensitive Decision Tree untuk Data Imbalance

Dalam banyak kasus manajemen (misal deteksi penipuan, churn pelanggan, atau NPL microfinancing), data bersifat **imbalanced**: kejadian "positif" relatif jarang. Jika tak ditangani, decision tree bias pada kelas mayoritas.

Pendekatan:

- **Weighting**: Beri bobot lebih tinggi pada kelas minoritas dalam fungsi impurity (Information Gain, Gini).
- **Threshold Adjustment**: Alih-alih memutuskan berdasarkan probabilitas 0,5, sesuaikan decision threshold demi menyeimbangkan precision dan recall.
- **Hybrid dengan Oversampling/Undersampling** (SMOTE, Random Undersampling): Melengkapi data minoritas agar model melihat lebih banyak contoh.

Contoh Kasus HR:

Sebuah perusahaan e-commerce menggunakan decision tree untuk memprediksi risiko **turnover** karyawan. Karena hanya 10 % karyawan yang berhenti tiap tahun, mereka menimbang bobot lebih tinggi pada "resign" di proses split, sehingga kaburnya "suara mayoritas bertahan" dapat diminimalkan.

3. Penerapan Lintas Fungsi: Pemasaran dan Rantai Pasok

1. Pemasaran

- **Segmentasi Pelanggan**: Pohon memecah database pelanggan berdasarkan atribut demografi, nilai transaksi, dan frekuensi kunjungan → tiap leaf mewakili segmen (misal "VIP Ultra", "Occasional Buyer"), memudahkan strategi kampanye terpersonalisasi.

2. Rantai Pasok (Supply Chain)

- **Penentuan Safety Stock:** Variabel permintaan historis, lead time, dan service level disusun dalam pohon keputusan guna menetapkan level stok optimal per gudang, mengurangi stock-out maupun excess inventory.

Diskusi:

Keunggulannya adalah model visual memudahkan lintas departemen memahami logika segmentasi atau alokasi stok. Namun, tim supply chain harus berhati-hati: variabel permintaan di era e-commerce bersifat volatile, sehingga pohon perlu di-*retrain* berkala (misal kuartalan).

4. Integrasi dengan Framework Pengambilan Keputusan Lain

- **Analytic Hierarchy Process (AHP):** Decision tree dapat memanfaatkan bobot kriteria AHP sebagai threshold; misalnya jika skor prioritas Criteria A (berdasarkan AHP) kurang dari nilai tertentu, aplikasi mengambil jalur “tunda”.
- **Decision Model and Notation (DMN):** Standar industri untuk memodelkan keputusan bisnis—DMN dapat merepresentasikan pohon keputusan sebagai “decision table”, memudahkan integrasi dengan *business rule engine*.

Opini:

Integrasi AHP + Decision Tree memberi kekuatan **subjektifitas terstruktur** (bobot kriteria) plus **objektivitas data-driven**, menghasilkan keputusan yang lebih “dapat dipertanggungjawabkan.”

5. Tren dan Inovasi: Explainable AI & Hybrid Models

- **Explainable AI (XAI):** Seiring regulasi (contoh: aturan fair lending di sektor keuangan), organisasi menuntut transparansi. Model decision tree tunggal lebih mudah dijelaskan ketimbang **ensemble** (Random Forest, Gradient Boosting). Namun, teknik XAI (SHAP values, LIME) kini memungkinkan interpretasi feature importance pada model ensemble.
 - **Fuzzy Decision Tree:** Mengizinkan aturan "kabur" (fuzzy rules), cocok untuk kriteria manajerial yang sulit dikategorikan biner, misalnya "kinerja tim baik" diukur dengan indikator subjektif.
 - **Hybrid dengan Neural Networks:** Pohon keputusan dapat dipakai sebagai tahap awal pre-filtering data untuk jaringan saraf, mengurangi kompleksitas training dan meningkatkan interpretability.
-

6. Tantangan dan Rekomendasi Tambahan

1. Cognitive Bias Management

- Manajer yang "menebak-tebak" threshold mungkin terperangkap bias *anchoring*. Solusinya: gunakan data-driven split, bukan intuisi semata.

2. Governance & Audit

- Tetapkan **Audit Trail**: setiap perubahan hyperparameter, split baru, atau retraining harus terdokumentasi.

3. Pelatihan Sumber Daya Manusia

- Adakan **workshop "Decision Tree Mastery"** untuk mengasah kemampuan tim analitik dan manajerial dalam membaca, memodifikasi, dan mengkritisi pohon keputusan.

Dengan menambahkan dimensi teknis, lintas fungsi, dan inovasi terkini ini, decision tree akan semakin kokoh sebagai **alat bantu keputusan** dalam ekosistem manajemen modern—menyatukan data science, kebijakan organisasi, dan etika bisnis dalam satu kerangka yang komprehensif.

