

IMPLEMENTASI *LEARNING ANALYTICS* DENGAN MENGGUNAKAN *ARTIFICIAL INTELLIGENCE* UNTUK EFEKTIVITAS PELATIHAN YANG BERDAMPAK

Eko Haryanto

Pusat Pengembangan Sumber Daya Manusia Meteorologi Klimatologi dan Geofisika

Informasi Artikel

Sejarah Artikel:

Accepted Mei 30, 2025

Kata Kunci :

Learning Analytics, Kecerdasan Buatan, Efektivitas Pelatihan, Riset Sains Desain

ABSTRAK

Pusat Pengembangan Sumber Daya Manusia (PPSDM) MKG menghadapi tantangan besar dalam menjamin efektivitas pelatihan bagi 2.581 pegawai di tengah dinamika operasional MKG yang kompleks. Evaluasi konvensional sering gagal memprediksi dampak kinerja secara real-time karena bersifat administratif. Penelitian ini bertujuan merancang implementasi *Learning Analytics* (LA) berbasis *Artificial Intelligence* (AI) guna meningkatkan kualitas evaluasi pelatihan yang berdampak. Metode yang digunakan adalah *Design Science Research* (DSR) dengan memanfaatkan data historis pelatihan teknis MKG periode 2017-2021 (10.245 entri) sebagai basis pemodelan dan data 2022-2024 sebagai uji implementasi. Hasil analisis menunjukkan algoritma *Random Forest* mencapai akurasi tertinggi 87,76% dengan skor AUC 0,94 dalam mengidentifikasi peserta berisiko. Implementasi fitur *Early Warning System* pada *dashboard* terbukti menurunkan tingkat kegagalan pelatihan secara drastis dari 8,1% menjadi 1,44%. Studi ini menyimpulkan bahwa integrasi LA berbasis AI mampu menyelaraskan kompetensi teknis dengan capaian Indikator Kinerja Utama (IKU) organisasi, khususnya dalam menjaga akurasi peringatan dini bencana di bawah tiga menit dalam bidang meteorologi, klimatologi, dan geofisika. Transformasi manajemen pelatihan berbasis data ini diharap menjadi fondasi penting bagi terwujudnya Smart ASN BMKG yang profesional.

This is an open access article under the [CC BY-SA](#) license.



Penulis Koresponden

Eko Haryanto, S.Si., M.Si.,

Pusat Pengembangan Sumber Daya Manusia Meteorologi, Klimatologi, dan Geofisika, BMKG, Indonesia
Jl. Perhubungan I No.5 Pondok Betung, Bintaro, Kec. Pd. Aren, Kota Tangerang Selatan, Banten 15221.

Email: eko.haryanto@bmkg.go.id

1. PENDAHULUAN

Dinamika lingkungan strategis global yang berciri *volatility*, *uncertainty*, *complexity*, dan *ambiguity* (VUCA) menuntut Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) untuk memiliki sumber daya manusia (SDM) yang tangkas. Berdasarkan data tahun 2024, terdapat 2.581 pegawai BMKG yang mengikuti pengembangan kompetensi yang diselenggarakan BMKG. Namun, pengelolaan SDM di BMKG saat ini masih menghadapi tantangan di mana peran manajemen sering kali terbatas pada tugas administratif dan bersifat parsial.

Pelatihan teknis bagi Aparatur Sipil Negara (ASN) di bidang meteorologi, klimatologi, dan geofisika maupun tenaga teknis di berbagai sektor MKG merupakan aspek penting dalam meningkatkan kompetensi dan kualitas sumber daya manusia di BMKG yang mendukung pembangunan nasional terlebih untuk pegawai di Badan Meteorologi, Klimatologi, dan Geofisika. Dalam era digital dan revolusi industri 4.0, kebutuhan akan pelatihan yang efektif, efisien, dan adaptif

semakin mendesak untuk menjawab tantangan kompleksitas pekerjaan dan perubahan teknologi yang cepat [1]. Namun, efektivitas pelatihan ini seringkali menghadapi tantangan dalam pengukuran hasil yang objektif dan personalisasi pembelajaran sesuai kebutuhan individu dan organisasi [2]. Pengukuran efektivitas pelatihan seringkali terbatas pada evaluasi pasca-pelatihan yang bersifat umum dan tidak memberikan gambaran mendalam tentang proses belajar peserta [3, 4, 5, 6].

Learning Analytics (LA) muncul sebagai salah satu solusi potensial untuk meningkatkan kualitas pelatihan online. *Learning Analytics* (LA) merupakan proses pengukuran, pengumpulan, analisis, dan pelaporan data pembelajaran yang bertujuan untuk memahami dan meningkatkan pengalaman belajar [7, 8, 9, 10]. Dengan memanfaatkan data pelatihan MKG tentang aktivitas peserta, prestasi, dan pola belajar, para pengampu materi dapat merancang pembelajaran yang lebih sesuai dengan kebutuhan peserta. Penggunaan *Learning Analytics* (LA) diharapkan dapat membantu Widyaiswara dan pengajar teknis untuk melakukan intervensi yang tepat waktu untuk meningkatkan keterlibatan serta hasil belajar peserta.

Learning Analytics (LA) muncul sebagai pendekatan inovatif yang memanfaatkan data interaksi data untuk mengumpulkan, menganalisis, dan menginterpretasi informasi yang relevan guna meningkatkan kualitas pembelajaran. Dengan dukungan teknologi *Artificial Intelligence* (AI), proses pengolahan data menjadi lebih canggih, memungkinkan identifikasi pola belajar individu, tingkat keterlibatan peserta, serta prediksi pencapaian kompetensi secara akurat dan personal [11, 12, 13].

