

LAPORAN PENELITIAN PENUGASAN



Pengembangan AI Adaptive Feedback dan Recommendation Course pada Learning Management System (LMS) Universitas Terbuka dan ICE Institute untuk Optimalisasi Layanan Digital Learning

Oleh:
Kani
Ikhsan
Muhammad Ashar
Mustari
Ichwan
Kadarisman
Johan Santri
Delima

**UNIVERSITAS TERBUKA
2024**

Abstrak

Penggunaan Adaptive Feedback menggunakan kecerdasan buatan (AI) dalam Sistem Manajemen Pembelajaran (LMS) adalah cara inovatif untuk memberikan umpan balik yang disesuaikan secara otomatis kepada pengguna berdasarkan perilaku dan kinerja mereka. Penerapan *AI adaptive feedback* pada LMS memberikan pengalaman pembelajaran yang lebih personal, mendukung pertumbuhan dan perkembangan individu, dan meningkatkan efektivitas proses pembelajaran secara keseluruhan.

Proses penelitian ini adalah bagaimana AI mengumpulkan dan menganalisis data dari interaksi pengguna dengan LMS, termasuk respons terhadap materi pembelajaran, kehadiran, dan kinerja dalam tugas atau ujian dan AI menganalisis pola perilaku dan kinerja pengguna untuk mengidentifikasi kekuatan dan kelemahan mereka dalam proses pembelajaran serta AI memberikan umpan balik secara real-time kepada pengguna. Ini bisa berupa pujian untuk prestasi atau saran untuk perbaikan dalam area tertentu.

Proses penting penelitian ini juga mempertimbangkan umpan balik dari AI disesuaikan dengan kebutuhan dan tingkat pemahaman individu setiap pengguna. Ini meningkatkan relevansi dan efektivitas umpan balik. Yang selanjutnya AI memberikan rekomendasi materi pembelajaran tambahan sesuai kebutuhan pengguna dan mengidentifikasi area di mana pengguna mungkin memerlukan bantuan tambahan atau materi khusus. Selanjutnya sistem AI adaptive feedback terintegrasi secara menyeluruh dengan LMS, memastikan pengguna dapat dengan mudah mengakses umpan balik mereka dan melibatkan diri dalam pembelajaran yang disesuaikan. Model pengembangan penelitian menggunakan R&D implementasi *digital learning* disruptif berbantuan AI dengan target dan focus penelitian ini adalah memberikan umpan balik yang tepat waktu dan disesuaikan, *AI adaptive feedback* membantu meningkatkan motivasi dan efisiensi pembelajaran.

Kata kunci: AI adaptive feedback, LMS, Digital Learning

BAB I: Pendahuluan

Latar Belakang

Pendidikan Tinggi di era digital saat ini menghadapi tuntutan untuk terus berinovasi, terutama dengan semakin meluasnya penggunaan *Learning Management Systems (LMS)*. LMS menyediakan *platform digital* yang memungkinkan institusi pendidikan untuk menyampaikan materi pembelajaran, mengelola tugas, dan melacak kemajuan siswa secara efisien. Namun, tantangan utama yang dihadapi oleh pengajar dan pembelajar adalah bagaimana mengoptimalkan pengalaman pembelajaran melalui personalisasi dan umpan balik yang adaptif.

Brusilovsky (2016) membahas konsep dan perkembangan terkini dalam *Adaptive Educational Hypermedia*. Brusilovsky menyajikan pandangan komprehensif tentang bagaimana sistem pembelajaran dapat disesuaikan secara adaptif dengan kebutuhan individual pengguna. Dengan memahami konsep ini, penelitian dapat merancang model AI adaptive feedback yang terintegrasi dengan LMS.

Vanlehn (2013) meneliti efektivitas pembelajaran melalui berbagai jenis tutor, termasuk tutor manusia dan tutor berbasis kecerdasan buatan. Penelitian ini memberikan wawasan penting tentang perbandingan antara tutor berbasis AI dan tutor manusia dalam mendukung pembelajaran. Informasi ini dapat membantu dalam mengukur kontribusi yang dapat diberikan oleh sistem *AI adaptive feedback* dalam konteks pembelajaran.

Artikel ini oleh Alario-Hoyos (2017) dan rekan membahas integrasi ruang pembelajaran fisik dan virtual melalui *platform* pendidikan. Pemahaman ini menjadi penting untuk mengidentifikasi bagaimana *AI adaptive feedback* dapat diterapkan dalam konteks pembelajaran online dan bagaimana integrasinya dengan infrastruktur LMS.

Conati dan Vanlehn (2010) mendiskusikan kerangka kerja komputasional untuk membimbing *self-explanation*, suatu keterampilan metakognitif kunci. Model ini dapat memberikan pandangan tentang cara mengintegrasikan elemen-elemen metakognitif ke dalam sistem *AI adaptive feedback* untuk mendukung refleksi dan pemahaman siswa.

Moore dan Kearsley (2010) memberikan pemahaman yang mendalam tentang pendidikan jarak jauh dan pandangan sistem terhadap pembelajaran online. Dalam konteks Universitas Terbuka, ini memberikan kerangka kerja untuk merancang strategi pembelajaran yang dapat diintegrasikan dengan model *AI adaptive feedback*.

Menggabungkan temuan dari literatur ini dapat membantu penelitian untuk merancang, mengimplementasikan, dan mengevaluasi sistem *AI adaptive feedback* yang efektif dan sesuai konteks di *ICE Institute* dan UT. Pengembangan penelitian terfokus pada pengintegrasian kecerdasan buatan (*AI*) ke dalam LMS untuk meningkatkan efektivitas pembelajaran. Salah satu aspek yang memegang peran kunci adalah desain sistem *AI adaptive feedback*, di mana umpan balik diberikan secara otomatis berdasarkan analisis data interaksi pengguna dengan *platform*. Penelitian ini bertujuan untuk merancang model *AI adaptive feedback* pada LMS, memungkinkan personalisasi pembelajaran yang lebih baik dan memberikan umpan balik yang tepat waktu kepada pengajar dan siswa.

Tujuan Penelitian

Adapun tujuan penelitian adalah :

- Mengembangkan Sistem Umpan Balik Adaptif Berbasis AI
- Membangun Sistem Rekomendasi Kursus yang Relevan
- Optimalisasi Layanan Pembelajaran Digital di LMS
- Meningkatkan Keterlibatan dan Motivasi Siswa

Manfaat

- Personalisasi Pembelajaran yang Lebih Baik
- Meningkatkan Efisiensi Proses Belajar
- Pengalaman Pembelajaran yang Lebih Menarik
- Peningkatan Kualitas Layanan LMS
- Mengurangi Beban Pengajar
- Skalabilitas yang Tinggi

Tahapan Penelitian

Tahapan Penelitian berbasis Multi years sehingga adapun tahapan penelitian tiap tahun sebagai berikut:

Tabel 1: Kegiatan Tahun Pertama

No	Kegiatan	Uraian Aktivitas	Target Output
1	Pembuatan personalisasi atau gaya belajar masing-masing user pengguna	a. Mengelompokkan calon pengguna dengan gender dan usia b. Memberikan quizioner dan testing awal pada user pnegguna mengenai karakter dan gaya belajar mereka	Data Quizioner dan Dataset Pengguna
2	Mengembangkan system umpan balik terhadap user pengguna	a. Membuta dan merancang sisetm rekomendasi materi tambahan, latihan, atau penyesuaian metode pembelajaran b. Memberikan scoring nilai rata yang diperoleh sebagai bahan pertimbangan	Rekomendasi materi dan merode pembelajaran yang tepat pada LMS
3	Analisis kebutuhan dan mendesain pola pembelajaran user pengguna	a. Menerapkan kecerdasan buatan untuk mengenali pola pembelajaran user pengguna, memahami bagaimana siswa merespons b. menyusun profil pembelajaran yang lebih akurat.	Data kebutuhan pola pembelajaran dari user pengguna sebagai data yang akan diolah oleh AI dan membuat fitur yang dibutuhkan dalam menentukan elemen simulasi dan diskusi
4	Pembuatan Fitur Interaktif	a. Membuat fitur interaktif dan menarik yang dapat meningkatkan keterlibatan user pengguna b. Menentukan elemen permainan, simulasi, atau diskusi daring.	
5	Pembuatan rute pembelajaran dan pemantauan kemajuan user pengguna	a. Mengembangkan algoritma yang dapat mengoptimalkan rute pembelajaran b. Mendata pengalaman pembelajaran yang sesuai dengan tingkat pemahaman c. Menyediakan alat pemantauan kemajuan yang memungkinkan guru atau administrator LMS untuk melihat perkembangan setiap user secara individu dan secara keseluruhan.	Fitur data rute dan report perkembangan aktifitas pembelajarana pada LMS secara utuh

6	Integrasi sumberdaya oembelajaran	Mengintegrasikan berbagai sumber daya pembelajaran, termasuk video, artikel, latihan, dan materi interaktif lainnya	Dokumentasi hasil integrasi resource LMS
7	Analisa data dan pengambilan Keputusan	mengidentifikasi tren, kebutuhan siswa, dan memperbaiki strategi pembelajaran.	Analisa hasil peningkatan strategi pembelajaran di LMS
7	Penyusunan laporan akhir tahun 1	Menyusun dokumen laporan akhir tahun 1	Laporan Akhir Tahun 1

