



## Model Chatbot Generatif Berdasarkan Jaringan Saraf Dalam Dengan Optimasi Hiperparameter Untuk Layanan Pelanggan

Vika Fransisca

Institut Prima Bangsa, Indonesia

Email: vikafransisca1704@gmail.com

Naskah diterima:

Direvisi: Tanggal publikasi:

### KEYWORDS

generative chatbots, deep neural networks, hyperparameter optimization, customer service.

### ABSTRACT

The development of artificial intelligence technology has driven the transformation of customer service through the implementation of generative chatbots. However, the main challenge in their development is selecting the right model architecture and hyperparameter tuning to achieve optimal performance. This study aims to design a Deep Neural Network (DNN)-based chatbot model with hyperparameter optimization using Bayesian Optimization techniques. Using a qualitative approach, data was collected through in-depth interviews with 15 AI developers and system analysts, technical documentation from 5 technology companies, and implementation observations across 3-month deployment periods. The results show a 34% increase in response accuracy (from 72% to 96%), a 24% decrease in average response latency (from 2.8s to 2.1s), and an improvement in user satisfaction scores from 6.8/10 to 8.9/10 after the model optimization. The developed chatbot is able to provide more relevant, responsive, and efficient interactions in the context of customer service. Practical implications of this study include improving operational effectiveness and the quality of customer experience, as well as providing technical guidance for developers of similar AI systems. This study also highlights the importance of an integrative approach between technology and user-based evaluation to produce adaptive and strategic chatbot models.

### KATA KUNCI

chatbot generatif, jaringan saraf dalam, pengoptimalan hiperparameter, layanan pelanggan.

### ABSTRAK

Perkembangan teknologi kecerdasan buatan telah mendorong transformasi layanan pelanggan melalui penerapan chatbot generatif. Namun, tantangan utama dalam pengembangannya adalah memilih arsitektur model yang tepat dan penyetelan hiperparameter untuk mencapai kinerja yang optimal. Penelitian ini bertujuan untuk merancang model chatbot berbasis Deep Neural Network (DNN) dengan optimasi hiperparameter menggunakan teknik Bayesian Optimization. Dengan pendekatan kualitatif, data dikumpulkan melalui wawancara mendalam dengan 15 pengembang AI dan analisis sistem, dokumentasi teknis dari 5 perusahaan teknologi, dan observasi implementasi selama periode deployment 3 bulan. Hasilnya menunjukkan peningkatan akurasi respons sebesar 34% (dari 72% menjadi 96%), penurunan latensi respons rata-rata sebesar 24% (dari 2,8 detik menjadi 2,1 detik), serta peningkatan skor kepuasan pengguna dari 6,8/10 menjadi 8,9/10 setelah model dioptimalkan. Chatbot yang dikembangkan mampu memberikan interaksi yang lebih relevan, responsif, dan efisien dalam konteks layanan pelanggan. Implikasi praktis dari penelitian ini termasuk meningkatkan efektivitas operasional dan kualitas pengalaman pelanggan, serta memberikan panduan teknis bagi pengembang sistem AI serupa. Penelitian ini juga menyoroti pentingnya pendekatan integratif antara teknologi dan evaluasi berbasis pengguna untuk menghasilkan model chatbot adaptif dan strategis.

## PENDAHULUAN

Perkembangan teknologi digital telah mendorong transformasi yang signifikan dalam interaksi antara perusahaan dan pelanggan, terutama melalui penggunaan chatbots. Chatbot

## **Model Chatbot Generatif Berdasarkan Jaringan Saraf Dalam Dengan Optimasi Hiperparameter Untuk Layanan Pelanggan**

generatif, didukung oleh kemajuan dalam pembelajaran mendalam dan pemrosesan bahasa alami, memungkinkan perusahaan untuk memberikan layanan pelanggan yang responsif dan dipersonalisasi. Teknologi ini tidak hanya meningkatkan efisiensi operasional tetapi juga memperkuat kepuasan pelanggan melalui interaksi yang lebih alami dan kontekstual. Menurut Boston Consulting Group (2023), menerapkan AI generatif dalam layanan pelanggan dapat meningkatkan produktivitas secara signifikan. Selain itu, sebuah studi oleh FastBots.ai (2023) menunjukkan bahwa chatbot generatif mampu mengubah interaksi layanan pelanggan menjadi lebih efektif. Namun, adopsi teknologi ini juga menimbulkan tantangan baru, terutama dalam hal keamanan data dan akurasi respons. Oleh karena itu, diperlukan pendekatan yang cermat dalam pengembangan dan implementasi chatbot generatif untuk memastikan implementasinya yang sukses.

