

Measurement and Optimization of TikTok Ads Effectiveness Using Bayesian Marketing Mix Modeling and Optimization

Fajar Legianto Asmin^{1*}, Alz Danny Wowor²

^{1,2} Teknik Informatika, Fakultas Teknologi Informasi, Universitas Kristen Satya Wacana, Salatiga, Indonesia

Email: ^{1*}672021088@student.uksw.edu, ²alzdanny.wowor@uksw.edu

(*: corresponding author)

Abstract - The rapid growth of digital advertising has intensified the need for accurate measurement of advertising effectiveness and efficient budget allocation. However, many businesses still struggle to quantitatively link marketing efforts to sales outcomes due to data uncertainty, channel interactions, and dynamic consumer behavior. This study proposes an integrated framework that combines Bayesian Marketing Mix Modeling (BMMM) with Bayesian Optimization (BO) to simultaneously measure advertising contribution and optimize budget allocation under uncertainty. The proposed framework was applied to a dataset of 456 daily TikTok advertising records collected from January 2024 to March 2025. Bayesian Ridge Regression was employed for model estimation and evaluated using 5-Fold Cross-Validation, yielding strong predictive performance with an R^2 of 0.8649 and MAPE of 0.55%. Optimization results indicate that Visual Shopping Ads (VSA) and Live Shopping Ads (LSA) deliver the highest marginal returns on sales, while Product Showcase Ads (PSA), Awareness, and GMV Max exhibit relatively lower contributions. Unlike previous studies that typically address marketing mix modeling or budget optimization separately, this research introduces integrated probabilistic framework that simultaneously measures advertising effectiveness and optimizes budget allocation by fully utilizing posterior distributions. This approach offers a more robust alternative to traditional Marketing Mix Modeling and manual allocation methods, particularly in fast-changing digital advertising environments such as TikTok Ads. The findings provide practical guidance for retailers in making data-driven marketing decisions and demonstrate the significant potential of Bayesian approaches in digital marketing analytics, especially for emerging markets like Indonesia.

Keywords: Advertising Effectiveness, Bayesian Marketing Mix Modeling, Bayesian Optimization, Budget Allocation, Digital Marketing

Abstrak - Perkembangan pesat periklanan digital telah meningkatkan kebutuhan akan pengukuran efektivitas iklan yang akurat dan alokasi anggaran yang efisien. Namun, banyak bisnis masih kesulitan menghubungkan aktivitas pemasaran dengan hasil penjualan secara kuantitatif akibat ketidakpastian data, interaksi antar kanal, dan perilaku konsumen yang dinamis. Penelitian ini mengusulkan kerangka terintegrasi yang menggabungkan *Bayesian Marketing Mix Modeling* (BMMM) dan *Bayesian Optimization* (BO) untuk mengukur kontribusi iklan sekaligus mengoptimalkan alokasi anggaran di tengah ketidakpastian. Kerangka ini diterapkan pada dataset yang terdiri dari 456 catatan harian aktivitas periklanan TikTok periode Januari 2024 hingga Maret 2025. Estimasi model dilakukan menggunakan *Bayesian Ridge Regression* dan dievaluasi melalui *5-Fold Cross-Validation*, menghasilkan performa prediksi yang kuat dengan nilai R^2 sebesar 0,8649 dan MAPE sebesar 0,55%. Hasil optimasi menunjukkan bahwa *Visual Shopping Ads* (VSA) dan *Live Shopping Ads* (LSA) memberikan *marginal return* tertinggi terhadap penjualan, sementara *Product Showcase Ads* (PSA), *Awareness*, dan *GMV Max* menunjukkan kontribusi yang lebih rendah. Berbeda dengan studi sebelumnya yang umumnya membahas *modeling* atau optimasi secara terpisah, penelitian ini menghadirkan kerangka probabilistik terintegrasi yang secara simultan mengukur efektivitas iklan dan mengoptimalkan alokasi anggaran dengan memanfaatkan distribusi posterior secara penuh. Kerangka ini menawarkan alternatif yang lebih *robust* dibandingkan *Marketing Mix Modeling* tradisional dan alokasi manual, khususnya dalam lingkungan periklanan digital yang cepat berubah seperti TikTok Ads. Temuan penelitian ini memberikan panduan praktis bagi pelaku ritel di Indonesia dalam pengambilan keputusan pemasaran berbasis data serta menunjukkan potensi besar pendekatan Bayesian dalam analitik pemasaran digital.

Kata Kunci: Alokasi Anggaran, *Bayesian Marketing Mix Modeling*, *Bayesian Optimization*, Efektivitas Periklanan, Pemasaran Digital.

1. PENDAHULUAN

Perkembangan pesat teknologi digital telah mengubah lanskap pemasaran secara fundamental. Saat ini, lebih dari 5,66 miliar orang atau sekitar 69,9% populasi global aktif menggunakan media sosial [1]. Pengeluaran iklan global diproyeksikan mencapai US\$1,04 triliun pada tahun 2026, meningkat 5,1% dibandingkan tahun sebelumnya dan merupakan pertama kalinya angka ini melampaui satu triliun dolar AS. Pertumbuhan ini didorong oleh *algorithm-driven advertising* yang diprediksi akan mencapai 71,6% dari total pengeluaran iklan pada 2026 [2]. Platform seperti Google Ads, Meta Ads, dan TikTok Ads tidak hanya menawarkan jangkauan luas dan personalisasi, tetapi juga mendorong pendekatan data-driven marketing. Sebagai gambaran, Alphabet (Google) meraup lebih dari US\$264,5 miliar dari iklan pada 2024 [3]. Bersama Meta dan Amazon, ketiga perusahaan ini diproyeksikan menguasai hampir 56% pangsa pasar iklan global di luar China pada tahun 2025 [4].

Meskipun investasi iklan digital terus meningkat, pengukuran efektivitasnya masih menghadapi tantangan signifikan. Analisis 15 eksperimen lapangan besar di Facebook menunjukkan bahwa metode observasional yang umum digunakan di industri sering kali gagal mereproduksi hasil *Randomized Controlled Trials* (RCT) [5].