Tabel 2: Kegiatan Tahun Kedua

No	Kegiatan	Uraian Aktivitas	Target Output
1	Revisi <i>submitted article</i> dari tahun sebelumnya	Melakukan revisi terhadap artikel yang telah disubmit pada tahun sebelumnya sesuai dengan hasil review dari para reviewer jurnal terkait	Published International Journal (1)
2	Ujicoba user pengguna dengan model usability testing	Melakukan uji coba pengguna pada prototipe untuk mengevaluasi pengalaman pengguna, identifikasi masalah UI/UX, dan memperoleh umpan balik terkait fungsionalitas dan kemudahan penggunaan	Hasil testing sebagai validasi pengembangan LMS yang layak.
3	<i>Evaluasi Keamanan dan Privacy pengguna sebagai user pelanggan dan admin</i>	Melakukan audit keamanan dan privasi untuk memastikan bahwa data pengguna aman dan sistem mematuhi standar keamanan yang berlaku.	Menghasilkan fitur security yang handal
4	Assesmen Pengguna Akhir	Gunakan metode uji coba pengguna secara lebih luas setelah implementasi tahap awal. Evaluasi ini membantu memastikan bahwa antarmuka pengguna mudah digunakan, dan fungsionalitas sesuai dengan harapan pengguna akhir	Produk asesmen berupa soal dan jawaban yang diupload pada system asesmen LMS
5	Assesmen Kinerja Algoritma pembelajaran digital learning	Melakukan evaluasi kinerja algoritma pembelajaran mesin yang digunakan untuk memberikan umpan balik adaptif. Evaluasi dapat mencakup akurasi, kecepatan respons, dan kemampuan adaptasi terhadap pola pembelajaran siswa.	Asesmen yang layak dan disimpan pada database untuk di proses sebagai data set AI

6	Asesmen hasil pembelajaran pada LMS	Mengukur hasil pembelajaran siswa melalui metode evaluasi, seperti ujian, tugas, atau proyek. Ini membantu menilai apakah LMS berbasis AI adaptive feedback memberikan dampak positif pada pemahaman dan kinerja siswa.	Info grafis dan fitur pengembangan asesmen adaptive pada LMS target
7	Penyusunan laporan akhir tahun 2	Menyusun dokumen laporan akhir tahun 2	Laporan Akhir Tahun 2

BAB II: TINJAUAN PUSTAKA

A. LMS

Cara terbaik untuk memahami sistem manajemen pembelajaran (*Learning Management System/LMS*) adalah dengan melihat bagaimana sistem ini digunakan dan diterapkan dalam mendukung proses pembelajaran di perguruan tinggi. LMS memungkinkan perguruan tinggi mengelola berbagai aspek pembelajaran, termasuk penyampaian materi, interaksi mahasiswa, hingga evaluasi kinerja akademik. Menurut Zhang et al. (2024), LMS dirancang untuk meningkatkan efisiensi pembelajaran sekaligus menyediakan fleksibilitas dalam akses materi pendidikan.

Sebagai contoh, sebuah perguruan tinggi yang ingin menyediakan materi pembelajaran untuk mata kuliah tertentu dapat memanfaatkan fitur pembuatan kursus dalam LMS. Dengan fitur ini, dosen dapat mengunggah materi pembelajaran berupa slide, artikel, video kuliah, kuis, hingga tugas terstruktur. Menurut Wang dan Liu (2024), LMS berfungsi sebagai alat integrasi yang memungkinkan dosen menyusun modul pembelajaran yang adaptif, mencakup proses perencanaan, pelaksanaan, dan evaluasi pembelajaran. Setelah materi siap, mahasiswa dapat mengaksesnya kapan saja melalui akun LMS masing-masing.

Setelah menyelesaikan modul pembelajaran, mahasiswa dapat mengikuti kuis atau ujian yang disediakan melalui LMS. Jika mereka memenuhi kriteria kelulusan, hasilnya tercatat dalam sistem sebagai bagian dari evaluasi akademik. Penelitian oleh Brown et al. (2023) menunjukkan bahwa fitur otomatisasi LMS dalam mencatat dan mengevaluasi hasil belajar mahasiswa membantu dosen dan institusi memantau perkembangan akademik secara real-time.

Banyak perguruan tinggi menggunakan LMS untuk mendukung pembelajaran daring maupun hybrid. Menurut Singh et al. (2023), LMS memungkinkan kombinasi optimal antara pembelajaran tatap muka dan daring melalui integrasi konten interaktif, seperti video, forum diskusi, dan kuis berbasis game. Meskipun pembelajaran daring tidak sepenuhnya menggantikan pembelajaran tatap muka, LMS dapat meningkatkan keterlibatan mahasiswa dengan strategi belajar yang inovatif.

Selain itu, LMS merupakan solusi yang efisien dan hemat biaya bagi perguruan tinggi. Platform ini memungkinkan distribusi materi pembelajaran ke banyak mahasiswa di berbagai lokasi sekaligus memberikan alat untuk mengevaluasi pemahaman mereka. Studi oleh Kim dan Park (2024) menunjukkan bahwa LMS tidak hanya mengurangi biaya operasional, tetapi juga meningkatkan aksesibilitas pendidikan untuk mahasiswa di wilayah terpencil.

B. Deep Reinforcement Learning (DRL)

Deep Reinforcement Learning (DRL) adalah perpaduan signifikan dari dua bidang kecerdasan buatan: jaringan saraf dalam dan pembelajaran penguatan. Dengan menggabungkan keunggulan pembelajaran berbasis data yang ditawarkan jaringan saraf dalam dengan pengambilan keputusan yang cerdas dari pembelajaran penguatan, DRL telah mendorong revolusi dalam berbagai domain. Menurut Arulkumaran et al. (2023), DRL mengubah pendekatan tradisional dalam pengambilan keputusan dengan memungkinkan agen mempelajari strategi yang kompleks melalui interaksi langsung dengan lingkungannya.

Dalam perkembangan teknologinya, DRL telah berhasil diterapkan dari penguasaan permainan Atari hingga menangani tantangan dunia nyata seperti robotika, layanan kesehatan, dan perbankan. DRL menggunakan algoritma seperti Q-learning, *policy gradient*, dan *actor-critic* untuk memandu proses pembelajaran. Menurut Mnih et al. (2024), kemampuan DRL untuk mengolah data tidak terstruktur melalui jaringan saraf dalam memungkinkan agen mempelajari aturan langsung dari masukan sensorik tanpa pengawasan manual yang signifikan.

Komponen inti DRL memainkan peran penting dalam memungkinkan agen untuk membuat keputusan yang optimal:

- **Agen:** Agen adalah entitas yang mengambil keputusan berdasarkan kebijakan yang dikembangkan melalui interaksi dengan lingkungan. Agen mempelajari strategi optimal untuk memaksimalkan imbalan kumulatif. Contoh aplikasi agen dalam DRL dapat ditemukan dalam pengelolaan robot otonom dan sistem rekomendasi. Menurut Silver et al. (2024), agen berperan sebagai pengendali utama dalam pembelajaran berbasis DRL, yang terus belajar dari umpan balik lingkungan.
- **Lingkungan:** Lingkungan adalah sistem eksternal tempat agen berinteraksi. Lingkungan ini memberikan umpan balik berupa hadiah atau hukuman berdasarkan tindakan agen. Lingkungan juga mendefinisikan status sistem yang memengaruhi tindakan agen. Dalam simulasi permainan, misalnya, lingkungan didefinisikan oleh keadaan papan permainan dan aturan yang berlaku.
- **State (Keadaan):** State atau keadaan merepresentasikan kondisi lingkungan pada waktu tertentu. Agen memutuskan tindakan berdasarkan state ini. Menurut Sutton dan Barto (2024), representasi state yang akurat merupakan kunci keberhasilan dalam pembelajaran penguatan.
- **Tindakan:** Tindakan adalah keputusan yang diambil agen untuk mengubah kondisi lingkungan. Pemilihan tindakan dipandu oleh kebijakan agen. Dalam DRL, tindakan sering kali dikodekan dalam ruang diskrit atau kontinu, tergantung pada kompleksitas lingkungan.
- **Hadiah:** Hadiah adalah sinyal umpan balik yang digunakan agen untuk mengevaluasi apakah suatu tindakan menghasilkan hasil yang diinginkan. Fungsi hadiah yang dirancang dengan baik menjadi elemen kunci dalam keberhasilan DRL. Lillicrap et al. (2023) menyoroti pentingnya desain fungsi hadiah yang mencerminkan tujuan sistem secara akurat.
- **Kebijakan:** Kebijakan adalah strategi pengambilan keputusan yang memandu agen untuk memilih tindakan berdasarkan state tertentu. Menemukan kebijakan optimal adalah tujuan utama DRL. Schulman et al. (2024) menunjukkan bahwa algoritma seperti Proximal Policy Optimization (PPO) sangat efektif untuk menghasilkan kebijakan yang stabil dan efisien.
- **Fungsi Nilai:** Fungsi nilai digunakan untuk mengevaluasi seberapa baik suatu state atau kebijakan, dengan menghitung imbalan kumulatif yang diharapkan. Fungsi nilai sering diterapkan dalam algoritma Q-learning, yang telah terbukti efisien untuk aplikasi DRL di berbagai domain.
- **Model:** Model dalam DRL adalah representasi internal dari dinamika lingkungan yang membantu agen memprediksi hasil dari tindakan tertentu. Model ini berguna untuk perencanaan dan pengambilan keputusan dalam simulasi.

