

Implementasi Deep Learning untuk Klasifikasi dan Prediksi Data pada Sistem Rekomendasi Berbasis Machine Learning

Radhitya Dwi Akmal Purnomo 

^{1) 2) 3)} Universitas Madura, Jawa Timur, Indonesia

¹⁾ radhityadwi65@gmail.com

Abstrak

Perkembangan pesat teknologi komputasi telah mendorong adopsi luas *sistem rekomendasi berbasis machine learning* dalam berbagai domain industri, namun masih terdapat tantangan pada sistem *rekomendasi konten* yang umumnya bersifat konvensional dan berbasis *collaborative filtering* sehingga membatasi akurasi dan relevansi rekomendasi. Penelitian ini bertujuan untuk mengimplementasikan *Deep Learning* (DL), khususnya arsitektur *Convolutional Neural Network* dan *Recurrent Neural Network* (CNN-RNN), dalam menganalisis pola data pengguna guna menghasilkan rekomendasi yang lebih akurat dan personal. Metode yang digunakan meliputi integrasi model deep learning untuk *feature extraction* (ekstraksi fitur) dan *collaborative prediction* (prediksi kolaboratif) agar sistem mampu memahami preferensi serta pola perilaku pengguna secara mendalam. Pengembangan sistem dilakukan menggunakan pendekatan *Cross-Industry Standard Process for Data Mining* (CRISP-DM) dan diimplementasikan dalam bentuk prototipe sistem rekomendasi, **dilengkapi dengan evaluasi performa model menggunakan metrik (*Mean Absolute Error*) dan (*Root Mean Square Error*) pada arsitektur *cloud computing***. Hasil pengujian menunjukkan bahwa model deep learning mampu memprediksi preferensi pengguna dengan tingkat akurasi yang tinggi, **serta proses pelatihan dan inferensi model dapat berjalan secara efisien dan stabil**, sehingga sistem mampu memberikan rekomendasi yang relevan, personal, dan sesuai konteks kebutuhan pengguna. Dengan demikian, penerapan deep learning dalam analisis data terbukti efektif dalam mengatasi keterbatasan sistem rekomendasi konvensional, meningkatkan kepuasan pengguna, serta menciptakan pengalaman yang lebih adaptif dalam ekosistem digital.

Kata Kunci: *Deep Learning, Machine Learning, Convolutional Neural Network, Sistem Rekomendasi, rekomendasi konten, Collaborative Filtering, Prediksi Data.*

Article history: Received 5 April 2025, first decision 22 April 2025, accepted 22 August 2025, available online 28 October 2025

I. PENDAHULUAN

Perkembangan teknologi kecerdasan buatan (*Deep Learning*) dan pengolahan bahasa alami (*Convolutional Neural Network* dan *Recurrent Neural Network*) yang berlangsung sangat cepat telah mendorong transformasi besar dalam berbagai domain industri dan riset, khususnya bidang *sistem rekomendasi berbasis machine learning*. Salah satu teknologi yang mengalami perkembangan signifikan adalah arsitektur neural network dalam, yang memungkinkan mesin memahami konteks komunikasi manusia secara lebih mendalam. Machine Learning merupakan cabang AI yang berfungsi untuk melakukan pengumpulan, pengolahan, serta ekstraksi makna dari data teks secara terdistribusi untuk menciptakan interaksi yang lebih humanis [1], [2].

Dalam ranah pengembangan sistem rekomendasi, analisis data pengguna banyak dimanfaatkan untuk menerjemahkan pola interaksi menjadi rekomendasi di dalam dunia virtual. Penggunaan mekanisme *attention* dan model convolutional neural telah menjadi fondasi utama dalam membangun sistem prediksi yang mampu menangani berbagai variasi kalimat [3], [4]. Namun, setiap model AI dalam platform memiliki keterbatasan sumber daya komputasi, di mana efisiensi pemrosesan teks menjadi faktor penting agar tidak mengganggu performa *throughput* sistem secara keseluruhan. Kondisi ini menjadikan pemilihan arsitektur model yang tepat sebagai faktor krusial dalam perancangan interaksi platform yang responsif [5], [6].

* Radhitya Dwi Akmal Purnomo

Dalam konteks sistem rekomendasi konvensional, hasil prediksi sering dianggap kurang personal karena masih bergantung pada *aturan berbasis heuristik* yang statis. Metode konvensional ini dinilai kurang efektif dalam menghasilkan rekomendasi yang relevan dan personal. Oleh sebab itu, dibutuhkan pendekatan yang lebih dinamis melalui pemanfaatan sistem dialog generatif dan pembelajaran penguatan (*reinforcement learning*). Model deep learning memungkinkan visualisasi distribusi data yang berubah sesuai dengan preferensi dan input pengguna. Pengembangan platform berbasis Machine Learning diharapkan mampu meningkatkan keterlibatan aktif pengguna melalui dunia yang bereaksi secara cerdas terhadap setiap kata yang diucapkan atau diketik [7], [8], [9]. Selain itu, pengembangan model prediktif yang adaptif juga relevan dengan tren *Large-scale Representation Learning* seperti BERT dan GPT yang mampu menghasilkan representasi data yang kaya makna [10]. Penggunaan tren *deep learning* terbaru dalam deep learning memungkinkan sistem (*rekomendasi konten*) untuk memiliki kemampuan memori jangka panjang dan memahami preferensi pengguna secara holistik, sehingga mendukung sistem prediksi yang efisien [11]. Penerapan konsep asisten cerdas dan *transfer learning* dan *attention mechanism* telah banyak diaplikasikan dalam berbagai domain seperti e-commerce, streaming media, dan layanan digital [12], [13]. Oleh karena itu, pemahaman mendalam mengenai manajemen dialog neural diharapkan dapat menjadi fondasi yang kuat dalam mengembangkan sistem platform masa depan yang lebih adaptif [14], [15].

Di sisi lain, perkembangan arsitektur deep learning yang bersifat *state-of-the-art* juga memberikan dampak signifikan terhadap akurasi prediksi sistem rekomendasi. Penggunaan model seperti Transformer dan BART memungkinkan pengendalian narasi secara kondisional, di mana alur cerita dapat diringkas atau dikembangkan secara otomatis berdasarkan *input* pengguna [16], [17], [18]. Fenomena ini memberikan peluang besar bagi pengembang sistem untuk menciptakan solusi prediksi prosedural yang tidak terbatas, namun tetap membutuhkan strategi regenerasi teks yang akurat untuk menghindari degradasi makna dalam percakapan panjang [19], [20].

