SOLUÇÃO DO PROBLEMA DE MARKETING DIRETO E SUAS VARIANTES ATRAVÉS DE MÉTODOS EXATOS E HEURÍSTICOS

Felipe Martins Müller
Universidade Federal de Santa Maria / PPGEP
Centro de Tecnologia, Prédio 07, 97105-900, Santa Maria - RS, Brasil
felipe@inf.ufsm.br

Vanessa Andréia Schneider
Universidade Federal de Santa Maria / PPGEP
Centro de Tecnologia, Prédio 07, 97105-900, Santa Maria - RS, Brasil
vanessaandreias@gmail.com

Veridiane Bárbara de Souza
Universidade Federal de Santa Maria / PPGEP
Centro de Tecnologia, Prédio 07, 97105-900, Santa Maria - RS, Brasil
veridianes@hotmail.com

Greici da Rosa da Cruz
Universidade Federal de Santa Maria / PPGCC
Centro de Tecnologia, Prédio 07, 97105-900, Santa Maria-RS, Brasil
inf.greici@gmail.com

Iaê Santos Bonilha
Universidade Federal de Santa Maria / PPGEP
Centro de Tecnologia, Prédio 07, 97105-900, Santa Maria - RS, Brasil
iaesb@hotmail.com

Gédson Mário Borges Dal Forno
Universidade Federal de Santa Maria / PPGEP
Centro de Tecnologia, Prédio 07, 97105-900, Santa Maria - RS, Brasil
gedsondf@gmail.com

RESUMO

O marketing direto é uma abordagem voltada ao cliente em nível individual, promovendo campanhas de promoção mais focadas, a fim obter ofertas cada vez mais assertivas e, consequentemente, a maximização do retorno financeiro. Diante disso, o presente estudo objetiva adaptar os modelos matemáticos e heurísticos para tratar o Problema de Marketing Direto com Oferta de Produto, testando em instâncias conhecidas na literatura e em dois novos conjuntos de instâncias, com maior grau de dificuldade. Em todos os casos, incluindo o efeito Canibalismo entre produtos. O problema foi resolvido por meio das metaheurísticas Grasp Tabu e algoritmo Genético, duas heurísticas H-R1 e H-R2 e, ainda, pelo método exato. Embora as heurísticas apresentaram bons resultados nas instâncias com maior número de clientes, elas foram incapazes de resolver instâncias de grande porte com maior grau de dificuldade, onde o método Grasp Tabu provou-se mais robusto e confiável.

Palavras-chave: Marketing Direto, Metaheurísticas, Heurísticas, Métodos exatos.

Tópicos: MH – Metaheurísticas, OA – Outras Aplicações em PO

Galoá { Este trabalho foi publicado utilizando o **Galoá** proceedings

ABSTRACT

Direct marketing is a customer-oriented approach on an individual level, promoting more focused promotion campaigns in order to obtain increasingly assertive offers and, consequently, the maximization of financial return. Therefore, this study aims to adapt mathematical and heuristic models to deal with the Problem of Direct Marketing with Product Offering, testing in known instances in the literature and in two new sets of instances, with a higher degree of difficulty. In all cases, including the cannibalism effect between products. The problem was solved by means of the Grasp Taboo metaheuristics and genetic algorithm, two heuristics H-R1 and H-R2 and also by the exact method. Although the heuristics presented good results in the large instances, they were unable to solve the large instances with greater degree of difficulty, where the Grasp Tabu method proved more robust and reliable.

Keywords: Direct Marketing, Metaheuristics, Heuristics, Exact Methods.

Paper topics: MH – Metaheuristics, OA – Other Apllications of OR

1. Introdução

Para muitas das organizações modernas, o marketing é uma parte essencial de suas operações, pois muitos dos produtos ofertados apresentam uma diferenciação relativamente pequena daqueles disponíveis nos concorrentes. Dessa forma, o sucesso - ou fracasso – de uma organização, depende muito da qualidade e eficácia de suas campanhas de marketing. Lançar uma campanha de marketing efetiva em mercados cada vez mais competitivos, é certamente uma tarefa desafiadora. Além disso, sucessivas campanhas são cada vez menos eficazes, pois os clientes, constantemente expostos a diferentes tipos de publicidade, tendem a ignorar.

Nesse sentido, uma das soluções, que está cada vez mais ganhando popularidade nos últimos anos, é o marketing direto [ŁADYZYNSKI et al. 2019], o qual é uma abordagem de marketing voltada ao cliente em nível individual, promovendo campanhas de promoção mais focadas, a fim obter ofertas cada vez mais assertivas e, consequentemente, a maximização do retorno financeiro [ABEMD 2017]. O marketing direto é um campo de atuação interessante e em expansão [CSIKÓSOVÁ et al. 2014].