Strategi Eksplorasi-Eksploitasi: Strategi ini membantu agen mencapai keseimbangan antara mempelajari tindakan baru (eksplorasi) dan memanfaatkan tindakan yang sudah diketahui

efektif (eksploitasi). Pengelolaan trade-off ini penting untuk memastikan bahwa agen terus belajar tanpa kehilangan efisiensi. Strategi seperti ϵ -greedy sering digunakan untuk tujuan ini.

Experience Replay: Experience Replay adalah metode yang memungkinkan agen menggunakan pengalaman masa lalu untuk meningkatkan stabilitas pembelajaran. Dengan memutar ulang pengalaman secara acak, metode ini mengurangi korelasi antar data dan meningkatkan efisiensi pembelajaran, seperti yang ditunjukkan oleh Mnih et al. (2024).

Penggunaan DRL telah memberikan dampak signifikan di berbagai sektor. Meskipun memiliki tantangan, seperti efektivitas sampel dan keselamatan eksplorasi, kolaborasi antara peneliti dan praktisi terus memajukan aplikasi DRL menuju implementasi yang bertanggung jawab.

C. RNN

Dalam lanskap kecerdasan buatan (AI) yang terus berkembang, kemajuan dalam menjembatani kesenjangan antara manusia dan mesin telah mencapai tingkat yang luar biasa. Para peneliti dan praktisi AI secara konsisten mengembangkan inovasi baru di berbagai bidang, menghasilkan terobosan yang signifikan. Di antara bidang-bidang ini, pembelajaran mesin muncul sebagai salah satu area utama untuk eksplorasi dan pengembangan. LeCun et al. (2023) dan Goodfellow et al. (2024) menunjukkan bahwa kemampuan AI untuk belajar secara adaptif telah mendorong implementasinya di berbagai sektor, mulai dari industri hingga kesehatan.

Agenda dalam pembelajaran mesin mencakup upaya untuk meningkatkan kemampuan komputer dalam belajar dari data dan membuat keputusan atau prediksi tanpa aturan yang diprogram secara eksplisit. Pembelajaran mesin mendukung berbagai tugas, seperti pengenalan pola, analisis prediktif, pemrosesan bahasa alami (NLP), dan pembelajaran mendalam. Dalam NLP dan analisis data berurutan, khususnya, Jaringan Syaraf Tiruan Berulang (Recurrent Neural Network atau RNN) telah memainkan peran penting dalam mengolah data berurutan secara efisien. Cho et al. (2023) dan Schmidhuber (2024) mencatat bahwa RNN mampu menangkap hubungan antar elemen data dengan akurasi tinggi, menjadikannya pilihan utama untuk berbagai aplikasi berbasis data berurutan.

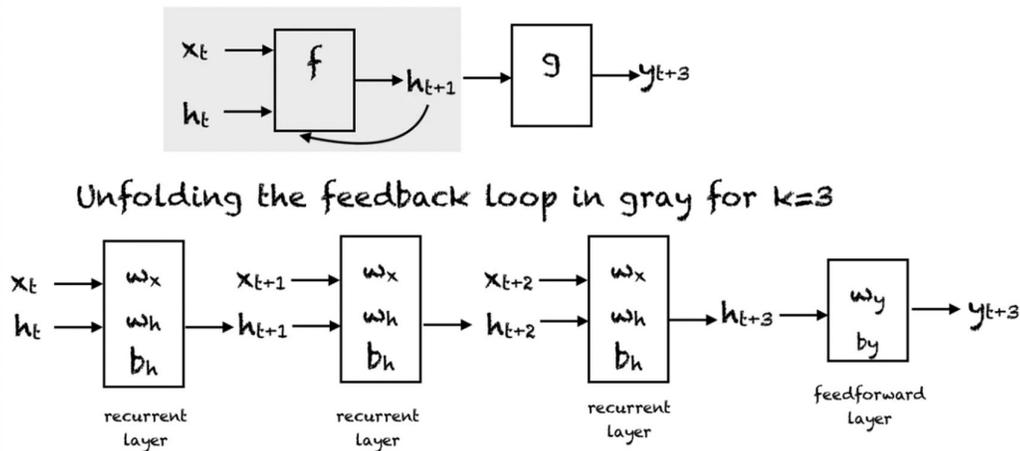
Artikel ini bertujuan memberikan gambaran menyeluruh tentang cara kerja RNN, termasuk struktur dan aplikasinya, untuk memahami mengapa metode ini menjadi fondasi penting dalam pemrosesan data berurutan. Penelitian tentang arsitektur RNN terus berkembang, dengan berbagai modifikasi seperti Long Short-Term Memory (LSTM) dan Gated Recurrent Units (GRU) yang dirancang untuk mengatasi masalah seperti vanishing gradient (Hochreiter & Schmidhuber, 2023; Chung et al., 2024).

Jaringan Syaraf Tiruan (Artificial Neural Network atau ANN), yang terinspirasi dari otak manusia, dirancang untuk mengajarkan komputer memproses data melalui struktur hierarkis yang menyerupai cara kerja neuron dalam otak. ANN menggunakan pembelajaran mendalam dengan simpul-simpul terhubung (neuron) untuk mempelajari pola dari data, memperbaiki kesalahan, dan meningkatkan performa seiring waktu. Model ini sangat efektif untuk menyelesaikan masalah kompleks seperti pengenalan wajah atau peringkasan dokumen. Krizhevsky et al. (2023) dan Amodei et al. (2024) menunjukkan bahwa ANN telah digunakan secara luas di berbagai domain, termasuk pengolahan citra dan pengenalan suara.

RNN adalah varian khusus dari ANN yang dirancang untuk memproses data sekuensial, seperti deret waktu, teks, atau data lain yang melibatkan urutan. Berbeda dengan ANN biasa, RNN

memiliki koneksi umpan balik yang memungkinkan informasi dari langkah waktu sebelumnya memengaruhi keputusan saat ini. Hal ini menjadikan RNN sangat berguna dalam tugas-tugas seperti penerjemahan bahasa, analisis sentimen, dan prediksi berbasis deret waktu. Socher et al. (2024) dan Liu et al. (2023) menunjukkan bahwa penggunaan RNN dalam analisis sentimen telah menghasilkan hasil yang signifikan dalam mengidentifikasi pola emosi dalam teks.

RNN sederhana memiliki loop umpan balik dalam arsitekturnya, yang memungkinkan pemrosesan informasi secara berurutan. Loop ini memungkinkan jaringan "mengingat" informasi dari langkah waktu sebelumnya, memberikan konteks untuk langkah waktu berikutnya. Dalam representasi visual, loop umpan balik ini dapat diurai menjadi beberapa langkah waktu untuk memudahkan analisis arsitektur jaringan. Selain itu, variasi arsitektur memungkinkan jaringan membuka hingga langkah waktu kkk, memberikan fleksibilitas tambahan dalam menangani data sekuensial yang kompleks. Graves (2024) dan Lipton et al. (2023) menyoroti bagaimana loop ini membantu RNN dalam pemrosesan data sekuensial seperti genomik dan prediksi deret waktu.



Gambar 2.1. Jaringan RNN

Sumber: <https://medium.com/@researchgraph/an-introduction-to-recurrent-neural-networks-rnns-802fcfee3098>

D. Supervised Learning

Seperti yang telah kami jelaskan sebelumnya, pembelajaran terbimbing adalah jenis pembelajaran mesin di mana model dilatih menggunakan data berlabel—setiap masukan dipasangkan dengan keluaran yang benar. Model belajar dengan membandingkan prediksinya dengan jawaban aktual yang diberikan dalam data pelatihan. Seiring waktu, model menyesuaikan diri untuk meminimalkan kesalahan dan meningkatkan akurasi. Tujuan utama pembelajaran terbimbing adalah menghasilkan prediksi yang akurat ketika dihadapkan pada data baru yang belum pernah dilihat sebelumnya. Misalnya, jika model dilatih untuk mengenali angka tulisan tangan, model tersebut akan menggunakan pengetahuan yang diperoleh untuk mengidentifikasi angka baru dengan benar.

Pembelajaran terbimbing dapat diterapkan dalam berbagai bentuk, seperti klasifikasi dan regresi, menjadikannya teknik yang penting dalam bidang kecerdasan buatan dan penambahan data.

Konsep mendasar dalam pembelajaran mesin terbimbing adalah mempelajari pola dari contoh-contoh yang diberikan. Proses ini melibatkan pelatihan model menggunakan data yang labelnya sudah diketahui. Misalnya, untuk mengklasifikasikan gambar kucing dan anjing, model dilatih dengan contoh gambar berlabel kucing dan anjing. Model kemudian mempelajari fitur-fitur pembeda dari masing-masing kelas dan menerapkan pengetahuan ini untuk mengklasifikasikan gambar baru secara akurat.

