



08, 09, 10 e 11 de novembro de 2022  
ISSN 2177-3866

## **O impacto causal de plano de mídia integrado no contexto imobiliário**

**GABRIEL GOMES FERREIRA**

MBA EACH USP

**KARINA MUNARI PAGAN**

UNIVERSIDADE DE SÃO PAULO (USP)

## O impacto causal de plano de mídia integrado no contexto imobiliário

### 1 INTRODUÇÃO

Com os avanços da globalização e da tecnologia, a forma de se comunicar mudou drasticamente, inclusive na forma que as marcas se comunicam com seus consumidores. Além de inovações como a internet, maior capacidade computacional, aplicações para celulares e redes sociais, estão surgindo tecnologias ainda mais radicais que envolvem inteligência artificial, internet das coisas e robótica, e todas essas inovações vêm exercendo um impacto direto na forma como o marketing é feito (Grewal *et al.*, 2020).

Além da complexidade de se estruturar um plano de mídia que consiga ser eficiente na comunicação entre marca e consumidor, um outro parâmetro de complexidade que surge é mensurar isso corretamente, isso ocorre devido a existência de diferentes exposições a mídia simultaneamente, que invalida os sistemas de mensuração mais comuns que isolam esses ecossistemas (Pilotta *et al.*, 2004). De acordo com Krizanova *et al.*, (2019) a mensuração da efetividade da comunicação em ambientes digitais é um desafio muito grande, e isso ganha ainda mais complexidade quando analisa-se dentro do ecossistema de marketing a união de estratégias de marketing “online” com as estratégias de marketing “offline”.

Uma estratégia bem definida é ainda mais importante em um contexto burocrático, desfragmentado e relevante como no mercado imobiliário. De acordo com o índice FIPEZAP (2021) de venda de imóveis que faz um acompanhamento sistematizado dos preços do mercado imobiliário brasileiro, houve um crescimento de 0,14% nos últimos 12 meses, o que é mais acentuado ainda em São Paulo, que é a maior cidade brasileira, onde o aumento foi de 2,23%.

Quando é observado o índice para locação, pode-se observar uma variação ainda maior, atingindo 5,03% no contexto nacional e de 7,93% em São Paulo (Fipezap, 2021). Esse crescimento tem um impacto econômico muito alto, visto que em 2020 o país totalizou a venda de 189.857 unidades de imóveis residenciais novos, um aumento de 9,8% comparado com 2019 (Cbic, 2021).

Com isso, tem-se a necessidade de procurar cada vez mais ferramentas e metodologias mais sofisticadas para garantir a confiabilidade de resultados de planos de mídia, como foi o caso do modelo logito generalizado proposto por Pedrick e Zufryden (1991). Porém, com os avanços da tecnologia e a necessidade de analisar a competitividade entre as marcas, foi necessário passar a considerar a quota de mercado das marcas surgindo então novos modelos que utilizam essas informações para a tomada de decisão (Pedrick *et al.*, 1993).

Outra abordagem é o caso apresentado por Purwanti (2021) onde ocorreu a aplicação de um teste t de hipóteses para entender a influência do marketing digital na performance escolar. Não obstante Qurratu'Aini *et al.*, (2019) utilizou a análise de regressão para estimar o quanto o marketing digital influencia o interesse de venda de produtos de micro e pequenas empresas na cidade de Bandung. Outras técnicas de experimentos controlados também foram utilizados para medir o efeito de campanhas de marketing digital em outros contextos como: consumo de produtos alimentícios (Erlangga, 2021), intenção de turismo doméstico no contexto de pandemia do COVID-19 (Nofal *et al.*, 2020) e no interesse de consumo de bebidas energéticas em jovens adultos (Buchanan *et al.*, 2017).

Porém, considerando todo o ecossistema de marketing, a tecnologia permitiu com que consumidores utilizassem conteúdo de mídia onde e quando quisessem, e conseqüentemente surgiu a necessidade das marcas estarem presentes em dois ou mais tipos de mídias (Garaus *et al.*, 2017). Conseqüentemente, a forma de mensurar uma única exposição à mídia passou a se tornar obsoleta, sendo necessário entender e mensurar as múltiplas exposições aos diferentes

formatos de mídia para um único ponto no tempo de um mesmo consumidor (Pilotta *et al.*, 2004).

Brodersen *et al.*, (2015), por exemplo, propôs uma metodologia baseada em estruturas bayesianas para modelos de séries temporais para inferir o impacto causal de intervenções de marketing considerando a dependência temporal das observações ao invés da tentativa de isolar o efeito da ação. Neste caso, acompanha-se a métrica de sucesso da ação de marketing historicamente e então é construído um modelo de séries temporais, e com isso, é possível fazer a predição do comportamento da métrica em um tempo futuro.

A partir do modelo estimado, é possível entender o contra-efeito, ou seja, a predição do que aconteceria caso o tratamento não existisse (Varian, 2016). A partir disso utiliza-se o teste de hipóteses para identificar se a mudança é de fato estatisticamente significativa.