Deep Neural Network (DNN) telah menjadi fondasi dalam pengembangan chatbot generatif. Arsitektur seperti Long Short-Term Memory (LSTM) dan Transformer memungkinkan model untuk memahami konteks percakapan dan menghasilkan respons yang relevan. Namun, kompleksitas arsitektur ini membutuhkan pendekatan yang cermat dalam pemilihan dan penyetelan hiperparameter untuk mencapai kinerja yang optimal. Studi oleh Zhang et al. (2019) menunjukkan bahwa optimasi hiperparameter dapat secara signifikan meningkatkan kinerja model DNN. Selain itu, penelitian oleh Snoek et al. (2012) menekankan pentingnya pendekatan sistematis dalam pengoptimalan hiperparameter untuk model pembelajaran mesin. Dalam konteks chatbots, memilih hiperparameter yang tepat dapat meningkatkan kualitas respons dan kepuasan pengguna. Oleh karena itu, integrasi antara arsitektur DNN dan strategi pengoptimalan hiperparameter adalah kunci dalam mengembangkan chatbot generatif yang efektif.

Salah satu tantangan utama dalam mengembangkan chatbot berbasis DNN adalah pengoptimalan hiperparameter, yang mencakup penyesuaian jumlah neuron, lapisan tersembunyi, fungsi aktivasi, dan algoritme pengoptimalan. Pemilihan hiperparameter yang tidak tepat dapat menyebabkan overfitting atau underfitting, yang berdampak negatif pada kualitas respons chatbot. Menurut Hutter et al. (2011), pendekatan tradisional seperti pencarian grid seringkali tidak efisien dalam menemukan kombinasi hiperparameter yang optimal. Sebaliknya, pendekatan seperti Optimasi Bayesian telah terbukti lebih efektif dalam menemukan konfigurasi hiperparameter yang optimal dengan jumlah evaluasi yang lebih sedikit. Namun, penerapan teknik ini dalam konteks chatbot masih terbatas dan membutuhkan penelitian lebih lanjut. Selain itu, variabilitas dalam data percakapan dan kebutuhan pengguna tertentu menambah kompleksitas pada proses pengoptimalan. Oleh karena itu, diperlukan strategi optimasi yang adaptif dan efisien untuk meningkatkan kinerja chatbot generatif.

Urgensi dari penelitian ini terletak pada kebutuhan untuk meningkatkan kualitas layanan pelanggan melalui chatbot yang lebih cerdas dan adaptif. Dengan meningkatnya ekspektasi pelanggan akan layanan yang cepat dan akurat, perusahaan harus mengadopsi solusi teknologi yang mampu memenuhi kebutuhan tersebut. Chatbot generatif yang dioptimalkan dengan baik dapat menjadi alat strategis dalam mencapai tujuan ini. Menurut IBM (2024), AI generatif memiliki potensi besar dalam meningkatkan produktivitas dan mempersonalisasi layanan pelanggan. Selain itu, sebuah studi oleh Ada.cx (2023) menunjukkan bahwa 85% eksekutif percaya bahwa AI generatif akan berinteraksi langsung dengan pelanggan dalam dua tahun ke depan. Namun, untuk memaksimalkan potensi ini, diperlukan penelitian mendalam tentang pengembangan dan optimasi chatbot generatif. Penelitian ini diharapkan dapat memberikan kontribusi yang signifikan di bidang ini.

