UMA PROPOSTA DE APROXIMAÇÃO PARA A FORMULAÇÃO CHANCE-CONSTRAINED UTILIZANDO MÉTODO DETERMINÍSTICO PARA O PROBLEMA DE ROTEAMENTO DE VEÍCULOS COM CAPACIDADE

Karina Thiebaut Sacramento
Universidade Federal Fluminense (UFF) – Departamento de Engenharia de Produção (TEP)
Rua Passo da Pátria nº 156, sala 306, Bloco D, S. Domingos, Niterói – RJ
karinathiebaut@gmail.com

Segundo Autor
Universidade Federal Fluminense (UFF) – Departamento de Engenharia de Produção (TEP)
Rua Passo da Pátria nº 156, sala 306, Bloco D, S. Domingos, Niterói – RJ
artur@producao.uff.br

RESUMO

O problema de roteamento de veículos vem sendo amplamente estudado devido à sua vasta aplicação em logística. E devido a esta aplicação em casos reais, há sempre incerteza em relação aos dados de entrada, que não são facilmente previsíveis. Visando captar esta variabilidade, diversos modelos de otimização mais complexos foram desenvolvidos para tratar a incerteza, dentre os quais cabe destacar o modelo de *chance-constrained* (CC) e a otimização robusta. O objetivo deste artigo é propor uma formulação para utilização do modelo determinístico com demanda ajustada para tentar aproximar o resultado CC. Os resultados mostraram que um dos modelos determinísticos permitiu encontrar a solução ótima CC em aproximadamente 60% dos cenários testados, enquanto o outro chegou a 73% de acertos. As instâncias com resultados diferentes não apresentaram perdas muito significativas do modelo determinístico em relação ao CC, tornando a formulação proposta uma boa alterativa quando se deseja resultados rápidos sem exigência de 100% de precisão.

PALAVRAS CHAVE. CVRP, *Chance-constrained*, Formulação Determinística.

OC – Otimização Combinatória

ABSTRACT

The vehicle routing problem has been widely studied due to its large application in logistics. In real cases, there is always uncertainty regarding the input data, which is not easily predictable. In order to capture this variability, several more complex optimization models were developed to deal with uncertainty, among which it is worth mentioning the chance-constrained (CC) model and robust optimization. The purpose of this article is to propose a formulation for using the deterministic model with adjusted demand to try to approximate the CC result. The experiments showed that one of the deterministic models allowed to find the optimal CC solution in approximately 60% of the tested scenarios, while the other reached 73% of correct answers. For the instances with different results between the two methods, the deterministic model did not lose much with respect to the CC, suggesting that the proposed formulation is a good alternative when fast results are needed, and accuracy is not required to be 100%.

KEYWORDS. CVRP, Chance-constrained, Deterministic Formulation

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

1. Introdução

O Problema de Roteamento de Veículos (do Inglês *Vehicle Routing Problem* – VRP) está entre os problemas mais estudados nas áreas de pesquisa operacional e otimização combinatória. Sua relevância decorre de sua grande aplicação em sistemas reais de distribuição de bens e serviços, gerando importantes reduções de custos para as empresas, característica essa essencial no cenário competitivo atual.

Mencionado pela primeira vez na literatura em 1959, o VRP foi proposto como uma generalização do Problema do Caixeiro Viajante, e aplicado para otimizar de forma determinística as rotas de uma frota de caminhões de combustível [Dantzig e Ramser, 1959], e desde então ganhou crescente importância para áreas de pesquisa como a logística, sofrendo diversas variações em seu estudo.

Uma das formulações de roteamento de veículos mais comumente adotadas é o problema de roteamento de veículos capacitados (do inglês *Capacitated Vehicle Routing Problem* - CVRP), que diz respeito ao custo mínimo de entrega de um único produto de um depósito a clientes por meio de veículos com capacidade restrita. Nesta linha, vale destacar os trabalhos de Toth and Vigo (2002), Golden et al. (2008), Baldacci et al. (2010) e Pecin et al (2017).

A incerteza em dados de entrada, como por exemplo na demanda, recorrente na realidade das empresas durante seu planejamento, levou ao desenvolvimento de modelos que consideram parâmetros estocásticos na programação. A literatura de programação estocástica pode ser consultada em Shapiro et al. (2009) e suas referências.

Um modelo bem reconhecido de programação com incerteza é o método de *Chance-Constrained*, que busca garantir que um determinado evento ocorra dentro de uma probabilidade desejada. Dentre os diversos estudos, para este trabalho vale destacar a pesquisa de Dihn et al. (2019), que propuseram um algoritmo exato para a solução do problema de roteamento de veículo utilizando o modelo de *Chance-Constrained* com restrição de capacidade (CCCVRP).

