

Universidade Federal do Paraná
Setor de Ciências Exatas
Departamento de Estatística
Programa de Especialização em *Data Science* e *Big Data*

Cristine Bosch

**Potencializar resultados de campanhas de
marketing digital de um e-commerce**

**Curitiba
2023**

Cristine Bosch

Potencializar resultados de campanhas de marketing digital de um e-commerce

Monografia apresentada ao Programa de Especialização em *Data Science* e *Big Data* da Universidade Federal do Paraná como requisito parcial para a obtenção do grau de especialista.

Orientador: Prof. Wagner Bonat

Curitiba
2023

Marketing mix modeling: potencializando campanhas de marketing digital

Marketing mix modeling: boosting digital marketing campaign

Critine Bosch

O objetivo deste artigo é utilizar um modelo de *Marketing Mix Modeling* (MMM) personalizado para um *e-commerce*, a fim de melhorar a eficiência na alocação de recursos de marketing. O MMM será construído utilizando técnicas de regressão ridge, que permite lidar com a multicolinearidade comumente presente em dados de marketing. Tal técnica, ajudará a encontrar uma solução ótima para a alocação de verba de mídia. Espera-se que a implementação do modelo proposto resulte em uma alocação de verba de mídia mais eficiente, maximizando o retorno sobre o investimento em marketing e melhorando os resultados do *e-commerce*. Isso permitirá que a empresa direcione seus recursos de forma estratégica, alcançando um público-alvo mais relevante e aumentando sua competitividade no mercado. Ao final deste artigo, serão apresentadas as conclusões e recomendações baseadas nos resultados obtidos com a aplicação do modelo de *Marketing Mix Modeling* personalizado. Espera-se que este trabalho contribua para a área de marketing digital, fornecendo uma abordagem inovadora e eficaz para a alocação de investimento em mídia, além de abrir possibilidades para futuras pesquisas e aprimoramentos nessa área.

Palavras-chave: Alocação de verba de mídia, *e-commerce*, *Marketing Mix Modeling*, Regressão Ridge, Eficiência na alocação de recursos de marketing, Retorno sobre o investimento, Otimização de campanhas de marketing.

The objective of this research is to employ a customized *Marketing Mix Modeling* (MMM) model for an *e-commerce* platform to enhance the efficiency in marketing resource allocation. The MMM will be built using Ridge regression techniques, which allow for handling the multicollinearity present in the marketing data, thereby aiding in finding an optimal solution for media budget allocation. It is anticipated that the implementation of the proposed model will result in a more efficient allocation of the media budget, maximizing the return on marketing investment, and improving *e-commerce* outcomes. This strategic resource allocation will enable the company to effectively target a more relevant audience and enhance its competitiveness in the market. At the conclusion of this study, conclusions and recommendations will be presented based on the results obtained from the application of the customized *Marketing Mix Modeling*. It is expected that this work will contribute to the field of digital marketing by providing an innovative and effective approach to media budget allocation in *e-commerce*, while also paving the way for future research and advancements in this area.

Keywords: Media budget allocation, *e-commerce*, *Marketing Mix Modeling*, Ridge regression, , Efficiency in marketing resource allocation, Return on investment, Optimization of marketing campaigns.

1. Introdução

Por muitas décadas, empresas com enormes orçamentos de publicidade buscam melhorar o alocação de investimento afim de gerar maiores retornos em vendas, *views*, reconhecimento de marca elevando o número de acesso ao site ou *e-commerce*. Para alcançar clientes, aumentar a conscientização sobre seu produto e, por sua vez, maximizar as vendas ou receita, os anunciantes utilizam diferentes canais de marketing, como TV, rádio, mídias sociais, entre outros. No entanto, eles precisam tomar decisões estratégicas sobre quais canais

são mais eficazes em comparação com outros e, mais importante, quanto orçamento deve ser alocado para cada um.