Essa metodologia traz vantagens em relação aos métodos tradicionais de mensuração do impacto de intervenções em marketing justamente por conseguir inferir a relação temporal da evolução do atributo, consegue absorver prioris empíricas nos seus parâmetros e é flexível à uma série de componentes de variação como sazonalidade e tendências locais (Brodersen *et al.*, 2015).

A utilização do modelo de séries temporais por estrutura bayesianas permite uma boa estimação para a relação de impacto causal de uma variável, sendo aplicada em diferentes contextos como mercado financeiro (Jammalamadaka *et al.*, 2019), gestão de tecnologias (Jun, 2019), saúde pública (Feroze, 2020) e marketing (Aggarwal, 2017).

Porém, no contexto do mercado imobiliário associado ao marketing, que vem em constante crescimento nos últimos anos e mesmo com a pandemia gerada pelo coronavírus (Rodrigues, 2021), não é possível encontrar na literatura a efetividade de uma campanha de marketing em massa, com a utilização de diferentes canais de mídia, muitos estudos são focados na percepção de marca com esse mercado em objetivos distintos como turismo (Liu *et al.*, 2016), ou com objetivos que não tange ao uso de mídias em si, como a previsão de valores de venda de imóveis (Ghysels *et al.*, 2013), o mercado imobiliário como um investimento financeiro (Ross *et al.*, 1991), os efeitos desse mercado em cenários macroeconômicos (Case *et al.*, 2000) ou ainda em relação ao planejamento urbano e a evolução desse mercado (Ratcliffe *et al.*, 2021). Logo, esse estudo pretende fazer uma aplicação da técnica desenvolvida por Brodersen no contexto imobiliário, analisando dados reais de desempenho de uma campanha de marca que utiliza canais de mídia “online” e “offline” com o foco na geração de conversões (contratos de compra e venda assinados).

Dessa forma o problema da pesquisa é o seguinte: “ Qual é o efeito casual da nova abordagem de mensuração dos efeitos de campanhas de marketing ?” O objetivo da pesquisa é propor uma nova abordagem de como mensurar efeitos de campanhas de marketing diante de tantos contextos, chamado de impacto causal

Assim, com a aplicação da metodologia de impacto causal, é possível verificar a eficiência do plano integrado de marketing diante dos resultados esperados e validar se os investimentos despendidos de fato contribuíram significativamente para os resultados da empresa, o que permite tomar ações mais assertivas ao trabalhar com diferentes tipos de mídias. Além disso, pretende-se preencher o espaço que existe na literatura em relação à análise do uso de mídias no contexto imobiliário, a partir de métodos quantitativos de impacto causal.

## **2 ASPECTOS METODOLÓGICOS**

Para o entendimento do objetivo proposto neste projeto, foi feita uma pesquisa quantitativa. Por se tratar de uma aplicação específica de uma empresa, todo o histórico de dados utilizados corresponde à população dos dados. Logo, não foi utilizado nenhum tipo de técnica de amostragem, e os resultados calculados foram obtidos considerando um estudo populacional para fomentar essa pesquisa explicativa.

A marca analisada é nova no mercado, e ingressou no universo imobiliário com o contexto de utilizar a tecnologia a favor de um mercado tão burocratizado e ultrapassado que é o mercado imobiliário. Através de um processo 100% digital, a marca tem como objetivo reduzir o tempo e facilitar o processo de procura de um imóvel através de recomendações e otimizações orientadas à dados, sendo assim caracterizada como uma *proptech* (Braesemann *et al.*, 2020).

A empresa teve um crescimento exponencial, potencializado por grandes aportes de investimentos, característico de *startups* que realizam angariação de fundos (Cremades). Apesar de recente, a empresa está em constante expansão de praças de atuação. Porém, nesse projeto foram analisados apenas os dados da praça de São Paulo, onde também fica a sede da empresa e que é a principal região de atuação da marca e responsável por mais de 90% dos contratos assinados.

A base de dados analisada consta com 642 observações que foram coletadas em uma granularidade diária, e ao todo foram observadas 8 variáveis explicativas que contemplam investimentos em diferentes canais de mídias online e offline, que variam de plataformas de busca, redes sociais, plataformas de *streaming*, jornais, revistas, televisão e etc. Por questões de privacidade das informações, os nomes das variáveis não serão revelados e nem as datas em que os dados foram coletados.

Mesmo com o pouco período de existência, os investimentos em mídias sempre existiram e evoluíram ao longo do tempo, dessa forma, tem-se dados que evidenciam o comportamento das flutuações de investimentos no número de contratos assinados. Tais dados foram coletados por ferramentas de monitoramento de performance de mídias e de sites, dentre as ferramentas citadas, destaca-se principalmente: Google Analytics, para a coleta de dados de performance do site e do aplicativo da empresa bem como dados de comportamento dos usuários da plataforma. *Google Ads*, para a coleta de dados de investimento de campanhas em ambientes digitais do *Google*. *Facebook Ads*, para a coleta de dados de investimentos de campanhas em ambientes digitais sob propriedade do *Facebook*. *Criteo Ad Platform*, para a coleta de dados de investimentos de campanhas de *retargeting* em ambientes da Criteo. Um sistema de ERP para a coleta de dados de investimentos em demais frentes do plano de mídia, como mídias “out-of-home” [OOH], imprensa, jornais e revistas de bairro e custos com mídias sociais