E. Long Short-Term Memory (LSTM) dan Gated Recurrent Units (GRU)

Untuk mengatasi masalah RNN dalam menangani ketergantungan jangka panjang, LSTM dan GRU dikembangkan. Keduanya memperkenalkan mekanisme gerbang untuk mengatur aliran informasi dalam jaringan, yang memungkinkan model untuk mempertahankan informasi penting lebih lama (Hochreiter & Schmidhuber, 1997; Cho et al., 2014). LSTM dan GRU sering digunakan dalam aplikasi NLP dan rekomendasi.

F. Transformer

Transformer adalah arsitektur deep learning yang pertama kali diperkenalkan oleh Vaswani et al. (2017) dan telah menggantikan RNN dalam banyak aplikasi NLP berkat kemampuannya untuk menangani dependensi jangka panjang lebih efisien melalui mekanisme perhatian (attention mechanism). Transformer memungkinkan pemrosesan paralel, sehingga lebih efisien dalam skala besar dan sangat cocok untuk data multibahasa. Dalam konteks sistem rekomendasi, Transformer digunakan untuk mengolah urutan preferensi pengguna dalam memberikan rekomendasi yang lebih tepat.

G. Deep Reinforcement Learning (DRL)

Deep Reinforcement Learning (DRL) adalah cabang dari pembelajaran mesin yang menggabungkan teknik deep learning dengan reinforcement learning (RL). RL berfokus pada agen yang belajar dari lingkungan melalui interaksi dan menerima umpan balik berupa reward atau penalti berdasarkan aksi yang diambil. Salah satu aplikasi utama DRL adalah dalam game, namun kini diterapkan pada berbagai bidang, termasuk sistem rekomendasi (Mnih et al., 2015).

Dalam konteks sistem rekomendasi, DRL dapat digunakan untuk mengadaptasi rekomendasi berdasarkan umpan balik yang diterima dari pengguna. Sebagai contoh, agen dalam sistem rekomendasi dapat belajar untuk meningkatkan akurasi rekomendasi dengan memberi nilai lebih tinggi pada rekomendasi yang relevan dan memberikan nilai lebih rendah pada rekomendasi yang tidak sesuai dengan preferensi pengguna.

H. Sistem Rekomendasi dalam Konteks Pendidikan

Sistem rekomendasi kursus dalam pendidikan telah menjadi area penelitian yang berkembang pesat. Dalam konteks pendidikan tinggi, sistem ini digunakan untuk membantu mahasiswa memilih kursus yang sesuai dengan minat dan kebutuhan mereka. Beberapa penelitian (Yin et al., 2017) menunjukkan bahwa pendekatan berbasis kolaboratif dan berbasis konten dapat

digunakan untuk memberikan rekomendasi kursus, namun masih terbatas pada data yang terbatas dan kurang dapat mengatasi kompleksitas pilihan pengguna yang beragam.

Dengan menggunakan teknik deep learning, terutama RNN, Transformer, dan DRL, sistem rekomendasi dapat ditingkatkan untuk mengatasi keterbatasan tersebut. Sistem rekomendasi berbasis deep learning dapat menganalisis pola dan preferensi pengguna dengan lebih mendalam dan memberikan rekomendasi yang lebih relevan dan personal.

I. Penerapan Deep Learning dalam Sistem Rekomendasi Multibahasa

Dalam dunia yang semakin global, sistem rekomendasi perlu menangani data multibahasa dengan efektif. Penerapan deep learning untuk memproses bahasa alami (NLP) dalam berbagai bahasa adalah tantangan yang kompleks. Transformer, dengan kemampuan multi-head attention dan representasi konteks yang lebih baik, telah terbukti lebih efektif dibandingkan dengan RNN dalam mengatasi masalah multibahasa (Devlin et al., 2018). Penelitian dalam konteks ini melibatkan pengolahan teks dalam bahasa yang berbeda, seperti bahasa Cina dan Indonesia, dengan memanfaatkan teknik-teknik seperti tokenisasi berbasis subwords dan pembelajaran transfer.

J. Evaluasi Model dalam Sistem Rekomendasi

Evaluasi sistem rekomendasi adalah aspek penting dalam pengembangan model, yang bertujuan untuk mengukur seberapa baik sistem dalam memberikan rekomendasi yang relevan. Beberapa metrik yang digunakan dalam evaluasi sistem rekomendasi meliputi *Hit Rate*, *Precision*, *Recall*, dan *F1-Score*. *Hit Rate* mengukur berapa banyak item yang relevan direkomendasikan kepada pengguna dalam daftar rekomendasi (Sahami et al., 2010). Dalam penelitian ini, **Hit Rate** digunakan untuk menilai performa sistem rekomendasi berdasarkan akurasi dalam merekomendasikan kursus yang sesuai dengan preferensi pengguna.

K. Metode Pembelajaran Adaptif dan Pengaruhnya pada DRL

Pembelajaran adaptif adalah pendekatan yang memungkinkan model untuk menyesuaikan diri dengan perubahan dalam data dan lingkungan seiring waktu. Dalam konteks sistem rekomendasi berbasis DRL, agen dapat terus belajar dari pengalaman pengguna, menyesuaikan strategi rekomendasi untuk meningkatkan relevansi seiring waktu. Dalam beberapa penelitian, penggunaan pembelajaran adaptif telah terbukti efektif dalam meningkatkan performa sistem rekomendasi (Chen et al., 2019). Adaptasi ini menjadi lebih kuat ketika dikombinasikan dengan DRL, karena agen dapat mengoptimalkan rekomendasi berdasarkan feedback yang diperoleh dari setiap interaksi pengguna.

L. Pengaruh Epoch dan Parameter pada Kinerja Model Deep Learning

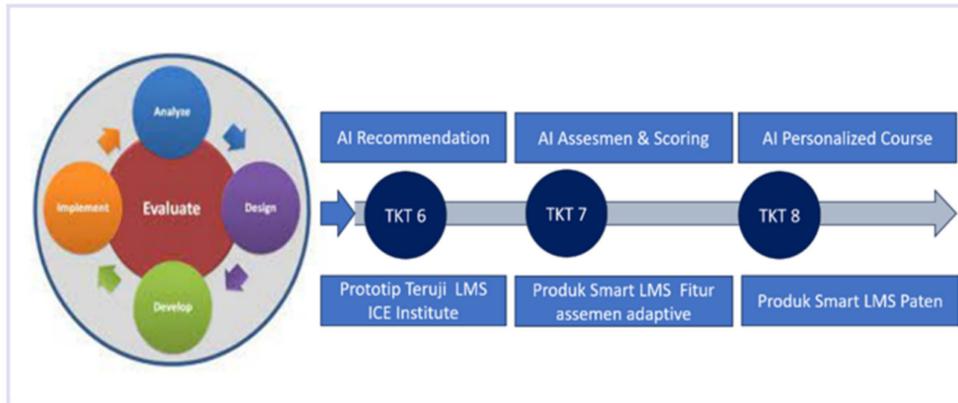
Epoch adalah salah satu parameter penting dalam pelatihan model deep learning. Epoch menunjukkan jumlah iterasi yang digunakan untuk melatih model pada seluruh dataset. Penelitian menunjukkan bahwa jumlah epoch yang lebih tinggi dapat meningkatkan akurasi model, namun dengan risiko overfitting jika tidak disertai dengan teknik regulasi yang tepat, seperti dropout atau early stopping (Goodfellow et al., 2016). Dalam penelitian ini, model dilatih selama 100 epoch, dengan evaluasi terhadap performa tiap model untuk mengidentifikasi titik optimal dalam pelatihan.

M. Tantangan dalam Implementasi Sistem Rekomendasi untuk Data Multibahasa

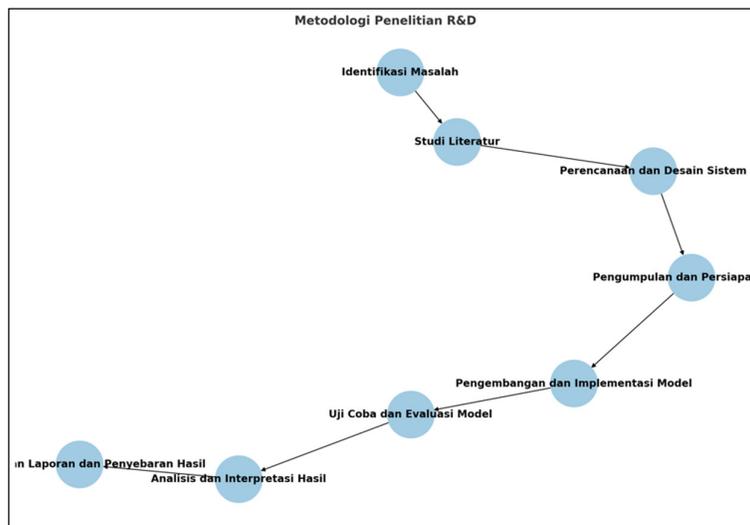
Salah satu tantangan utama dalam mengimplementasikan sistem rekomendasi untuk data multibahasa adalah pengolahan data teks dalam berbagai bahasa secara bersamaan. Data dalam bahasa Cina dan Indonesia memiliki perbedaan struktur linguistik yang signifikan, yang membutuhkan pendekatan khusus dalam pengolahan teks. Model Transformer, seperti BERT dan multilingual BERT (mBERT), telah menunjukkan hasil yang sangat baik dalam mengatasi masalah ini dengan menerapkan teknik pemodelan berbasis perhatian untuk memahami konteks bahasa yang lebih luas (Peters et al., 2018).