Glosarium

Berikut adalah **Glosarium** istilah-istilah kunci terkait **Decision Tree**:

Istilah	Definisi
Decision Tree	Model pengambilan keputusan berbentuk pohon yang memecah suatu masalah ke dalam serangkaian kriteria (node) hingga mencapai hasil akhir (leaf).
Root Node	Titik awal pohon keputusan yang mewakili seluruh populasi data atau masalah utama yang akan dianalisis.
Internal Node	Titik percabangan yang mewakili pertanyaan atau kriteria untuk memisahkan data ke dalam subset berdasarkan jawaban atau kategori.
Branch	Jalur yang menghubungkan node dengan sub-node, menunjukkan alur keputusan untuk setiap kondisi atau jawaban.
Leaf Node	Titik akhir pohon yang menunjukkan hasil keputusan atau klasifikasi setelah rangkaian kriteria terpenuhi.
Information Gain	Metrik yang mengukur pengurangan ketidakpastian (entropy) ketika data dipisah berdasarkan suatu atribut; digunakan untuk memilih split terbaik.
Gini Index	Ukuran impuritas yang menunjukkan probabilitas salah klasifikasi dalam subset

Istilah	Definisi
	data; alternatif umum selain Information Gain.
Pruning	Proses pemangkasan cabang pohon yang kontribusi informasinya rendah, bertujuan mengurangi kompleksitas dan mencegah overfitting.
Overfitting	Kondisi di mana model terlalu kompleks dan "menghafal" data latih sehingga gagal menggeneralisasi ke data baru.
Underfitting	Kondisi di mana model terlalu sederhana sehingga tidak mampu menangkap pola kunci dalam data, menghasilkan performa buruk pada data latih maupun tes.
Hyperparameter	Parameter eksternal (misal max_depth, min_samples_split) yang ditetapkan sebelum pelatihan untuk mengontrol ukuran dan kompleksitas pohon.
Cross-Validation	Teknik evaluasi model dengan membagi data menjadi beberapa lipatan (fold) untuk mengukur performa rata-rata dan menghindari bias pengukuran.
Ensemble Methods	Metode penggabungan beberapa model (misal Random Forest, Gradient Boosting) untuk meningkatkan akurasi prediksi dengan mengurangi varians.
Random Forest	Ensemble yang terdiri dari banyak pohon keputusan independen, hasilnya

Istilah	Definisi
	digabungkan (misal voting) untuk klasifikasi atau rata-rata untuk regresi.
Gradient Boosting	Teknik ensemble yang membangun pohon secara bertahap; setiap pohon baru memperbaiki kesalahan prediksi model sebelumnya.
SHAP (SHapley Additive exPlanations)	Metode XAI untuk mengukur kontribusi setiap fitur terhadap prediksi model, termasuk model ensemble, sehingga meningkatkan interpretabilitas.
LIME (Local Interpretable Model-agnostic Explanations)	Teknik XAI yang menjelaskan prediksi individual dengan membangun model lokal sederhana di sekitar titik data tertentu.
Fuzzy Decision Tree	Variant pohon keputusan yang menggunakan logika fuzzy untuk memisahkan atribut, cocok untuk kriteria yang tidak bersifat biner tegas (hard split).

Semoga glosarium ini membantu memperjelas istilah-istilah penting dalam penerapan dan diskusi Decision Tree.

Daftar Pustaka

Berikut **Daftar Pustaka Lengkap** dalam format APA yang mencakup rujukan buku, artikel, dan sumber daring terkait **Decision Tree** serta konsep-konsep pendukung yang dibahas:

1. Breiman, L., Friedman, J. H., Olshen, R. A., & Stone, C. J. (1984). *Classification and Regression Trees*. Wadsworth International Group.
2. Quinlan, J. R. (1993). *C4.5: Programs for Machine Learning*. Morgan Kaufmann.
3. Kass, G. V. (1980). An exploratory technique for investigating large quantities of categorical data. *Applied Statistics*, 29(2), 119-127.
4. Han, J., Kamber, M., & Pei, J. (2011). *Data Mining: Concepts and Techniques* (3rd ed.). Morgan Kaufmann.
5. Phillips, L. D., & Bana e Costa, C. A. (2007). *Multicriteria Decision Analysis: State of the Art Surveys*. Springer.
6. Saaty, T. L. (1988). *Decision Making with the Analytic Hierarchy Process*. McGraw-Hill.
7. Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *Annals of Statistics*, 29(5), 1189-1232.
8. Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5-32.
9. Lundberg, S. M., & Lee, S.-I. (2017). A unified approach to interpreting model predictions. In *Advances in Neural Information Processing Systems* (Vol. 30).

10. Ribeiro, M. T., Singh, S., & Guestrin, C. (2016, August). "Why Should I Trust You?" Explaining the Predictions of Any Classifier. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*.
 11. Molnar, C. (2020). *Interpretable Machine Learning*. Retrieved April 29, 2025, from <https://christophm.github.io/interpretable-ml-book/>
 12. Object Management Group. (2018). *Decision Model and Notation (DMN) Version 1.3*. Retrieved from <https://www.omg.org/spec/DMN/1.3>
 13. 12manage. (n.d.). *Decision Tree*. Retrieved April 29, 2025, from https://www.12manage.com/description_decision_tree.html
 14. Lantz, B. (2015). *Machine Learning with R: Expert Techniques for Predictive Modeling*. Packt Publishing.
 15. Han, J., Pei, J., & Kamber, M. (2012). *Data Mining: Concepts and Techniques* (3rd ed.). Morgan Kaufmann.
 16. ChatGPT o4-mini (2025). Kopilot Artikel ini. Tanggal akses: 29 April 2025. Akun dan prompt penulis (Rudy C Tarumingkeng). <https://chatgpt.com/c/68104135-cfbc-8013-9717-0531e7025d6e>
-