## 2.1 Modelo Bayesiano

Para validar se a contribuição é estatisticamente significativa, uma das formas é analisar o impacto causal do plano integrado de mídia, a metodologia de impacto causal utilizada nesta pesquisa tem como premissa a utilização de um modelo de de série temporal de estruturas Bayesianas. Os modelos estruturais de séries temporais podem ser definidos pelo seguinte par de equações:

$$(2.1) \quad y_t = Z_t^T \alpha_t + \varepsilon_t,$$

$$(2.2) \quad \alpha_{t+1} = T_t \alpha_t + R_t \eta_t,$$

em que  $\varepsilon_t \sim N(0, \sigma^2)$  e  $\eta_t \sim N(0, Q_t)$  são independentes. E que a equação (2.1) é chamada de equação observada e a equação (2.2) é chamada de equação de estado (Brodersen et al., 2015).

Os modelos estruturais para séries temporais são úteis pois conseguem ser flexíveis e modulares, permitindo serem ajustados em diversos modelos já existente e comumente utilizados na literatura como modelos auto-regressivos [AR], modelos com suavização [ARMA] e modelos com maior complexidade como ARIMA e SARIMA (Harvey, 1990).

Logo, devido a essa flexibilidade, pode-se considerar componentes da série como a tendência linear local, que permite identificar no decorrer de uma série temporal a expectativa de crescimento entre um tempo  $t$  e o tempo  $t + 1$ . Outro fator importante a ser considerado é a

sazonalidade, que permite identificar comportamentos cíclicos da série que podem impactar diretamente na previsão da série (Kitagawa *et al.*, 1984).

Além disso, como há oscilações temporais de investimentos ao longo do período da campanha, outro fator importante a se considerar é a contribuição dessas covariáveis na série principal a partir da estimação de coeficientes dinâmicos (Banerjee *et al.*, 2007; West *et al.*, 1997), ou seja, dados as covariáveis  $j = 1, \dots, J$  tem-se que o componente da regressão dinâmica é dados por:

$$(2.3) \quad x_t^T \beta_t = \sum_{j=1}^J x_{j,t} \beta_{j,t},$$

$$(2.4) \quad \beta_{j,t+1} = \beta_{j,t} + \eta \beta_{j,t},$$

Por fim, como o banco de dados consiste em diferentes covariáveis, utiliza-se a metodologia de spike-and-slab para seleção de variáveis, pois ao incluir esparsidade nos regressores, é possível reduzir drasticamente o tamanho do problema de estimação dos coeficientes (Scott *et al.*, 2014). Assim, será incluído no modelo apenas os investimentos que possuem alta probabilidade de estarem contribuindo com os resultados na campanha.

Com as componentes definidas, parte-se para o processo de estimação que tem como base a aplicação do amostrador de Gibbs a partir de uma cadeia de Markov para ajustar a posteriori adequada (Durbin *et al.*, 2002). A partir da posteriori obtida, é possível estimar o efeito incremental da posteriori, que é o principal objetivo da análise de impacto causal, que é dado por (2.4) (Brodersen *et al.*, 2015):

$$(4.4) \quad p(\underline{y}_{n+1:m} | y_{1:n}, x_{1:m}).$$

Em (2.4) pode-se ver que a densidade da equação é definida pela porção de séries temporais não observadas, ou seja, o efeito contrafactual de resposta de mercado que seria observado na ausência do tratamento. Em outras palavras, a partir disso observa-se a estimativa do resultado esperado do comportamento natural da série caso não existisse a execução da campanha de interesse.

Então, a partir do resultado esperado e o resultado real, é possível avaliar o impacto do plano de comunicação a cada unidade de tempo, em que o tempo é dados por  $t = n + 1, \dots, m$ , logo o impacto é definido por:

$$(2.5) \quad \phi_t^{(\tau)} := y_t - \underline{y}_t^{(\tau)},$$

ou então, pela soma acumulada dos incrementos causais, que facilita a interpretação da contribuição total da campanha e é definido por:

$$(2.6) \quad \sum_{t'=n+1}^t \phi_{t'}^{(\tau)}, \forall t = n + 1, \dots, m.$$

Dessa forma, é possível obter de acordo com um valor-p pré-estabelecido se a contribuição do plano de mídia integrado é de fato significativa.

### 3 RESULTADOS E DISCUSSÃO

A partir dos dados coletados, foi feita uma análise descritiva para identificar o comportamento das séries temporais que serão trabalhadas. Uma série temporal, é um sistema dinâmico (Hamilton, 2020) que descreve o comportamento de uma variável e intervalos dependentes, no banco de dados analisado observa-se que a coleta dos dados foi feita em intervalos diários de tempo.

Considerando as 642 observações dos nossos dados, tem-se que o período de execução da campanha com o plano de mídia integrado se deu entre os pontos 593 e 642, ou seja, a campanha circulou na praça de interesse por um total de 49 dias. O objetivo primário da ação é o crescimento do número de contratos, que será tratado com a variável resposta, apesar de haver objetivos secundários de construção de marca e ganho de percentual de mercado, que não foram analisados nesta pesquisa.