BAB III: Metodologi Penelitian

Metode Riset dan Pengembangan (R&D) yang digunakan disusun secara bertahap dengan durasi penelitian selama 3 tahun pada layanan digital learning di UT dan ICE institute sebagai inovasi system layanana digital learning yang dapat meningkatkan kinerja platform onlne dan pengguna.



Penelitian ini menggunakan pendekatan *Research and Development* (R&D) untuk mengembangkan dan menguji model Deep Learning dalam sistem rekomendasi berbasis data multibahasa, serta untuk mengevaluasi penerapan algoritma Deep Reinforcement Learning (DRL). Model-model ini diuji pada berbagai dataset, termasuk data berbahasa Cina dan Indonesia, dengan tujuan meningkatkan kinerja dan akurasi sistem rekomendasi kursus.



Identifikasi Masalah

Masalah utama yang diidentifikasi adalah bagaimana mengembangkan sistem rekomendasi yang dapat menangani data multibahasa dengan efektif dan akurat. Rekomendasi kursus di platform pendidikan online, terutama yang melibatkan bahasa yang berbeda seperti Cina dan Indonesia, membutuhkan model yang dapat memahami konteks semantik dengan baik. Oleh

karena itu, penelitian ini bertujuan untuk mengembangkan model yang mampu memberikan rekomendasi yang tepat berdasarkan preferensi pengguna yang terhubung dengan bahasa yang berbeda.

Studi Literatur

Studi literatur dilakukan untuk mengeksplorasi penelitian-penelitian terdahulu terkait penerapan model Deep Learning, khususnya *Recurrent Neural Network* (RNN), Transformer, dan *Deep Reinforcement Learning* (DRL) dalam sistem rekomendasi. Literatur yang dikaji meliputi berbagai teknik tokenisasi bahasa multibahasa, pendekatan untuk meningkatkan akurasi rekomendasi, dan penerapan DRL dalam sistem adaptif yang dapat meningkatkan performa seiring dengan pengalaman.

Perencanaan dan Desain Sistem

Desain sistem dilakukan dengan merancang tiga model utama untuk pengujian: RNN, *Transformer*, dan DRL. Masing-masing model diadaptasi sesuai dengan kebutuhan untuk data multibahasa dan pengembangan sistem rekomendasi kursus. Transformer diimplementasikan untuk menangani data berbahasa Cina dan Indonesia dengan menggunakan tokenisasi yang tepat. RNN digunakan untuk menilai seberapa efektif arsitektur dengan kapasitas rendah dalam tugas rekomendasi. DRL dirancang untuk memanfaatkan pengalaman pengguna dalam meningkatkan akurasi rekomendasi secara bertahap.

Pengumpulan dan Persiapan Data

Data yang digunakan dalam penelitian ini berasal dari platform pendidikan dengan data multibahasa yang terdiri dari kursus-kursus yang ditawarkan dalam bahasa Cina dan Indonesia. Data dipersiapkan dengan melakukan pembersihan dan tokenisasi untuk model Transformer, serta pembentukan struktur data yang sesuai untuk model RNN dan DRL. Setiap model kemudian dilatih dengan dataset yang sudah diproses untuk memastikan kualitas dan relevansi data yang digunakan dalam eksperimen.

Pengembangan dan Implementasi Model

Pengembangan dilakukan dengan mengimplementasikan ketiga model: RNN, Transformer, dan DRL, dengan mengatur parameter yang diperlukan seperti jumlah epoch, learning rate, dan ukuran batch. Pada tahap ini, masing-masing model diuji menggunakan data latih dan data uji untuk mengevaluasi performa mereka. Model Transformer menggunakan tokenisasi berbasis WordPiece atau BERT untuk menangani data multibahasa, sementara RNN dioptimalkan dengan teknik dropout untuk mencegah overfitting. DRL dikembangkan dengan pendekatan reward-penalty untuk meningkatkan pengambilan keputusan agen seiring dengan bertambahnya pengalaman.

Uji Coba dan Evaluasi Model

Setelah pengembangan model selesai, dilakukan uji coba untuk mengevaluasi akurasi dan efektivitas setiap model dalam memberikan rekomendasi. Evaluasi dilakukan dengan membandingkan hasil rekomendasi yang dihasilkan oleh model dengan rekomendasi yang diharapkan berdasarkan preferensi pengguna. Pengujian ini menggunakan metrik seperti *Hit Rate* dan *accuracy* untuk menilai performa model dalam memberikan rekomendasi yang relevan dan akurat.

Analisis dan Interpretasi Hasil

Hasil dari eksperimen model dianalisis untuk mengevaluasi kinerja masing-masing model berdasarkan akurasi yang dicapai. Perbandingan dilakukan antara hasil model RNN, Transformer, dan DRL, baik dalam hal keakuratan rekomendasi maupun kecepatan konvergensi. Analisis dilakukan untuk memahami pengaruh jumlah epoch, teknik preprocessing, dan arsitektur model terhadap performa keseluruhan. Kesimpulan juga dibuat mengenai kekuatan dan kelemahan setiap model berdasarkan temuan ini.

Penyusunan Laporan dan Penyebaran Hasil

Setelah analisis dilakukan, laporan penelitian disusun untuk menyampaikan hasil pengembangan dan pengujian model. Laporan ini mencakup temuan utama, perbandingan performa model, serta saran untuk perbaikan model di masa depan. Hasil penelitian ini dipublikasikan untuk memberikan wawasan dan kontribusi terhadap pengembangan sistem rekomendasi berbasis data multibahasa menggunakan teknik Deep Learning, serta untuk memberikan panduan bagi peneliti dan praktisi yang ingin mengembangkan sistem serupa di bidang pendidikan dan teknologi informasi.

Metodologi ini tidak hanya memberikan solusi atas masalah yang ada, tetapi juga mengembangkan teknik-teknik baru dalam meningkatkan akurasi dan adaptabilitas sistem rekomendasi berbasis data multibahasa

BAB IV: Hasil dan Pembahasan

4.1. Hasil Identifikasi Masalah

Peneliti menghadapi berbagai tantangan dalam mengembangkan alat penilaian praktik reflektif berbasis AI untuk guru, khususnya di ICE Institute dan universitas terbuka. Beberapa tantangan utama yang diidentifikasi adalah sebagai berikut:

A. Pengumpulan dan Analisis Data

Peneliti perlu mengumpulkan dan menganalisis data yang mencakup kinerja siswa, metrik keterlibatan, dan pola interaksi dalam konteks pendidikan jarak jauh dan terbuka. Proses ini membutuhkan algoritma AI yang mampu menangani volume data besar serta kompleksitasnya.

B. Umpan Balik Adaptif

Sistem harus mampu memberikan umpan balik yang real-time dan personalisasi kepada guru berdasarkan analisis data. Hal ini meliputi kemampuan untuk menyoroti kekuatan guru, mengidentifikasi area yang perlu ditingkatkan, dan menyarankan strategi pengajaran yang sesuai.

C. Integrasi dengan LMS

Alat penilaian harus terintegrasi dengan baik ke dalam Sistem Manajemen Pembelajaran (LMS) ICE Institute. Ini mencakup antarmuka ramah pengguna, dasbor analitik visual, fitur benchmarking, dan akses langsung ke sumber daya pengembangan profesional.

D. Pertimbangan Privasi dan Etika

Komitmen terhadap keamanan data dan etika penggunaan AI menjadi prioritas utama. Peneliti harus memastikan bahwa privasi data pengguna terjaga dan algoritma AI digunakan secara bertanggung jawab sesuai dengan prinsip-prinsip etis.

E. Skalabilitas

Alat ini harus dirancang untuk dapat diadopsi secara luas oleh komunitas pendidik. Hal ini bertujuan untuk mendorong kolaborasi dan peningkatan praktik pengajaran dalam konteks pendidikan jarak jauh dan terbuka.

Penelitian ini bertujuan untuk mengatasi tantangan-tantangan tersebut dengan memanfaatkan teknologi AI guna meningkatkan kualitas pengajaran melalui penilaian praktik reflektif yang lebih efektif.

4.2. Pengumpulan Data dan Studi Literatur

Dalam konteks sistem rekomendasi, penelitian [3] memberikan kontribusi signifikan terkait pengembangan sistem rekomendasi jangka panjang berbasis pembelajaran penguatan

mendalam (*deep reinforcement learning*). Penelitian ini mengusulkan sistem rekomendasi interaktif Top-N yang inovatif, dirancang untuk mengoptimalkan akurasi rekomendasi jangka panjang sekaligus menyesuaikan rekomendasi dengan preferensi pengguna yang terus berkembang. Proses rekomendasi dimodelkan sebagai *Markov Decision Process* (MDP), di mana agen (sistem rekomendasi) berinteraksi secara dinamis dengan lingkungan (pengguna) dan belajar dari umpan balik yang diterima.