Tantangan ini diperparah oleh kompleksitas *multi-touch attribution*, sehingga pengukuran efektivitas iklan harus menjadi bagian integral sepanjang siklus perencanaan dan evaluasi kampanye [6]. *Marketing Mix Modeling* (MMM) konvensional berbasis regresi OLS merupakan pendekatan yang umum digunakan, namun memiliki keterbatasan dalam menangani efek non-linear, interaksi antar kanal, dan ketidakpastian data [7].

Kemajuan signifikan dicapai melalui penerapan pendekatan Bayesian pada MMM. *Bayesian Media Mix Model* dengan *functional forms* fleksibel memungkinkan pemodelan efek *adstock* dan saturasi secara lebih akurat [7], sementara model hierarkis dengan *sign constraints* menghasilkan estimasi yang lebih sesuai logika bisnis [8]. *Hierarchical Bayesian Market Mix Models* (HBMMM) mampu meningkatkan akurasi prediksi hingga 30,4% melalui integrasi data individual dan agregat [9]. *Bayesian Deep Learning* dengan *self-attention mechanism* juga berhasil meningkatkan akurasi *forecasting* ROAS yang *risk-aware* pada platform *e-commerce* [10]. Lebih jauh, kerangka *Lightweight Bayesian* untuk data pemasaran berdimensi tinggi terbukti efisien secara komputasi tanpa mengorbankan akurasi [11], dan pendekatan *CausalMMM* telah menunjukkan kemampuan yang baik dalam *causal structure learning* pada data heterogen antar toko [12].

Di sisi optimasi, berbagai pendekatan telah dieksplorasi: *multi-armed bandits* [13], *reinforcement learning* multimodal [14], [15], [16], *ROI-constrained bidding* berbasis *Bayesian reinforcement learning* [17], serta *Bayesian Optimization* dengan *Gaussian Process* untuk mengoptimalkan strategi iklan secara periodik [18] dan menangani *budget constraint* [19]. Studi *multi-objective Bayesian Optimization* menekankan pentingnya integrasi antara model pengukuran dan proses optimasi ketika menangani beberapa metrik iklan secara simultan [20]. Namun, sebagian besar studi yang ada masih memisahkan kedua tahap tersebut, sehingga distribusi *posterior* dari model pengukuran belum dimanfaatkan secara penuh.

Pada konteks Indonesia, pendekatan yang ada masih didominasi sistem deterministik: implementasi *e-commerce* [21], sistem pendukung keputusan berbasis TOPSIS [22] dan *Fuzzy AHP* [23], serta prediksi penjualan ritel berbasis *machine learning* seperti *Random Forest* [24]. Pendekatan-pendekatan tersebut belum mampu menangani karakteristik *time-series* yang dinamis dan stokastik, termasuk efek *carryover*, saturasi, dan interaksi antar kanal pada periklanan digital. Kesenjangan ini memotivasi penelitian yang mengintegrasikan BMMM dan BO dalam satu *pipeline* probabilistik yang koheren untuk konteks TikTok Ads di Indonesia.

Berdasarkan kesenjangan yang telah diidentifikasi, penelitian ini dirumuskan untuk menjawab dua pertanyaan utama (RQ): RQ1: Seberapa akurat kerangka BMMM dapat mengukur kontribusi masing-masing kanal iklan TikTok terhadap penjualan di tengah ketidakpastian data?, dan RQ2: Bagaimana integrasi BMMM dengan *Bayesian Optimization* dapat menghasilkan rekomendasi alokasi anggaran yang lebih optimal dibandingkan pendekatan konvensional?

Secara operasional, tujuan penelitian ini adalah: (1) mengembangkan dan memvalidasi model BMMM berbasis *Bayesian Ridge Regression* pada data TikTok Ads harian; (2) mengintegrasikan hasil model tersebut sebagai *objective function* dalam *Bayesian Optimization*; dan (3) memberikan rekomendasi alokasi anggaran yang *actionable* bagi perusahaan ritel dalam pengambilan keputusan pemasaran berbasis data. Penelitian ini memberikan tiga jenis kontribusi yang saling melengkapi, pertama kontribusi metodologis dengan mengusulkan kerangka terintegrasi yang menggabungkan *Bayesian Marketing Mix Modeling* dengan *Bayesian Optimization* dalam satu model probabilistik. Integrasi ini memungkinkan pengukuran ketidakpastian yang eksplisit sekaligus optimasi anggaran yang adaptif, sesuatu yang belum dilakukan pada studi sebelumnya. Kedua kontribusi empiris, dengan menyediakan bukti kuantitatif tentang efektivitas relatif lima kanal TikTok Ads (VSA, LSA, PSA, *Awareness*, GMV Max) pada data nyata dari perusahaan ritel Indonesia selama 15 bulan, termasuk pemodelan efek *carryover*, saturasi, dan interaksi musiman.

Terakhir memberikan kontribusi praktis, yaitu memberikan rekomendasi alokasi anggaran yang *actionable* dan berbasis data bagi praktisi pemasaran digital Indonesia, khususnya retailer yang menggunakan TikTok Ads sebagai kanal utama menggantikan pendekatan intuitif yang masih umum digunakan. Penelitian ini dilakukan pada sebuah perusahaan ritel yang masih menghadapi kesenjangan antara biaya iklan dan hasil penjualan akibat belum adanya sistem pengukuran dan optimasi yang terstruktur. Oleh karena itu, penelitian ini bertujuan untuk mengembangkan kerangka analitis berbasis Bayesian yang mampu mengukur efektivitas iklan digital sekaligus menentukan strategi alokasi anggaran yang optimal dan berbasis data.

2. METODE PENELITIAN


Penelitian ini menggabungkan *Bayesian Marketing Mix Modeling* (BMMM) dengan *Bayesian Optimization* (BO). Pendekatan Bayesian dipilih karena mampu mengakomodasi ketidakpastian data dan menghasilkan distribusi posterior untuk setiap parameter, sehingga estimasi kontribusi masing-masing kanal iklan menjadi lebih *robust* dibandingkan metode regresi klasik. Keunggulan BMMM dalam memodelkan efek *carryover* dan *saturation* telah ditunjukkan melalui *functional forms* yang fleksibel [7]. Pendekatan tersebut juga telah diperkaya dengan *hierarchical structure* dan *sign constraints* [8]. Untuk aspek optimasi alokasi anggaran, penelitian ini terinspirasi dari penerapan BO dengan *Gaussian Process Regression* yang digunakan untuk mengoptimalkan

strategi iklan secara periodik di lingkungan *e-commerce* [18]. Pendekatan ini telah terbukti efektif dalam meningkatkan efisiensi pengeluaran iklan, terutama ketika mempertimbangkan karakteristik waktu dan dinamika pasar.