No entanto, uma campanha de promoção pode tornar-se um problema de difícil resolução. As organizações podem contar com um banco de dados com informações de milhares e até milhões de clientes, também chamado de big-data, e um complexo conjunto de restrições de negócio, não sendo uma tarefa simples a análise de tais informações e a escolha de quais produtos oferecer e para quais clientes, de forma que a campanha tenha o maior retorno possível, visto que a resposta dos clientes é um tópico importante no marketing direto [SCHNEIDER, 2019]. Além disso, incorpora-se a possibilidade da venda de um produto interferir na venda de outro similar, se essa interferência for destrutiva esse efeito é chamado de canibalismo entre produtos [Traylor 1986], dificultando ainda mais o problema.

Logo, conjuntos de dados que não podem ser manipulados de maneiras tradicionais, requerem técnicas de processamento de informações avançadas, proporcionando a integração da área de marketing direto com métodos matemáticos, dentre eles a Pesquisa Operacional [OLIVEIRA et al. 2014]. Esta integração possibilita a aplicação de modelagem matemática e heurísticas eficientes para auxiliar na resolução de problemas que organizações enfrentam para compreender as reações de comportamento do consumidor em relação às campanhas de marketing direto, de acordo com suas características individuais. Além disso, essas bases de dados com milhares de clientes possuem restrições, como limite orçamentário, número máximo e mínimo de produtos que podem ser ofertados, custo fixo e taxa de retorno, que são fatores que exigem tempo para processar todas essas informações dos clientes, tornando as campanhas um problema de difícil solução.

Galoá { Este trabalho foi publicado utilizando o **Galoá** proceedings

Nobibon, Leus e Spieksma [2011], desenvolveram um modelo de otimização relacionado ao problema de marketing direto com oferta de produtos para maximizar o lucro total, sujeito a um conjunto de limitações. O estudo dos autores foi utilizado como base para alguns autores, dentre eles Oliveira et al. [2014], Cetin e Alabas-Uslu [2015], Souza [2018], Müller et al. [2018] e Schneider [2019], que empregaram modificações nos algoritmos propostos, resultando em contribuições teóricas e práticas. Além do modelo matemático Nobibon et al. [2011] disponibilizaram um conjunto de instâncias teste, que foram amplamente usadas por todas essas publicações, porém essas instâncias se mostraram com pouca dificuldade de resolução, necessitando serem ampliadas para um novo conjunto que demonstrasse que alguma das heurísticas antes consolidadas na literatura, mostrassem a sua falta de robustez.

Diante disso, o presente estudo objetiva adaptar os modelos matemáticos e heurísticos para tratar o Problema de Marketing Direto com Oferta de Produto, testando em instâncias conhecidas na literatura e em dois novos conjuntos de instâncias, com maior grau de dificuldade. Em todos os casos, incluindo o efeito Canibalismo entre produtos.

Esta pesquisa proporciona para comunidade científica novas contribuições, fortalecendo o embasamento teórico, pois trata métodos exatos e algoritmos heurísticos em um único estudo. Além disso, destaca-se a inserção de dois novos conjuntos de instâncias de grande porte e, também, a inserção do canibalismo entre produtos nas novas instâncias, diferenciando-se de estudos anteriores.

O restante do trabalho está organizado da seguinte forma: na seção 2 apresenta-se os estudos anteriores, na seção 3 a definição do problema, na seção 4 os experimentos computacionais e as conclusões na seção 5.

2. Estudos anteriores

Nobibon et al. [2011] desenvolveram um modelo de otimização relacionado ao problema de marketing direto com oferta de produtos para maximizar o lucro total, sujeito a um conjunto de limitações, como orçamento, retorno mínimo sobre o investimento, o número máximo e o número mínimo de produtos oferecidos aos clientes. Eles também propuseram técnicas heurísticas para aproximar soluções ótimas. Foram desenvolvidos oito algoritmos, sete baseados em métodos exatos e um baseado na meta-heurística Busca Tabu. Para o mesmo problema, Oliveira et al. [2014] apresentaram um algoritmo heurístico denominado GGVNS, que é a combinação dos procedimentos GRASP (Greedy Randomized Adaptive Search Procedure) e GVNS (Busca Geral em Vizinhança Variável), utilizando como busca local o método Descida em Vizinhança Variável (VND).