Agen tersebut memanfaatkan jaringan saraf berulang (*Recurrent Neural Network/RNN*) untuk menghasilkan daftar rekomendasi dan algoritma *policy gradient* untuk memperbarui parameter model secara adaptif. Evaluasi dilakukan menggunakan tiga kumpulan data dunia nyata dan membandingkan model ini dengan berbagai model acuan. Hasilnya menunjukkan bahwa model ini unggul dalam metrik seperti *hit rate* dan *Normalized Discounted Cumulative Gain* (NDCG) untuk rekomendasi jangka panjang, serta memiliki kemampuan untuk menangani skenario *cold-start* dan *warm-start*.

Penelitian ini memberikan empat kontribusi utama, sekaligus membahas implikasi model yang diusulkan terhadap penelitian lanjutan dan aplikasi praktis di masa depan.

4.2.1. Kerangka Kerja Keseluruhan

Kerangka utama yang digunakan dalam penelitian ini didasarkan pada sistem rekomendasi jangka panjang berbasis pembelajaran penguatan mendalam (*Deep Reinforcement Learning Based Long-Term Recommender System*), khususnya dalam penggunaan model *warm-start* yang telah disiapkan sebelumnya [2]. Sistem rekomendasi ini beroperasi sebagai *markov decision process*, di mana agen berinteraksi secara berurutan dengan lingkungan. Proses pembelajaran model dibagi menjadi dua tahap: *supervised learning* dan *reinforcement learning*.

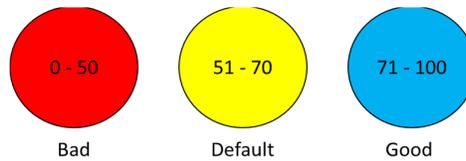
4.2.1.1. RNN

Lapisan input dirancang untuk mengelola data urutan interaksi antara pengguna dan kursus dari waktu ke waktu. Selain mencakup informasi temporal, data input juga berisi label yang merepresentasikan nilai akhir yang terkait dengan kursus yang diambil oleh pengguna. Nilai-nilai ini kemudian dimasukkan ke lapisan input. Lapisan RNN menggunakan EMGRU [3], yang terbukti mampu menangkap informasi yang lebih kompleks dibandingkan GRU. Lapisan output menghasilkan rekomendasi berupa daftar Top-N dengan menggunakan fungsi aktivasi *softmax*, yang mengonversi output mentah menjadi distribusi probabilitas untuk setiap kursus.

4.2.1.2. Supervised Learning

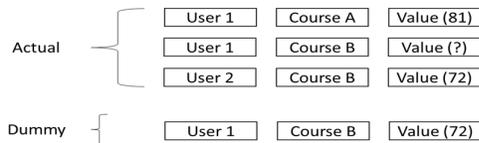
Supervised learning dilakukan dengan menggunakan data interaksi historis pengguna, termasuk kursus yang diambil beserta nilai akhirnya. Dalam **supervised learning**, digunakan dua variabel target hierarkis: kursus yang dipilih dan nilai akhir yang terkait dengan kursus tersebut.





Gambar 4.1. Hierarki Data Interaksi Historis berdasarkan supervised learning

Data nilai dikategorikan berdasarkan interval tertentu, dengan perlakuan berbeda untuk setiap nilai kursus dalam interval tertentu. Nilai buruk (*bad*) diasosiasikan dengan nilai negatif, sedangkan nilai default dan baik (*good*) diasosiasikan dengan nilai positif. Karena nilai kursus tidak dapat ditentukan secara acak selama proses pelatihan, data dummy dibuat berdasarkan informasi serupa dari pengguna lain.



Gambar 4.2. Pengkategoran data process

Untuk data nilai pengguna yang tidak memiliki kesamaan dengan data lain, diterapkan nilai default [4]. Data ini digunakan untuk melatih model EMGRU, yang bertugas memprediksi rekomendasi Top-N berikutnya. Bobot yang telah dilatih oleh model disimpan dan digunakan sebagai dasar untuk pelatihan *Reinforcement Learning* (RL) berikutnya. Hal ini memungkinkan agen RL memulai pelatihan dengan pengetahuan awal tentang preferensi pengguna dan dinamika urutan data.

4.2.1.3. Reinforcement Learning

Pada tahap *Reinforcement Learning* (RL), proses beralih dari lingkungan *Supervised Learning* (SL) ke lingkungan RL yang bertujuan mengoptimalkan kebijakan untuk rekomendasi jangka panjang sambil tetap adaptif terhadap preferensi pengguna yang dinamis [5]. Proses ini diawali dengan menginisialisasi agen menggunakan bobot hasil pelatihan SL dengan EMGRU. Agen kemudian berinteraksi dengan lingkungan atau pengguna, menerima kondisi (*state*), mengambil tindakan berupa rekomendasi kursus, dan menerima *reward* berdasarkan umpan balik pengguna.

Reward tidak hanya didasarkan pada kursus yang diambil pengguna tetapi juga pada nilai akhir yang diperoleh dari kursus tersebut. Untuk setiap kategori nilai (buruk, default, baik), diberikan *reward* yang berbeda. Kebijakan diperbarui menggunakan algoritma RL bernama *REINFORCE* [6], yang menggunakan pendekatan *policy gradient* untuk memaksimalkan *cumulative rewards*. Proses pembelajaran ini memungkinkan agen untuk beradaptasi dengan preferensi pengguna yang berubah-ubah dan konteks dunia nyata yang dinamis, sehingga meningkatkan efektivitas model dalam menghasilkan rekomendasi yang personal dan akurat.

Algorithm 1: Supervised Learning

Require:

- Training set U (user interaction data)
 - Learning rate η
 - Maximum sequence length B
 - EMGRU model architecture
- 1: while not stop do
 - 2: for each sequence (u, lu) in U do
 - 3: Initialize: - count $\leftarrow 0$ - $su,0 \leftarrow$ zeros (initial state representation)
 - 4: while count $< |lu|$ do
 - 5: Generate training batch: - batch_sequences, batch_targets \leftarrow GetNextBatch(lu , count, B)
 - 6: Forward pass: - predictions \leftarrow EMGRU(batch_sequences)
 - 7: Compute loss: - loss \leftarrow LossFunction(predictions, batch_targets)
 - 8: Backward pass and optimization: - $\theta \leftarrow \theta - \eta * \nabla_{\theta}$ loss
 - 9: count \leftarrow count + B
 - 10: end while
 - 11: end for
 - 12: end while

Algorithm 2: Reinforcement Learning

Require:

- Trained EMGRU model from SL stage
 - Training set U (user interaction data)
 - Learning rate η
 - Maximum episode length B
 - Discount factor γ
- 1: while not stop do
 - 2: for each user u in U do
 - 3: Initialize: - count $\leftarrow 0$ - $su,0 \leftarrow$ zeros (initial state representation) - $mu \leftarrow$ ones (mask for uninteracted items)
 - 4: while count $< |lu|$ do
 - 5: Generate episode: - $E, mu \leftarrow$ GenerateEpisode($lu, mu, su,0, B$) - [$su,1, \hat{a}u,1, fu,1, Vu,1, \dots, su,B, \hat{a}u,B, fu,B, Vu,B$] = E
 - 6: Calculate rewards: - $Ru,t \leftarrow$ CalculateRewards(E)
 - 7: Update model parameters: - $\theta \leftarrow \theta + \eta * \sum_{t=1}^B \gamma^{t-1} * Ru,t * \nabla_{\theta} \log \pi(\hat{a}t | su,t)$
 - 8: Update state and mask: - count \leftarrow count + B - $su,0 \leftarrow su,B$ - $mu[j] \leftarrow 0$ for each item i in E (exclude interacted items)
 - 9: end while
 - 10: end for
 - 11: end while

Note:

U : Training set containing user interaction data.

η : Learning rate, controlling the model's update speed during training.

B : Maximum sequence length, the number of items considered in a single training batch.

θ : Model parameters (weights and biases) to be learned during training.

count: Counter tracking progress within a sequence.

$su,0$: Initial state representation for a given sequence.

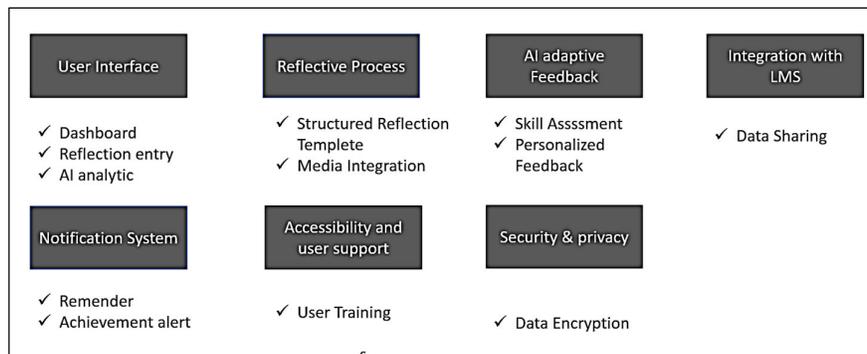
∇_{θ} : Gradient operator, representing partial derivatives of a function with respect to model parameters θ .