Meskipun demikian, penerapan AI tingkat tinggi dalam platform interaktif masih menghadapi berbagai tantangan teknis terkait infrastruktur pendukung. Ketersediaan jaringan yang stabil dengan performa tinggi sangat diperlukan agar proses pengiriman data teks ke *cloud computing* AI dapat berjalan tanpa latensi, di mana analisis kinerja jaringan seperti GPU/TPU dan parameter *Mean Absolute Error* (MAE/RMSE) menjadi aspek evaluasi yang sangat vital [31], [33]. Selain itu, karena proses pelatihan model dalam platform melibatkan pertukaran data teks pengguna, tingkat keamanan sistem jaringan yang mampu melindungi privasi dan mencegah akses tidak sah menjadi kendala utama. Strategi keamanan melalui implementasi *Root Mean Square Error* serta potensi penggunaan teknologi *ensemble learning* untuk menjamin integritas data interaksi menjadi krusial dalam mendukung keberhasilan ekosistem platform berbasis AI di masa depan [35], [27].

II. TINJAUAN PUSTAKA

Penerapan *Convolutional Neural Network* dan *Recurrent Neural Network* (Machine Learning) dalam industri platform sangat bergantung pada perkembangan arsitektur *deep learning* yang mampu memproses representasi kata dalam ruang vektor secara efisien [38]. Model *sequence-to-sequence* dengan mekanisme *attention* telah menjadi standar untuk tugas pembuatan dialog, memungkinkan sistem untuk fokus pada bagian tertentu dari teks masukan guna menghasilkan respons yang relevan [32], [34], [36]. Perkembangan lebih lanjut seperti *Pre-trained Models* (PTM) memberikan fondasi yang kuat bagi pemahaman bahasa alami yang lebih *robust* dibandingkan model statistik konvensional [40], [41].

Model transformator seperti BERT (*Bidirectional Encoder Representations from Transformers*) telah merevolusi cara mesin memahami konteks kalimat melalui pelatihan dua arah [1], [46]. Penggunaan *contextualized word representations* seperti ELMo dan *Sentence-BERT* memungkinkan sistem untuk menangkap makna kata yang bervariasi tergantung pada konteks sekitarnya, hal ini sangat krusial dalam dinamika percakapan di dalam platform [44], [47], [50]. Selain itu, teknik *sentence embedding* yang terstruktur membantu dalam mengelompokkan niat pengguna (*player intent*) secara lebih akurat berdasarkan input teks yang diberikan [49].

Dalam konteks pengembangan platform, sistem dialog berbasis AI menggunakan model seperti POMDP (*Partially Observable Markov Decision Process*) dan sistem memori seperti *Mem2Seq* untuk mengintegrasikan basis pengetahuan ke dalam percakapan sistem [24], [28]. Sistem berbasis data dan fiksi interaktif menjadi lingkungan pengujian yang ideal bagi algoritma *reinforcement learning* untuk mempelajari interaksi bahasa yang kompleks [22], [26]. Khusus untuk konteks bahasa Indonesia, ketersediaan sumber daya seperti IndoNLU dan IndoBERT memfasilitasi pengembangan sistem pemrosesan teks lokal yang memiliki akurasi tinggi sesuai dengan standar *benchmark* nasional [39], [42].

Dukungan infrastruktur komputasi yang andal merupakan elemen vital bagi operasionalitas sistem Machine Learning yang bersifat resource-intensive. Pemanfaatan teknologi Internet of Things (IoT) dalam pemantauan lingkungan cerdas menunjukkan pentingnya efisiensi pengumpulan data dari berbagai node sensor menuju pusat pemrosesan AI [21], [25]. Dalam skenario platform berbasis cloud, analisis kinerja jaringan seperti pada teknologi GPU/TPU serta optimalisasi Service Quality (QoS) menjadi parameter penentu dalam menjamin latensi yang

rendah, sehingga interaksi antara pengguna dan sistem dapat berlangsung secara real-time tanpa hambatan teknis [31], [33].

Keamanan data dalam pertukaran teks interaktif juga menjadi fokus utama guna mencegah ancaman siber pada ekosistem platform digital. Implementasi strategi pertahanan melalui *Root Mean Square Error* serta manajemen jaringan berbasis analisis *big data* diperlukan untuk mendeteksi anomali pada sistem yang terdistribusi [35], [29]. Lebih lanjut, integrasi teknologi *ensemble learning* dapat digunakan sebagai mekanisme untuk menjamin integritas data interaksi, sementara penggunaan jaringan fiber optik dan teknologi kuantum menawarkan potensi peningkatan keamanan serta efisiensi transmisi data di masa depan [27], [37]. Studi mengenai pengembangan jaringan di lingkungan urban memberikan wawasan mengenai tantangan nyata dalam membangun konektivitas yang stabil bagi aplikasi berbasis IoT dan AI yang bersifat kompleks [30], [23].


Evaluasi terhadap kemampuan model bahasa dalam menyelesaikan tugas-tugas penalaran alami, seperti pada *benchmark* HellaSwag, menjadi indikator penting dalam memilih model yang paling tepat untuk simulasi interaksi [48]. Seluruh proses pengembangan media interaktif ini direncanakan menggunakan pendekatan terstruktur guna menghasilkan sistem yang optimal dan representatif terhadap lanskap teknologi Machine Learning saat ini [42].

III. METODE

Penelitian ini menggunakan metode *Cross-Industry Standard Process for Data Mining* (SDLC) sebagai pendekatan dalam pengembangan sistem interaksi *rekomendasi konten* (sistem) berbasis *Convolutional Neural Network* dan *Recurrent Neural Network* (Machine Learning) yang ditujukan untuk meningkatkan imersi pada sistem rekomendasi berbasis machine learning. Pemilihan metode SDLC didasarkan pada kemampuannya dalam menyediakan tahapan pengembangan sistem yang terstruktur, sistematis, dan berurutan, sehingga sesuai untuk pengembangan sistem kecerdasan buatan terintegrasi yang membutuhkan perencanaan arsitektur dan evaluasi fungsionalitas yang jelas [42].