Di sisi lain, *Artificial Intelligence* (AI) menawarkan kemampuan analisis yang mendalam dan pengolahan data yang cepat. *Artificial Intelligence* (AI) dapat membantu dalam mengevaluasi sejumlah besar data untuk mengidentifikasi pola dan tren yang mungkin tidak terlihat oleh manusia [14, 15]. Dalam konteks pelatihan, *Artificial Intelligence* (AI) dapat digunakan untuk memberikan rekomendasi belajar yang lebih personal dan membantu peserta dalam proses pembelajaran mereka. Dengan menggabungkan *Learning Analytics* (LA) dan *Artificial Intelligence* (AI), pelatihan teknis online dapat menjadi lebih adaptif dan responsif terhadap kebutuhan peserta, sehingga memperbaiki hasil pembelajaran secara keseluruhan, sistematis dan real-time, memperkuat kemampuan analisis dengan prediksi dan rekomendasi yang adaptif, serta personalisasi pembelajaran [15, 16, 17, 18, 19].

Berbagai penelitian dan studi terkini mendukung pentingnya integrasi *learning analytics* dan AI dalam pelatihan teknis, khususnya di sektor publik. Misalnya, Anwar Rashed dan Ali Abdullah Alazmi [2] menekankan peran AI dalam meningkatkan kualitas pelatihan melalui metode pembelajaran adaptif dan peningkatan keterlibatan peserta, Mutlu Cukurova [20] menguraikan visi *hybrid intelligence* yang menggabungkan *learning analytics* dan AI untuk menciptakan pengalaman belajar yang lebih efektif dan personal. Selain itu, Wong B [21] dan Ramaswami G [16] memberikan kerangka kerja evaluasi efektivitas pelatihan yang mengintegrasikan data analitik untuk mengukur dampak pelatihan secara komprehensif. Dengan demikian, tulisan ini akan membahas secara mendalam konsep, metodologi, dan hasil implementasi *learning analytics* dengan AI dalam pelatihan teknis MKG, serta implikasi praktis dan strategisnya bagi pengembangan sumber daya manusia di sektor MKG. Implementasi *Learning Analytics* (LA) berbasis AI menawarkan solusi untuk mentransformasi jejak digital peserta di LMS menjadi wawasan pengetahuan prediktif. Penelitian ini menggunakan data historis 2017-2021 sebagai landasan awal dan mengevaluasi efektivitasnya pada periode implementasi 2022-2024.

2. METODE

2.1. Taxonomi *Learning Analytics* (LA) dan *Artificial Intelligence* (AI)

Pengembangan kompetensi di era digital memerlukan pemahaman terhadap kontinum analitik pembelajaran yang terdiri dari empat level utama [22, 23, 24, 25, 26, 27] meliputi: (1) analitik deskriptif menjelaskan apa yang terjadi (misal: jumlah *login*, penyelesaian modul); (2) analitik diagnostik menganalisis mengapa suatu fenomena terjadi (misal: pola kegagalan pada modul tertentu); (3) analitik prediktif menggunakan model statistik untuk meramalkan hasil belajar di masa depan; dan (4) analitik preskriptif merekomendasikan tindakan yang harus diambil untuk mencapai hasil optimal.

Integrasi AI ke dalam taksonomi LA memungkinkan terciptanya sistem yang tidak hanya melaporkan kejadian pasif, tetapi juga melakukan pemodelan komputasi untuk mensimulasikan

dinamika sistem pembelajaran [28, 29, 30]. Pendekatan ini memungkinkan AI untuk mengidentifikasi hubungan tersembunyi dalam perilaku peserta melalui pengenalan pola yang mendalam, sehingga dapat menyarankan sumber daya pembelajaran yang dipersonalisasi sesuai profil unik setiap individu. Dengan demikian, pelatihan klasikal yang bersifat "satu ukuran untuk semua" (*one-size-fits-all*) mulai bergeser ke arah pembelajaran adaptif yang lebih responsif terhadap kebutuhan kompetensi spesifik pegawai.

Lebih jauh lagi, perkembangan *Large Language Models* (LLMs) dalam ekosistem AI pendidikan telah memperluas kapabilitas analitik preskriptif melalui otomasi umpan balik yang lebih kontekstual dan empatik [31, 32]. AI kini mampu memberikan penjelasan transparan (*Explainable AI*) mengenai alasan di balik sebuah prediksi risiko kegagalan, sehingga pengelola pelatihan dapat memahami faktor penyebab secara mendalam sebelum melakukan intervensi. Sinergi antara model prediktif yang akurat dan asisten tutor otomatis ini memastikan bahwa setiap tahapan dalam siklus pembelajaran digital di BMKG mendapatkan dukungan yang tepat waktu dan berbasis bukti nyata.

2.2. Algoritma Machine Learning dalam Pendidikan dan Pelatihan

Penelitian pada platform Learning Management System (LMS) *Moodle* menunjukkan algoritma ensemble learning memiliki performa superior dalam data perilaku pembelajar yang kompleks. Algoritma *Random Forest* (RF), yang dikembangkan oleh Leo Breiman [33], bekerja dengan membangun sekumpulan pohon keputusan (*decision trees*) *decorrelated*. Keunggulan *Random Forest* terletak pada kemampuannya melakukan *bagging* (*bootstrap aggregating*) dan *feature randomness* untuk meminimalkan varians pada data multivariat log LMS yang seringkali berisik (*noisy data*). Selain itu, *XGBoost* dan *CatBoost* juga terbukti efektif dalam menangani dataset kategorikal dan meminimalisir kesalahan klasifikasi pada peserta berisiko gagal (*at-risk students*)

2.3. Metode Design Science Research (DSR)

Penelitian ini menggunakan metodologi *Design Science Research* (DSR) yang berorientasi pada penciptaan artefak teknologi untuk memecahkan masalah praktis organisasi. Penelitian ini mengadopsi metodologi *Design Science Research* (DSR) [34, 35, 36, 37] melalui enam tahapan : (1) identifikasi masalah, menganalisis rendahnya intervensi pada peserta akibat beban kerja (*work pressure*); (2) tujuan solusi, menetapkan target akurasi prediksi risiko kegagalan $\geq 85\%$; (3) desain dan pengembangan, membangun plugin LA pada LMS *Moodle* BMKG dengan integrasi mesin Python; (4) demonstrasi, uji coba pada data 2.581 peserta pelatihan teknis tahun 2024; dan (5) evaluasi, validasi statistik model menggunakan matriks teknis dan korelasi IKU.