Cetin e Alabas-Uslu [2015] utilizaram o modelo de otimização de Nobibon et al. [2011], realizando alterações para tornar o modelo relaxado através da linearização das variáveis inteiras, derivando novas abordagens heurísticas denominadas H-R1 e H-R2 para o problema que é considerado NP-difícil. Esta estratégia foi realizada em duas fases, que são conectadas por uma regra heurística com base em programação matemática. Na fase I, um novo modelo de programação linear é utilizado para prever quais produtos são selecionados ou removidos da campanha. Uma vez que os produtos da campanha são determinados, o problema de seleção do produto é reduzido a um tipo de problema de atribuição. Na fase II, os produtos que foram selecionados na fase I são distribuídos aos clientes de forma otimizada por outro modelo de otimização. Os resultados computacionais obtidos de acordo com os autores, geraram soluções superiores para o problema em comparação com os métodos propostos na literatura. Porém, nesse trabalho, mostramos sua falta de robustez.

Souza [2018] propôs três algoritmos heurísticos para testar as instâncias encontradas na literatura, um algoritmo baseado em Busca Tabu, um em Busca Tabu em conjunto com GRASP e ainda um terceiro, de Busca Tabu em conjunto com GRASP com efeito de canibalismo. Dando sequência, Müller, Bonilha e Souza [2018] propuseram um algoritmo Genético, que gera uma

Galoá { Este trabalho foi publicado utilizando o **Galoá** proceedings

solução inicial de boa qualidade, cuja solução é melhorada por uma versão modificada do procedimento de Busca Tabu implementado por Nobibon, Leus e Spieksma [2011].

O estudo de Schneider [2019] objetivou conhecer os limitantes superiores do trabalho desenvolvido por Souza [2018], a partir da modelagem matemática aplicada por Nobibon et al. [2011] para problemas sem canibalismo entre produtos e com a inclusão da restrição de pares mutuamente excludentes para os problemas com canibalismo entre produtos. Schneider [2019] propôs ainda, duas estratégias distintas de pares mutuamente excludentes onde é considerada a Dissimilaridade e Similaridade dos produtos. O método exato aplicado mostrou-se suficiente para os problemas em questão para os problemas já citados, visto que o mesmo forneceu os limitantes superiores para todos os problemas e em sua maioria, na otimalidade, executando os mesmos em tempo computacional aceitável.

3. Definição do Problema

O Problema de Marketing Direto com Oferta de Produtos é um problema de otimização combinatória classificado pela literatura como pertencente à classe NP-difícil e busca definir se o produto *j* é ofertado ao cliente *i* e se o produto *j* irá fazer parte da campanha promocional. As variáveis de decisão x_{ij} e y_j são binárias, sendo $x_{ij} = 1$, representa que o produto *j* foi ofertado ao cliente *i*, e 0 caso contrário, e $y_j = 1$, representa que o produto j foi utilizado na campanha, e 0, caso contrário.

A construção do modelo baseou-se no modelo proposto por Nobibon et al. [2011] e possui os seguintes parâmetros: *C* corresponde ao conjunto de clientes, *O* é o conjunto de oferta de produtos, *Can* corresponde ao conjunto de pares (*i*,*j*) de produtos canibais, isto é, aqueles que não podem ser ofertados simultaneamente, ***j*** representa o produto ofertado (O_j), *i* representa o cliente (C_j), representa a probabilidade de o cliente *i* reagir positivamente a uma oferta do produto *j*, é o retorno esperado (receita) do cliente *i* quando o produto *j* é ofertado, é o custo associado com a oferta do produto *j* ao cliente *i*, corresponde ao lucro potencial líquido, do inglês *"net potential profit"*, que representa a diferença de receitas e custos associados à oferta do produto *j* ao cliente *i*, é o custo fixo incorrido quando o produto *j* é utilizado na campanha, *R* (*hurdle rate*) é a taxa mínima de retorno sobre o investimento global da campanha expresso em percentual e depende do risco do investimento, corresponde ao orçamento disponível para cada produto, é o número máximo de ofertas que o cliente *i* pode receber e é o compromisso de quantidade mínima (MQC – *minimum quantity commitment*), ou seja, o número mínimo de clientes que devem receber uma oferta do produto *j* para que este produto faça parte da campanha.