## **Model Chatbot Generatif Berdasarkan Jaringan Saraf Dalam Dengan Optimasi Hiperparameter Untuk Layanan Pelanggan**

Penelitian sebelumnya telah mengeksplorasi berbagai pendekatan untuk pengembangan chatbot, termasuk penggunaan model seq2seq dan mekanisme perhatian. Namun, masih ada kesenjangan dalam penerapan sistematis dan terintegrasi teknik optimasi hiperparameter dalam pengembangan chatbot generatif. Beberapa penelitian menunjukkan bahwa pendekatan seperti Pengoptimalan Bayesian dapat meningkatkan kinerja model, tetapi penerapannya dalam konteks chatbot masih terbatas. Studi oleh Bergstra et al. (2011) menekankan pentingnya algoritma optimasi hiperparameter dalam meningkatkan kinerja model pembelajaran mesin. Selain itu, penelitian oleh Snoek et al. (2012) menunjukkan bahwa Optimasi Bayesian dapat secara signifikan meningkatkan efisiensi dan efektivitas proses optimasi. Namun, penerapan teknik ini dalam pengembangan chatbot generatif masih membutuhkan eksplorasi lebih lanjut. Oleh karena itu, penelitian ini bertujuan untuk mengisi kesenjangan tersebut dengan mengintegrasikan teknik optimasi hiperparameter dalam pengembangan chatbot generatif berbasis DNN.

Kebaruan dari penelitian ini terletak pada integrasi metode optimasi hiperparameter canggih dalam pengembangan chatbot generatif berbasis DNN untuk layanan pelanggan. Secara spesifik, penelitian ini mengembangkan kerangka kerja sistematis yang mengombinasikan Bayesian Optimization dengan evaluasi berbasis pengguna dalam konteks real-time deployment, yang membedakannya dari studi sebelumnya yang hanya menguji pada dataset benchmark. Selain itu, penelitian ini memperkenalkan pendekatan hybrid yang mengintegrasikan metrik kinerja teknis (akurasi, latensi) dengan evaluasi kualitatif mendalam dari perspektif developer dan end-user, menciptakan framework evaluasi holistik yang belum banyak dieksplorasi dalam literatur chatbot berbasis DNN. Dengan menggabungkan teknik optimasi seperti Bayesian Optimization dan Random Search, penelitian ini bertujuan untuk meningkatkan akurasi dan relevansi respons chatbot. Pendekatan ini diharapkan dapat mengisi kesenjangan dalam literatur dan praktik pengembangan chatbot saat ini. Selain itu, penelitian ini juga akan mengevaluasi efektivitas berbagai teknik optimasi hiperparameter dalam konteks chatbot generatif. Dengan demikian, penelitian ini tidak hanya memberikan kontribusi teoritis tetapi juga praktis dalam pengembangan chatbot generatif yang lebih efektif dan efisien. Diharapkan hasil penelitian ini dapat menjadi acuan bagi pengembang dan peneliti dalam menerapkan strategi optimasi hiperparameter dalam mengembangkan chatbot generatif. Dengan demikian, penelitian ini berpotensi memberikan dampak yang signifikan di bidang layanan pelanggan berbasis AI.

Tujuan dari penelitian ini adalah untuk merancang dan mengembangkan model chatbot generatif berbasis Deep Neural Network yang dioptimalkan melalui teknik optimasi hiperparameter untuk meningkatkan kualitas layanan pelanggan. Penelitian ini juga bertujuan untuk mengevaluasi efektivitas berbagai teknik optimasi hiperparameter, seperti Bayesian Optimization dan Random Search, dalam meningkatkan kinerja chatbot generatif. Selain itu, penelitian ini akan mengkaji dampak optimasi hiperparameter terhadap kualitas respons dan kepuasan pengguna. Dengan demikian, diharapkan penelitian ini dapat memberikan kontribusi yang signifikan bagi pengembangan chatbot generatif yang lebih efektif dan efisien untuk layanan pelanggan.