2.4. Integrasi Model Kirkpatrick dengan Artificial Intelligence (AI)

Evaluasi pelatihan berdampak tinggi menuntut pengukuran yang melampaui level reaksi. Dengan dukungan AI, Model Kirkpatrick bertransformasi menjadi sistem evaluasi dinamis : (a) Level 1 (*Reaction*) menggunakan *Natural Language Processing* (NLP) untuk menganalisis sentimen ribuan postingan forum diskusi secara otomatis [38]; (b) Level 2 (*Learning*) penggunaan *predictive scoring* untuk memproyeksikan penguasaan kompetensi sebelum ujian akhir; (c) Level 3 (*Behavior*): pemantauan pola aktivitas digital sebagai proksi perubahan perilaku kerja pasca-pelatihan, dan (d) Level 4 (*Results*) korelasi statistik antara profil kelulusan digital dengan capaian IKU teknis BMKG.

2.5. Deskripsi Data dan Variabel Analisis

Variabel input diekstraksi dari basis data log LMS *Moodle* BMKG untuk periode tahun 2017-2024. Dimana dataset Pelatihan (2017-2021) digunakan sebagai data historis 10.245 entri digunakan untuk melatih model (*training phase*) dan dataset implementasi (2022-2024) data riil dari pelatihan operasional digunakan untuk pengujian dan validasi dampak (*testing phase*). Proses rekayasa fitur (*feature engineering*) berfokus pada ekstraksi variabel keterlibatan yang mencakup dimensi frekuensi, temporal, dan performa awal, seperti *Total_Duration* yang menghitung akumulasi aktivitas aktif dalam satuan detik, serta *Freq_Course_View* yang merepresentasikan intensitas paparan peserta terhadap materi teknis meteorologi. Integrasi data ini sangat penting mengingat variabilitas pola akses pegawai di stasiun daerah yang tersebar di tiga zona waktu berbeda, sehingga fitur *Active_Days* dan *Session_Count* digunakan untuk memitigasi bias aktivitas yang terjadi pasca-shift kerja operasional.

Pada tahap pra-pemrosesan data, dilakukan standardisasi menggunakan teknik *Z-score normalization* untuk menyeimbangkan skala antara fitur yang memiliki variansi tinggi, seperti

jumlah klik log, dengan fitur yang memiliki rentang terbatas seperti skor kuis formatif. Selain itu, variabel nominal diolah melalui metode *Label Encoding* guna mentransformasi kategori jabatan dan unit kerja menjadi nilai numerik yang dapat diproses oleh mesin algoritma tanpa menghilangkan bobot signifikansi kontekstualnya. Variabel target (*Achievement*) ditetapkan sebagai variabel biner melalui ambang batas (*threshold*) nilai akhir ≥ 70.1 untuk kategori 'Success' (1) dan < 70.1 untuk kategori 'At-Risk' (0), yang diselaraskan dengan standar kelulusan pelatihan teknis BMKG guna menjamin validitas prediksi terhadap kesiapan operasional SDM di lapangan.

Tabel 1. Definisi Operasional Variabel Indikator Keterlibatan (Engagement Indicators)			
Kode Variabel	Deskripsi Operasional		Cara Penghitungan
<i>Total_Duration</i>	Akumulasi waktu belajar aktif		Jumlah detik antara log masuk dan aktivitas terakhir dalam satu sesi
<i>Quiz_Avg_Score</i>	Akurasi pemahaman materi		Rata-rata skor kuis formatif pada 50% awal durasi pelatihan
<i>Session_Count</i>	Intensitas kehadiran digital		Jumlah total sesi masuk-keluar (<i>login-logout</i>) selama periode pelatihan
<i>Freq_Forum_Post</i>	Partisipasi diskusi aktif		Jumlah postingan baru dan balasan yang dibuat di forum LMS
<i>Freq_Course_View</i>	Paparan materi terhadap		Frekuensi total klik <i>log</i> pada halaman modul kursus spesifik

Variabel Target (*achievement*): klasifikasi biner (lulus/gagal) berdasarkan ambang batas kelulusan ≥ 70.1 dan 0 (*at-risk*) jika skor akhir < 70.1 .

2.6. Rekayasa Fitur dan Analisis Statistik

Data mentah diproses melalui teknik normalisasi sebelum pemodelan guna memastikan keseragaman skala antar fitur :

1. *Z-Score Normalization (Standardization)*:

$$X' = \frac{x - \mu}{\sigma}$$

Dimana μ adalah rata-rata fitur dan σ adalah standar deviasi fitur dalam populasi pembelajar BMKG.

2. *Gini Impurity (Split Criterion Random Forest)*

$$Gini = 1 - \sum_{i=1}^c (p_i)^2$$

Dimana p_i mewakili probabilitas klasifikasi kelulusan pada node tertentu.

Keandalan model dievaluasi secara statistik menggunakan matriks dari *confusion matrix*:

1. Akurasi : rasio prediksi benar terhadap total data.

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN}$$

2. *Recall (sensitivity)* : kemampuan model menangkap seluruh peserta yang benar-benar berisiko gagal

$$Recall = \frac{TP}{TP + FN}$$

3. *F1-Score* : rata-rata harmonik *presisi* dan *recall*, ini penting untuk dataset yang tidak seimbang (*imbalanced*)

Dimana:

- *True Positive (TP)*: Jumlah peserta yang benar diprediksi berisiko gagal (*At-Risk*) dan pada kenyataannya memang gagal.