Dessa forma, após a determinação dos parâmetros e variáveis, define-se a função objetivo do problema como o objetivo de maximizar a soma dos lucros líquidos de cada oferta do produto *j* ao cliente *i*, menos os custos fixos f_j de cada produto utilizado na campanha, considerando o efeito de canibalismo entre produtos.

$$\max \quad \sum_{i=1}^{m} \sum_{j=1}^{n} (p_{ij} - c_{ij}) x_{ij} - \sum_{j=1}^{n} f_j y_j \tag{1}$$

A função objetivo do problema está sujeita às seguintes restrições:

$$\sum_{i=1}^{m} \sum_{j=1}^{n} p_{ij} x_{ij} \geq (1 + R) \left[\sum_{i=1}^{m} \sum_{j=1}^{n} c_{ij} x_{ij} + \sum_{j=1}^{n} f_j y_j \right] \tag{2}$$

$$\sum_{i=1}^{m} c_{ij} x_{ij} \leq B_j \qquad j = 1, \ldots, n \tag{3}$$

$$\sum_{j=1}^{n} x_{ij} \leq M_i \qquad i = 1, \ldots, m, \tag{4}$$

$$\sum_{i=1}^{m} x_{ij} \leq m y_j \qquad j = 1, \ldots, n \tag{5}$$

$$\sum_{i=1}^{m} x_{ij} \geq O_j y_j \qquad j = 1, \ldots, n \tag{6}$$

$$y_i + y_j \leq 1 \qquad \forall (i,j) \in Can \qquad (7)$$

$$y_j, x_{ij} \in \{0,1\} \qquad i = 1, \dots, m, \; j = 1, \dots, n \qquad (8)$$

A primeira restrição (2) diz respeito à taxa mínima de retorno, que garante que o total de receita exceda o total dos custos da campanha adicionados do percentual *R* (*hurdle rate*). A segunda restrição (3) garante que o orçamento B_j alocado ao produto *j* não seja excedido. A terceira restrição (4) assegura que serão ofertados no máximo M_i produtos ao cliente *i*. As próximas restrições (5) e (6) referem-se ao número mínimo de ofertas que devem ser feitas para que o produto *j* faça parte da campanha. Logo, se o produto não faz parte da campanha ele não será ofertado a nenhum cliente, porém, se o produto *j* fizer parte da campanha, pelo menos $O_j > 0$ clientes receberão a oferta. A restrição (7) impede a oferta de produtos similares (efeito canibalismo), tornando-os mutuamente excludentes. Por fim, a restrição de integralidade (8).

O problema é considerado NP-difícil [NOBIBON et al., 2011; OLIVEIRA et al., 2014] e foi resolvido utilizando três conjuntos de instâncias, com e sem efeito de canibalismo entre produtos, por meio das metaheurísticas Grasp Tabu, algoritmo Genético, duas heurísticas propostas por Cetin e Alabas-Uslu [2015] e, ainda, pelo método exato, apresentando, assim, um estudo completo de todos os modelos, mostrando resultados novos para esse tipo de problema. Foram executados ao total 3580 testes.

4. Experimentos computacionais

Os testes realizados foram efetuados com três conjuntos de instâncias, todas na versão com canibalismo entre produtos (pares canibais determinados por distância euclidiana) e sem canibalismo entre produtos (chamadas originais). Ao total foram consideradas 681 instâncias.

O primeiro conjunto com 324 instâncias elaborado e disponibilizado por Nobibon et al. [2011] pertencem ao grupo de instâncias grandes com 100, 200, 300, 1.000, 2.000, 10.000 clientes para 5, 10 e 15 produtos. O segundo conjunto com 16 instâncias de grande porte, foram geradas seguindo os mesmos critérios utilizados por Nobibon et al. [2011], mas com 15.000, 20.000, 40.000, 50.000 clientes para 5, 10, 15, 20, 30, 40 e 50 produtos. E o terceiro conjunto com 18 instâncias estratificadas, com 100, 5.000 e 15.000 clientes para 10, 15 e 40 produtos, que foram criadas ao longo deste estudo.

O algoritmo para geração do conjunto com 18 instâncias estratificadas, consiste na ideia de que o banco de dados de clientes de uma determinada empresa pode não ter apenas clientes com perfis de consumo diferentes, mas também clientes com poder aquisitivo diferentes. Essas diferenças podem gerar padrões de consumo distintos entre a base de clientes. Outro fator levado em consideração por esse algoritmo, é o fato de que os próprios produtos podem ter perfis de consumo diferentes associados a eles, um exemplo disso é o fenômeno: produtos similares com diferentes níveis de qualidade e preço, visando diferentes segmentos de mercado.

Durante o processo de geração das instâncias estratificadas, a base de clientes é dividida em três níveis chamados de estrato 1, 2 e 3. Estes estratos refletem no poder aquisitivo do cliente, sendo o estrato 1, composto por clientes com maior poder aquisitivo, o estrato 2 representam os clientes de poder aquisitivo intermediário e o estrato 3, compreende a maioria da população de clientes, pois são os que possuem o menor poder aquisitivo. O estrato do cliente afetará o custo da oferta, pois para cada cliente, um número máximo de ofertas será gerado e essa quantidade é afetada pelo estrato ao qual o cliente pertence, sendo que estratos mais altos terão um número maior de ofertas.