Bayesian Optimization (BO) juga telah terbukti efektif dalam mengoptimalkan alokasi sumber daya di bawah *budget constraint* dan ketidakpastian, seperti pada *multi-step budgeted BO* [19]. Namun, penerapannya pada alokasi budget iklan digital masih relatif terbatas. Berbeda dengan studi sebelumnya yang umumnya membahas BMMM atau BO secara terpisah, penelitian ini mengintegrasikan kedua metode tersebut dalam satu kerangka terpadu. Integrasi ini memungkinkan pengukuran kontribusi iklan yang probabilistik sekaligus rekomendasi alokasi anggaran yang dinamis dan adaptif terhadap lingkungan periklanan TikTok Ads yang cepat berubah. Pendekatan ini diharapkan dapat mengisi gap yang ada dengan menyediakan solusi yang lebih komprehensif dan *data-driven*.

2.1. Tahapan dan Alur Penelitian

Gambar 1 menunjukkan kerangka metodologis yang digunakan dalam penelitian ini. Proses penelitian dimulai dengan pengumpulan data aktivitas pemasaran dan data penjualan, yang kemudian dilanjutkan dengan tahap *feature engineering* untuk mempersiapkan dataset sebelum dilakukan pemodelan.



Gambar 1. Kerangka Pemodelan dan Optimasi *Marketing Mix Bayesian*

Tahap berikutnya adalah proses estimasi model *Bayesian Marketing Mix Modeling* (BMMM), yang digunakan untuk mengukur kontribusi masing-masing kanal pemasaran terhadap kinerja penjualan. Selanjutnya, hasil estimasi model digunakan sebagai masukan pada tahap optimasi. Pada tahap ini, alokasi anggaran iklan ditentukan menggunakan pendekatan *Bayesian Optimization* (BO) untuk memperoleh kombinasi distribusi anggaran yang menghasilkan performa pemasaran yang paling optimal.

2.2. Pengumpulan dan Pembersihan Data

Data penelitian diperoleh dari aktivitas pemasaran digital dan penjualan harian pada platform TikTok, yang dikumpulkan oleh tim pengiklan pada sebuah perusahaan ritel Indonesia. Periode observasi mencakup data harian dari Januari 2024 hingga Maret 2025, dengan total 456 titik observasi. Data sudah terorganisir dengan baik sehingga pembersihan yang diperlukan bersifat minimal, terutama penanganan *missing values* pada beberapa fitur yang memiliki nilai kosong (*null*). Proses ini memastikan konsistensi, kelengkapan, dan kualitas data sebelum dilanjutkan ke tahap transformasi dan pemodelan.

2.3. Feature Engineering

Tahap ini bertujuan menyiapkan data agar stabil, representatif, dan siap dipakai dalam pemodelan. Proses dilakukan melalui tiga langkah utama: transformasi variabel, konstruksi fitur baru, dan *encoding* variabel kategorikal.

a. Transformasi Variabel

Variabel target (*Sales*) ditransformasikan menggunakan logaritma natural (*log1p*) untuk menstabilkan varians data. Seluruh prediktor distandarisasi dengan *Standard Scaler* untuk memastikan bahwa setiap variabel berada pada skala yang sebanding sekaligus mengurangi potensi multikolinearitas. Variabel pengeluaran iklan yang dilibatkan dalam tahap ini mencakup *Visual Shopping Ads* (VSA), *Live Shopping Ads* (LSA), *Product*

Showcase Ads (PSA), dan GMV Max, serta metrik *Awareness*. Setiap kanal periklanan TikTok yang digunakan dalam penelitian ini memiliki karakteristik yang berbeda, yaitu sebagai berikut:

1. *Visual Shopping Ads* (VSA): iklan yang menampilkan visual produk secara menarik dan berfokus pada produk, biasanya ditampilkan pada *in-feed* atau halaman *explore* untuk menarik perhatian pengguna.
2. *Live Shopping Ads* (LSA): iklan yang terintegrasi dengan sesi *live streaming*, memungkinkan pengguna melakukan pembelian secara langsung selama siaran berlangsung.
3. *Product Showcase Ads* (PSA): iklan interaktif berbentuk katalog yang memungkinkan pengguna menjelajahi beberapa produk dalam satu unit iklan.
4. *Awareness*: jenis kampanye iklan yang berfokus pada peningkatan visibilitas dan kesadaran merek, bukan pada konversi penjualan secara langsung.
5. GMV Max: sistem otomatis berbasis algoritma yang dirancang untuk mengoptimalkan *Gross Merchandise Value* (GMV) dengan menggabungkan lalu lintas berbayar (*paid traffic*) dan organik (*organic traffic*). Algoritma ini secara dinamis menyesuaikan aset kreatif, pemilihan produk, serta strategi penawaran (*bidding strategy*) untuk meningkatkan efisiensi konversi.

b. Kontruksi Fitur Baru

Fitur tambahan dibangun untuk menangkap pola musiman, interaksi, dan dinamika historis:

1. Musiman : *cyclic encoding* waktu (*Month_Sin*, *Month_Cos*, *Week_Sin*, *Week_Cos*).
2. Interaksi : gabungan variabel (misalnya $AdSpend \times Discount$, $AdSpend \times Holiday$).
3. *Lag features* : penjualan sebelumnya (*Sales_Lag_1*, *Sales_Lag_7*, *Sales_Lag_30*).

c. *Encoding* Variabel Kategorikal

Variabel biner seperti *Holiday_Flag* dan *Payday_Flag* dikonversi menjadi numerik (0/1) agar dapat digunakan dalam pemodelan, karena keduanya berpengaruh pada pola penjualan.