Na análise foi observado que nem todas as mídias utilizadas pela marca foram operadas durante o período de ação do plano de mídia, isso deve-se às particularidades de mensagem e canal de interesse da marca para se comunicar com o seu público-alvo, tendo canais que funcionam ativamente todos os dias e outros que são utilizados em intervalos específicos de tempo.

As médias diárias das variáveis no período inicial da marca (200 primeiros dias), no período pré-campanha (entre o dia 201 e 592) e no período durante a campanha (entre o dia 593 e 642) que evidenciam as oscilações pelas particularidades citadas acima, podem ser analisadas na Tabela 1:

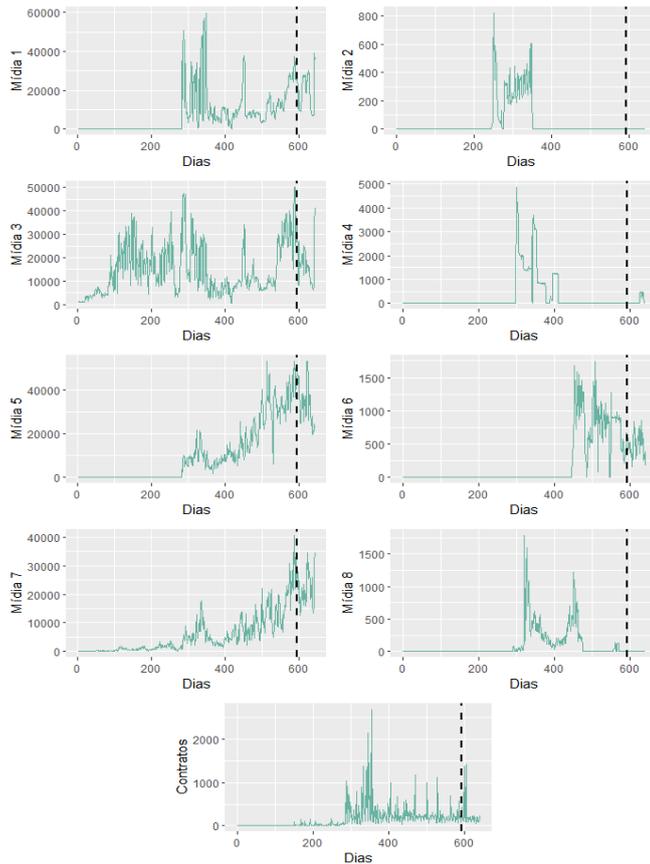
Tabela 1. Valor médio das variáveis explicativas e variável respostas em períodos distintos de tempo

Variável	Média - Período Inicial	Média - Período Pré-campanha	Média - Período de Campanha
Total de Contratos	6,44	224,35	237,84
Investimento Média 1	0,00	11227,41	19401,43
Variável	Média - Período Inicial	Média - Período Pré-campanha	Média - Período de Campanha
Investimento Média 2	0,00	74,51	0,00
Investimento Média 3	12878,36	15961,28	17174,04
Investimento Média 4	0,00	415,79	88,00
Investimento Média 5	0,00	14746,34	34244,43
Investimento Média 6	0,00	298,18	493,23
Investimento Média 7	491,62	7632,17	22024,84
Investimento Média 8	0,00	151,88	0,00

Pode-se observar o comportamento das variáveis na Figura 1, figura que foi construída com o apoio do *software* estatístico R e com o auxílio do pacote *ggplot2*:

Descritivamente, pode-se observar um aumento no número médio de contratos diários durante o período de campanha, o que pode ser um indicativo de que o plano integrado de mídia foi eficaz. Além disso, durante o período de campanha tem-se que parte dos investimentos sofreram redução e alguns até mesmo foram zerados (médias 2, 4 e 8), enquanto outros sofreram aumento (mídia 1, 3, 5, 6 e 7). Porém, não se tem evidências para afirmar que a contribuição do plano de mídia foi estatisticamente significativa.

Figura 1. Comportamento temporal das variáveis explicativas e da variável resposta nos 642 dias observados.

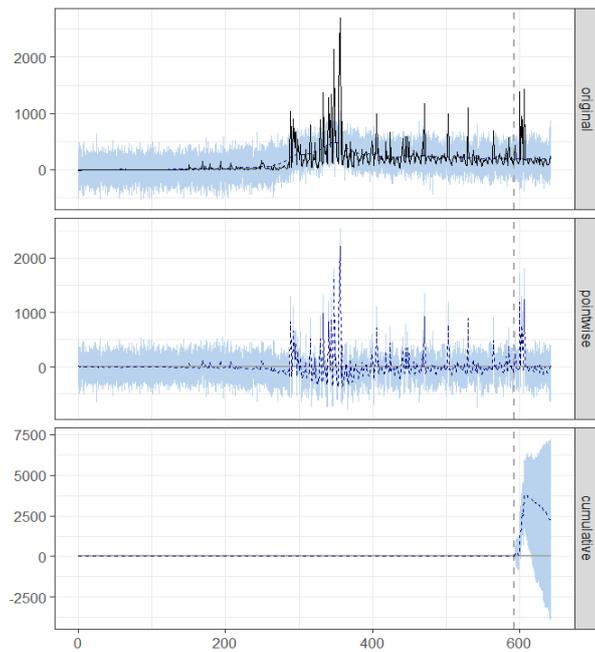


Para entender a significância, foi utilizado a metodologia de impacto causal através de um modelo auto-regressivo, ou seja, através do comportamento da própria série temporal de contratos assinados, dessa forma é possível estimar o resultado esperado durante o período da campanha e compará-lo com o resultado real, conforme na Figura 2,