O MMM (*Marketing Mix Modeling*) é uma técnica que visa apurar a contribuição de cada canal de marketing nas vendas, auxiliando na decisão de em qual canal de marketing investir e, mais importante, quanto investir. Além disso, o MMM possibilita a realocação de orçamento entre diferentes canais de marketing, visando maximizar os retornos sobre os investimentos. [6].

Atualmente, o marketing digital se tornou uma das áreas de oportunidade mais relevantes para a aplicação de ciência de dados e aprendizado de máquina. Nesse contexto, o MMM desempenha um papel fundamental na determinação do impacto dos esforços de marketing nas vendas ou participação de mercado. Além disso, empresas de tecnologia de anúncios, como Google e Meta, têm se concentrado ativamente nessa abordagem principalmente após as novas leis e ações das empresas voltadas a segurança de dados.

O objetivo deste artigo é propor uma estratégia de alocação de verba para marketing digital baseada em técnicas de *Marketing mix modeling* para um cliente de *e-commerce*. Com essa metodologia espera-se aprimorar as estratégias de alocação de verba de mídia do *e-commerce*, possibilitando uma tomada de decisão mais eficiente resultando em maior retorno financeiro.

O trabalho está dividido como segue: Nesta seção apresentamos o problema geral de marketing digital e motivamos o uso das ferramenta MM. Na seção 2 apresentamos os materiais e métodos. Os resultados são apresentados na seção 3. Discutimos os principais resultados na seção 4.

2. Materiais e Métodos

O MMM é um modelo econométrico que busca quantificar o impacto incremental das atividades de marketing em um indicador-chave de desempenho, como vendas, participação de mercado ou visitas ao site.

No modelo de decisão típico descrito por Guadagni e Little (1983), assume-se que a resposta das vendas a uma variável de mídia é linear. Essa curva de resposta linear não é capaz de considerar a saturação do anúncio e o declínio dos retornos em níveis elevados de gasto. Além disso, esse modelo considera apenas o efeito atual da publicidade, ou seja, a variação nas vendas causada pela exposição à publicidade que ocorre no mesmo período. É amplamente reconhecido que a publicidade possui um efeito defasado ou de carregamento, que é a porção de seu efeito que ocorre em períodos subsequentes à exposição. Isso pode ser devido à resposta do consumidor com atraso, atraso na compra devido ao estoque dos consumidores ou compras de consumidores que ouviram falar do anúncio pelos primeiros a vê-lo [1]

Neste artigo, será utilizado o Robyn, um pacote R de código aberto, desenvolvido pela equipe da Meta. Ele usa várias técnicas de aprendizado de máquina, tais

como Regressão ridge, algoritmo evolutivo multiobjetivo e técnicas de análise de séries temporais.

A regressão ridge é uma técnica utilizada no modelo de regressão linear para lidar com o problema de multicolinearidade, que ocorre quando há alta correlação entre as variáveis independentes. Esta técnica auxilia na seleção de covariáveis, permitindo encontrar um subconjunto de covariáveis altamente significativas estatisticamente, mostrando como a variável dependente é afetada por cada uma das covariáveis. Algoritmo evolutivo multiobjetivo é utilizado para otimização de hiperparâmetros, enquanto técnicas de séries temporais são usadas para decompor a série temporal da variável resposta em termos de tendências e sazonalidade.

O modelo ainda automatiza a seleção de hiperparâmetros ideais para efeitos de *Adstocks* e saturação, que são dois princípios de marketing. O *Adstock* captura o efeito de longo prazo das atividades de publicidade e marketing. Ele se baseia na ideia de que o impacto de uma campanha publicitária não é apenas imediato, mas também persiste ao longo do tempo. De acordo com Joy (2006), o *Adstock* refere-se ao processo pelo qual o impacto da publicidade ou outra atividade de marketing diminuiu ao longo do tempo, em vez de desaparecer imediatamente após a exposição [2]. No modelo desse artigo foi utilizada a opção de transformação de *adstock* geométrico que apresenta um decaimento exponencial, conforme ilustra a Figura 1. Tal função é controlada por um parâmetro de decaimento θ . Por exemplo, um *adstock* de $\theta = 0,75$ significa que 75% dos anúncios do Período 1 são transferidos para o Período 2. Para mais detalhes sobre o modelo, ver [5].