2.4. Asumsi Utama Model Bayesian

Sebelum memaparkan spesifikasi teknis, penting untuk memahami asumsi mendasar yang melandasi pendekatan Bayesian dalam penelitian ini:

- a. Asumsi linearitas dalam skala log: hubungan antara pengeluaran iklan dan penjualan diasumsikan linear setelah transformasi logaritmik, yang berarti setiap peningkatan relatif pengeluaran iklan berdampak proporsional pada penjualan.
- b. Asumsi independensi residual: kesalahan prediksi diasumsikan berdistribusi normal dengan rata-rata nol, meskipun fitur lag dimasukkan untuk menangkap dependensi temporal.
- c. Asumsi informatif prior: distribusi prior mencerminkan keyakinan awal bahwa koefisien iklan cenderung kecil dan positif. Prior Gamma pada parameter regularisasi mencegah *overfitting* pada dataset dengan ukuran sedang.
- d. Asumsi stasioneritas relatif: hubungan antara variabel diasumsikan relatif stabil sepanjang periode observasi, meskipun fitur musiman dan lag dimasukkan untuk menangkap variasi periodik.

2.5. Spesifikasi Bayesian Marketing Mix Modeling

a. Struktur Model

Estimasi model dilakukan menggunakan *Bayesian Ridge Regression* yang diimplementasikan dengan pustaka PyMC. Metode ini dipilih karena mampu mengakomodasi regularisasi secara probabilistik serta menghasilkan distribusi posterior untuk setiap parameter, sehingga ketidakpastian estimasi dapat diukur secara lebih transparan. Secara umum, hubungan antara variabel independen dan variabel dependen dalam model dinyatakan pada persamaan (1).

$$y = \alpha + \sum_{i=1}^k \beta_i x_i + \varepsilon, \quad \varepsilon \sim \mathcal{N}(0, \sigma^2) \quad (1)$$

Variabel target ditransformasikan menggunakan fungsi logaritmik untuk mengurangi *skewness* dan meningkatkan stabilitas model sebagaimana ditunjukkan pada Persamaan (2).

$$y = \log(1 + Sales) \quad (2)$$

b. Distribusi Prior

Distribusi prior untuk setiap parameter ditentukan seperti yang ditunjukkan pada Tabel 1, beserta justifikasi pemilihannya.

Tabel 1. Spesifikasi Distribusi Prior pada Model *Bayesian Marketing Mix*

Parameter	Notasi	Distribusi Prior	Keterangan	Justifikasi Pemilihan
Intercept	α	Normal(0, 5)	Rata-rata awal penjualan	Prior lemah (<i>weakly informative</i>); memberi kebebasan model mengestimasi <i>baseline</i>
Koefisien fitur	β_i	Normal(0, λ^{-1})	Regresi dengan regularisasi	Regularisasi Bayesian mencegah <i>overfitting</i> ; varians dikontrol oleh λ
Regularisasi	λ	Gamma(2, 0.5)	Kontrol kompleksitas model	Mendorong regularisasi sedang; sesuai untuk dataset berukuran menengah (456 hari)
Noise/residual	σ	HalfNormal(2)	Error standar	Memastikan $\sigma > 0$ secara definitif; skala 2 sesuai rentang nilai <i>log transformed</i>

c. Fitur-fitur dalam model

Model mengikutsertakan berbagai fitur hasil transformasi dan konstruksi yang telah dijelaskan pada bagian

2.3. Variabel tersebut dikelompokkan sebagai berikut:

1. Fitur iklan : *VSA_Centered, LSA_Centered, PSA_Centered, Awareness_Centered, GMV_Centered*
2. Fitur harga : *WAP*
3. Diskon dan promosi : *Discount_Rate*
4. Interaksi : *AdSpend_Discount_Interaction_Centered, AdSpend_Season_Interaction, Discount_Season_Interaction, AdSpend_Holiday_Interaction, Discount_Holiday_Interaction*
5. Musiman : *Month_Sin, Month_Cos, Week_Sin, Week_Cos, Seasonality_Index*
6. Lag penjualan : *Sales_Lag_1, Sales_Lag_7, Sales_Lag_30*
7. Fitur dummy : *Holiday_Flag, Payday_Flag*

Seluruh prediktor numerik serta variabel target distandarisasi menggunakan metode *Standard Scaler* untuk menjaga konsistensi skala di antara seluruh fitur. Proses ini memastikan bahwa tidak ada variabel yang mendominasi proses estimasi akibat perbedaan magnitudo atau skala nilai antar variabel.

d. Inferensi dan Estimasi

Inferensi parameter dilakukan menggunakan metode *sampling Markov Chain Monte Carlo* (MCMC) yang diimplementasikan melalui fungsi `pm.sample()` pada perangkat lunak PyMC. Prosedur ini menggunakan 1.000 iterasi sampling dengan 500 langkah tuning untuk mencapai konvergensi yang stabil pada distribusi posterior. Sampel posterior yang dihasilkan kemudian digunakan untuk menghasilkan estimasi prediktif serta mengevaluasi kinerja model pada subset data validasi. Pendekatan ini memungkinkan setiap koefisien model diinterpretasikan secara probabilistik, sehingga tidak hanya merepresentasikan besarnya pengaruh yang diestimasi, tetapi juga tingkat ketidakpastian yang menyertainya. Hal ini merupakan salah satu keunggulan utama kerangka Bayesian dibandingkan metode tradisional yang hanya menghasilkan estimasi titik (*point estimate*).

2.6. Evaluasi Model

Evaluasi kinerja model dilakukan dengan strategi *5-Fold Cross-Validation* untuk menilai kemampuan generalisasi terhadap data yang tidak digunakan selama pelatihan. Pendekatan ini dipilih agar model tidak hanya menyesuaikan diri dengan data historis, tetapi juga mampu memberikan prediksi yang konsisten pada data baru. Evaluasi dilakukan berdasarkan empat metrik utama, yaitu:

- a. *Mean Absolute Error* (MAE)
- b. *Root Mean Squared Error* (RMSE)
- c. *R-squared* (R^2)
- d. *Mean Absolute Percentage Error* (MAPE)

Kombinasi metrik ini dipilih untuk memberikan gambaran menyeluruh mengenai akurasi prediksi, baik dari sisi kesalahan absolut, kesalahan kuadrat, maupun proporsi variansi yang dijelaskan. Dengan demikian, hasil evaluasi model tidak hanya mengukur ketepatan prediksi, tetapi juga menjadi dasar validasi sebelum model digunakan dalam proses optimasi alokasi anggaran pada tahap berikutnya.