A visualização foi feita novamente com o auxílio do *software* estatístico R através do pacote *CausalImpact*. Observa-se no gráfico de resultado acumulado (terceiro gráfico) que o resultado real do período da campanha teve uma performance acima do resultado esperado, pode-se também observar que o resultado foi altamente alavancado nos primeiros dias da campanha e depois houve uma estabilização nos dias restantes.

Além disso, nota-se que o resultado estimado contempla a sazonalidade natural da variável resposta e isso é utilizado na projeção. Conforme a metodologia proposta por Brodersen *et al.*, (2015), foi calculado o valor médio da variável resposta no período de intervenção da ação que foi de 237,84, e na ausência de uma intervenção, a média esperada foi de 191,84, resultando de um intervalo de confiança de 95% dado por [90,75 ; 315,28]. Subtraindo-se o valor predito pelo valor da variável resposta, tem-se que a estimativa do efeito causal na média diária foi de 46,00, com um intervalo de confiança de 95% dado por [-77,44 ; 147,00].

Figura 2. Visualização do impacto causal no modelo autoregressivo



Através da soma acumulada das observações individuais, obtém-se que a variável resposta teve um valor acumulado de 11,89 mil contratos, e caso não houvesse a intervenção do plano de mídia integrado, o resultado esperado seria 9,59 mil contratos, em que o intervalo de confiança 95% para a predição é [4,54 mil ; 15,76 mil].

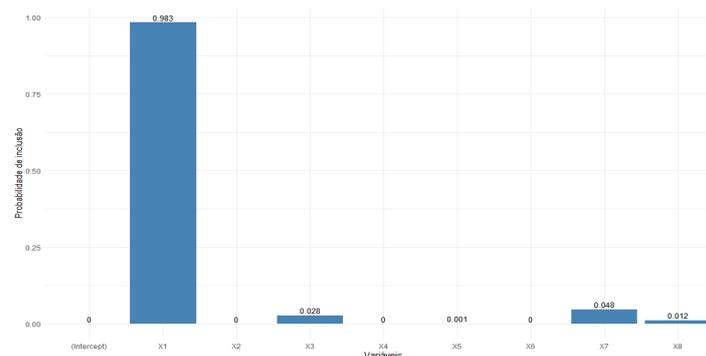
Ou seja, em termos relativos, tem-se que o número de contratos apresentou um aumento de 24% em relação ao que se era esperado, e que o intervalo de confiança 95% é [-40% , +77%], resultando em uma valor-p de 0,281.

Portanto, sob a perspectiva da metodologia de impacto causal, com o uso de um modelo autoregressivo, tem-se evidências de que a marca não atingiu o objetivo de ter um aumento significativo de contratos através de um plano integrado de mídia, já que não rejeita-se a hipótese nula de contribuição para o resultado da variável resposta (Gibbons *et. al.*, 1975).

Porém, uma segunda abordagem é utilizar os dados de mídia para auxiliar na estimativa do modelo, logo pode-se usar a característica Bayesiana do modelo BSTS para entender quais investimentos em mídia possuem alta probabilidade de influenciarem o valor total de contratos, e a partir disso, realizar um ajuste mais adequado do modelo e estimar de forma mais eficiente o resultado esperado para o período de campanha.

Pelo critério de spike-and-slab (Scott *et al.*, 2014), obtêm-se as seguintes probabilidades de contribuição de cada um dos investimentos apresentados na Figura 3:

Figura 3. Visualização das probabilidades estimadas de contribuição dos diferentes investimentos de mídia.



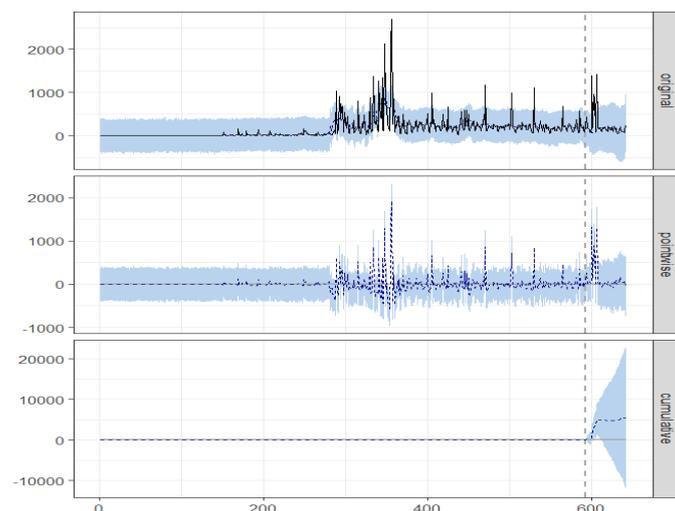
Pode-se observar que a variável com maior probabilidade de inclusão no modelo é o investimento na mídia 1 (X1), com uma probabilidade muito próxima de 1. Em seguida, tem-se com maior probabilidade de inclusão os investimentos nas mídias 7 (X7), 3 (X3), 8 (X8) e 5 (X5) respectivamente, porém todas com valores abaixo de 0,05.