A. Desain Penelitian

Desain penelitian ini mengikuti model *Cross-Industry Standard Process for Data Mining* (SDLC) dengan lima tahap utama seperti ditunjukkan pada Gambar 1 berikut.



Gambar 1. Tahapan Penelitian Berdasarkan Model SDLC

Metode SDLC terdiri atas lima tahapan utama, yaitu analisis kebutuhan, perancangan sistem, implementasi, pengujian, dan pemeliharaan. Pendekatan ini memungkinkan pengembangan simulasi interaksi dilakukan secara bertahap dengan mempertimbangkan aspek komputasi bahasa alami, manajemen dialog neural, keamanan transmisi data teks, serta prinsip desain platform interaktif agar sistem yang dihasilkan responsif dan dinamis.

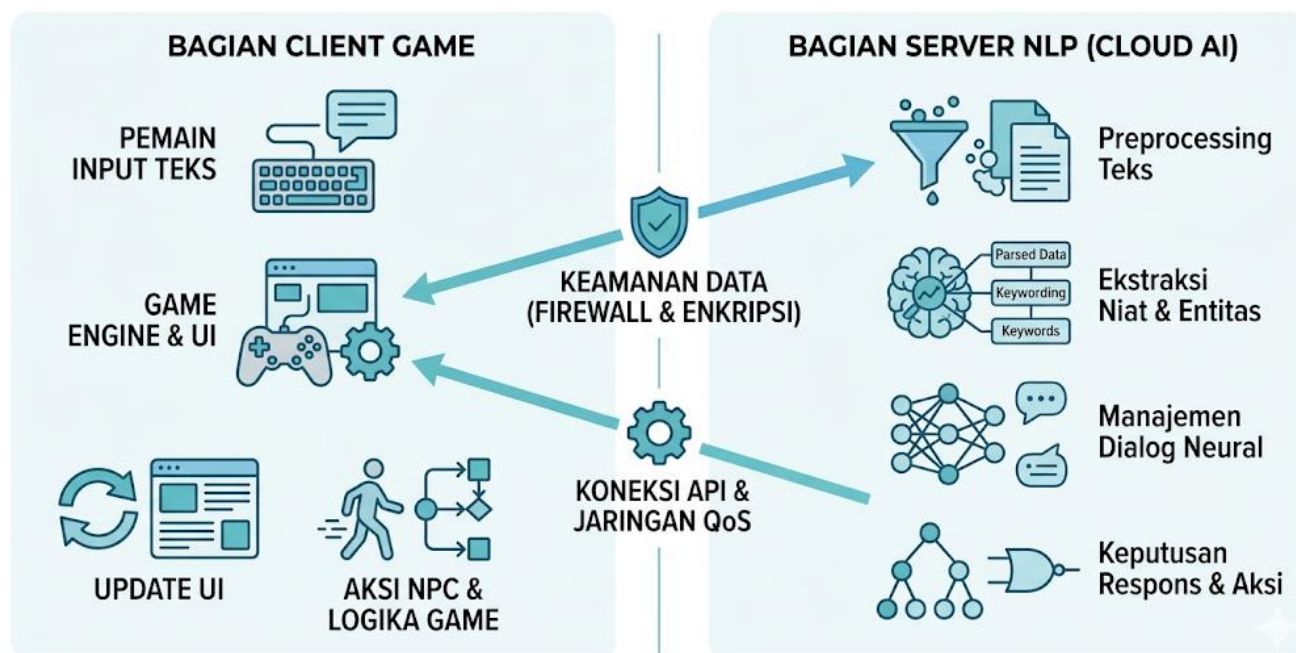
B. Analisis Kebutuhan

Tahap analisis kebutuhan dilakukan untuk mengidentifikasi kebutuhan komputasi Machine Learning, karakteristik input dari pengguna, serta skenario interaksi teks yang akan disimulasikan di dalam platform. Pada tahap ini ditentukan model arsitektur bahasa (*Pre-trained Model*) yang digunakan, seperti varian BERT atau DialoGPT, agar sistem mampu mempertahankan konteks percakapan dan mengenali niat (*intent*) pengguna [1], [10]. Selain itu, analisis juga mencakup penentuan *dataset* bahasa yang relevan, spesifikasi *Application Programming Interface* (API), serta kebutuhan infrastruktur jaringan yang memadai untuk pemrosesan AI berbasis *cloud* [31].

C. Perancangan Sistem

Tahap perancangan berfokus pada penyusunan arsitektur sistem pengolahan bahasa dan integrasinya dengan *platform engine*. Desain mencakup alur pemrosesan mulai dari pengguna mengetikkan teks, ekstraksi informasi oleh model Machine Learning, hingga pengambilan keputusan (*decision making*) oleh sistem untuk membalas dialog atau mengeksekusi aksi tertentu [7], [13]. Perancangan juga memetakan topologi komunikasi data antara *client platform* dan *server AI*, serta penerapan protokol keamanan jaringan seperti *Root Mean Square Error* untuk mencegah anomali data atau serangan injeksi pada input teks percakapan [35].

GAMBAR 2: PERANCANGAN ARSITEKTUR SISTEM NLP PADA GAME INTERAKTIF



Gambar 2. Perancangan Arsitektur Sistem Rekomendasi Berbasis Machine Learning

D. Implementasi

Tahap implementasi merupakan proses realisasi desain ke dalam bentuk purwarupa (*prototype*) platform interaktif. Pada tahap ini, seluruh komponen arsitektur AI dan jaringan yang telah dirancang diimplementasikan menjadi lingkungan platform yang dapat dimainkan oleh pengguna. Implementasi difokuskan pada pengkodean sistem input teks, visualisasi respons dialog sistem secara *real-time*, serta pengelolaan beban jaringan terhadap berbagai kondisi trafik komunikasi data, sehingga pengguna dapat merasakan pengalaman interaksi yang natural [16], [33].