- *True Negative* (TN): Jumlah peserta yang benar diprediksi berhasil/lulus dan pada kenyataannya memang lulus.
- *False Positive* (FP): Disebut juga "False Alarm"; jumlah peserta yang diprediksi berisiko gagal padahal kenyataannya lulus.
- *False Negative* (FN): Disebut juga "Missed Case"; jumlah peserta yang diprediksi akan lulus padahal kenyataannya berisiko gagal atau gagal.

3. HASIL DAN PEMBAHASAN

3.1. Performa Algoritma *Artificial Intelligence* (AI) dalam *Learning Analytics* (LA)

Analisis komparatif dilakukan terhadap empat algoritma utama untuk menentukan model yang paling presisi dalam mengidentifikasi hambatan belajar ASN BMKG. Dataset hibrid meliputi 10.245 entri historis dan 2.581 data uji/*training* digunakan untuk menjamin stabilitas prediksi.

Tabel 2. Komparasi Kinerja Algoritma Prediksi Risiko Kegagalan Pelatihan

Algoritma	Akurasi (%)	Presisi	Recall	AUC Score	F1-Score
<i>Random Forest</i>	87,76	0,85	0,81	0,94	0,83
<i>XGBoost</i>	86,50	0,83	0,79	0,92	0,81
<i>CatBoost</i>	86,90	0,84	0,80	0,93	0,82
<i>Logistic Regression</i>	76,00	0,72	0,70	0,82	0,71

Hasil analisis statistik pada Tabel 2 mengonfirmasi superioritas algoritma *Random Forest* (RF) sebagai model paling andal untuk platform LMS BMKG. Dengan nilai akurasi mencapai 87,76% pada dataset hibrid, *Random Forest* membuktikan kemampuannya mengungguli model klasifikasi lainnya dalam mengidentifikasi pola perilaku belajar ASN yang kompleks. Keunggulan ini berakar pada mekanisme *ensemble learning* yang menggunakan teknik *bagging* (*bootstrap aggregating*), di mana algoritma membangun ribuan pohon keputusan decorrelated untuk kemudian mengambil suara mayoritas (*majority vote*) dalam prediksi akhir. Pendekatan ini secara efektif mereduksi varians pada data multivariat log Moodle yang cenderung memiliki tingkat "kebisingan" (*noise*) tinggi akibat perbedaan durasi akses antar wilayah waktu di Indonesia.

Perbandingan dengan *Logistic Regression* sebagai model dasar (*baseline*) memberikan wawasan krusial mengenai karakteristik data pembelajar BMKG. *Logistic Regression* hanya mampu mencapai akurasi 76%, yang mengindikasikan adanya hubungan non-linear yang kuat antara variabel perilaku belajar, seperti kaitan antara waktu login larut malam dengan konsistensi pengerjaan tugas yang tidak dapat ditangkap oleh fungsi *sigmoid linear* sederhana. Sebaliknya, model berbasis pohon seperti RF dan *XGBoost* mampu memetakan interaksi variabel yang rumit tersebut secara rekursif. Temuan ini menegaskan bahwa perilaku belajar digital ASN BMKG bersifat stokastik dan memerlukan pendekatan analitik tingkat lanjut untuk menghasilkan prediksi yang benar-benar bermakna.

Penajaman matriks pada skor AUC (Area Under the Curve) 0,94 menunjukkan bahwa RF memiliki "daya pembeda" (*discriminative power*) yang dikategorikan sebagai "Sangat Luar Biasa". Dalam konteks operasional PPSDM, nilai AUC yang mendekati sempurna ini menjamin bahwa sistem *dashboard* hampir selalu dapat membedakan dengan benar antara peserta yang berpotensi menjadi *Excellence Performer* dan mereka yang benar-benar membutuhkan pendampingan khusus. Hal ini memberikan keyakinan tinggi bagi Analisis Pengembangan Kompetensi untuk mempercayai rekomendasi intervensi sistem, sehingga alokasi sumber daya bimbingan teknis dapat difokuskan secara presisi pada kelompok peserta yang paling rentan gagal.

Analisis terhadap matriks *Recall* (*Sensitivity*) sebesar 0,81 memiliki implikasi strategis terhadap mitigasi risiko operasional lembaga. Bagi BMKG, meminimalkan *False Negative* (FN) atau kondisi di mana peserta diprediksi akan sukses padahal sebenarnya memiliki celah pemahaman yang kritis adalah prioritas keamanan utama. Pada pelatihan kritical seperti operator sistem peringatan dini gempabumi (InaEEWS), kegagalan mendeteksi personil yang belum kompeten dapat berakibat pada keterlambatan diseminasi informasi bencana. Matriks Recall yang tinggi menjamin bahwa 81% dari seluruh potensi kegagalan dapat "ditangkap" oleh sistem sejak minggu kedua, memungkinkan dilakukannya langkah penyelamatan kompetensi sebelum pelatihan berakhir.

Keunggulan RF juga diperkuat oleh analisis *Feature Importance (Mean Decrease Gini)* yang menyertai model tersebut. Data menunjukkan bahwa variabel *Quiz_Avg_Score* (skor kuis awal) dan *Total_Duration* (akumulasi waktu belajar) menyumbang kontribusi gabungan sebesar 48% terhadap akurasi prediksi kelulusan. Temuan ini memberikan dasar empiris bagi Widyaiswara untuk tidak hanya memantau partisipasi, tetapi juga memberikan perhatian ekstra pada kualitas pemahaman awal peserta. Jika seorang peserta menunjukkan skor kuis formatif rendah di paruh pertama pelatihan, AI secara otomatis memberikan bobot risiko yang lebih tinggi, memicu protokol "Waspada" pada sistem EWS dashboard.