Os retornos decrescentes, também conhecidos como saturação, referem-se a um fenômeno observado nas atividades de marketing em que o impacto incremental dessas atividades diminui à medida que são intensificadas. Em outras palavras, à medida que o investimento em marketing aumenta, o crescimento adicional nos resultados esperados, como vendas, receita, participação de mercado torna-se cada vez menor.

Os retornos decrescentes são um resultado natural da saturação do mercado e da resposta limitada dos consumidores às atividades de marketing. Inicialmente, quando uma empresa aumenta seus investimentos em marketing, pode ocorrer um aumento significativo nos resultados. No entanto, à medida que esses investimentos continuam a crescer, o impacto adicional nas métricas de desempenho se torna menor e, eventualmente, pode atingir um ponto de saturação,

no qual aumentos adicionais nos investimentos não geram um crescimento proporcional nos resultados [4].

Por fim o modelo inclui na estratégia o *Prophet* que é um procedimento original da Meta para prever dados de séries temporais, com base em um modelo em que tendências não lineares são ajustadas com sazonalidade anual, semanal e diária, além de efeitos de feriados e a otimização de hiperparâmetros [5].

Os hiperparâmetros controlam aspectos do processo de aprendizado, como a complexidade do modelo, a taxa de aprendizado, o número de camadas em uma rede neural, o tamanho do lote de treinamento, entre outros. Esses hiperparâmetros desempenham um papel fundamental na determinação de como o modelo aprenderá e como será sua capacidade de generalização. O modelo da meta automatiza a penalidade de regularização, seleção de *Adstocking*, saturação e tamanho dos conjuntos de treinamento e validação. Por sua vez, nos fornece candidatos a modelos com grande poder preditivo.

De acordo com a documentação da Meta, a estratégia implementa três funções objetivas como "metas" para a otimização dos hiperparâmetros:

NRMSE: O erro quadrático médio normalizado, também conhecido como erro de previsão, é utilizado para validação de séries temporais.

DECOMP.RSSD: A soma da raiz da decomposição da distância quadrada, também chamada de erro de negócios, ela representa a diferença entre a parcela de gastos e a parcela de efeito para variáveis de mídia paga. Essa função objetivo permite restringir a seleção do modelo, descartando resultados de decomposição mais extremos.

MAPE.LIFT: O erro percentual médio absoluto para experimentos é ativado durante a calibração e é chamado de erro de calibração. Essa função permite que o modelo minimize a diferença entre o efeito previsto e o efeito causal.

O modelo ainda utiliza o conceito de otimização de Pareto, buscando equilibrar todas as funções objetivo. Dessa forma, o modelo gera um conjunto de candidatos a modelos de otimização de Pareto considerados os melhores [5].

Os modelos de MMM geralmente utilizam dados mensais ou semanais e são explorados conceitos-chave, como vendas, preço, distribuição do produto, investimento em mídia em diferentes canais e fatores externos, como macroeconomia, clima, sazonalidade e concorrência de mercado.

3. Resultados

Para potencializar os resultados em vendas do *e-commerce*, o modelo foi aplicado em uma base de dados com investimento em sete canais de marketing digital do anunciante, sendo utilizados dados de 01/01/2021 a 31/12/2022, agrupados por semana.

A variável dependente será o total de vendas e as variáveis independentes foram, investimento em mídia digital, *Black Friday* além dos fatores externos como sazonalidade e feriados.