Manfaat dari penelitian ini antara lain meningkatkan efisiensi operasional perusahaan melalui pengurangan beban kerja layanan pelanggan, peningkatan kepuasan pelanggan melalui interaksi yang lebih alami dan relevan, serta berkontribusi pada pengembangan teknologi chatbot yang lebih adaptif dan cerdas. Selain itu, penelitian ini juga dapat menjadi acuan bagi pengembang dan peneliti dalam menerapkan strategi optimasi hiperparameter dalam mengembangkan chatbot generatif. Dengan demikian, hasil penelitian ini diharapkan dapat memberikan dampak positif terhadap peningkatan kualitas layanan pelanggan berbasis AI.

Implikasi dari penelitian ini termasuk penerapan model chatbot yang lebih efektif di berbagai sektor industri, seperti perbankan, e-commerce, dan perawatan kesehatan, serta mendorong penelitian lebih lanjut di bidang pemrosesan bahasa alami dan pembelajaran mesin. Selain itu, penelitian ini juga dapat memberikan wawasan baru dalam pengembangan strategi optimasi hiperparameter untuk model machine learning lainnya. Dengan demikian, penelitian ini berpotensi memberikan kontribusi yang signifikan terhadap pengembangan teknologi AI yang lebih adaptif dan efisien.

## **METODE**

Studi mixed-method ini memadukan analisis kualitatif mendalam dan uji kuantitatif terkontrol untuk mengembangkan serta mengoptimalkan chatbot berbasis DNN pada layanan pelanggan. Fokusnya adalah integrasi teknik hyperparameter tuning (Grid Search, Random Search, Bayesian Optimization) terhadap kinerja, menggunakan 50.000 interaksi nyata dari lima perusahaan (split 70/15/15) dengan baseline DNN tanpa optimasi sebagai kontrol. Implikasinya, desain ini tidak hanya menguji “apa yang bekerja” tetapi juga “bagaimana” dan “mengapa” dalam konteks operasional.

Populasi adalah perusahaan pengguna AI service; sampel dipilih secara purposive agar perspektif pengembang, analis, dan manajer layanan terwakili. Instrumen meliputi wawancara semi-terstruktur dan analisis dokumen; validasi memakai metrik standar (akurasi, precision, recall, F1, latensi, dan kepuasan) serta A/B testing (500 pengguna per perusahaan). Prosedur lima tahap dengan triangulasi lintas sumber (Creswell & Poth, 2018) meningkatkan kredibilitas, sehingga temuan relevan sekaligus bisa langsung ditindaklanjuti untuk perbaikan proses.

Analisis konten tematik memetakan pola kinerja, tantangan, dan strategi optimasi; uji t berpasangan dan ANOVA ( $\alpha=0,05$ ) membedakan efektivitas metode. Implementasi menggunakan Python 3.9 (TensorFlow 2.8, Keras, scikit-optimize) dan SPSS 26; alur coding–kategorisasi–pemetaan ke model teoretis memastikan replikasi. Implikasinya, setelan hiperparameter—laju belajar, ukuran layer tersembunyi, fungsi aktivasi—secara nyata mengungkit performa di dunia nyata, sementara rigor kualitatif menjaga trustworthiness (Nowell et al., 2017), sehingga rekomendasi teknis siap diadopsi.

## **HASIL DAN PEMBAHASAN**

### **Efektivitas Respons Chatbot Setelah Optimasi Hiperparameter**

Penerapan optimasi hiperparameter khususnya Bayesian Optimization secara nyata meningkatkan akurasi respons chatbot: baseline 72%, naik menjadi 81% dengan Grid Search, 85% dengan Random Search, dan tertinggi 96% dengan Bayesian Optimization ( $p<0,001$ ); precision/recall pun melonjak dari 0,68/0,71 (baseline) ke 0,94/0,95. Uji ANOVA menunjukkan perbedaan signifikan antar metode ( $F=127,34$ ;  $p<0,001$ ) dan uji post-hoc Tukey mengonfirmasi superioritas Bayesian Optimization. Di praktiknya, model tanpa optimasi kerap menghasilkan jawaban kurang jelas untuk pertanyaan kompleks, sedangkan setelah optimasi Bayesian, pemahaman konteks dan relevansi respons meningkat, tingkat handoff/penggantian serta percakapan buntu turun, dan kemampuan menangkap dependensi panjang pada kueri transaksional membaik. Pengembang mengaitkan lonjakan performa ini dengan pemilihan laju belajar dan fungsi aktivasi yang lebih tepat sehingga konvergensi gradien lebih stabil, menegaskan bahwa optimasi hiperparameter berdampak bukan hanya pada metrik, tetapi juga pada adaptabilitas linguistik yang praktis (Pandian, 2025).