Além disso, os produtos são divididos em quatro tipos. Cada tipo de produto define a faixa de penetração de produto entre os estratos de cada cliente, a rotatividade mínima de respostas positivas à oferta, a rotatividade máxima para respostas positivas da oferta e o custo da

Galoá { Este trabalho foi publicado utilizando o **Galoá** proceedings

oferta do produto para cada estrato de cliente. Assim, cada tipo de produto possui uma participação percentual em cada estrato de cliente, o que representa a quantidade de indivíduos entre estratos que apresentará uma resposta positiva à oferta do produto, respeitando os intervalos pré-determinados.

O custo da oferta é baseado no status do cliente e no tipo de produto que será ofertado. Também foi criado o requisito mínimo de oferta, para evitar que produtos tenham ofertas intangíveis. Para cada cliente selecionado, é gerada uma oferta individual com valor aleatório definido pelo algoritmo. Finalizando os critérios para criação do conjunto de instâncias estratificadas, tem-se que o orçamento e o custo fixo de cada produto são gerados somente após a criação da oferta individual de cada produto.

Após a definição das instâncias, todos os conjuntos foram executados com códigos encontrados na literatura, conforme quadro 1.

Para análise dos dados foi realizada uma comparação entre as soluções obtidas nos testes focando-se em: performance pontual (número total de instâncias nas quais a heurística obteve o melhor resultado) e performance geral (distância relativa média em relação à solução ótima).

Quadro 1 - Métodos de solução utilizados

Método de solução	**Referência de base**	**Solucionador**
Método exato	Nobibon et al. [2011] e Schneider [2019]	IBM ILOG CPLEX Optimization Studio 12.9.0 utilizando linguagem Zimpl
Modelo 2	Cetin e Alabas Uslu [2015]	Gurobi 8.1.1 utilizando a linguagem Julia Pro 1.2.0-1
Heurística H-R1		
Heurística H-R2		
Tabu GRASP	Souza [2018]	Visual Studio Community utilizando a linguagem de programação C++
Algoritmo Genético	Müller et al. [2018]	

Primeiramente, realizou-se o diagnóstico dos resultados de cada heurística estudada utilizando como critério o valor de função objetivo que está mais aproximado do limitante superior fornecido pelo método exato. Neste contexto, como métrica para mensurar a qualidade da solução heurística implementada, adotou-se como medida a distância relativa das soluções geradas ao ótimo, conforme exposto na equação (9).

$$\Delta\% = \frac{Z_{UB} - Z_{AP}}{Z_{UB}} x\ 100 \qquad (9)$$

O parâmetro Δ% mensura a distância percentual entre o *upper bound* (limitante superior) encontrado pelo método exato e a solução obtida a partir de cada algoritmo heurístico. Deste modo, ZUB é considerado o limite superior encontrado pelo presente estudo e ZAP o valor da função objetivo encontrado através da implementação da heurística.

É importante destacar que, como ocorreram casos onde uma heurística não foi capaz de resolver uma determinada instância, para fins de consistência na comparação, foi considerado que a heurística produziu uma solução com um Δ de 100%. A tabela 1, expõe as médias percentuais relacionadas ao distanciamento do ótimo para cada problema associado aos conjuntos e aplicações heurísticas.

Ao analisar os resultados, percebe-se que, as 16 instâncias de grande porte, o desempenho superior foi identificado para o problema original no algoritmo H-R2 com uma

distância de 6,81% do ótimo e para o problema com canibalismo o melhor desempenho foi a heurística H-R1 com distância de 15,41% do ótimo. Para o conjunto de das 18 instâncias estratificadas, o desempenho superior está relacionado à estratégia Grasp Tabu, tanto para o problema original (8,13%) e com efeito de canibalismo entre produtos (14,35%).