Meskipun algoritma *boosting* seperti *CatBoost* dan *XGBoost* menunjukkan performa yang kompetitif (masing-masing 86,90% dan 86,50%), algoritma RF tetap dipilih karena stabilitasnya terhadap ketidakseimbangan data (class imbalance). Pada dataset PPSDM MKG di mana jumlah peserta lulus jauh lebih besar daripada peserta gagal, algoritma *boosting* cenderung lebih sensitif terhadap pencilan (*outliers*) yang dapat meningkatkan risiko kesalahan *False Positive*. Dengan memilih RF yang memiliki keseimbangan antara metrik Presisi dan Recall (F1-Score 0,83), PPSDM MKG memperoleh model yang tidak hanya akurat secara statistik, tetapi juga "adil" (fair classification) dalam mengevaluasi profil kompetensi digital seluruh ASN di berbagai unit kerja.

3.2. Analisis Visualisasi *Dashboard Learning Analytics*: Status Risiko "Traffic Light System" (EWS)

Dashboard yang dirancang untuk menyederhanakan data kompleks menjadi tindakan nyata (*actionable insights*) bagi Analisis Pengembangan Kompetensi dan Widyaiswara. *Dashboard Learning Analytics* (LA) dirancang sebagai instrumen orkestrasi instruksional berbasis data [39][40]. Salah satu fitur paling penting adalah *Traffic Light System* yang mengotomatisasi klasifikasi risiko individu berdasarkan probabilitas kelulusan (P) yang dihasilkan oleh model *Random Forest* secara real-time.

3.2.1. Heatmap Keterlibatan Temporal (*Engagement Heatmap*)

Hal ini untuk memetakan densitas aktivitas 2.581 peserta pada sumbu waktu (jam vs hari). Analisis pola pada data 2022-2024 menunjukkan konsentrasi aktivitas tertinggi pada pukul 19.00 - 22.00 WIB. Detail Analitik menunjukkan bahwa pada malam hari mengonfirmasi bahwa pegawai operasional di stasiun daerah cenderung melakukan pembelajaran mandiri pasca-shift kerja (*asynchronous*). Sehingga implikasi strategis yang bisa digunakan oleh PPSDM MKG adalah melakukan penyesuaian jadwal sesi *Live Chat* teknis atau bimbingan sinkronus ke jendela waktu tersebut guna menjamin ketersediaan dukungan Widyaiswara saat peserta paling aktif. Di samping itu PPSDM MKG juga merekomendasikan penjadwalan sesi diskusi sinkronus yang adaptif pada jendela waktu tersebut guna memaksimalkan interaksi mentor-mentee.

Tabel 3. Matriks Intervensi Berdasarkan Klasifikasi Risiko *Dashboard*

Indikator Visual	Probabilitas (P)	Interpretasi Kinerja	Tindakan Operasional AI & Manusia
Merah (Berisiko)	- $P < 0,50$	Keterlibatan rendah, skor kuis kritis	Email personal otomatis, <i>alert</i> ke widyaiswara bimbingan khusus
Kuning (Waspada)	- $0,50 \leq P \leq 0,80$	Progres melambat, risiko tertinggal	Notifikasi "Pacing Cues" (peringat tenggat) pada aplikasi LMS
Hijau (Aman)	- $P > 0,80$	Partisipasi aktif, progres konsisten	Pemberian <i>Digital Badge</i> motivasi secara otomatis

3.2.2. Probabilistik dan Klasifikasi Risiko

Model *Random Forest* mengekstraksi nilai probabilitas P dari 0 hingga 1 untuk setiap peserta berdasarkan fitur keterlibatan mingguan. Berdasarkan kalibrasi pada dataset historis 2017-2021, ditetapkan tiga ambang batas (*threshold*) intervensi yang divisualisasikan melalui sistem lampu lalu lintas:

1. Zona Merah (Risiko Tinggi: $P < 0,50$)

Peserta pada zona ini diidentifikasi memiliki pola perilaku yang sangat mirip dengan profil peserta yang gagal di masa lalu, ditandai dengan durasi belajar rendah ($< 30\%$) dan skor kuis formatif di bawah ambang batas kritis. *Dashboard* memberikan peringatan (*alert*) prioritas tinggi kepada widyaiswara.

2. Zona Kuning (Waspada: $0,50 \leq P \leq 0,80$)

Zona ini mencakup peserta yang memiliki potensi lulus namun menunjukkan gejala ketidakteraturan (*irregularity*) atau penurunan kecepatan akuisisi keterampilan (*skill acquisition speed*). Peserta ini belum kritis, namun membutuhkan dorongan ekstra untuk tetap berada pada jalur penyelesaian kompetensi.

3. Zona Hijau (Aman: $P > 0,80$)

Peserta menunjukkan konsistensi tinggi dalam akses materi dan interaksi forum, dengan probabilitas kelulusan yang stabil di atas rata-rata populasi pembelajar BMKG.

3.2.3 Mekanisme Intervensi Berbasis Artificial Intelligence (Prescriptive Actions)

Kecanggihan *dashboard* ini terletak pada kemampuannya mengonversi status visual menjadi tindakan preskriptif yang dipersonalisasi:

a. Intervensi Otomatis (Zona Kuning): Sistem secara mandiri mengirimkan notifikasi "Pacing Cues" atau pengingat modul yang belum diselesaikan melalui aplikasi pesan terintegrasi. Hal ini bertujuan untuk memperkuat regulasi diri (*self-regulation*) peserta tanpa membebani sumber daya manusia pengelola pelatihan.

b. Intervensi *Human-in-the-Loop* (Zona Merah): *Dashboard* memicu bimbingan personal (*one-on-one*) wajib antara Widyaiswara dan peserta. Analisis Pengembangan Kompetensi menggunakan data diagnosa *dashboard* (misal: "Hambatan pada Modul Dinamika Atmosfer") untuk memberikan tutorial tambahan yang spesifik. Hasil implementasi 2022-2024 menunjukkan bahwa kombinasi komunikasi manusia dan AI jauh lebih efektif daripada intervensi AI secara murni dalam mempertahankan motivasi peserta di unit kerja terpencil.