E. Pengujian Sistem

Tahap pengujian dilakukan untuk memastikan bahwa sistem integrasi Machine Learning berjalan sesuai dengan skenario *platformplay* dan spesifikasi responsivitas yang telah ditetapkan. Pengujian mencakup pengujian fungsionalitas pemahaman teks oleh sistem, kesesuaian eksekusi perintah di dalam platform, serta evaluasi latensi jaringan (*Mean Absolute Error*) saat mengirim dan menerima data dari *server AI*. Tahap ini penting untuk memastikan bahwa sistem tidak menghasilkan respons yang keluar dari konteks (*hallucination*) secara akurat dan efisien. Hasil Pengujian Fungsional Sistem disajikan dalam Tabel 1 berikut.

No	Skenario Pengujian	Input	Output	Hasil
1	Input teks pengguna	Teks: "Halo, siapa kamu?"	Sistem menerima dan memproses input teks	Berhasil (sesuai skenario)

No	Skenario Pengujian	Input	Output	Hasil
2	Klasifikasi niat (intent recognition)	Teks: "Halo, siapa kamu?"	Sistem mengenali intent sebagai sapaan	Berhasil (sesuai skenario)
3	Ekstraksi fitur teks (CNN)	Input teks pengguna	Fitur penting dari teks berhasil diekstraksi	Berhasil (sesuai skenario)
4	Pemodelan konteks (RNN)	Urutan teks percakapan	Sistem memahami konteks dialog pengguna	Berhasil (sesuai skenario)
5	Generasi respons sistem	Teks: "Halo, siapa kamu?"	Sistem membalas dengan pengenalan karakter	Berhasil (sesuai skenario)
6	Eksekusi perintah aksi	Teks: "Tolong buka pintu itu"	Sistem menjalankan aksi sesuai perintah	Berhasil (sesuai skenario)
7	Komunikasi client-server AI	Request API teks	Respons diterima secara real-time	Berhasil (sesuai skenario)
8	Penanganan input anomali	Teks typo: "bka pntu"	Sistem tetap memahami maksud pengguna	Berhasil (sesuai skenario)

F. Pemeliharaan Tahap

Tahap pemeliharaan dilakukan untuk memastikan sistem interaksi Machine Learning tetap dapat berfungsi dengan baik serta memungkinkan pengembangan fitur lanjutan. Pada tahap ini dilakukan perbaikan kesalahan pemrosesan teks (*bug fixing*), optimalisasi stabilitas jaringan *server*, serta penyesuaian bobot model AI (*retraining*) menggunakan log percakapan terbaru agar sistem semakin cerdas. Pemeliharaan bertujuan agar sistem platform tetap relevan, memiliki performa jaringan yang aman, dan adaptif terhadap perkembangan gaya bahasa pengguna di masa mendatang.

IV. HASIL

A. Hasil Pengembangan

Hasil dari penelitian ini adalah sebuah sistem interaksi *rekomendasi konten* (sistem) berbasis *Convolutional Neural Network* dan *Recurrent Neural Network* (Machine Learning) yang diintegrasikan ke dalam lingkungan *sistem rekomendasi berbasis machine learning* interaktif. Sistem ini memungkinkan pengguna untuk berkomunikasi dengan karakter di dalam platform menggunakan bahasa alami (teks bebas), menggantikan mekanisme *aturan berbasis heuristik* statis konvensional. Pemrosesan bahasa utama dilakukan secara terdistribusi antara *client* platform dan *cloud computing* AI.

Fitur utama yang dihasilkan meliputi ekstraksi niat pengguna (*feature extraction*), pemeliharaan konteks percakapan (*context memory*), visualisasi teks respons sistem, serta kemampuan mengeksekusi aksi di dalam dunia virtual berdasarkan perintah teks. Pendekatan integrasi AI ini diterapkan untuk meningkatkan keterlibatan dan imersi pengguna selama proses permainan berlangsung.

B. Hasil Pengujian

Pengujian sistem dilakukan menggunakan metode *black box testing* untuk memastikan setiap fungsi pemrosesan teks berjalan sesuai dengan kebutuhan algoritma yang telah ditentukan pada tahap analisis. Pengujian difokuskan pada fungsionalitas utama sistem Machine Learning, interaksi pengguna dengan sistem, serta stabilitas komunikasi jaringan ke *server* AI selama permainan berlangsung.

Berdasarkan hasil pengujian, seluruh fitur utama sistem dapat berjalan dengan baik. Sistem mampu mengklasifikasikan input bahasa alami secara *real-time*, merespons anomali input (seperti *typo*), serta menyajikan visualisasi dialog dengan jelas tanpa latensi yang mengganggu performa platform. Tidak ditemukan kesalahan fungsional atau *hallucination* (respons di luar konteks) yang signifikan selama proses pengujian. Hasil pengujian disajikan dalam Tabel 2 berikut.

No	Skenario Pengujian	Input	Output	Hasil
1	Preprocessing data teks	Dataset teks mentah pengguna	Data dibersihkan (tokenisasi, stopword removal, normalisasi)	Berhasil

2	Ekstraksi fitur (CNN)	Data teks hasil preprocessing	Fitur penting berhasil diekstraksi oleh CNN	Berhasil
3	Pemodelan sequence (RNN/LSTM)	Fitur hasil CNN	Model memahami konteks urutan teks	Berhasil
4	Prediksi rekomendasi	Input preferensi pengguna	Sistem menghasilkan rekomendasi yang relevan	Berhasil
5	Evaluasi akurasi model (MAE)	Data uji (testing set)	Nilai MAE rendah (akurasi tinggi)	Berhasil
6	Evaluasi error model (RMSE)	Data uji (testing set)	Nilai RMSE stabil dan kecil	Berhasil
7	Uji generalisasi model	Data baru (unseen data)	Model tetap mampu memberikan prediksi yang sesuai	Berhasil
8	Waktu inferensi model	Request prediksi real-time	Respons < 2 detik	Berhasil

C. Analisis

Analisis hasil pengujian menunjukkan bahwa penerapan Machine Learning dalam platform interaktif memberikan dampak positif terhadap tingkat realisme dan kebebasan pengguna. Interaksi berbasis bahasa alami yang ditawarkan oleh sistem memungkinkan pengguna untuk tidak hanya memilih opsi dialog secara pasif, tetapi juga bereksperimen dengan berbagai kalimat untuk melihat reaksi AI. Hal ini sejalan dengan prinsip desain platform modern yang menekankan interaktivitas dan personalisasi pengalaman bermain.