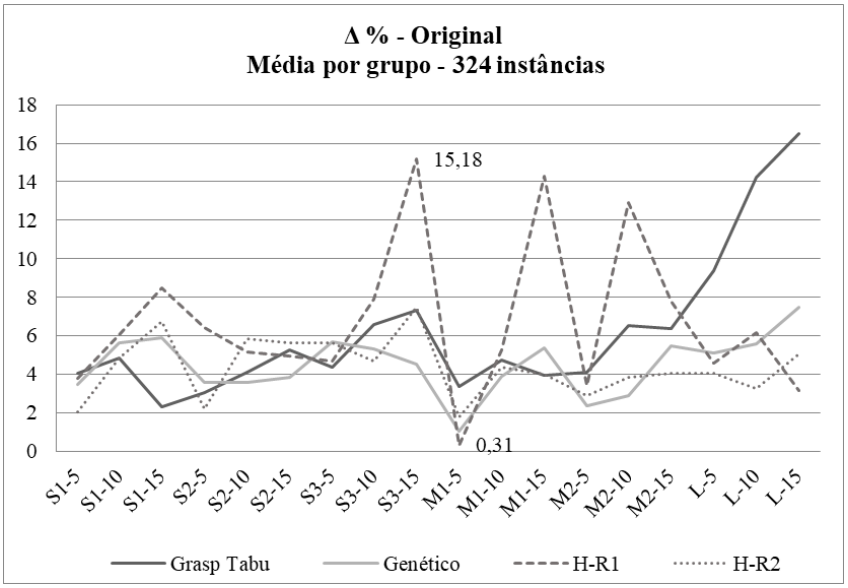
Para as 324 instâncias, na variação do problema com e sem canibalismo (original), a heurística H-R2 apresentou melhor desempenho com uma distância de 5,13% e 4,35%, respectivamente, seguido com o Genético que apresentou segundo melhor desempenho com 5,91% e 5,13%, respectivamente.

Tabela 1 - Distância percentual do ótimo

		Médias de Δ %			
		Grasp Tabu	Genético	H-R1	H-R2
324	Original	6,17	4,47	6,69	4,35
	Com Canibalismo	6,71	5,91	7,20	5,13
16	Original	17,46	19,92	7,91	6,81
	Com Canibalismo	22,67	21,67	15,41	15,60
18	Original	14,35	24,37	21,07	71,97
	Com Canibalismo	8,13	23,22	27,04	70,97

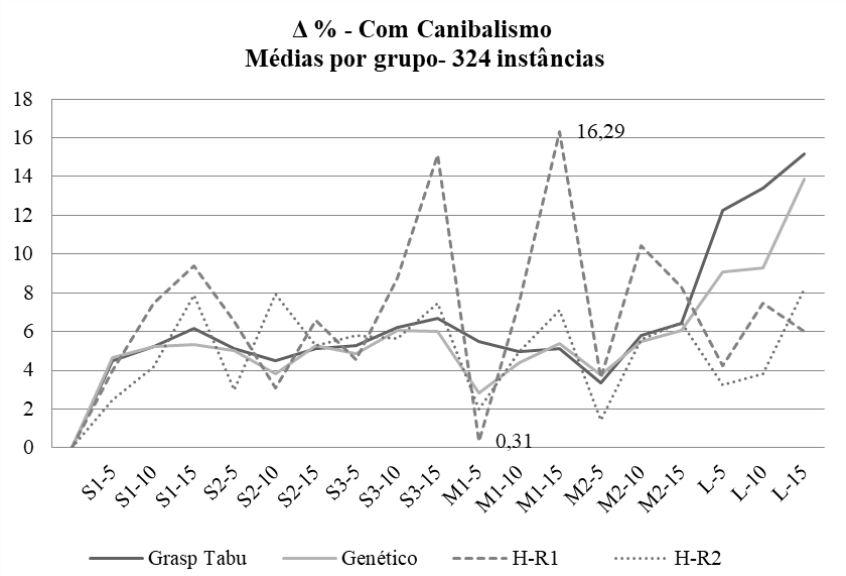
Na sequência, verificou-se o distanciamento do ótimo em relação aos grupos em que as instâncias do primeiro conjunto (324) estão subdivididas, conforme figura 1. Foi possível notar que, para o problema em sua versão original, a heurística H-R1 demonstrou comportamento mais instável que os outros métodos. O Genético e H-R2 mantiveram-se com resultados próximos. Já o algoritmo Grasp Tabu, nas instâncias L (10 mil clientes), apresentou os piores resultados, com maior distância do ótimo.

Figura 1 - Distância percentual do ótimo por grupos - Problema Original



Para o problema com canibalismo, conforme figura 2, é possível observar conduta similar entre os métodos Grasp Tabu, Genético e H-R2, embora o Grasp Tabu ainda apresenta piores resultados. Ressalta-se, novamente, o contexto onde a heurística H-R2 apresenta melhor desempenho ao atingir o grupo de instâncias L e o método H-R1 aponta maior variabilidade.

Figura 2: Distância percentual do ótimo por grupos - Problema Com Canibalismo



Por fim, verificou-se o registro absoluto referente as resoluções heurísticas para os três conjuntos de instâncias, onde cada instância foi analisada e contabilizada na heurística em que demonstrou solução mais próxima ao ótimo, conforme desempenho exposto na tabela 2. Para o conjunto de 324 instâncias, o melhor desempenho delineado é a partir da heurística H-R1 para o problema original e com canibalismo. O pior desempenho registrou-se para o problema original na heurística Grasp Tabu e para a variação do problema com canibalismo no algoritmo Genético.