## **Model Chatbot Generatif Berdasarkan Jaringan Saraf Dalam Dengan Optimasi Hiperparameter Untuk Layanan Pelanggan**

Akurasi yang ditingkatkan juga membantu dalam skenario dukungan multibahasa, di mana chatbot yang sama harus merespons dalam bahasa Indonesia dan Inggris. Sebelum pengoptimalan, terjemahan dan pemetaan niat sering kali tidak sejajar. Setelah pengoptimalan, kemampuan chatbot untuk menggeneralisasi lintas bahasa meningkat, seperti yang diukur dengan peningkatan skor BLEU dalam tugas terjemahan. Simulasi pengguna menunjukkan bahwa lebih dari 80% pengguna menganggap jawaban chatbot "relevan" atau "sangat relevan". Model yang dioptimalkan juga dapat mendeteksi sentimen pelanggan dengan lebih baik dan menawarkan respons yang disesuaikan. Kemampuan ini memberi chatbot persona yang lebih "manusiawi" dalam interaksi pelanggan. Terakhir, peningkatan akurasi berarti lebih sedikit penyerahan ke agen manusia, mengurangi biaya dukungan secara keseluruhan (Pandian, 2025).

### **Pengurangan Latensi dan Efisiensi Sistem**

Latensi terbukti krusial bagi kesan “responsif” chatbot: rata-rata response time turun dari 2,8 detik (baseline) menjadi 2,5 detik (Grid Search), 2,3 detik (Random Search), dan 2,1 detik dengan Bayesian Optimization—improvement 24% ( $p < 0,01$ ); pada uji beban 1.000 concurrent users, model teroptimasi mempertahankan 450 requests/second pada CPU 68% dibanding baseline 320 requests/second pada CPU 89%. Grid/Random Search memberi kenaikan terbatas namun boros sumber daya dan kurang konsisten, sedangkan Bayesian Optimization mempercepat konvergensi pelatihan dan memangkas waktu inferensi dengan menyeimbangkan kompleksitas–kecepatan melalui pengaturan jumlah lapisan tersembunyi, fungsi aktivasi, dan dropout, sehingga model berjalan lebih efisien di infrastruktur yang ada. Pengurangan beban komputasi ini membuat penerapan real-time kian layak di lingkungan cloud dengan sumber daya terbatas (Pandian, 2025).

Dari perspektif pengguna, waktu respons yang lebih cepat diterjemahkan menjadi pengalaman yang lebih baik. Data pengamatan dari log obrolan langsung menunjukkan pengurangan 24% dalam durasi sesi rata-rata, tanpa mengurangi jumlah pesan. Dengan kata lain, pengguna mencapai resolusi lebih cepat tanpa merasa "korsleting". Insinyur juga mengamati penurunan konsumsi memori dan beban server selama pengujian stres. Ini menunjukkan bahwa penyetelan hiperparameter juga mendukung skalabilitas horizontal untuk penyebaran perusahaan volume tinggi. Peningkatan efisiensi memungkinkan untuk menyematkan chatbot dalam aplikasi seluler dan antarmuka IoT tanpa jeda yang terlihat. Manfaat ini sangat berharga bagi organisasi yang ingin mengotomatiskan layanan pelanggan sambil mempertahankan kelincahan operasional (Pandian, 2025).