2.7. Optimasi Anggaran

Fungsi prediktif yang dihasilkan oleh model *Bayesian Marketing Mix* kemudian digunakan sebagai *objective function* dalam *Bayesian Optimization*. Variabel yang dioptimasi mencakup biaya iklan VSA, biaya iklan LSA, biaya iklan PSA, *awareness* (alokasi kampanye kesadaran merek), serta GMV (alokasi untuk mendorong *Gross Merchandise Value*).

a. Batasan Alokasi

Untuk memastikan bahwa solusi yang dihasilkan tetap realistis dan sesuai dengan kondisi operasional di dunia nyata, batas atas dan batas bawah untuk setiap variabel ditentukan berdasarkan nilai minimum dan

maksimum historis yang telah dibulatkan. Mekanisme pembatasan ini bertujuan untuk mencegah algoritma optimasi merekomendasikan tingkat pengeluaran yang tidak realistis atau berada di luar kapasitas operasional perusahaan.

b. Proses Optimasi

Proses optimasi dilakukan menggunakan pendekatan *Bayesian Optimization* dengan *Gaussian Process* sebagai *surrogate model* dan fungsi akuisisi *Expected Improvement* (EI). Proses optimasi diawali dengan lima titik awal acak ($init_points = 5$) untuk mengeksplorasi ruang parameter. Selanjutnya, dilakukan sepuluh iterasi eksploitasi ($n_iter = 10$) yang bertujuan untuk memperdalam pencarian pada wilayah parameter yang menunjukkan potensi hasil terbaik. Tujuan optimasi (*optimization objective*) dalam penelitian ini dinyatakan pada Persamaan (3), yaitu memaksimalkan hasil prediksi model terhadap nilai penjualan.

$$\max f(x) = \hat{y} = model(x) \quad (3)$$

Adapun himpunan variabel yang digunakan dalam proses optimasi ditunjukkan pada Persamaan (4).

$$x = \{ad_spend_VSA, ad_spend_LSA, ad_spend_PSA, awareness, GMV\} \quad (4)$$

Melalui pendekatan ini, diperoleh kombinasi alokasi anggaran yang memberikan estimasi penjualan tertinggi dalam batasan yang telah ditetapkan.

2.8. Pseudocode Alur Penelitian

Pseudocode berikut merangkum langkah-langkah operasional penelitian secara rinci, mulai dari persiapan data hingga proses optimasi alokasi anggaran:

Input : Data Tiktok Ads Harian ($N=456$, Jan 2024 – Mar 2025)

Output : Alokasi anggaran iklan optimal & prediksi penjualan maksimal

Fase 1 : Persiapan Data

1. Muat data mentah; tangani *missing values* (imputasi median)
2. Transformasi: $y \leftarrow \log 1p(Sales)$; standarisasi prediktor numerik
3. Bangun fitur interaksi, *cyclic encoding*, *lag features*

Fase 2: *Bayesian Marketing Mix Modeling* (BMMM)

4. Definisikan prior: $\alpha \sim N(0,5)$; $\beta_i \sim N(0, \lambda^{-1})$; $\lambda \sim \text{Gamma}(2,0.5)$; $\sigma \sim \text{HalfNormal}(2)$
5. Spesifikasi *likelihood*: $y \sim N(\alpha + \sum \beta_i x_i, \sigma^2)$
6. Jalankan MCMC (1000 iterasi, 500 tuning) $\rightarrow$ sampel posterior
7. Evaluasi: *5-Fold CV* $\rightarrow$ hitung MAE, RMSE, R^2 , MAPE
8. JIKA $R^2 < 0.80$ ATAU $MAPE > 5\%$: kembali ke langkah 2 (revisi fitur)

Fase 3: *Bayesian Optimization*

9. Tetapkan batas [min_hist , max_hist] untuk setiap variabel iklan
10. Inisialisasi Gaussian Process sebagai surrogate model
11. Jalankan 5 titik awal acak ($init_points=5$)
12. Iterasi 10 kali eksploitasi menggunakan *Expected Improvement* (EI)
13. $\max f(x) = \hat{y} = model(x)$, di mana $x = \{VSA, LSA, PSA, Awareness, GMV\}$
14. Kembalikan: alokasi optimal x^* dan prediksi penjualan $\hat{y}^*$

3. HASIL DAN PEMBAHASAN

3.1. Ringkasan Hasil Estimasi Model


Model *Bayesian Marketing Mix Modeling* (BMMM) dievaluasi menggunakan strategi *5-Fold Cross-Validation*. Tabel 2 menyajikan metrik performa rata-rata pada data validasi.

Tabel 2. Rata-Rata Performa Validasi 5-Fold BMMM

Metrik Evaluasi	Nilai Rata-rata
MAE	0.09
RMSE	0.14
R^2	0.8649
MAPE (%)	0.55%

3.2. Visualisasi Hasil Prediksi vs Aktual (*Fold* ke-5)

Gambar 2 memperlihatkan perbandingan antara nilai penjualan aktual dan prediksi model pada *fold* ke-5. Secara visual, garis prediksi (oranye) mengikuti tren penjualan aktual (biru) dengan sangat baik, termasuk mampu menangkap lonjakan (*spike*) dan penurunan tajam.



Gambar 2. Perbandingan Nilai Aktual dan Prediksi Penjualan pada *Fold* ke-5

3.3. Interpretasi Hasil Model

Nilai R^2 sebesar 0.8649 menunjukkan bahwa model berhasil menjelaskan 86,49 % variasi penjualan (dalam skala *log transformed*). Artinya, lebih dari 86 % fluktuasi penjualan harian dapat dijelaskan oleh variabel iklan, harga, promosi, musim, dan interaksi antar faktor yang dimasukkan dalam model. MAPE yang sangat rendah (0,55 %) mengindikasikan bahwa rata-rata kesalahan prediksi penjualan hanya 0,55 % dari nilai aktual, jauh dibawah 5% yang lazim dianggap sebagai batas akurasi tinggi dalam literatur peramalan.