- Janela do modelo: 2019-12-30 a 2022-12-31 (157 weeks).
- Variável dependente: Receita.
- Variável contexto: Eventos.
- Prophet (Gerado automaticamente): tendência, temporada, feriado no Brasil.
- Variáveis não utilizadas: *dv360*, Outros*.
- Mídia paga - investimento: Pinterestads, Twitterads, Search, Instagram, Facebook, Criteo.

A Figura 1 retorna um conjunto de resultados ideais. No gráfico cada ponto azul representa uma solução de modelo explorada.

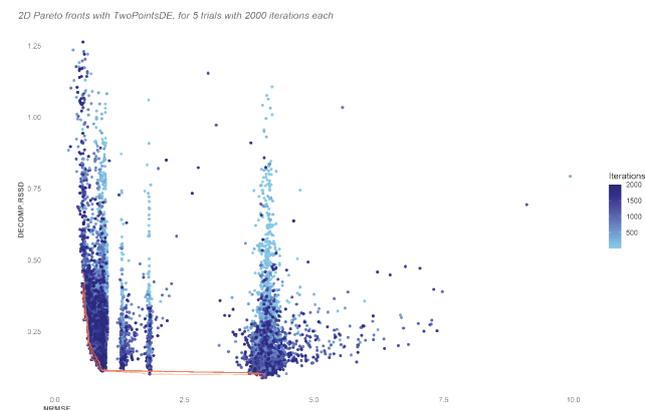


Figura 1: Desempenho Evolucionário multi-objetivo

Os gráficos abaixo mostram quanto o modelo previu a variável dependente, ficando o R-quadrado em 0,7233.

Em testes anteriores o modelo estava gerando resultados inferiores de precisão em determinados períodos e para isso foi identificado períodos relacionados a promoções, como *Black Friday*. Essa variável contextual foi incluída no modelo, melhorando o R-quadrado, bem como a saída do gráfico acima.

Após ajusta o modelo de MMM e entender a melhor combinação entre canais foi possível determinar a melhor Alocação de orçamento. Para isso, foi definido um

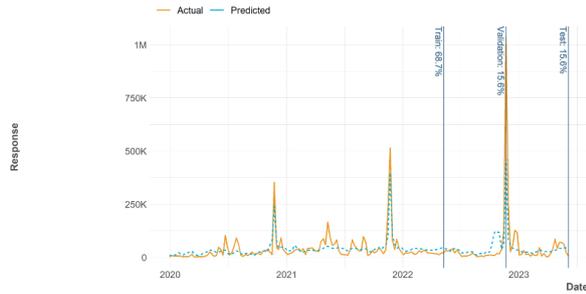


Figura 2: Resposta real vs. prevista

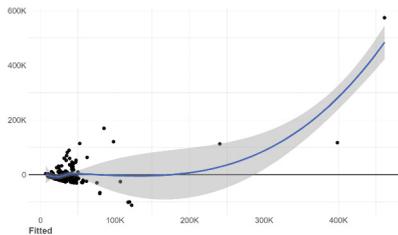


Figura 3: Ajustado vs. Residual

limite mínimo e máximo para mudança de verba a ser alocada em cada canal, sendo mínimo uma variação de 80% no valor original e no máximo um aumento de 120% no valor original.

As três colunas de dados apresentadas abaixo referem-se aos resultados obtidos com base nas últimas 10 semanas através da aplicação do MMM. Simulando um investimento de R\$50.000,00, a primeira coluna refere-se ao gasto total e à resposta das últimas 10 semanas da janela de dados. A segunda coluna "Bounded" refere-se à resposta total otimizada com o mesmo gasto sob as restrições de nível de canal definidas anteriormente. Por fim, a coluna "Bounded x5" refere-se à resposta total otimizada com o mesmo gasto sob restrições 5x mais amplas. Com 0,7–1,2 como restrições definidas no modelo, permitindo um deslocamento de -30% e +20% do orçamento da média. Restrições 5x maiores significam intervalo de -150% e +100%, o que resulta em um novo limite de -0,5–1 [5].