Outra metodologia reconhecida é a Otimização Robusta, proposta inicialmente por Bertsimas and Sim (2003), que modela as incertezas nos parâmetros como variáveis aleatórias. Porém, diferente do CCCVRP, ela não requer informações sobre a distribuição das incertezas, motivo pelo qual vem ganhando destaque. Outros trabalhos de destaque são Gounaris et al. (2013), Fukasawa et al (2006) que relacionam esta metodologia com o modelo estocástico, e Pessoa et al. (no prelo 2020), que propõem um algoritmo para solução do problema.

Apesar de todos os modelos apresentados, não se encontra na literatura uma tentativa de aproximação destes métodos de forma determinística, apesar de ser um método de mais rápida resolução, usualmente. Este artigo visa preencher este gap na literatura e fazer uma aproximação para a programação estocástica, supondo conhecida a distribuição de incerteza. A ideia central é fazer adequações nos dados de entrada da demanda e resolvê-la de forma determinística, buscando resultados próximos aos obtidos utilizando o CCCVRP.

O restante do artigo é estruturado da seguinte forma: A seção 2 define o problema, a seção 3 traz a proposta de formulação para o modelo determinístico e na seção 4 é explicada a geração das instâncias. Na seção 5 os resultados obtidos são apresentados, e por fim a seção 6 traz uma conclusão do trabalho e sugestão de trabalhos futuros.

2. Formulações para o CVRP

O CVRP Determinístico pode ser descrito da seguinte forma:

Seja $G = (V, A)$ um grafo completo, não direcionado, com vértices $V = \{0, 1, \dots, n\}$, e arcos $A = \{(i, j) \in V \times V : i \neq j\}$. O vértice 0 represente o depósito, com demanda 0, e os vértices $V_+ = \{1, \dots, n\}$ representam os clientes, cada cliente i com sua demanda d_i. O comprimento do arco e é definido por $l_e \geq 0$. O depósito contém m veículos homogêneos de capacidade Q. O conjunto de veículos pode ser definido como $K = \{1, \dots, m\}$. Uma rota é um ciclo C passando pelo depósito (rota

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

$0 - v_1 - \cdots - v_k - 0$ para $v_1, \ldots, v_k \in V_+$).

2.1. Formulação baseada em arestas

Seja x_e o número de vezes que uma aresta e é usada em uma solução. Para $S \subseteq V$, $\delta(S)$ é o conjunto de arestas incidentes aos vértices do conjunto S que se removidas desconectam o grafo G (cut-set definido por S).

Minimizar

$$\sum_{e \in E} l_e x_e \qquad (1)$$

Sujeito à

$$\sum_{e \in \delta(\{i\})} x_e = 2 \qquad i \in V_+ \qquad (2)$$

$$\sum_{e \in \delta(\{0\})} x_e = 2K \qquad (3)$$

$$\sum_{e \in \delta(S)} x_e = 2\,k(S) \qquad S \subseteq V_+ \qquad (4)$$

$$x_e \leq 1 \qquad e \in E \setminus \delta(\{0\}) \qquad (5)$$

$$x_e \in Z_+ \qquad e \in E \qquad (6)$$

As restrições (2) indicam que cada cliente (vértice) deve ser atendido por apenas um veículo, e a (3) garante que os K veículos vão sair e retornar do depósito. As restrições (4) são chamadas restrições de eliminação de subciclos que especificam que, para qualquer subconjunto S de clientes, $k(S)$ veículos devem entrar e sair de S. As restrições (5) e (6) garantem que cada aresta deve ser percorrida no máximo uma vez (com exceção de arestas adjascentes ao depósito, que podem ser percorridas duas vezes em caso de rotra de um cliente), e não podem ter valores negativos.

A mesma formulação pode ser usada tanto para o modelo determinístico quanto para o robusto e o CC, bastando para isso, adaptar a definição de $k(S)$ de acordo com o modelo. No modelo determinístico, basta respeitar a restrição de que a soma das demandas dos clientes atendidos por cada rota não ultrapasse Q. Já no CC, μ_i é a demanda média do cliente i, que segue uma distribuição normal com desvio σ_i, e requer-se que a probabilidade da soma das demandas ultrapassar Q não seja maior que ε. Neste trabalho, tratamos apenas o caso em que as demandas são independentes entre si.

As restrições (2) indicam que cada cliente (vértice) deve ser atendido por apenas um veículo, e a (3) garante que os K veículos vão sair e retornar do depósito. As restrições (4) são chamadas restrições de eliminação de subciclos que especificam que, para qualquer subconjunto S de clientes, $k(S)$ veículos devem entrar e sair de S. As restrições (5) e (6) garantem que cada aresta deve ser percorrida no máximo uma vez (com exceção de arestas adjascentes ao depósito, que podem ser percorridas duas vezes em caso de rotra de um cliente), e não podem ter valores negativos.

A mesma formulação pode ser usada tanto para o modelo determinístico quanto para o robusto e o CC, bastando para isso, adaptar a definição de $k(S)$ de acordo com o modelo. No

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

modelo determinístico, basta respeitar a restrição de que a soma das demandas dos clientes atendidos por cada rota não ultrapasse Q. Já no CC, μ_i é a demanda média do cliente i, que segue uma distribuição normal com desvio σ_i, e requer-se que a probabilidade da soma das demandas ultrapassar Q não seja maior que ε. Neste trabalho, tratamos apenas o caso em que as demandas são independentes entre si.