Penyimpangan kecil yang terlihat pada beberapa titik observasi mencerminkan variabilitas yang tidak sepenuhnya dijelaskan oleh variabel input, seperti faktor eksternal (tren viral, perubahan algoritma TikTok). Namun deviasi tersebut tidak berdampak signifikan terhadap performa keseluruhan, sebagaimana dibuktikan oleh konsistensi metrik antar *fold*. Performa yang konsisten ini menegaskan kemampuan generalisasi model yang baik.

3.4. Perbandingan dengan Pendekatan Non-Bayesian

Untuk memberikan konteks metodologis yang lebih kuat, Tabel 3 menyajikan perbandingan konseptual dan empiris antara pendekatan BMMM yang diusulkan dengan *Ordinary Least Squares* (OLS) *Regression*, yang hingga kini masih menjadi pendekatan MMM konvensional paling umum digunakan dalam industri. Perbedaan mendasar antara kedua pendekatan ini terletak pada aspek kuantifikasi ketidakpastian prediktor, terutama saat menghadapi data pemasaran bertipe *time-series* yang rentan terhadap multikolinearitas. OLS hanya mampu menghasilkan estimasi titik tunggal (*point estimate*), sehingga pengambil keputusan kesulitan mengukur tingkat keandalan, variabilitas, dan sensitivitas dari parameter efektivitas iklan yang dihasilkan. Sebaliknya, BMMM mampu menghasilkan distribusi posterior penuh atas setiap koefisien regresi melalui integrasi *prior knowledge*. Karakteristik Bayesian ini sangat krusial bagi manajer pemasaran untuk menilai risiko serta ketidakpastian dalam simulasi skenario alokasi anggaran iklan secara lebih eksplisit, adaptif, dan terukur.

Tabel 3. Perbandingan Karakteristik Teoretis Pendekatan OLS dan BMMM

Dimensi Perbandingan	OLS <i>Regression</i> (Konvensional)	BMMM (Penelitian Ini)
Estimasi parameter	<i>Point estimate</i> tunggal	Distribusi posterior (mean + interval)
Kuantifikasi ketidakpastian	Tidak tersedia secara probalistik	Eksplisit melalui distribusi posterior
Regularisasi	Tidak ada (rentan <i>overfitting</i>)	Prior informatif (<i>Bayesian regularization</i>)
Penanganan data kecil/menengah	Tidak stabil pada $n < 1000$	Stabil dengan <i>prior knowledge</i>
Integrasi dengan optimasi	Membutuhkan tahap terpisah	Terintegrasi dalam satu <i>pipeline</i>

3.5. Hasil Optimasi Anggaran

Berdasarkan model BMMM yang telah tervalidasi, *Bayesian Optimization* menghasilkan kombinasi alokasi belanja iklan yang memaksimalkan prediksi penjualan dalam batasan historis. Hasil optimasi disajikan pada Tabel 4.

Tabel 4. Hasil Optimasi Alokasi Anggaran Iklan

Variabel	Alokasi Optimal
VSA Spend	Rp5,984,057.36
LSA Spend	Rp4,122,115.42
PSA Spend	Rp1,125,175.52
Awareness Spend	Rp183,808.46
GMV	Rp938,375.83
Total Spend	Rp12,353,532.59
Prediksi Penjualan	Rp24,234,209.43

3.6. Interpretasi Bisnis per Kanal Iklan

Hasil optimasi memberikan implikasi manajerial yang berbeda untuk setiap kanal:

- Visual Shopping Ads* (VSA). Prioritas Tinggi (48,4% anggaran): VSA memperoleh porsi terbesar karena format visual produk yang kuat berkontribusi langsung pada konversi. Dari perspektif manajerial, VSA sebaiknya menjadi kanal utama dengan kreasi konten visual yang terus diperbarui secara berkala. Investasi dalam kualitas konten visual (foto produk profesional, video singkat) diproyeksikan memberikan imbal hasil terbaik.
- Live Shopping Ads* (LSA). Prioritas Tinggi (33,4% anggaran): LSA menunjukkan marginal *return* tertinggi kedua karena sesi *live streaming* menciptakan urgensi pembelian yang tinggi. *Retailer* disarankan meningkatkan frekuensi sesi *live* berkualitas, mengoptimalkan jam tayang (*prime time*), dan mengintegrasikan promosi eksklusif khusus *live* untuk memaksimalkan konversi.
- Product Showcase Ads* (PSA). Prioritas Menengah (9,1% anggaran): PSA berguna sebagai pelengkap untuk mendorong eksplorasi produk, namun menunjukkan *diminishing return* yang lebih cepat. Alokasi sedang disarankan, dengan fokus pada produk dengan margin tinggi atau produk baru yang perlu diperkenalkan.
- GMV Max. Prioritas Menengah (7,6% anggaran): Meskipun sistem GMV Max bersifat otomatis, kontribusinya terhadap peningkatan penjualan inkremental terbukti lebih rendah dibandingkan VSA dan LSA. *Retailer* disarankan menggunakannya sebagai booster pelengkap, bukan sebagai kanal utama, sambil terus memantau efisiensi konversinya.
- Awareness*. Prioritas Rendah (1,5% anggaran): *Awareness* mendapat alokasi terkecil karena secara inheren tidak dirancang untuk konversi langsung. Namun peran jangka panjangnya dalam membangun ekuitas merek tidak boleh diabaikan. Disarankan untuk mempertahankan investasi minimal yang konsisten guna menjaga visibilitas merek, terutama di momentum musiman.

3.7. Analisis Sensitivitas dan Skenario Alokasi Alternatif

Untuk memberikan gambaran proyeksi yang lebih komprehensif kepada pengambil keputusan, Tabel 5 menyajikan simulasi alokasi anggaran pada setiap kanal iklan beserta proyeksi target penjualan yang dihasilkan oleh model BMMM. Seluruh nominal angka di dalam tabel disajikan dalam satuan Rupiah utuh untuk menjaga konsistensi interpretasi.