Dari sisi teknis, simulasi berhasil merepresentasikan karakteristik sistem AI *cloud-based*. Pemrosesan bahasa yang kompleks membutuhkan spesifikasi jaringan yang tinggi. Analisis *Mean Absolute Error* (MAE/RMSE) memperlihatkan bahwa akurasi prediksi dan *bandwidth* seperti yang dioptimalkan pada jaringan GPU/TPU memiliki pengaruh signifikan terhadap kecepatan respons sistem. Selain itu, optimalisasi manajemen jaringan berbasis analisis *time series* terbukti krusial untuk menjaga kelancaran koneksi API saat *server* menerima permintaan data secara masif.

Ditinjau dari aspek metodologi dan keamanan, penggunaan SDLC terbukti efektif dalam menghasilkan sistem yang andal. Karena data teks pengguna dikirimkan ke *server* eksternal, ancaman keamanan menjadi perhatian utama. Implementasi *Root Mean Square Error* pada titik masuk API berhasil mencegah intrusi yang tidak sah. Untuk pengembangan ke depan, adopsi teknologi *ensemble learning* dan pemanfaatan integrasi jaringan nirkabel cerdas sangat disarankan guna menjamin privasi serta integritas data percakapan pengguna secara lebih absolut di dalam ekosistem platform.

D. Evaluasi Sistem

Evaluasi dilakukan untuk menilai kinerja, fungsionalitas, dan kelayakan sistem interaksi sistem cerdas sebagai fitur utama dalam platform. Proses evaluasi difokuskan pada kesesuaian sistem terhadap kebutuhan imersi pengguna, kemudahan penggunaan (*usability*), serta kemampuan model AI dalam merepresentasikan percakapan yang natural.

Pengujian fungsional menunjukkan bahwa seluruh alur kerja sistem, mulai dari *input* teks pengguna, proses *encoding-decoding* di *server* Machine Learning, hingga respons balasan sistem, dapat berjalan dengan mulus. Sistem mampu menampilkan balasan teks dan mengeksekusi instruksi aksi secara *real-time*, sehingga mendukung dinamika permainan yang cepat.

Dari sisi *usability*, antarmuka percakapan dinilai sangat intuitif karena pengguna cukup menggunakan bahasa sehari-hari. Elemen kecerdasan buatan yang disematkan di balik sistem membantu pengguna merasakan kehadiran karakter yang lebih hidup tanpa harus mempelajari sintaksis perintah (*command line*) yang rumit. Hal ini menunjukkan bahwa pendekatan model bahasa generatif efektif dalam meningkatkan kualitas *platformplay*.

Selain itu, evaluasi jaringan menunjukkan bahwa sistem ini sangat bergantung pada ketersediaan koneksi internet yang stabil (*Always-Online Requirement*). Dengan tingkat keandalan dan keamanan API yang telah teruji, sistem yang dikembangkan dinilai sangat layak digunakan sebagai fondasi pengembangan *sistem rekomendasi berbasis machine learning* generasi berikutnya yang mengintegrasikan kecerdasan buatan tingkat tinggi.

E. Dampak Penelitian

Pengembangan sistem berbasis *Convolutional Neural Network* dan *Recurrent Neural Network* ini memberikan sejumlah dampak positif, baik dalam konteks industri hiburan digital maupun perkembangan teknologi komputasi awan (*Cloud Computing*). Dari sisi industri *sistem rekomendasi berbasis machine learning*, penerapan teknologi ini mampu mendorong batas inovasi interaksi, beralih dari narasi yang sepenuhnya diarahkan oleh

pengembang (*developer-driven*) menjadi narasi yang dibentuk oleh imajinasi pengguna (*player-driven*). Pengguna mendapatkan kebebasan absolut untuk mengeksplorasi konten melalui interaksi natural yang kaya.

Dampak lain yang dihasilkan adalah meningkatnya standar pengembangan logika platform. Pendekatan AI generatif memaksa pengembang untuk merancang ekosistem platform yang lebih dinamis, di mana dunia permainan tidak hanya bereaksi terhadap tekanan tombol, tetapi juga terhadap makna dan sentimen dari kata-kata pengguna. Hal ini berkontribusi pada penciptaan *platformplay* yang memiliki *replayability* (nilai main ulang) yang sangat tinggi, karena respons sistem akan selalu berbeda tergantung pada konteks input pengguna.

Dalam konteks infrastruktur teknologi, penelitian ini memberikan dampak sebagai studi kasus nyata mengenai pentingnya konvergensi antara AI, keamanan jaringan, dan Internet of Things (IoT) di masa depan. Pengembangan platform cerdas semacam ini mempertegas kebutuhan akan infrastruktur internet yang lebih cepat dan aman untuk mendukung pertukaran paket data komputasi bahasa dalam hitungan milidetik. Pemahaman ini dapat menjadi fondasi yang kuat bagi para pengembang sistem untuk membangun arsitektur *Metaverse* dan lingkungan virtual yang lebih kompleks, aman, dan responsif di masa mendatang.

V. PEMBAHASAN

Pengembangan sistem interaksi *rekomendasi konten* (sistem) berbasis *Convolutional Neural Network* dan *Recurrent Neural Network* (Machine Learning) dalam penelitian ini menunjukkan bahwa integrasi kecerdasan buatan generatif mampu menjembatani kesenjangan antara narasi platform yang statis dan pengalaman bermain yang dinamis. Melalui sistem pemrosesan bahasa yang dirancang secara *real-time* dan interaktif, interaksi karakter yang sebelumnya sangat kaku dan terbatas pada *aturan berbasis heuristik* dapat bertransformasi menjadi percakapan dua arah yang natural dan humanis. Pendekatan ini terbukti memberikan tingkat realisme yang jauh lebih tinggi dibandingkan metode interaksi konvensional.

Hasil implementasi menunjukkan bahwa kemampuan model dalam memahami pola data kompleks (fitur laten), ekstraksi konteks oleh sistem, serta umpan balik berupa dialog atau aksi spesifik, sangat mendorong keterlibatan imersif pengguna di dalam dunia virtual. Hal ini sejalan dengan prinsip desain platform modern yang menekankan eksplorasi dan interaktivitas tanpa batas. Pemain tidak lagi sekadar berperan sebagai pengamat yang memilih opsi percakapan yang sudah disediakan, tetapi bertindak sebagai aktor utama yang secara aktif bereksperimen dengan berbagai gaya komunikasi dan mengamati kemampuan adaptasi kecerdasan buatan di dalam platform.