### **Kepuasan Pengguna dan Persepsi Kecerdasan Chatbot**

Kepuasan pengguna dievaluasi melalui wawancara, survei pasca-sesi, dan umpan balik berkelanjutan selama uji beta; dari 2.500 responden dengan skala Likert 1–10, skor rata-rata meningkat dari baseline 6,8 (SD=1,2) menjadi 7,4 (Grid Search; SD=1,1), 8,1 (Random Search; SD=0,9), dan 8,9 (Bayesian Optimization; SD=0,7), dengan uji paired t-test menegaskan perbedaan signifikan antara baseline dan Bayesian Optimization ( $t=18,42$ ;  $p < 0,001$ ). Net Promoter Score turut naik dari 32 menjadi 67, menandakan loyalitas yang lebih tinggi. Setelah pengoptimalan, kepribadian chatbot, kecerdasan yang dirasakan, dan koherensi meningkat nyata; pelanggan menyebutnya lebih “penuh perhatian”, “akurat”, dan “pengertian”, terutama pada kasus keluhan atau pertanyaan bernuansa, sebagian dipicu oleh deteksi sentimen yang memunculkan respons empatik. Temuan ini menegaskan bahwa penyesuaian hiperparameter tidak hanya meningkatkan presisi teknis, tetapi juga memperbaiki persepsi emosional dalam interaksi manusia–chatbot (Lu, 2024).

Kecerdasan chatbot yang dirasakan terkait erat dengan kemampuannya untuk mempertahankan percakapan multi-langkah tanpa kehilangan koherensi. Ini dimungkinkan dengan menyetel panjang urutan dan meningkatkan retensi vektor konteks di seluruh interaksi. Pengguna cenderung tidak mengulangi diri mereka sendiri, dan permintaan klarifikasi menurun sebesar 35%. Selain itu, mekanisme perhatian yang disesuaikan meningkatkan deteksi niat dalam pesan ambigu. Hal ini membuat chatbot tampak lebih proaktif dan berwawasan dalam memberikan solusi. Fitur-fitur semacam itu sangat penting dalam domain seperti e-commerce dan perawatan kesehatan, di mana niat pengguna bisa kompleks atau sensitif. Dengan demikian, pengoptimalan tidak hanya meningkatkan efisiensi backend tetapi juga pengalaman frontend, yang mengarah pada metrik keterlibatan yang lebih kuat (Lu, 2024).

### **Perbandingan dengan Penelitian Sebelumnya dan Implikasi Praktis**

Dibandingkan dengan penelitian sebelumnya, penelitian ini memberikan kontribusi unik dengan menggabungkan arsitektur jaringan saraf dalam dengan pengoptimalan hiperparameter praktis di lingkungan siap produksi. Studi oleh Snoek et al. (2012) melaporkan peningkatan akurasi 8-12% pada dataset MNIST dan CIFAR-10, sedangkan penelitian ini mencapai improvement 24% (dari 72% menjadi 96%) pada real-world customer service dataset. Bergstra et al. (2011) menunjukkan efisiensi Bayesian Optimization pada image classification tasks, namun penelitian ini memperluas aplikasinya pada conversational AI dengan kompleksitas yang lebih tinggi. Dibandingkan dengan penelitian Wang et al. (2021) tentang context-aware chatbot yang mencapai accuracy 88%, penelitian ini mengungguli dengan 96% accuracy melalui systematic hyperparameter tuning. Studi sebelumnya oleh Snoek et al. (2012) dan Bergstra et al. (2011) terutama berfokus pada model pembandingan pada kumpulan data seperti CIFAR atau MNIST tetapi kurang dalam konteks aplikasi dunia nyata. Penelitian ini memperluas pekerjaan mereka dengan menerapkan teknik pengoptimalan serupa pada chatbot layanan pelanggan yang beroperasi di lingkungan berisiko tinggi. Selain itu, penelitian ini mengintegrasikan umpan balik kualitatif dari pengembang dan pengguna, menawarkan perspektif yang lebih luas tentang bagaimana pengoptimalan memengaruhi kinerja dan kegunaan. Ini kontras dengan penelitian ML tradisional, yang sering mengabaikan evaluasi yang berpusat pada manusia (Lu, 2024).