Tabel 5. Proyeksi Penjualan Berdasarkan Skenario Alokasi Anggaran Iklan

Skenario	VSA (Rp)	LSA (Rp)	PSA (Rp)	Awareness (Rp)	GMV (Rp)	Total Spend (Rp)	Prediksi Penjualan (Rp)
S1	5.984.057	4.122.115	1.125.175	183.808	938.375	12.353.533	24.234.209
S2	4.488.000	3.092.000	844.000	138.000	703.000	9.265.000	18.200.000
S3	7.500.000	5.000.000	0	0	0	12.500.000	22.800.000
S4	2.471.000	2.471.000	2.471.000	2.471.000	2.469.000	12.353.000	19.100.000

Simulasi eksperimen pada Tabel 5 dibagi menjadi empat skenario strategis utama dengan karakteristik sebagai berikut:

- Skenario 1 (S1 - Optimal/Baseline): Alokasi optimal yang direkomendasikan langsung oleh model BMMM berdasarkan efisiensi dan performa historis data.
- Skenario 2 (S2 - Efisiensi Anggaran): Skenario penghematan dengan memotong total anggaran belanja iklan sebesar 25% yang didistribusikan secara proporsional.

- c. Skenario 3 (S3 - Fokus VSA dan LSA): Skenario agresif yang memusatkan seluruh modal anggaran hanya pada dua kanal utama dan menonaktifkan kanal lainnya.
- d. Skenario 4 (S4 - Distribusi Merata): Skenario konvensional non-biad di mana total anggaran dibagi secara rata ke seluruh kanal periklanan TikTok yang tersedia.

Prediksi penjualan untuk skenario alternatif (S2 hingga S4) diestimasi menggunakan model BMMM yang sama, dengan asumsi variabel eksternal di luar model berada pada nilai rata-rata historis (*ceteris paribus*). Hasil proyeksi menunjukkan bahwa Skenario S2 diperkirakan menghasilkan penjualan sebesar Rp18.200.000, Skenario S3 sebesar Rp22.800.000, dan Skenario S4 sebesar Rp19.100.000. Ketiga skenario alternatif tersebut menghasilkan performa penjualan yang lebih rendah jika dibandingkan dengan skenario optimal (S1) yang mampu mencapai Rp24.234.209.

Berdasarkan analisis sensitivitas tersebut, penerapan alokasi anggaran secara merata (S4) terbukti menghasilkan proyeksi penjualan yang tidak efisien. Temuan ini secara empiris mengonfirmasi adanya nilai tambah (*value add*) yang signifikan dari penerapan pendekatan optimasi berbasis data (*data-driven*). Di sisi lain, skenario fokus anggaran pada saluran *Visual Shopping Ads* (VSA) dan *Live Shopping Ads* (LSA) (S3) mampu memberikan hasil pencapaian yang mendekati optimal meskipun menonaktifkan tiga kanal lainnya. Hal ini memperkuat rekomendasi strategis bagi manajemen untuk memprioritaskan alokasi anggaran pada kanal-kanal pemasaran yang memiliki nilai pengembalian marjinal (*marginal return*) tertinggi.

4. KESIMPULAN

Penelitian ini berhasil mengembangkan kerangka terintegrasi yang menggabungkan *Bayesian Marketing Mix Modeling* (BMMM) dengan *Bayesian Optimization* (BO) untuk mengukur efektivitas belanja iklan digital dan mengoptimalkan alokasi anggaran secara simultan pada platform TikTok Ads. Model *Bayesian Ridge Regression* yang divalidasi melalui *5-Fold Cross Validation* mencapai $R^2 = 0,8649$ dan $MAPE = 0,55\%$, membuktikan kemampuannya memberikan estimasi kontribusi per kanal yang akurat dan probabilistik (RQ1). Integrasi dengan BO menghasilkan rekomendasi alokasi anggaran total Rp12.353.533 dengan prediksi penjualan Rp24.234.209, terbukti lebih optimal dibandingkan distribusi merata (RQ2).

Hasil optimasi mengungkapkan bahwa *Visual Shopping Ads* (VSA, 48,4%) dan *Live Shopping Ads* (LSA, 33,4%) memberikan *marginal return* tertinggi, sementara PSA, *Awareness*, dan GMV Max menunjukkan kontribusi lebih rendah dengan *diminishing return* yang lebih cepat. Secara metodologis, pendekatan Bayesian terbukti mengungguli MMM konvensional tidak hanya dalam akurasi prediksi, tetapi juga dalam transparansi ketidakpastian estimasi, keunggulan kritis bagi pengambil keputusan pemasaran digital.

Bagi praktisi, tiga rekomendasi operasional yang dapat segera diterapkan adalah: (1) realokasi minimal 80% anggaran iklan ke VSA dan LSA untuk memaksimalkan ROI; (2) optimasi sesi *live streaming* pada hari Jumat–Minggu dan menjelang tanggal gaji, sesuai interaksi positif yang diidentifikasi model; serta (3) menjalankan ulang optimasi setiap kuartal dengan data terbaru, mengingat dinamika algoritma TikTok yang cepat berubah.

Keterbatasan penelitian ini meliputi cakupan satu platform dan periode observasi 15 bulan. Agenda lanjutan mencakup: (1) *multi-platform extension* pada TikTok, Instagram Ads, dan Shopee Ads; (2) *rolling optimization* berbasis data mingguan via API TikTok Ads; dan (3) validasi melalui *A/B test* minimum 8 minggu untuk mengukur dampak ROI aktual. Secara keseluruhan, integrasi BMMM dan BO membuka arah baru dalam analitik pemasaran digital berbasis probabilistik dan memberikan kontribusi bagi kemajuan teori serta praktik keputusan pemasaran di Indonesia.