3.3. Dampak Pelatihan terhadap IKU Organisasi (Level 4 Kirkpatrick)

Integrasi data *Learning Analytics* (LA) dengan Laporan Kinerja (LAKIP) BMKG 2024 membuktikan korelasi positif antara kesiapan teknis SDM yang dipantau *Artificial Intelligence* dengan kualitas layanan keselamatan publik.

Tabel 4. Matriks Dampak Pelatihan Berbasis AI terhadap Kinerja Strategis BMKG

Metrik Dampak	Baseline (2017-2021)	Implementasi (2024)	Perubahan	Relevansi IKU BMKG
Tingkat kegagalan peserta	8,1%	1,44%	-82,2%	Efisiensi Anggaran Pengembangan
Info gempa < 3 menit	Standar	98,5%	Terjamin	Kesiapan Operasional InaEEWS
<i>Excellence rate</i> peserta	5,1%	11,25%	+120,6%	Kualitas Layanan Informasi MKG
Penghematan Jam Pelatihan	Dasar	-391 Jam	ROI Tinggi	Efisiensi Kerja (<i>Digital-Driven</i>)

Penurunan tingkat kegagalan sebesar 82,2% (dari 8,1% ke 1,44%) secara empiris membuktikan kekuatan intervensi proaktif berbasis AI dalam mendeteksi hambatan belajar lebih dini. Sebelum implementasi AI, identifikasi peserta yang tertinggal sering kali baru diketahui saat ujian akhir, namun melalui sistem EWS "Traffic Light", bimbingan khusus dapat diberikan tepat pada saat peserta menunjukkan anomali perilaku di minggu kedua pelatihan. Hal ini memberikan dampak langsung pada efisiensi anggaran PPSDM BMKG karena drastisnya pengurangan biaya operasional untuk penyelenggaraan pelatihan *remedial* atau pengulangan pelatihan bagi peserta yang tidak lulus.

Peningkatan *Excellence Rate* yang sangat signifikan sebesar 120,6% (dari 5,1% ke 11,25%) menunjukkan bahwa sistem LA tidak hanya berfungsi sebagai jaring pengaman kelulusan, tetapi juga pendorong kualitas penguasaan materi teknis. Peningkatan ini berakar dari kemampuan AI dalam menyajikan jalur belajar yang dipersonalisasi (*adaptive learning paths*) dan asisten tutor otomatis yang tersedia 24/7 bagi pegawai di stasiun-stasiun daerah. Secara akademis, ini membuktikan bahwa pemanfaatan data besar (*Big Data*) pada pelatihan mampu memicu perubahan perilaku belajar yang lebih kompetitif dan berorientasi pada pencapaian tertinggi.

Keberhasilan menjaga capaian IKU akurasi info gempa bumi < 3 Menit di level 98,5% merupakan manifestasi nyata dari kesiapan operasional SDM yang terstandarisasi secara digital. Dalam sistem peringatan dini tsunami (InaEEWS), akurasi data radar dan sismik sangat bergantung pada kematangan teknis operator di Pusat Gempabumi dan Tsunami. Pelatihan berbasis AI menjamin bahwa setiap operator yang bertugas telah melalui evaluasi kompetensi adaptif yang ketat, sehingga meminimalkan potensi kesalahan manusia (*human error*) dalam situasi darurat yang menuntut respon cepat.

Penghematan sebanyak 391 jam pelatihan melalui penggunaan platform adaptif berbasis AI memberikan nilai tambah produktivitas yang luar biasa bagi BMKG secara institusional. Di era VUCA, pegawai operasional sering menghadapi tekanan beban kerja tinggi (*work pressure*) yang menyulitkan mereka untuk meninggalkan pos tugas demi pelatihan klasikal yang lama. Dengan optimasi waktu belajar yang hanya berfokus pada celah kompetensi (*skill gaps*) yang belum dikuasai, pegawai dapat menyelesaikan target 20 JP per tahun dengan lebih cepat dan efektif tanpa mengganggu jadwal pengamatan meteorologi atau geofisika di lapangan.

Korelasi positif antara profil kelulusan digital dengan peningkatan kualitas layanan MKG menegaskan bahwa PPSDM BMKG telah berhasil melakukan transformasi evaluasi pelatihan menuju Level 4 *Kirkpatrick*. Data analitik ini memungkinkan Analisis Pengembangan Kompetensi untuk membuktikan secara empiris kepada pimpinan lembaga mengenai nilai strategis (ROI) dari setiap rupiah anggaran yang diinvestasikan dalam modal insani. Strategi ini tidak hanya memperkuat legitimasi program pelatihan, tetapi juga membangun fondasi sistem meritokrasi yang kokoh di mana penempatan jabatan kritical didasarkan pada bukti nyata penguasaan kompetensi digital yang objektif dan terukur.

4. KESIMPULAN

Implementasi *Learning Analytics* berbasis *Artificial Intelligence* di PPSDM BMKG terbukti secara empiris meningkatkan efektivitas pelatihan dari administratif menjadi prediktif dan berdampak nyata. Pemanfaatan data historis 2017-2021 memungkinkan algoritma *Random Forest* mencapai akurasi prediksi 87,76% dalam mendeteksi hambatan belajar pada data implementasi 2022-2024. Visualisasi Traffic Light System pada *dashboard Learning Analytics* memberikan instrumen intervensi dini yang presisi, yang secara nyata menurunkan angka kegagalan pelatihan sampai dengan 82%. Transformasi ini memperkuat kontribusi pengembangan kompetensi terhadap misi keselamatan publik melalui layanan informasi MKG yang lebih akurat dan andal.