Kontribusi signifikan lainnya terletak pada metodologi holistik. Sebagian besar pekerjaan yang ada menilai metrik kinerja atau hasil kualitatif tetapi jarang keduanya. Studi ini menjembatani kesenjangan dengan menggabungkan metrik model (akurasi, latensi) dengan kepuasan pengguna dan dampak tingkat sistem. Selain itu, pengaturan penelitian, yang melibatkan sistem real-time dalam konteks multibahasa dan multikultural, menambah keragaman geografis dan linguistik yang tidak terlihat dalam penelitian sebelumnya. Dengan menempatkan studi ini di Asia Tenggara, studi ini memberikan wawasan baru tentang bagaimana sistem AI yang dioptimalkan berperilaku di ekonomi digital yang sedang berkembang. Hal ini membuat temuan ini lebih berlaku untuk perusahaan yang ingin menerapkan solusi AI dalam lingkungan sosio-linguistik yang beragam (Lu, 2024).

Implikasi praktis dari penelitian ini sangat banyak. Pertama, perusahaan yang ingin menerapkan chatbot AI dapat memperoleh manfaat yang signifikan dari memasukkan pengoptimalan hiperparameter ke dalam siklus pengembangan mereka. Dengan teknik seperti Pengoptimalan Bayesian, mereka dapat mencapai akurasi tinggi dan efisiensi sistem tanpa coba-coba yang membosankan. Pendekatan ini sangat berguna untuk startup atau UKM yang memiliki sumber daya komputasi terbatas tetapi bertujuan untuk kinerja tingkat perusahaan. Selain itu, penggunaan kerangka kerja evaluasi yang berpusat pada pengguna membantu organisasi

menyelaraskan peningkatan teknis dengan tujuan kepuasan pelanggan. Chatbots semakin terintegrasi ke dalam strategi omnichannel, dan penelitian ini memberikan peta jalan untuk implementasi yang terukur dan responsif (Pandian, 2025).

Namun, beberapa keterbatasan perlu diakui. Pertama, penelitian ini hanya berfokus pada interaksi chatbot berbasis teks dan belum mengeksplorasi sistem obrolan berbasis suara atau multimodal. Kedua, ukuran sampel, meskipun kaya dalam kedalaman kualitatif, mungkin tidak mencerminkan variabilitas penuh implementasi chatbot di seluruh sektor industri. Ketiga, metrik jangka panjang seperti retensi pelanggan dan dampak terhadap customer lifetime value belum dilacak karena keterbatasan durasi proyek. Keempat, teknik pengoptimalan alternatif seperti algoritme genetik atau penyetelan berbasis pembelajaran penguatan belum dieksplorasi dalam studi ini. Terlepas dari hambatan tersebut, penelitian ini membangun fondasi yang kuat untuk eksplorasi akademik dan inovasi praktis dalam pengembangan chatbot (Pandian, 2025).

## **KESIMPULAN**

Penelitian ini menunjukkan bahwa penerapan chatbot generatif berbasis Deep Neural Network (DNN) dengan hyperparameter tuning melalui Bayesian Optimization secara signifikan meningkatkan kinerja layanan pelanggan akurasi respons naik 21%, latensi turun 25%, dan kepuasan pengguna naik 31% dengan dampak nyata pada relevansi jawaban, penurunan waktu tanggap, dan kecerdasan yang dirasakan, sehingga chatbot berfungsi sebagai representasi layanan yang adaptif. Integrasi pendekatan teknis dengan evaluasi berbasis pengalaman pengguna menegaskan bahwa kualitas pengoptimalan sangat menentukan performa dan memberi dasar kuat bagi pengembangan chatbot yang lebih responsif dan efisien dalam konteks operasional. Kontribusi utama mencakup kerangka kerja integratif (optimasi hiperparameter + evaluasi pengguna), bukti empiris efektivitas Bayesian Optimization pada chatbot layanan pelanggan, serta wawasan praktis implementasi sistem yang adaptif, sehingga memperkaya literatur dengan pendekatan kontekstual dan terukur. Keterbatasan penelitian meliputi fokus interaksi berbasis teks, sampel terbatas pada lima perusahaan, dan belum adanya analisis jangka panjang terhadap retensi pelanggan. Arah riset selanjutnya disarankan mencakup pengembangan chatbot multimodal (teks–suara–visual), studi longitudinal untuk menilai dampak terhadap customer lifetime value, pengujian teknik optimasi alternatif (algoritme genetik, reinforcement learning), serta perluasan sampel lintas sektor agar temuan lebih generalizable. Secara praktis, penelitian ini menawarkan kerangka penerapan optimasi hiperparameter yang replikatif bagi berbagai industri dan menegaskan pentingnya data serta pendekatan berpusat pada pengguna untuk meningkatkan efisiensi dan kualitas layanan digital.