Tabela 2 - Desempenho

Heurística	DESEMPENHO					
	324 instâncias		16 instâncias		18 instâncias	
	Original	Com Canibalismo	Original	Com Canibalismo	Original	Com Canibalismo
Grasp Tabu	28	42	1	2	7	9
Genético	60	24			1	1
H-R1	125	115	2	4	8	6
H-R2	45	64	13	7		
Grasp Tabu = Genético					1	
Grasp Tabu = H-R1	1	1				
Grasp Tabu = H-R2		1			1	2
Grasp Tabu = Genético = H-R1						
Grasp Tabu = Genético = H-R2	1	2				
Grasp Tabu = H-R1 = H-R2	1	6				
Grasp Tabu = Genético = H-R1 = H-R2	1	2				
Genético = H-R1						
Genético = H-R2	2					
H-R1 = H-R2	57	67		3		
Genético = H-R1 = H-R2	3					

Galoá { Este trabalho foi publicado utilizando o **Galoá** proceedings

Verifica-se que, para o conjunto de 324 instâncias, ocorreram alguns empates nos algoritmos, resultando em 20% (66 instâncias do problema original) e 24% (79 instâncias com canibalismo) do total, onde o cenário mais significativo apresentou-se na igualdade de soluções encontradas através das heurísticas H-R1 e H-R2, sendo 18% para instâncias sem canibalismo e de 21% para instâncias que apresentam canibalismo de produtos. Vale ressaltar, a incapacidade de H-R1 resolver o problema original e com canibalismo em 3 instâncias.

Para o segundo conjunto, de 16 instâncias, notou-se superioridade de resolução na heurística H-R2, visto que obteve melhor desempenho em 81% (13 instâncias) dos resultados para o problema original e 44% (7 instâncias) para o problema com canibalismo. Constatou-se, também, que nenhuma instância obteve melhor resultado com o algoritmo Genético, inclusive o algoritmo demonstrou incapacidade de resolução em uma instância com 100 mil clientes e 15 produtos, devido a problemas de memória que não pôde ser resolvido até a finalização deste trabalho. Novamente as heurísticas H-R1 e H-R2 ocasionaram empates em 3 das 16 instâncias.

Quanto ao comportamento geral do terceiro conjunto, as instâncias estratificadas, o desempenho superior para o problema com canibalismo é apresentado pela heurística Grasp Tabu, visto que 50% (9 instâncias) dos problemas foram solucionados com valor de função objetivo mais próximo ao exato neste algoritmo. Já para a variação do problema sem canibalismo entre produtos, obteve-se superioridade em 44% (8 instâncias) do conjunto no algoritmo H-R1. Houve igualdade de resultados entre Grasp Tabu e H-R1 em 2 instâncias (problema original). No problema com canibalismo identificou-se 1 instância igual no Grasp Tabu e Genético e 1 no Grasp Tabu e H-R2.

Apesar das heurísticas H-R1 e H-R2 propostas por Cetin e Alabas-Uslu [2015] apresentarem bons resultados nas instâncias propostas por Noibibon et al. [2011], nas instâncias de maior porte as heurísticas não solucionaram algumas instâncias. A heurística H-R2, nos problemas com e sem canibalismo, não solucionou 9 das 18 instâncias estratificadas. O quadro estende-se também para a heurística H-R1 que não solucionou 1 instância estratificada em ambas as variações do problema, conforme exposto na tabela 3.

Tabela 3 - Instâncias não solucionadas

Heurística	Não solucionadas					
	324 instâncias		16 instâncias		18 instâncias	
	Original	Com Canibalismo	Original	Com Canibalismo	Original	Com Canibalismo
Grasp Tabu	Todas instâncias solucionadas					
Genético			1	1		
H-R1	3	3			1	1
H-R2					9	9

Posto isso, observa-se a falta de robustez do método apresentado por Cetin e Alabas-Uslu [2015], visto que as heurísticas propostas não solucionam todas as instâncias de grande porte e, consequentemente, evidencia uma falta de confiabilidade no método. Posto isso, o método Grasp Tabu foi identificado como o mais robusto, pois resolveu todas as instâncias testadas.