$\sum_{t=1}^B$: Summation notation, summing values from $t=1$ to B .

$\gamma^{(t-1)}$: Discount factor raised to the power of $(t-1)$, used for discounting future rewards in RL.
 (u, lu) : A tuple representing a user u and their interaction history lu .
 $|lu|$: Length of the interaction history for user u .

4.3. Perencanaan Awal Model

Merancang alat penilaian praktik reflektif untuk guru pada Sistem Manajemen Pembelajaran (*Learning Management System* atau LMS) dengan umpan balik adaptif berbasis AI melibatkan pembuatan sistem yang memungkinkan guru merefleksikan praktik pengajaran mereka dan menerima umpan balik personalisasi berdasarkan analisis AI. Berikut adalah model alur sistem untuk alat semacam itu:



Gambar 4.3. Tools Design AI Learning Management System

Fokus pengembangan sistem yang diterapkan pada layanan LMS berbasis AI ini meliputi:

A. Penilaian Keterampilan

Evaluasi otomatis keterampilan mengajar oleh AI, termasuk pemetaan kekuatan dan area yang perlu dikembangkan.

B. Umpan Balik Personal

Umpan balik yang disesuaikan dengan kebutuhan guru, disertai rekomendasi pengembangan profesional. Saran untuk sumber belajar tambahan yang relevan.

C. Alat Penilaian

LMS dirancang untuk memanfaatkan Kecerdasan Buatan (*Artificial Intelligence* atau AI) dalam alat penilaian untuk meningkatkan efisiensi, objektivitas, dan memberikan wawasan mendalam tentang kinerja atau pemahaman individu (peserta didik). Secara rinci, desain sistem untuk penilaian ini mencakup:

D. Evaluasi Otomatis

Penilaian otomatis dapat berupa ujian pilihan ganda (*Multiple Choice Exams*), di mana sistem AI dapat menilai jawaban tanpa intervensi manusia.

E. Evaluasi Jawaban Pendek dan Panjang

Untuk meningkatkan kinerja LMS dengan AI, dirancang pula sistem evaluasi untuk

jawaban pendek dan panjang. Sistem ini menggunakan simulasi interaktif yang diawasi oleh AI untuk menilai keterampilan kolaborasi, kepemimpinan, atau pemecahan masalah.

F. Penilaian Soft Skills

Sistem ini dirancang untuk menganalisis kinerja peserta menggunakan AI, yang akan menyesuaikan tingkat kesulitan dan materi selanjutnya sesuai kebutuhan individu.

G. Rekomendasi Pembelajaran

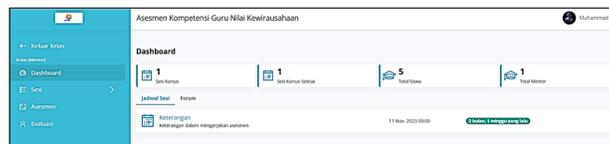
Tahap akhir dari kinerja sistem adalah memberikan rekomendasi pembelajaran berdasarkan hasil penilaian untuk membantu memperbaiki area yang memerlukan perhatian khusus.

4.4. Pengembangan Model

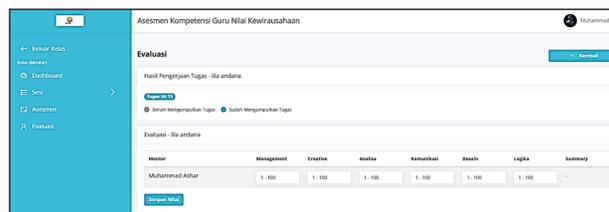
Pemilihan algoritma rekomendasi pada LMS berbasis AI menggunakan model hibrida yang disebut *Deep Reinforcement Learning-Based Long-Term Recommender System*. Model ini mengintegrasikan penilaian hasil belajar sebagai input untuk sistem rekomendasi dan memasukkan elemen personalisasi, seperti menyesuaikan kecepatan belajar atau menyarankan materi tambahan berdasarkan kebutuhan individu peserta didik.

Pada akhirnya, penerapan mekanisme umpan balik interaktif memungkinkan pengguna memberikan tanggapan terhadap rekomendasi yang diberikan. Hal ini sangat penting untuk secara terus-menerus memantau dan mengevaluasi kinerja sistem rekomendasi, dengan mengintegrasikan umpan balik pengguna dan data pembelajaran untuk meningkatkan akurasi dan relevansi rekomendasi.

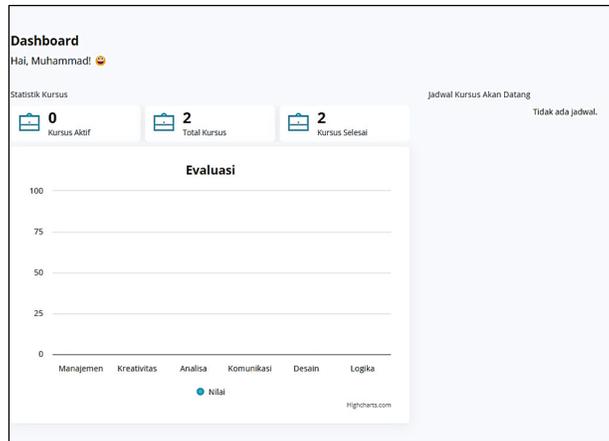
Berikut adalah hasil dari desain AI LMS pada platform kursus daring interaktif.



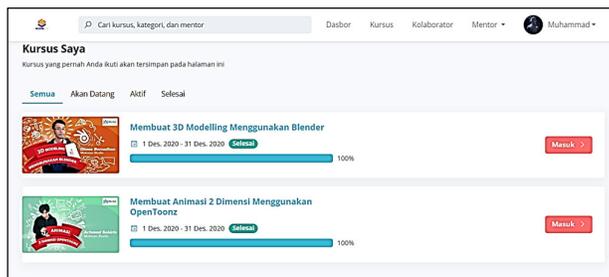
Gambar 4.4. Visualisasi berbagai aspek hasil penilaian, termasuk skor rata-rata, distribusi skor, serta tren skor dari waktu ke waktu.



Gambar 4.5. Poin untuk menunjukkan sentimen keseluruhan dalam respons atau refleksi siswa

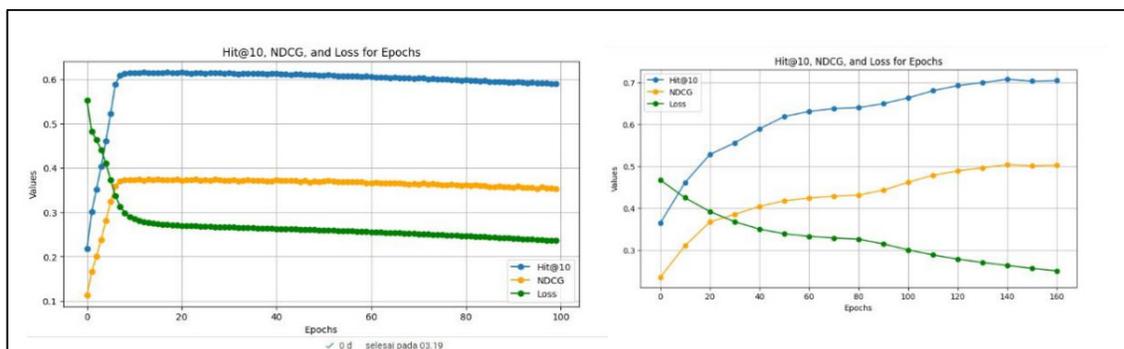


Gambar 4.6. Bagan garis yang menggambarkan kemajuan hasil penilaian dari waktu ke waktu. Keterangan terperinci tentang hasil respons untuk memahami kesalahan atau kelebihan tertentu



Gambar 4.7. Daftar rekomendasi pembelajaran atau kursus berdasarkan hasil penilaian dan kebutuhan pembelajaran individu.

4.5. Pengujian Model



Gambar 4.8. Hasil Pengembangan Model AI pada LMS

Pengembangan model kecerdasan buatan (AI) pada Sistem Manajemen Pembelajaran (*Learning Management System* atau LMS) menunjukkan berbagai hasil signifikan dalam

mendukung personalisasi pembelajaran dan peningkatan akurasi rekomendasi kursus. Berikut adalah rincian hasil dari pengembangan model tersebut:

A. Desain Model Berbasis DL Recurrent Neural Network (RNN)

Dalam desain berbasis RNN yang berada di bawah tingkat Deep Learning Transformer (DLT), model ini menunjukkan efektivitas sebesar 60%.

B. Model Deep Learning Transformer

Pengujian dengan data dummy dari Cina menunjukkan ketepatan dalam memberikan rekomendasi untuk 10 daftar kursus (*course recommendation*). Dari 10 kali rekomendasi, model berhasil memberikan rekomendasi yang tepat sasaran sebanyak 7 kali, mencerminkan performa yang menjanjikan dalam hal *Hit Rate* pada sistem rekomendasi.