## **DAFTAR PUSTAKA**

- Ahmad, W. S. W., & Jambli, M. N. (2023). Meningkatkan model chatbot berbasis generatif jaringan saraf dalam. *Jurnal Teknik Terapan*, 14(1), 1–10.
- Al-Zoubi, AM, Alsmirat, MA, & Rawashdeh, TA (2021). Evaluasi model pembelajaran mendalam untuk desain chatbot dalam layanan pelanggan. *Jurnal Internasional Ilmu dan Aplikasi Komputer Lanjutan*, 12(8), 172–178.
- Ashfaq, R., & Siddiqui, FM (2021). Mengoptimalkan hiperparameter model pembelajaran mendalam: Tinjauan literatur sistematis. *Komputasi dan Aplikasi Saraf*, 33, 11221–11257.
- Bai, X., Yang, L., & Zhang, C. (2022). Survei tentang pengoptimalan Bayesian. *Transaksi ACM pada Sistem dan Teknologi Cerdas (TIST)*, 13(1), 1–39.

## **Model Chatbot Generatif Berdasarkan Jaringan Saraf Dalam Dengan Optimasi Hiperparameter Untuk Layanan Pelanggan**

- Barredo Arrieta, A., Díaz-Rodríguez, N., & Del Ser, J. (2020). Kecerdasan buatan yang dapat dijelaskan (XAI): Konsep, taksonomi, peluang, dan tantangan terhadap AI yang bertanggung jawab. *Fusi Informasi*, 58, 82–115.
- Boussaid, I., Beldjilali, B., & Serhani, MA (2021). Chatbot dukungan pelanggan cerdas menggunakan pembelajaran penguatan dan grafik pengetahuan. *Sistem Pakar dengan Aplikasi*, 186, 115760.
- Casalegno, F., Ahmed, M., & Bianchi, F. (2021). Chatbots dan layanan pelanggan: Teknik pembelajaran mesin untuk meningkatkan pengalaman pengguna. *Jurnal Internasional Studi Manusia-Komputer*, 151, 102621.
- Gupta, M., & Arora, A. (2020). Chatbot multibahasa menggunakan terjemahan mesin saraf dan analisis sentimen. *Ilmu Komputer Prosedur*, 167, 2252–2259.
- Hutter, F., Kotthoff, L., & Vanschoren, J. (2019). *Pembelajaran mesin otomatis: Metode, sistem, tantangan*. Alam Springer.
- Jia, X., Yu, J., & Wang, R. (2022). Meningkatkan kualitas percakapan chatbot menggunakan model transformator yang disesuaikan. *Akses IEEE*, 10, 9931–9945.
- Lu, J. (2024). Meningkatkan kepuasan pengguna chatbot: Pendekatan pembelajaran mesin yang mengintegrasikan pohon keputusan, TF-IDF, dan BERTopic. *Preprints.org*.
- Mahapatra, D., & Borah, S. (2021). Mengevaluasi dampak chatbot berkemampuan AI dalam operasi layanan pelanggan. *Jurnal Riset Bisnis*, 129, 902–912.
- Pandian, S. (2023). Panduan komprehensif tentang penyetelan hiperparameter dan tekniknya. *Jurnal Internasional Aplikasi Komputer*, 183(42), 34–41.
- Ramesh, G., & Ravindran, B. (2022). Perbandingan kinerja teknik pengoptimalan hiperparameter untuk jaringan saraf. *Komputasi Lunak Terapan*, 118, 108464.
- Wang, S., Zhang, Q., & Jin, H. (2021). Menuju kerangka kerja chatbot yang sadar konteks dengan deteksi niat berbasis pembelajaran mendalam dan pengisian slot. *Transaksi IEEE pada Sistem Sosial Komputasi*, 8(4), 923–934.