Berdasarkan hasil penelitian ini, diharapkan penguatan ekosistem digital di lingkungan BMKG dapat berlanjut menuju integrasi data pembelajaran yang lebih holistik dengan sistem manajemen kinerja individu (e-kinerja) secara longitudinal. Hal ini penting untuk memastikan bahwa kompetensi yang diakuisisi di platform LMS tidak hanya berhenti pada level kelulusan, tetapi teraktualisasi secara konsisten dalam perilaku kerja sehari-hari di unit operasional. Pengembangan lebih lanjut harus difokuskan pada pemanfaatan asisten tutor berbasis *Generative AI* yang mampu memberikan bimbingan personal bagi pegawai di stasiun-stasiun MKG terpencil, guna menutup kesenjangan literasi teknologi dan teknis secara inklusif.

Ke depan, strategi implementasi AI dalam pengembangan kompetensi harus senantiasa didasarkan pada prinsip tata kelola data yang etis, transparan, dan berpusat pada manusia (*human-centered governance*). Penggunaan model AI harus tetap menempatkan peran Instruktur dan Analisis Pengembangan Kompetensi sebagai pengambil keputusan akhir (*human-in-the-loop*) guna menghindari bias algoritma yang dapat merugikan karier pegawai. Dengan sinergi antara kecanggihan mesin dan kearifan profesionalisme ASN, BMKG akan mampu melahirkan talenta-talenta unggul yang tidak hanya kompeten secara teknis, tetapi juga adaptif dalam menghadapi kompleksitas perubahan global demi keselamatan masyarakat luas.

REFERENSI

- [1] M. J. Sousa and Á. Rocha, "Learning Analytics Measuring Impacts on Organisational Performance," *J. Grid Comput.*, vol. 18, no. 3, 2020, doi: 10.1007/s10723-018-9463-1.
- [2] A. Rashed and A. A. Alazmi, "The Importance of Using Artificial Intelligence Techniques in Improving the Quality of Training," *Print) International Journal of Social Science and Humanities Research*, vol. 13, pp. 211–217, doi: 10.5281/zenodo.14999095.

- [3] J. P. Cerro Martínez, M. Guitert Catasús, and T. Romeu Fontanillas, "Impact of using *Learning Analytics* in asynchronous online discussions in higher education," *International Journal of Educational Technology in Higher Education*, vol. 17, no. 1, 2020, doi: 10.1186/s41239-020-00217-y.
- [4] O. H. T. Lu, A. Y. Q. Huang, J. C. H. Huang, A. J. Q. Lin, H. Ogata, and S. J. H. Yang, "Applying *Learning Analytics* for the early prediction of students' academic performance in blended learning," *Educational Technology and Society*, vol. 21, no. 2, 2018.
- [5] F. Martin and A. Ndoye, "Using *Learning Analytics* to assess student learning in online courses," *Journal of University Teaching and Learning Practice*, vol. 13, no. 3, 2016, doi: 10.53761/1.13.3.7.
- [6] S. N. Kew and Z. Tasir, "*Learning Analytics* in Online Learning Environment: A Systematic Review on the Focuses and the Types of Student-Related Analytics Data," *Technology, Knowledge and Learning*, vol. 27, no. 2, 2022, doi: 10.1007/s10758-021-09541-2.
- [7] G. Siemens, "Learning Analytics: The Emergence of a Discipline," *American Behavioral Scientist*, vol. 57, no. 10, 2013, doi: 10.1177/0002764213498851.
- [8] H. Aldowah, H. Al-Samarraie, and W. M. Fauzy, "Educational data mining and *Learning Analytics* for 21st century higher education: A review and synthesis," 2019. doi: 10.1016/j.tele.2019.01.007.
- [9] K. Mangaroska and M. Giannakos, "*Learning Analytics* for Learning Design: A Systematic Literature Review of Analytics-Driven Design to Enhance Learning," *IEEE Transactions on Learning Technologies*, vol. 12, no. 4, 2019, doi: 10.1109/TLT.2018.2868673.
- [10] N. Sghir, A. Adadi, and M. Lahmer, "Recent advances in Predictive Learning Analytics: A decade systematic review (2012–2022)," *Educ. Inf. Technol. (Dordr.)*, vol. 28, no. 7, 2023, doi: 10.1007/s10639-022-11536-0.
- [11] P. Topali, A. Ortega-Arranz, M. J. Rodríguez-Triana, E. Er, M. Khalil, and G. Akçapınar, "Designing human-centered *Learning Analytics* and *Artificial Intelligence* in education solutions: a systematic literature review," *Behaviour and Information Technology*, vol. 44, no. 5, 2025, doi: 10.1080/0144929X.2024.2345295.
- [12] A. Wilson, C. Watson, T. L. Thompson, V. Drew, and S. Doyle, "Learning analytics: challenges and limitations," *Teaching in Higher Education*, vol. 22, no. 8, 2017, doi: 10.1080/13562517.2017.1332026.
- [13] F. Ouyang, M. Wu, L. Zheng, L. Zhang, and P. Jiao, "Integration of *Artificial Intelligence* performance prediction and *Learning Analytics* to improve student learning in online engineering course," *International Journal of Educational Technology in Higher Education*, vol. 20, no. 1, 2023, doi: 10.1186/s41239-022-00372-4.
- [14] S. A. Samsul, N. Yahaya, and H. Abuhassna, "Education big data and learning analytics: a bibliometric analysis," *Humanit. Soc. Sci. Commun.*, vol. 10, no. 1, 2023, doi: 10.1057/s41599-023-02176-x.
- [15] R. Kaliisa, I. Jivet, and P. Prinsloo, "A checklist to guide the planning, designing, implementation, and evaluation of *Learning Analytics* dashboards," 2023. doi: 10.1186/s41239-023-00394-6.
- [16] G. Ramaswami, T. Susnjak, and A. Mathrani, "Effectiveness of a *Learning Analytics Dashboard* for Increasing Student Engagement Levels," *Journal of Learning Analytics*, vol. 10, no. 3, 2023, doi: 10.18608/jla.2023.7935.
- [17] R. Ferguson, "Learning analytics: Drivers, developments and challenges," 2012. doi: 10.1504/IJTEL.2012.051816.
- [18] S. Dawson and G. Siemens, "Analytics to literacies: The development of a *Learning Analytics* framework for multiliteracies assessment," *International Review of Research in Open and Distance Learning*, vol. 15, no. 4, 2014, doi: 10.19173/irrodl.v15i4.1878.
- [19] A. Chiappe and L. P. Rodríguez, "*Learning Analytics* in 21st century education: A review," 2017. doi: 10.1590/S0104-40362017002501211.
- [20] M. Giannakos *et al.*, "The promise and challenges of generative AI in education," *Behaviour and Information Technology*, vol. 44, no. 11, 2025, doi: 10.1080/0144929X.2024.2394886.
- [21] B. T. M. Wong, K. C. Li, and M. Liu, "The Role of *Learning Analytics* in Evaluating Course Effectiveness," 2025. doi: 10.3390/su17020559.
- [22] A. Sakr and T. Abdullah, "Virtual, augmented reality and *Learning Analytics* impact on learners, and educators: A systematic review," *Educ. Inf. Technol. (Dordr.)*, vol. 29, no. 15, 2024, doi: 10.1007/s10639-024-12602-5.
- [23] Y. Wang, Y. Lai, and X. Huang, "Innovations in Online Learning Analytics: A Review of Recent Research and Emerging Trends," 2024. doi: 10.1109/ACCESS.2024.3493621.