Por fim, tem-se que o intercepto, que pode ser interpretado como o resultado esperado naturalmente pela série caso não houvesse nenhum efeito complementar ao resultado estimado (Chan et. al., 1995), tem probabilidade de inclusão 0, junto com os investimentos nas mídias 2 (X2), 4 (X4) e 6 (X6).

Ou seja, a maior parte da contribuição do resultado esperado durante o período de campanha é proveniente dos investimentos da mídia 1. Logo, será utilizado apenas essa covariável para a construção do modelo de previsão de séries temporais para que o entendimento do efeito do plano de mídia integrado possa ser melhor mensurado.

Logo, com a seleção de variáveis finalizadas, é possível construir o modelo mais adequado para a predição e então utilizar a metodologia de impacto causal para identificar o efeito do plano de mídia integrado na série temporal observada conforme a Figura 4.

Figura 4. Visualização do impacto causal no modelo BSTS utilizando os investimentos na mídia 1 como regressores.



Mais uma vez foi feito o uso do *software* estatístico R com o pacote *CausalImpact* para a construção da figura, dessa vez utilizando o modelo BSTS com regressores (Scott et. al., 2014). Nele, é possível observar novamente que mesmo com o modelo com covariáveis ainda existe um aumento relativo no número de contratos, conforme a imagem com o total acumulado mostra.

Porém, diferente do modelo autoregressivo, esse aumento é mais sutil no início da campanha e após o período de crescimento ele se estabiliza diferente do resultado anterior onde havia uma queda brusca da soma acumulada, indicando que desta vez o número de contratos assinados foi próximo do valor estimado pelo modelo durante o período da campanha.

Novamente, comparando os resultados de acordo com a metodologia de impacto causal (Brodersen et. al., 2015) tem-se que o valor médio da variável resposta no período de intervenção da ação foi de 237,84 conforme citado anteriormente, porém com o modelo atual, na ausência de uma intervenção, a média esperada é de 128,38 contratos, com um intervalo de confiança de 95% dado por [-262,38 ; 458,36]. Ou seja, no valor médio tem-se que a estimativa atual é 63,46 menos contratos do que no modelo autoregressivo, o que é justificado pelos investimentos na mídia X1.

Logo, a estimativa do efeito causal dado pela diferença entre o valor observado e o valor estimado é de 109,46 contratos, com um intervalo de confiança de 95% dado por [-262,38 ; 458,36].

A análise da soma acumulada do período nos mostra que a estimativa para o período seria o total de 6,42 mil contratos, com um intervalo de confiança de 95% dado por [-11,03 mil ; 25,01 mil]. Que comparado com o valor observado de 11,89 mil contratos, tem-se um aumento relativo de 85% em relação ao valor esperado.

Porém, apesar do aumento, o intervalo de confiança é dado por [-204% ; +357%], resultando em um valor-p de 0,254. Logo, adotando-se um nível de significância de 5%, não tem-se evidência para rejeitar a hipótese nula de que a contribuição do plano de mídia é diferente de 0, portanto, não pode-se afirmar que a execução de um plano de mídia integrado teve contribuição para o total de contratos assinados (Gibbons *et. al.*, 1975).

Além disso, é possível observar que o modelo com a utilização de regressores proporcionou uma estimativa do resultado médio menor do que o modelo autoregressivo, porém com intervalos de confiança mais amplos. Logo, pode identificar que a inclusão da nova variável de investimento na mídia 1 trouxe maior variância para as estimativas (DRAPER *et. al.*, 1998).

No estudo de Aggarwal (2017) é possível observar um resultado diferente, onde ao analisar campanhas de marketing que foram executadas durante o evento de *Super Bowl* americano, o maior evento de futebol americano do mundo, encontrou-se resultados que indicam um aumento descritivo no número de pesquisas sobre as marcas no *Google* variando esse aumento de acordo com o seu nicho de mercado.

Também é apresentado por Brodersen (2015) uma aplicação dessa metodologia em dados empíricos para observar o número de vezes que um usuário era redirecionado à página de seus produtos após clicar em um *link* do *Google*. Nesse estudo observa-se um aumento descritivo e estatisticamente significativo na métrica de interesse, chegando em um aumento de 22% e com um intervalo de confiança 95% dado por [13%, 30%].

Logo, apesar do estudo aqui apresentado mostrar um aumento de 24% nos resultados para o modelo autoregressivo e um aumento de 85% no modelo com a inclusão de regressores, o intervalo de confiança contempla o número 0, não sendo possível afirmar que o aumento foi significativo (Jesus Loureiro *et. al.*, 2011). Isso pode ser explicado pelo comportamento natural da série e à falta de parâmetros que permitam uma melhor estimativa (Granger, 2001).