Initial	Bounded	Bounded x5
Spend: 0.0%	Spend: -39.9%	Spend: -80.6%
Resp: 0.0%	Resp: -10.1%	Resp: -35.1%
ROAS : 0.59	ROAS : 0.89	ROAS : 1.99
total spend total response	total spend total response	total spend total response

Figura 4: Resultados

Para chegar na otimização do ROAS, chegando a R\$1.99, conforme tabela abaixo, é necessário ajustar a alocação de investimentos, reduzindo 8,1% de investimento em Facebook, investir 1 em Pinterest. reduzir

9,5% o investimento em Search, investir 0,5 em Twitter e 1,1% em Criteo e, por fim, aumentar 14,9% o investimento em Instagram.

Canais	Share de Investimento		
	Inicial	Limitado	Limitado (x5)
Facebook	59,7%	60,0%	51,6%
Pinteres	0,0%	2,0%	1,0%
Search	13,4%	7,7%	3,9%
Twitter	0,0%	0,4%	0,5%
Criteo	0,0%	0,8%	1,1%
Instagram	26,9%	28,7%	41,8%

Tabela 1: Melhor alocação de investimento, com base nas últimas 10 semanas da base.

4. Discussão

Com base na aplicação do modelo e nos resultados obtidos nas últimas 10 semanas, foi possível obter *insights* valiosos sobre a alocação eficiente de recursos de marketing e seu impacto nas vendas. Os principais achados são descritos a seguir:

Primeiramente, ao analisar os dados históricos e identificar os padrões e tendências relacionados ao desempenho das atividades de marketing, foi possível entender a relação entre os investimentos em diferentes canais e as vendas, bem como considerar fatores externos, como sazonalidade e feriados.

Ao adotar uma estratégia de alocação eficiente de recursos, que resultou em uma redução de 81% no investimento, mas com um ROAS de 1,99, constatamos um impacto positivo nos resultados de vendas.

Essa otimização permitiu obter um retorno maior sobre o investimento, mesmo com uma redução significativa nos gastos. Essa descoberta enfatiza a importância da alocação inteligente de recursos de marketing para maximizar os resultados.

Através desse artigo, fica evidente o valor do MMM na tomada de decisões de marketing. O modelo auxiliou a compreensão da complexa relação entre os investimentos em diferentes canais de marketing e os resultados de vendas, considerando diversos fatores de influência. Essas informações embasadas em dados nos permitiram tomar decisões mais informadas e estratégicas sobre a alocação de recursos, buscando otimizar o desempenho de nossas atividades de marketing.

O MMM demonstrou ser uma ferramenta valiosa para a tomada de decisões estratégicas de marketing,

permitindo maximizaros resultados, mesmo em cenários de restrição orçamentária. Essas descobertas têm implicações significativas, fornecendo insights práticos para a otimização do mix de marketing e o alcance de melhores resultados financeiros.

Referências

- [1] Yuxue Jin, Yueqing Wang, Yunting Sun, David Chan, Jim Koehler, *Bayesian Methods for Media Mix Modeling with Carryover and Shape Effects*, (<https://static.googleusercontent.com/media/research.google.com/en//pubs/archive/46001.pdf>).
- [2] V. Joseoh, UNDERSTANDING ADVERTISING ADSTOCK TRANSFORMATIONS, (<https://mpra.ub.uni-muenchen.de/>).
- [3] P. Kumar, *Introduction to Market Mix Model Using Robyn*, (url www.analyticsvidhya.com).
- [4] B. Lutkevich, L. Aberle, CDEFINITION law of diminishing returns, (<https://www.techtarget.com/searchcustomerexperience>).
- [5] facebook experimental, (<https://facebookexperimental.github.io>).
- [6] H. Takeda, *Media Mix Modeling: How to Measure the Effectiveness of Advertising with Python LightweightMMM*, (url <https://towardsdatascience.com>).