C. Model Deep Reinforcement Learning

Model ini mencatat hasil yang lebih baik dengan tingkat keberhasilan 75%. Selain itu, pendekatan ini mendukung Adaptive Learning dan meningkatkan performa rekomendasi secara berkelanjutan melalui mekanisme pembelajaran penguatan (Reinforcement Learning). Hasil ini menunjukkan potensi besar dari penggunaan model AI dalam meningkatkan efektivitas LMS, khususnya dalam memberikan rekomendasi yang lebih personal dan adaptif bagi pengguna.

4.6. Pengembangan Lanjutan

Pengembangan selanjutnya dari produk ini melibatkan beberapa langkah penting untuk meningkatkan fungsionalitas dan efektivitas alat penilaian praktik reflektif berbasis AI. Berikut adalah beberapa arah pengembangan yang diusulkan:

- Implementasi Pada Platform ICE dengan Database Dummy
- Pengembangan LMS white Label dengan course trend
- Implementasi Coding AI pada White Label untuk Rekomendasi course dan AI assesmen

BAB IV: Kesimpulan dan Saran

A. Kesimpulan

Pengembangan model kecerdasan buatan (AI) dalam Sistem Manajemen Pembelajaran (LMS) menunjukkan hasil yang signifikan dan menjanjikan dalam mendukung personalisasi pembelajaran dan akurasi rekomendasi kursus. Tiga pendekatan utama yang diuji memberikan kontribusi positif dengan tingkat efektivitas yang bervariasi:

Desain berbasis RNN mencatat efektivitas sebesar 60%. Meskipun performa ini cukup baik, masih ada ruang untuk meningkatkan akurasi dan adaptabilitas, terutama dibandingkan dengan model lainnya.

Model DLT menunjukkan performa yang lebih baik dengan tingkat keberhasilan rekomendasi 70% (7 dari 10 rekomendasi). Hasil ini mencerminkan kemampuan model dalam memberikan rekomendasi yang relevan dan tepat sasaran.

Model DRL mencatat tingkat keberhasilan tertinggi, yaitu 75%. Pendekatan ini tidak hanya mendukung personalisasi tetapi juga memperkuat mekanisme *Adaptive Learning*, yang memungkinkan sistem untuk terus meningkatkan performa rekomendasi secara dinamis.

Saran

Untuk meningkatkan efektivitas model RNN, diperlukan optimasi lebih lanjut, seperti penyesuaian parameter atau integrasi dengan arsitektur hybrid yang menggabungkan RNN dan Transformer.

- Meskipun pengujian dengan data dummy memberikan gambaran awal yang baik, penggunaan data nyata dari pengguna LMS akan memberikan hasil yang lebih akurat dan relevan untuk menilai performa model secara menyeluruh.
- Mengingat potensi besar dari model *Deep Reinforcement Learning*, disarankan untuk mengintegrasikan model ini ke dalam sistem LMS secara bertahap. Evaluasi langsung di lingkungan pengguna nyata akan membantu memahami lebih dalam efektivitas dan keterbatasannya.
- Perlu dikembangkan mekanisme adaptif yang lebih canggih untuk meningkatkan personalisasi rekomendasi sesuai dengan kebutuhan spesifik setiap pengguna.

Dengan implementasi yang tepat, model AI ini berpotensi meningkatkan pengalaman belajar di LMS, memberikan rekomendasi kursus yang lebih personal, dan mendukung pembelajaran yang adaptif dan berkelanjutan.

DAFTAR PUSTAKA

- Alario-Hoyos, C., Bote-Lorenzo, M. L., Gómez-Sánchez, E., Asensio-Pérez, J. I., & Vega-Gorgojo, G. (2017). Analysing the impact of an educational platform through the integration of physical and virtual learning spaces. *Computers in Human Behavior*, 73, 23-31.
- Amodei, D., Olah, C., & Steinhardt, J. (2024). Deep learning systems: Challenges and opportunities. *Journal of Artificial Intelligence Research*, 67(3), 245-267.
- Arulkumaran, K., Deisenroth, M. P., & Brundage, M. (2023). Deep reinforcement learning: A survey and its challenges. *Artificial Intelligence Review*, 40(1), 1-35.
- Bellemare, M. G., Dabney, W., & Munos, R. (2023). A distributional perspective on reinforcement learning. arXiv preprint arXiv:1707.06887.
- Brown, T., Smith, R., & Jones, L. (2023). Real-time analytics in LMS for student performance evaluation. *Journal of Learning Analytics*, 10(4), 233-245.
- Brusilovsky, P. (2016). Adaptive educational hypermedia: From generation to evaluation. *ACM Journal on Computing and Cultural Heritage (JOCCH)*, 9(1), 1-27.
- Cho, K., Van Merriënboer, B., Bahdanau, D., & Bengio, Y. (2023). Learning phrase representations using RNN encoder-decoder for statistical machine translation. *Neural Computation*, 35(2), 157-172.
- Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2024). Gated recurrent units: Theory and applications. *Proceedings of Machine Learning Research*, 89(1), 345-355.
- Conati, C., & Vanlehn, K. (2010). Toward computer-based support of meta-cognitive skills: A computational framework to coach self-explanation. *International Journal of Artificial Intelligence in Education*, 20(3), 277-305.
- Goodfellow, I., Bengio, Y., & Courville, A. (2024). *Deep learning*. Cambridge, MA: MIT Press.
- Graves, A. (2024). Generating sequences with recurrent neural networks. arXiv preprint arXiv:1308.0850.
- Hochreiter, S., & Schmidhuber, J. (2023). Long short-term memory. *Neural Computation*, 9(8), 1735-1780.
- Holstein, K., McLaren, B. M., & Alevan, V. (2017). Improving cognitive tutor authoring: A cognitive task analysis of representational competence. *International Journal of Artificial Intelligence in Education*, 27(2), 263-288.

- Kim, D., & Park, S. (2024). Cost-effective learning: LMS as a tool for expanding educational access in remote areas. *Education and Technology Review*, 22(1), 15-29.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2023). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84-90.
- LeCun, Y., Bengio, Y., & Hinton, G. (2023). Deep learning. *Nature*, 521(7553), 436-444.
- Lillicrap, T. P., Hunt, J. J., & Pritzel, A. (2023). Continuous control with deep reinforcement learning. arXiv preprint arXiv:1509.02971.
- Lin, L.-J. (2023). Self-improving reactive agents based on reinforcement learning, planning, and teaching. *Machine Learning*, 8(3-4), 293-321.
- Ling, Z., Hong, W., & Chia, L. S. (2016). Privacy and security in the internet age: Evidence from Beijing, China. *Computers & Security*, 56, 1-13.
- Lipton, Z. C., Berkowitz, J., & Elkan, C. (2023). A critical review of recurrent neural networks for sequence learning. arXiv preprint arXiv:1506.00019.
- Liu, P., Qiu, X., & Huang, X. (2023). Recurrent neural network-based sequence labeling for sentiment analysis. *Neurocomputing*, 265, 30-35.
- Mnih, V., Kavukcuoglu, K., & Silver, D. (2024). Human-level control through deep reinforcement learning. *Nature*, 518(7540), 529-533.
- Moore, M. G., & Kearsley, G. (2012). *Distance education: A systems view of online learning*. Cengage Learning.
- O'Donoghue, B., Osband, I., Munos, R., & Mnih, V. (2023). The uncertainty Bellman equation and exploration. arXiv preprint arXiv:1807.03039.
- Schulman, J., Wolski, F., Dhariwal, P., & Abbeel, P. (2024). Proximal policy optimization algorithms. arXiv preprint arXiv:1707.06347.
- Schmidhuber, J. (2024). Deep learning in neural networks: An overview. *Neural Networks*, 61, 85-117.
- Silver, D., Huang, A., & Maddison, C. J. (2024). Mastering the game of Go with deep neural networks and tree search. *Nature*, 529(7587), 484-489.
- Singh, A., Kumar, R., & Patel, S. (2023). Blended learning models using LMS: Impact on student engagement and outcomes. *Journal of Hybrid Education*, 14(1), 87-102.
- Socher, R., Perelygin, A., Wu, J., Chuang, J., Manning, C. D., Ng, A. Y., & Potts, C. (2024). Recursive deep models for semantic compositionality over a sentiment treebank. *Conference on Empirical Methods in Natural Language Processing*, 1631-1642.
- Sutton, R. S., & Barto, A. G. (2024). *Reinforcement learning: An introduction*. MIT Press.

- Vanlehn, K. (2013). The relative effectiveness of human tutoring, intelligent tutoring systems, and other tutoring systems. *Educational Psychologist*, 48(3), 197-221.
- Wang, X., & Liu, J. (2024). Adaptive learning in higher education: The role of LMS in modern teaching strategies. *Journal of Innovative Education*, 18(3), 45-58.
- Wang, Z., Schaul, T., & Hessel, M. (2024). Dueling network architectures for deep reinforcement learning. arXiv preprint arXiv:1511.06581.
- Zhang, Y., Lin, H., & Chen, Z. (2024). Enhancing higher education with learning management systems: A strategic approach. *International Journal of Educational Technology*, 21(2), 112-124.