## 5 CONCLUSÃO E CONSIDERAÇÕES FINAIS

Por meio da metodologia de impacto causal, com a utilização tanto de um modelo autoregressivo quanto com a utilização de um modelo com covariáveis, não foi possível inferir que a marca atingiu seu objetivo de aumento do número total de contratos. Apesar do aumento descritivo da variável resposta de 24% no modelo autoregressivo e de 85% no modelo com regressores, em ambos casos o 0 estava incluso no intervalo de confiança, adotando-se um nível de significância de 5%. Além disso, foi observado que o modelo com regressores apesar de diminuir a estimativa pontual dos resultados esperados, trouxe um intervalo de confiança maior, implicando no aumento de variabilidade analisada na série temporal. Porém, pode-se observar que a utilização de um plano de mídia integrado amplo, como o analisado aqui, tende a ter efeitos mais imediatos em métricas como alcance, impressões e percepção sob a marca que não foram objetivos estudados nesse projeto. Além disso, o tempo de jornada de compra de um apartamento pode ser longo devido a fatores de escolha, relação com instituições bancárias em casos de financiamento ou ainda outras variáveis. O que pode indicar que o período de 49 dias de campanha não foi suficiente para chegar em conclusões estatisticamente significativas. Logo, o estudo aqui apresentado tem limitações em relação aos dados coletados, já que o

período de tempo de campanha é relativamente curto e não tem dados de efeitos pós campanha, além de que métricas de topo de funil não foram analisadas. Portanto, para trabalhos futuros, uma abordagem a ser adotada é trabalhar com métricas de percepção de marca ou que estejam relacionadas com as etapas de topo de funil e utilizar um período de tempo de análise maior para que possa ter um melhor entendimento de janelas de conversão do primeiro momento de contato de um cliente com a à marca até a conversão de interesse de fato.

## Referências

- Grewal, D., Hulland, J., Kopalle, P. K., & Karahanna, E. The future of technology and marketing: A multidisciplinary perspective, 2020.
- Pilotta, J. J., Schultz, D. E., Drenik, G., & Rist, P. (2004). Simultaneous media usage: A critical consumer orientation to media planning. *Journal of Consumer Behaviour: An International Research Review*, 3(3), 285-292.
- Krizanova, A., Lăzăroiu, G., Gajanova, L., Kliestikova, J., Nadanyiova, M., & Moravcikova, D. (2019). The effectiveness of marketing communication and importance of its evaluation in an online environment. *Sustainability*, 11(24), 7016.
- Índices FipeZap de preços de Imóveis Anunciados [FIPEZAP]. 2021. Variação do índice FIPEZAP. Disponível em: <<https://fipezap.zapimoveis.com.br/>> . Acesso em: 27 set. 2021.
- Câmara Brasileira da Indústria da Construção [CBIC]. 2021. Indicadores Imobiliários Nacionais. Disponível em: <<http://www.cbicdados.com.br/menu/mercado-imobiliario/indicadores-imobiliarios-nacionais>> . Acesso em: 27 set. 2021.
- Pedrick, J. H., & Zufryden, F. S. (1991). Evaluating the impact of advertising media plans: A model of consumer purchase dynamics using single-source data. *Marketing Science*, 10(2), 111-130.
- Pedrick, J. H., & Zufryden, F. S. (1993). Measuring the competitive effects of advertising media plans. *Journal of Advertising Research*, 33(6), 11-21.
- Purwanti, Y. (2021). The Influence Of Digital Marketing & Innovasion On The School Performance. *Turkish Journal of Computer and Mathematics Education (TURCOMAT)*, 12(7), 118-127.
- Qurratu'Aini, H., & Hapsari, A. Y. (2019). Interests influence of digital marketing product sales in exports by SMEs in bandung. *Global Business and Management Research*, 11(1), 217-225.
- Erlangga, H. (2021). Effect Of Digital Marketing And Social Media On Purchase Intention Of Smes Food Products. *Turkish Journal of Computer and Mathematics Education (TURCOMAT)*, 12(3), 3672-3678.
- Nofal, M. I., Al-Adwan, A. S., Yaseen, H., & Alsheikh, G. A. A. (2020). Digital marketing effect to intention to domestic tourism during COVID-19 in Jordan. *Periodicals of Engineering and Natural Sciences (PEN)*, 8(4), 2471-2483.
- Buchanan, L., Kelly, B., & Yeatman, H. (2017). Exposure to digital marketing enhances young adults' interest in energy drinks: An exploratory investigation. *PloS one*, 12(2), e0171226.
- Garaus, M., Wagner, U., & Bäck, A. M. (2017). The effect of media multitasking on advertising message effectiveness. *Psychology & Marketing*, 34(2), 138-156.
- Brodersen, K. H., Gallusser, F., Koehler, J., Remy, N., & Scott, S. L. (2015). Inferring causal impact using Bayesian structural time-series models. *The Annals of Applied Statistics*, 9(1), 247-274.
- Varian, H. R. (2016). Causal inference in economics and marketing. *Proceedings of the National Academy of Sciences*, 113(27), 7310-7315.