-
- [24] A. Palanci, R. M. Yılmaz, and Z. Turan, “*Learning Analytics* in distance education: A systematic review study,” *Educ. Inf. Technol. (Dordr.)*, vol. 29, no. 17, 2024, doi: 10.1007/s10639-024-12737-5.
 - [25] D. Ifenthaler and J. Y. K. Yau, “Utilising *Learning Analytics* to support study success in higher education: a systematic review,” *Educational Technology Research and Development*, vol. 68, no. 4, 2020, doi: 10.1007/s11423-020-09788-z.
 - [26] I. D. Stanciu, Á. Hernández-García, M. Á. Conde, and N. Nistor, “Decoding a decade. Trends and evolution in learning analytics: A comprehensive synthesis,” *Comput. Human Behav.*, vol. 165, 2025, doi: 10.1016/j.chb.2024.108526.
 - [27] O. Viberg, M. Hatakka, O. Bälter, and A. Mavroudi, “The current landscape of *Learning Analytics* in higher education,” 2018. doi: 10.1016/j.chb.2018.07.027.
 - [28] A. Ahmad *et al.*, “Connecting the dots – A literature review on *Learning Analytics* indicators from a learning design perspective,” *J. Comput. Assist. Learn.*, vol. 40, no. 6, 2024, doi: 10.1111/jcal.12716.
 - [29] N. A. Johar, S. N. Kew, Z. Tasir, and E. Koh, “*Learning Analytics* on Student Engagement to Enhance Students’ Learning Performance: A Systematic Review,” 2023. doi: 10.3390/su15107849.
 - [30] H. Ouhaichi, D. Spikol, and B. Vogel, “Research trends in multimodal learning analytics: A systematic mapping study,” 2023. doi: 10.1016/j.caeai.2023.100136.
 - [31] I. Masiello, Z. Mohseni, F. Palma, S. Nordmark, H. Augustsson, and R. Rundquist, “A Current Overview of the Use of *Learning Analytics* Dashboards,” 2024. doi: 10.3390/educsci14010082.
 - [32] S. K. Banihashem, H. Dehghanzadeh, D. Clark, O. Noroozi, and H. J. A. Biemans, “*Learning Analytics* for online game-Based learning: a systematic literature review,” *Behaviour and Information Technology*, vol. 43, no. 12, 2024, doi: 10.1080/0144929X.2023.2255301.
 - [33] L. Breiman, “Random Forests,” 2001.
 - [34] N. Nistor and Á. Hernández-García, “What types of data are used in learning analytics? An overview of six cases,” *Comput. Human Behav.*, vol. 89, 2018, doi: 10.1016/j.chb.2018.07.038.
 - [35] L. Zheng, Kinshuk, Y. Fan, and M. Long, “The impacts of the comprehensive *Learning Analytics* approach on learning performance in online collaborative learning,” *Educ. Inf. Technol. (Dordr.)*, vol. 28, no. 12, 2023, doi: 10.1007/s10639-023-11886-3.
 - [36] D. Vlahek, D. Oreški, and M. P. Lukinec, “Learning from the features we ignore: a critical perspective on feature engineering and the role of feature learning in learning analytics,” *IEEE Access*, 2025, doi: 10.1109/ACCESS.2025.3627304.
 - [37] M. Blumenstein, “Synergies of *Learning Analytics* and learning design: A systematic review of student outcomes,” *Journal of Learning Analytics*, vol. 7, no. 3, 2020, doi: 10.18608/JLA.2020.73.3.
 - [38] H. K. Gharkan, M. J. Radif, and A. H. Alsaedi, “Analysis of AI- Empower Predictive Models for Predicting Student Performance in Higher Education,” *Journal of Al-Qadisiyah for Computer Science and Mathematics*, vol. 17, no. 1, Mar. 2025, doi: 10.29304/jqcs.2025.17.11967.
 - [39] O. K. Xin and D. Singh, “Development of *Learning Analytics Dashboard* based on Moodle Learning Management System,” *International Journal of Advanced Computer Science and Applications*, vol. 12, no. 7, 2021, doi: 10.14569/IJACSA.2021.0120793.
 - [40] W. Matcha, N. A. Uzir, D. Gasevic, and A. Pardo, “A Systematic Review of Empirical Studies on *Learning Analytics* Dashboards: A Self-Regulated Learning Perspective,” 2020. doi: 10.1109/TLT.2019.2916802.