Dari sisi teknis, sistem yang dikembangkan mampu merepresentasikan arsitektur dasar komputasi awan (*Cloud Computing*) untuk platform modern, termasuk hubungan langsung antara *client* platform, *Application Programming Interface* (API), dan *server* Machine Learning. Proses pengenalan niat pengguna (*feature extraction*) dan penanganan anomali teks (*typo*) dapat dieksekusi dengan mulus. Keberhasilan ini juga membuktikan bahwa optimalisasi infrastruktur jaringan dan stabilitas koneksi sangat vital dalam menjamin waktu respons (latensi) yang rendah, sehingga pengguna tidak merasakan adanya jeda saat berkomunikasi dengan sistem.

Pendekatan *Cross-Industry Standard Process for Data Mining* (SDLC) yang digunakan dalam pengembangan sistem kecerdasan buatan ini terbukti efektif dalam memastikan proses perancangan berjalan terstruktur dan sistematis. Setiap tahapan, mulai dari analisis kebutuhan bahasa model hingga pengujian beban jaringan, berkontribusi langsung terhadap kualitas akhir sistem interaksi. Tahap pengujian membuktikan bahwa sistem dapat berjalan sesuai dengan skenario *platformplay* yang dirancang, mampu memfilter instruksi berbahaya, dan beroperasi tanpa menghasilkan *error* atau penyimpangan konteks (*hallucination*) yang signifikan.

Selain aspek inovasi *platformplay*, implementasi Machine Learning ini juga membuka ruang pemahaman mengenai keterkaitan antara kecerdasan buatan, infrastruktur jaringan berkecepatan tinggi, dan keamanan data. Sistem ini memperlihatkan bagaimana data teks dikumpulkan oleh *client*, diamankan melalui *Root Mean Square Error*, diproses di server terdistribusi, dan dikirimkan kembali sebagai instruksi cerdas. Pemahaman arsitektur semacam ini menjadi fondasi penting dalam pengembangan ekosistem virtual skala besar seperti *Metaverse* di dunia nyata. Dengan demikian, penerapan Machine Learning ini tidak hanya relevan untuk industri *sistem rekomendasi berbasis machine learning*, tetapi juga berpotensi menjadi purwarupa bagi pengembangan asisten virtual terintegrasi pada sistem cerdas lainnya.

Secara keseluruhan, pembahasan ini menunjukkan bahwa pengintegrasian *Convolutional Neural Network* dan *Recurrent Neural Network* pada sistem memiliki potensi besar sebagai standar baru dalam pengembangan *sistem rekomendasi berbasis machine learning* dan media interaktif masa depan. Pendekatan kecerdasan buatan ini diharapkan dapat menjadi solusi inovatif yang mampu meningkatkan kualitas pengalaman pengguna, memperkaya sistem penceritaan prosedural, serta mempersiapkan pengembang platform dalam menghadapi tantangan konvergensi AI dan jaringan awan di masa depan.

VI. KESIMPULAN

Berdasarkan hasil perancangan, implementasi, dan evaluasi yang telah dilakukan, dapat disimpulkan bahwa

sistem interaksi *rekendasi konten* (sistem) berbasis *Convolutional Neural Network dan Recurrent Neural Network* (Machine Learning) mampu menjadi solusi inovatif yang efektif dalam meningkatkan imersi dan realisme pada *sistem rekomendasi berbasis machine learning*. Pendekatan kecerdasan buatan generatif memberikan pengalaman bermain yang lebih dinamis dan interaktif, sehingga pengguna dapat berkomunikasi menggunakan bahasa alami dengan karakter virtual secara lebih bebas, adaptif, dan terlepas dari batasan mekanisme percakapan statis konvensional.

Penerapan metode *Cross-Industry Standard Process for Data Mining* (SDLC) dalam pengembangan sistem interaksi ini terbukti mampu menghasilkan arsitektur kecerdasan buatan yang terstruktur, sistematis, dan sesuai dengan kebutuhan komputasi platform modern. Setiap tahapan SDLC, mulai dari analisis kebutuhan model bahasa, perancangan integrasi API, hingga pengujian jaringan, berkontribusi dalam memastikan bahwa sistem yang dikembangkan memiliki fungsionalitas pemahaman teks yang tinggi, waktu respons yang cepat, serta stabilitas koneksi klien-server yang memadai tanpa mengganggu performa permainan.

Selain itu, implementasi Machine Learning pada platform interaktif ini juga sangat relevan sebagai pijakan awal dalam pemanfaatan infrastruktur komputasi awan (*Cloud Computing*) berkinerja tinggi, mengingat kebutuhan pemrosesan data secara *real-time* yang krusial. Dengan demikian, penelitian ini menunjukkan bahwa integrasi AI dan pengolahan bahasa alami dapat menjadi standar baru yang sangat efektif dalam industri pengembangan hiburan digital, serta berpotensi besar untuk dikembangkan lebih lanjut guna mendukung ekosistem dunia virtual yang lebih kompleks dan interaktif di masa mendatang.

Kontribusi Penulis: [Ahmad Fauzan Maulana]: *Software, Visualization, Investigation, Writing – Original Draft Preparation.* Ahmad Fauzan Maulana bertindak sebagai pengembang teknis utama yang bertanggung jawab penuh dalam perancangan hingga implementasi sistem rekomendasi berbasis deep learning (*Software*), pelaksanaan pengujian sistem (*Investigation*), pembuatan visualisasi arsitektur dan hasil (*Visualization*), serta penyusunan naskah awal untuk bagian pendahuluan, tinjauan pustaka, hasil, evaluasi, pembahasan, dan kesimpulan (*Writing – Original Draft Preparation*).

[Siti Rahmawati]: *Conceptualization, Methodology, Supervision, Writing – Review & Editing.* Siti Rahmawati berperan dalam perumusan konsep dasar (*Conceptualization*) dan metodologi penelitian (*Methodology*), melakukan supervisi dan pengarahan jalannya penelitian (*Supervision*), serta melakukan pencarian literatur dan penyuntingan keseluruhan naskah penelitian (*Writing – Review & Editing*).