- Jammalamadaka, S. R., Qiu, J., & Ning, N. (2019). Predicting a stock portfolio with the multivariate Bayesian structural time series model: do news or emotions matter?. *International Journal of Artificial Intelligence*, 17(2), 81-104.
- Jun, S. (2019). Bayesian structural time series and regression modeling for sustainable technology management. *Sustainability*, 11(18), 4945.
- Feroze, N. (2020). Forecasting the patterns of COVID-19 and causal impacts of lockdown in top five affected countries using Bayesian Structural Time Series Models. *Chaos, Solitons & Fractals*, 140, 110196.
- Aggarwal, N. (2017). Inferring the causal impact of Super Bowl marketing campaigns using a Bayesian structural time series model (Doctoral dissertation, COOPER UNION).
- Rodrigues, H. A. X. (2021). Coronavírus e Direito Imobiliário: mudanças e impactos trazidos pela Pandemia ao Mercado Imobiliário.
- Hamilton, J. D. (2020). *Time series analysis*. Princeton university press.
- Harvey, A. C. (1990). Forecasting, structural time series models and the Kalman filter.
- Kitagawa, G., & Gersch, W. (1984). A smoothness priors–state space modeling of time series with trend and seasonality. *Journal of the American Statistical Association*, 79(386), 378-389.
- Kauffman, R. J., & Techatassanasoontorn, A. A. (2009). Understanding early diffusion of digital wireless phones. *Telecommunications Policy*, 33(8), 432-450.
- West, M., & Harrison, J. (2006). *Bayesian forecasting and dynamic models*. Springer Science & Business Media.
- Scott, S. L., & Varian, H. R. (2014). Predicting the present with Bayesian structural time series. *International Journal of Mathematical Modelling and Numerical Optimisation*, 5(1-2), 4-23.
- Durbin, J., & Koopman, S. J. (2002). A simple and efficient simulation smoother for state space time series analysis. *Biometrika*, 89(3), 603-616.
- Malhotra, N., Hall, J., Shaw, M., & Oppenheim, P. (2006). *Marketing research: An applied orientation*. Pearson Education Australia.
- Malhotra, N. K., Patil, A., & Kim, S. S. (2007). Bias breakdown. *Marketing Research*, 19(1).
- Braesemann, F., & Baum, A. (2020). PropTech: Turning real estate into a data-driven market?. Available at SSRN 3607238.
- Cerutti, E., Dagher, J., & Dell'Araccia, G. (2017). Housing finance and real-estate booms: A cross-country perspective. *Journal of Housing Economics*, 38, 1-13.
- Cremades, A. (2016). *The art of startup fundraising: pitching investors, negotiating the deal, and everything else entrepreneurs need to know*. John Wiley & Sons.
- Sampieri, R. H., Collado, C. F., Lucio, M. P. B. (2013). *Metodologia de Pesquisa*. Tradução de Daisy Vaz de Moraes. 5.ed. Porto Alegre.
- Chan, K. S., & Ledolter, J. (1995). Monte Carlo EM estimation for time series models involving counts. *Journal of the American Statistical Association*, 90(429), 242-252.
- Draper, N. R., & Smith, H. (1998). *Applied regression analysis* (Vol. 326). John Wiley & Sons.
- Granger, C. W. (2001). Forecasting white noise. *ECONOMETRIC SOCIETY MONOGRAPHS*, 32, 457-471.
- Sissors, J. Z. (2003). *Planejamento de mídia–Grupo de mídia*. NBL Editora.
- Pais, J. M., Cairns, D., & Pappámikail, L. (2005). Jovens europeus: retrato da diversidade. *Tempo social*, 17(2), 109-140.
- de Jesus Loureiro, L. M., & Gameiro, M. G. H. (2011). Interpretação crítica dos resultados estatísticos: para lá da significância estatística. *Revista de Enfermagem Referência*, 3(3), 151-162.
- Guimarães Filho, A. C. C. (2019). Análise do processo de compra e venda de imóveis residenciais urbanos no Brasil: uma proposta para redução de atritos.

- Gibbons, J. D., & Pratt, J. W. (1975). P-values: interpretation and methodology. *The American Statistician*, 29(1), 20-25.
- Scott, S. L., & Varian, H. R. (2014). Predicting the present with Bayesian structural time series. *International Journal of Mathematical Modelling and Numerical Optimisation*, 5(1-2), 4-23.
- Liu, Z., Huang, S. S., Hallak, R., & Liang, M. (2016). Chinese consumers' brand personality perceptions of tourism real estate firms. *Tourism Management*, 52, 310-326.
- Ghysels, E., Plazzi, A., Valkanov, R., & Torous, W. (2013). Forecasting real estate prices. *Handbook of economic forecasting*, 2, 509-580.
- Ross, S. A., & Zisler, R. C. (1991). Risk and return in real estate. *The Journal of Real Estate Finance and Economics*, 4(2), 175-190.
- Ratcliffe, J., Stubbs, M., & Keeping, M. (2021). *Urban planning and real estate development*. Routledge.