5. Conclusão

O presente estudo objetivou adaptar os modelos matemáticos e heurísticos para tratar o Problema de Marketing Direto com Oferta de Produto, testando em instâncias conhecidas na literatura (324 instâncias encontradas em Nobibon et al. [2011]) e em dois novos conjuntos de instâncias, com maior grau de dificuldade. Em todos os casos, incluindo o efeito Canibalismo entre produtos. Os dois novos conjuntos de instâncias são: 16 instâncias geradas através da lógica

utilizada em Nobibon et al. [2011], porém, com dimensões maiores às utilizadas pelos autores; 18 instâncias geradas através de uma lógica de estratificação da base de clientes e geração de produtos com diferentes graus de penetração em diferentes estratos de clientela. Os valores ótimos de solução de cada uma das instâncias foram obtido através da resolução do modelo exato, e tais valores foram utilizados para fins de comparação das heurísticas testadas.

Foram realizados testes comparativos entre as heurísticas H-R1 e H-R2, desenvolvidas por Cetin et al. [2015], Grasp Tabu, desenvolvida por Souza [2018], e Genético, desenvolvido por Müller et al. [2018], para todas as instâncias sem canibalismo (chamadas originais) e com canibalismo entre produtos.

Durante os testes, observou-se que, embora as heurísticas H-R1 e H-R2, obtiveram soluções mais próximas do ótimo, estas heurísticas apresentaram-se incapazes de resolver algumas instâncias do primeiro conjunto de dados e, em maior número, no terceiro conjunto, o de instâncias estratificadas. Em relação aos outros algoritmos testados, o Grasp Tabu foi capaz de resolver todas as instâncias, provando-se, portanto, métodos mais robustos que as heurísticas propostas por Cetin et al. [2015]. O algoritmo Genético não foi capaz de resolver apenas uma instância com 100 mil clientes, não por uma questão lógica, mas limitações de memória do dispositivo utilizado para os testes. Uma revisão no código do algoritmo Genético foi feita e constatou-se que possíveis alterações futuras na administração das estruturas de dados do código podem corrigir esta limitação.

Como trabalhos futuros sugere-se aplicar as heurísticas H-R1, H-R2 e algoritmo Genético aos conjuntos de instâncias com pares mutuamente excludentes utilizando as estratégias de Similaridade e Dissimilaridade gerados por Schneider [2019].

Referências

Associação Brasileira de Marketing Direto [ABEMD]. http://abemd.org.br/glossario-de-marketing-de-dados. Acessado em: 15 março de 2020.

Cetin, F.; Alabas-Uslu, C. (2015) Heuristic solution to the product targeting problem based on mathematical programming. *International Journal of Production Research*, v. 55, n.1, p. 3 – 17.

Czikosova, A.; Antošova, M.; Čukolova, K. (2014) Strategy in Direct and Interactive Marketing Communications. *Procedia - Social and Behavioral Sciences*, v. 116, p. 1615-1619.

Ładyzynski, P., Zbikowski, K., Gawrysiak, P. (2019). Direct marketing campaigns in retail banking with the use of deep learning and random forests. *Expert Systems With Applications*, v. 134, p. 28 - 35.

Müller, F. M.; Bonilha, I. S.; Souza, V. B. (2018). A hybrid approach (GA+TS) to solve the direct marketing problem. *Anais do XIX Latin-Iberoamerican Conference on Operations Research Computers and Operation Research*.

Nobibon, F. T.; Leus, R.; Spieksma, F. C. (2011) Optimization models for targeted offers in direct marketing: Exact and heuristic algorithms. *European Journal of Operational Research*, v. 210, n. 3, p. 670 – 683.

OLIVEIRA, T.A.; COELHO, V.N.; SOUZA, M.J.F.; BOAVA, D.L.T.; BOAVA, F.M.F.M.; COELHO, I.M.; COELHO, B.N. (2014). Um algoritmo heurístico aplicado ao problema de oferta de produtos em campanhas de marketing direto. *Anais do XLVI Simpósio Brasileiro de Pesquisa Operacional*, p. 103 – 114.

Galoá { Este trabalho foi publicado utilizando o **Galoá** proceedings

Schneider, V. A. (2019). Análise de Modelos Matemáticos para o Problema de Marketing Direto com a Oferta de Produtos. Dissertação (Mestrado Acadêmico em Engenharia de Produção) - Universidade Federal de Santa Maria, Santa Maria.

Souza, V. B. (2018). Uma Abordagem Meta-Heurística para o Problema de Marketing Direto considerando o Canibalismo entre Produtos. Dissertação (Mestrado Acadêmico em Administração). Universidade Federal de Santa Maria, Santa Maria

Traylor, M. B. (1986) Cannibalism in multibrand firms. *Journal of Consumer Marketing*, v. 3, n. 2, p. 69-75, Spring.

Galoá { Este trabalho foi publicado utilizando o **Galoá** proceedings