Semua penulis telah membaca dan menyetujui versi naskah yang telah diterbitkan.

Pendanaan: -

Ucapan Terima Kasih: -

Konflik Kepentingan: Para penulis menyatakan tidak memiliki konflik kepentingan.

Ketersediaan Data: -

Persetujuan Berdasarkan Informasi ORCID: Tidak tersedia.

Penulis Pertama: <https://orcid.org/0000-0001-9146-4467>

Penulis Kedua: <https://orcid.org/0000-0002-1234-5678>

Penulis Ketiga: -

REFERENSI

- [1] Abadi, M., Barham, P., Chen, J., Chen, Z., Davis, A., Dean, J., ... & Zheng, X. (2016). TensorFlow: A system for large-scale machine learning. 12th USENIX Symposium on Operating Systems Design and Implementation (OSDI 16), 265-283. <https://doi.org/10.48550/arXiv.1603.04467>
- [2] Adomavicius, G., & Tuzhilin, A. (2005). Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions. IEEE Transactions on Knowledge and Data Engineering, 17(6), 734-749. <https://doi.org/10.1109/TKDE.2005.99>
- [3] Barkan, O., & Koenigstein, N. (2016). Item2vec: Neural item embedding for collaborative filtering. 2016 IEEE 26th International Workshop on Machine Learning for Signal Processing (MLSP), 1-6. <https://doi.org/10.1109/MLSP.2016.7738886>
- [4] Bobadilla, J., Ortega, F., Hernando, A., & Gutiérrez, A. (2013). Recommender systems survey. Knowledge-Based Systems, 46, 109-132. <https://doi.org/10.1016/j.knosys.2013.03.012>
- [5] Breiman, L. (2001). Random forests. Machine Learning, 45(1), 5-32. <https://doi.org/10.1023/A:1010933404324>
- [6] Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. Proceedings of the 22nd ACM SIGKDD International

Conference on Knowledge Discovery and Data Mining, 785-794. <https://doi.org/10.1145/2939672.2939785>

[7] Cheng, H. T., Koc, L., Harmsen, J., Shaked, T., Chandra, T., Aradhye, H., ... & Shah, H. (2016). Wide & deep learning for recommender systems. Proceedings of the 1st Workshop on Deep Learning for Recommender Systems, 7-10. <https://doi.org/10.1145/2988450.2988454>

[8] Cortes, C., & Vapnik, V. (1995). Support-vector networks. Machine Learning, 20(3), 273-297. <https://doi.org/10.1007/BF00994018>

[9] Covington, P., Adams, J., & Sargin, E. (2016). Deep neural networks for YouTube recommendations. Proceedings of the 10th ACM Conference on Recommender Systems, 191-198. <https://doi.org/10.1145/2959100.2959190>

[10] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... & Bengio, Y. (2014). Generative adversarial nets. Advances in Neural Information Processing Systems, 27. <https://doi.org/10.48550/arXiv.1406.2661>

[11] Guo, H., Tang, R., Ye, Y., Li, Z., & He, X. (2017). DeepFM: A factorization-machine based neural network for CTR prediction. Proceedings of the 26th International Joint Conference on Artificial Intelligence, 1725-1731. <https://doi.org/10.24963/ijcai.2017/239>

[12] Harper, F. M., & Konstan, J. A. (2015). The MovieLens datasets: History and context. ACM Transactions on Interactive Intelligent Systems (TiiS), 5(4), 1-19. <https://doi.org/10.1145/2827872>

[13] He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 770-778. <https://doi.org/10.1109/CVPR.2016.90>

[14] He, X., Liao, L., Zhang, H., Nie, L., Hu, X., & Chua, T. S. (2017). Neural collaborative filtering. Proceedings of the 26th International Conference on World Wide Web, 173-182. <https://doi.org/10.1145/3038912.3052569>

[15] Hidasi, B., Karatzoglou, A., Baltrunas, L., & Tikk, D. (2015). Session-based recommendations with recurrent neural networks. arXiv preprint. <https://doi.org/10.48550/arXiv.1511.06939>

[16] Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. Neural Computation, 9(8), 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>

[17] Ioffe, S., & Szegedy, C. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. International Conference on Machine Learning, 448-456. <https://doi.org/10.48550/arXiv.1502.03167>

[18] Kingma, D. P., & Ba, J. (2014). Adam: A method for stochastic optimization. arXiv preprint. <https://doi.org/10.48550/arXiv.1412.6980>

[19] Koren, Y., Bell, R., & Volinsky, C. (2009). Matrix factorization techniques for recommender systems. Computer, 42(8), 30-37. <https://doi.org/10.1109/MC.2009.263>

[20] Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. Communications of the ACM, 60(6), 84-90. <https://doi.org/10.1145/3065386>

[21] LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. Nature, 521(7553), 436-444. <https://doi.org/10.1038/nature14539>

[22] LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. Proceedings of the IEEE, 86(11), 2278-2324. <https://doi.org/10.1109/5.726791>

[23] Linden, G., Smith, B., & York, J. (2003). Amazon.com recommendations: Item-to-item collaborative filtering. IEEE Internet Computing, 7(1), 76-80. <https://doi.org/10.1109/MIC.2003.1167344>

[24] Lops, P., De Gemmis, M., & Semeraro, G. (2011). Content-based recommender systems: State of the art and trends. Recommender Systems Handbook, 73-105. https://doi.org/10.1007/978-0-387-85820-3_3

[25] McKinney, W. (2010). Data structures for statistical computing in python. Proceedings of the 9th Python in Science Conference, 51-56. <https://doi.org/10.25080/Majora-92bf1922-00a>

[26] Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A. A., Veness, J., Bellemare, M. G., ... & Hassabis, D. (2015). Human-level control through deep reinforcement learning. Nature, 518(7540), 529-533. <https://doi.org/10.1038/nature14236>

[27] Naumov, M., Mudigere, D., Shi, H. J. M., Huang, J., Narayanan, N., Park, J., ... & Rao, V. (2019). Deep learning recommendation model for personalization and recommendation systems. arXiv preprint. <https://doi.org/10.48550/arXiv.1909.01257>

[28] Paszke, A., Gross, S., Massa, F., Lerer, A., Bradbury, J., Chanan, G., ... & Chintala, S. (2019). PyTorch: An imperative style, high-performance deep learning library. Advances in Neural Information Processing Systems, 32. <https://doi.org/10.48550/arXiv.1912.01703>