DAFTAR PUSTAKA

- [1] S. Kemp, "Digital 2025: Global Overview Report," Feb. 2025. [Online]. Available: <https://datareportal.com/reports/digital-2025-global-overview-report>
- [2] Dentsu, "Global Ad Spend Forecasts December 2025," Dec. 2025. [Online]. Available: <https://insight.dentsu.com/ad-spend-dec-2025/>
- [3] Statista, "Advertising revenue of Google from 2001 to 2024," Statista. [Online]. Available: https://www.statista.com/statistics/266249/advertising-revenue-of-google/?srsltid=AfmBOohwTTQTfbuXXnGx2f_f4iBtaKQxpj4_znE-OOLyCg2WN_d3PbB
- [4] eMarketer, "Worldwide Ad Spending Forecast 2025," eMarketer. [Online]. Available: <https://www.emarketer.com/content/worldwide-ad-spending-forecast-2025#page-report>
- [5] B. R. Gordon, F. Zettelmeyer, N. Bhargava, and D. Chapsky, "A Comparison of Approaches to Advertising Measurement: Evidence from Big Field Experiments at Facebook," *Marketing Science*, vol. 38, no. 2, pp. 193–225, Mar. 2019, doi: 10.1287/mksc.2018.1135.
- [6] J. T. Yun, C. M. Segijn, S. Pearson, E. C. Malthouse, J. A. Konstan, and V. Shankar, "Challenges and Future Directions of Computational Advertising Measurement Systems," *J. Advert.*, vol. 49, no. 4, pp. 446–458, 2020, doi: 10.1080/00913367.2020.1795757.

- [7] Y. Jin, Y. Wang, Y. Sun, D. Chan, and J. Koehler, "Bayesian Methods for Media Mix Modeling with Carryover and Shape Effects," *Google Research*, Apr. 2017.
- [8] H. Chen, M. Zhang, L. Han, and A. Lim, "Hierarchical marketing mix models with sign constraints," *J. Appl. Stat.*, vol. 48, no. 13–15, pp. 2944–2960, 2021, doi: 10.1080/02664763.2021.1946020.
- [9] X. Ni, Y. Zhang, Y. Pu, M. Wei, and Q. Lou, "A Personalized Causal Inference Framework for Media Effectiveness Using Hierarchical Bayesian Market Mix Models," *Journal of Advanced Computing Systems (JACS)*, vol. 3, no. 9, pp. 9–23, 2023.
- [10] A. Jha, A. Bhatia, and K. Tiwari, "Bayesian Deep Learning Meets Self-Attention: A Risk-Aware Approach to Advertisement Optimization," *IEEE Access*, vol. 13, pp. 86413–86429, 2025, doi: 10.1109/ACCESS.2025.3570537.
- [11] K. H. Brodersen, F. Gallusser, J. Koehler, N. Remy, and S. L. Scott, "Inferring causal impact using Bayesian structural time-series models," *Ann. Appl. Stat.*, vol. 9, no. 1, 2015, doi: 10.1214/14-AOAS788.
- [12] C. Gong *et al.*, "CausalMMM: Learning Causal Structure for Marketing Mix Modeling," in *Proceedings of the 17th ACM International Conference on Web Search and Data Mining*, New York, NY, USA: ACM, 2024, pp. 238–246. doi: 10.1145/3616855.3635766.
- [13] M. Gigli and F. Stella, "Multi-armed bandits for performance marketing," *Int. J. Data Sci. Anal.*, vol. 20, no. 1, pp. 151–165, Jun. 2025, doi: 10.1007/s41060-023-00493-7.
- [14] W. Gao, X. Meng, and Y. Zhang, "Multimodal Reinforcement Learning for Dynamic Cross-Media Advertising Budget Allocation Via DDPG and PPO Combined with Meta-Learning and Adversarial Training," *Informatica*, vol. 49, no. 30, 2025, doi: 10.31449/inf.v49i30.11440.
- [15] M. Yang, Q. Cao, L. Tong, and J. Shi, "Reinforcement learning-based optimization strategy for online advertising budget allocation," in *2025 4th International Conference on Artificial Intelligence, Internet and Digital Economy (ICAID)*, IEEE, Apr. 2025, pp. 115–118. doi: 10.1109/ICAID65275.2025.11034517.
- [16] Z. Pan, "A Reinforcement Learning Approach for Adaptive Budget Allocation in Pharmaceutical Digital Marketing: Maximizing ROI Across Patient Journey Touchpoints," *Journal of Sustainability, Policy, and Practice*, vol. 1, no. 4, 2025.
- [17] H. Wang *et al.*, "ROI-Constrained Bidding via Curriculum-Guided Bayesian Reinforcement Learning," in *Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*, New York, NY, USA: ACM, 2022, pp. 4021–4031. doi: 10.1145/3534678.3539211.
- [18] Y. Wang, "Application of Bayesian Optimization in Periodic Delivery," in *Proceedings of the 2025 6th International Conference on Computer Information and Big Data Applications*, New York, NY, USA, 2025, pp. 556–561. doi: 10.1145/3746709.3746805.
- [19] R. A. Astudillo, D. R. Jiang, M. Balandat, E. Bakshy, and P. I. Frazier, "Multi-Step Budgeted Bayesian Optimization with Unknown Evaluation Costs," in *35th Conference on Neural Information Processing Systems (NeurIPS 2021)*, Nov. 2021.
- [20] S. Daulton, M. Balandat, and E. Bakshy, "Differentiable expected hypervolume improvement for parallel multi-objective Bayesian optimization," in *NIPS'20: Proceedings of the 34th International Conference on Neural Information Processing Systems*, Vancouver: Curran Associates Inc., Dec. 2020, pp. 9851–9864.
- [21] I. R. Arief and I. Novita, "Penerapan E-Commerce Untuk Mengoptimalkan Penjualan Pada Toko Gita Giza," *IDEALIS: Indonesia Journal Information System*, vol. 4, no. 1, pp. 127–136, 2021, doi: 10.36080/idealis.v4i1.2823.
- [22] F. R. R. Santoso and E. I. H. Ujianto, "A decision support system for the determination of additional stock items using the Topsis method based on Android," *IDEALIS: Indonesia Journal Information System*, vol. 8, no. 1, pp. 42–52, 2025, doi: 10.36080/idealis.v8i2.3339.
- [23] R. A. Zilasari, Y. A. Pranoto, and F. X. Ariwibisono, "Sistem Pendukung Keputusan Pemilihan Produk Kaca Dan Cermin Menggunakan Metode Fuzzy AHP," *IDEALIS: Indonesia Journal Information System*, vol. 9, no. 1, pp. 21–29, 2026, doi: 10.36080/idealis.v9i1.3617.
- [24] S. N. Windrasari, H. Margono, and Y. A. N. S. Putra, "Predictive Sales Analysis in Coffee Shops Using the Random Forest Algorithm," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 5, no. 3, pp. 1000–1011, 2025, doi: 10.57152/malcom.v5i3.2023.