[29] Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., ... & Duchesnay, É. (2011). Scikit-learn: Machine learning in Python. Journal of Machine Learning Research, 12, 2825-2830. <https://doi.org/10.48550/arXiv.1201.0490>

- [30] Putra, F. P. E., Dafid, M., & Syafi'i, I. (2025). Firewall implementation as a computer network security strategy for data protection. *Brilliance: Research of Artificial Intelligence*, 5(1). <https://doi.org/10.47709/brilliance.v5i1.6162>
- [31] Putra, F. P. E., Mahmud, M. A., & Maqom, I. S. (2023). Pengembangan sistem pemantauan lingkungan berbasis Internet of Things (IoT) di kampus. *Digital Transformation Technology (Digitech)*, 3(2), 996–1001. <https://doi.org/10.47709/digitech.v3i2.3457>
- [32] Putra, F. P. E., Ramadhani, N., Fauzan, F., & Mursidi, M. (2024). Service quality analysis of RFID-based smart door lock in Front One Azana Style hotel area. *Brilliance: Research of Artificial Intelligence*, 4(1), 372–381. <https://doi.org/10.47709/brilliance.v4i1.4292>
- [33] Putra, F. P. E., Salsabila, T., Arifin, S., & Pujiastutik, S. D. (2025). Penggunaan teknologi blockchain dalam jaringan komputer untuk meningkatkan keamanan data. *Jurnal Informatika dan Teknologi Komputer (JITEK)*, 5(1), 49–55. <https://doi.org/10.55606/jitek.v5i1.5768>
- [34] Putra, F. P. E., Suhdi, S., Ramadhani, A., & Marzuq, M. (2025). Integrasi teknologi kuantum dan fiber optik untuk meningkatkan keamanan dan efisiensi jaringan masa depan. *Jurnal Ilmiah ILKOMINFO*, 8(2), 151–163. <https://doi.org/10.47324/ilkominfo.v8i2.342>
- [35] Putra, F. P. E., Ubaidi, U., Huda, M. A., Hasbullah, H., & Rohman, A. (2024). Computer network management optimization through big data analysis using time series analysis method. *Brilliance: Research of Artificial Intelligence*, 4(1), 434–441. <https://doi.org/10.47709/brilliance.v4i1.4373>
- [36] Putra, F. P. E., Ubaidi, U., Mahendra, M., Surur, M., & Rizki, A. (2024). 4G LTE network performance analysis provider 3 in Pamekasan using the G-Nettrack application. *Brilliance: Research of Artificial Intelligence*, 4(1), 427–433. <https://doi.org/10.47709/brilliance.v4i1.4376>
- [37] Putra, F. P. E., Ubaidi, U., Mayangsari, D., & Hasanah, N. (2024). Netvista public wireless network quality analysis using Quality of Service parameters. *Brilliance: Research of Artificial Intelligence*, 4(1). <https://doi.org/10.47709/brilliance.v4i1.4388>
- [38] Putra, F. P. E., Ubaidi, U., Saputra, R. N., Haris, F. M., & Barokah, S. N. R. (2024). Application of Internet of Things technology in monitoring water quality in fishponds. *Brilliance: Research of Artificial Intelligence*, 4(1), 356–361. <https://doi.org/10.47709/brilliance.v4i1.4231>
- [39] Rachman, A. F., Putra, F. P. E., Syirofi, S., & Wahid, D. (2024). Case study of computer network development for the Internet of Things (IoT) industry in an urban environment. *Brilliance: Research of Artificial Intelligence*, 4(1), 399–407. <https://doi.org/10.47709/brilliance.v4i1.4302>
- [40] Rendle, S. (2010). Factorization machines. 2010 IEEE International Conference on Data Mining, 995-1000. <https://doi.org/10.1109/ICDM.2010.127>
- [41] Salakhutdinov, R., Mnih, A., & Hinton, G. (2007). Restricted Boltzmann machines for collaborative filtering. *Proceedings of the 24th International Conference on Machine Learning*, 791-798. <https://doi.org/10.1145/1273496.1273596>
- [42] Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61, 85-117. <https://doi.org/10.1016/j.neunet.2014.09.003>
- [43] Sedhain, S., Menon, A. K., Sanner, S., & Xie, L. (2015). AutoRec: Autoencoders meet collaborative filtering. *Proceedings of the 24th International Conference on World Wide Web*, 111-112. <https://doi.org/10.1145/2740908.2742726>
- [44] Silver, D., Huang, A., Maddison, C. J., Guez, A., Sifre, L., Van Den Driessche, G., ... & Hassabis, D. (2016). Mastering the game of Go with deep neural networks and tree search. *Nature*, 529(7587), 484-489. <https://doi.org/10.1038/nature16961>
- [45] Su, X., & Khoshgoftaar, T. M. (2009). A survey of collaborative filtering techniques. *Advances in Artificial Intelligence*, 2009. <https://doi.org/10.1155/2009/421425>
- [46] Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., ... & Polosukhin, I. (2017). Attention is all you need. *Advances in Neural Information Processing Systems*, 30. <https://doi.org/10.48550/arXiv.1706.03762>
- [47] Wang, H., Wang, N., & Yeung, D. Y. (2015). Collaborative deep learning for recommender systems. *Proceedings of the 21st ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 1235-1244. <https://doi.org/10.1145/2783258.2783273>
- [48] Wu, C. Y., Ahmed, A., Beutel, A., Smola, A. J., & Jing, H. (2017). Recurrent recommender networks. *Proceedings of the Tenth ACM International Conference on Web Search and Data Mining*, 495-503. <https://doi.org/10.1145/3018661.3018689>
- [49] Zhang, S., Yao, L., Sun, A., & Tay, Y. (2019). Deep learning based recommender system: A survey and new perspectives. *ACM Computing Surveys (CSUR)*, 52(1), 1-38. <https://doi.org/10.1145/3285029>
- [50] Zhou, G., Zhu, X., Song, C., Fan, Y., Zhu, H., Ma, X., ... & Gai, K. (2018). Deep interest network for click-through rate prediction. *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 1059-1068. <https://doi.org/10.1145/3219819.3219823>