Cabe aqui mencionar que, mesmo utilizando esta mesma formulação diretamente, como foi feito neste trabalho, o modelo determinístico é tipicamente resolvido muito mais rapidamente do que o CC. Quando se considera o estado-da-arte na resolução exata de ambos os modelos, a diferença de desempenho em favor do determinístico chega a várias ordens de grandeza.

2.1. Definição dos *lower bouns*

Calcular o valor exato de $k(S)$ para o modelo determinístico requer a solução de um problema NP-difícil , uma vez que corresponde à resolução de uma instância do *Bin-Packing Problem*. Por isso, um *lower bound* válido pode ser calculado como $k(S) = \left\lceil \frac{d(S)}{Q} \right\rceil$, onde $d(S)$ é a soma das demandas dos clientes de S.

Para o problema CC, Laporte et al (1989) propuseram o seguinte *lower bound*:

$$k(S) = \left\lceil \frac{\left(\mu(S) + \emptyset^{-1}(1-\varepsilon)\sqrt{\sigma^2(S)}\right)}{Q} \right\rceil \qquad (7)$$

Onde $\emptyset^{-1}$ é o inverso da função cumulativa da distribuição normal padrão, $\mu(S)$ é a média e $\sigma^2(S)$ é a variância da soma das demandas dos clientes de S.

Neste trabalho, estas serão as formulações utilizadas para solução do problema determinístico e do CCCVRP.

3. Proposta para o Modelo Determinístico

O objetivo principal da aproximar a solução do CCCVRP, no caso de demanda com distribuição normal, através de um modelo determinístico, que é de mais fácil implementação e resolução.

Suponha agora a demanda individual de cada cliente (d_i) como sendo uma variável aleatória com distribuição normal, média μ_i e desvio padrão σ_i. Neste caso a ideia é definir $\hat{d}_i$ para $i = 1, \dots, n$ e resolver a variante determinística do problema satisfazendo $\hat{D}(S) \leq Q$.

Seja $\emptyset(x) = \int_0^x \frac{1}{\sqrt{2\pi}} e^{\frac{-x}{2}} dx$, $\bar{\mu} = \frac{\sum_{i=1}^n \mu_i}{n}$, $\bar{\sigma} = \sqrt{\frac{\sum_{i=1}^n {\sigma_i}^2}{n}}$, e $\bar{L}$ o número médio de clientes da rota.

Dada uma rota com $\bar{L}$ clientes idênticos de demanda $\bar{\mu}$ e desvio $\bar{\sigma}$, a demanda total é maior que $\bar{L}\bar{\mu} + \bar{L}^{-1/2}\,\bar{\sigma}\,\emptyset^{-1}(0{,}5 - \varepsilon)$ com probabilidade ε. Calculamos então α, que é o desvio normal padrão individual de cada cliente, tal que $\bar{L} = \frac{Q}{\bar{\mu} + \alpha\bar{\sigma}}$, onde $\bar{\mu} + \alpha\bar{\sigma}$ representa a demanda determinística para o caso de clientes idênticos, ou seja $\bar{L}(\bar{\mu} + \alpha\bar{\sigma}) = Q = \bar{L}\bar{\mu} + \bar{L}^{-1/2}\,\bar{\sigma}\,\emptyset^{-1}(0{,}5 - \varepsilon)$.

Desenvolvendo, temos:

$$\bar{L}^{-1/2}\,\alpha = \emptyset^{-1}(0{,}5 - \varepsilon)$$

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

$$\alpha\sqrt{\frac{Q}{\bar{\mu}+\alpha\bar{\sigma}}} = \emptyset^{-1}(0{,}5-\varepsilon)$$

$$\frac{\alpha^2 Q}{\bar{\mu}+\alpha\bar{\sigma}} = (\emptyset^{-1}(0{,}5-\varepsilon))^2$$

$$\alpha^2 Q - \bar{\sigma}\left(\emptyset^{-1}(0{,}5-\varepsilon)\right)^2\alpha - \bar{\mu}\left(\emptyset^{-1}(0{,}5-\varepsilon)\right)^2 = 0$$

Que é uma equação do 2º grau em α, com uma única solução inteira positiva.

3.1. Calculando o tamanho da rota ($\bar{L}$) e o desvio α

Para o tamanho médio da rota, foram testadas duas suposições diferentes:

a) $\bar{L} = \frac{Q}{\bar{\mu}+\alpha\bar{\sigma}}$, conforme formulação anterior. Nesta suposição, o tamanho da rota seria o tamanho máximo esperado, que chamaremos de $\bar{L}_{max}$.
b) A segunda suposição vamos chamar de $\bar{L}_{med}$. Neste caso, temos Y como sendo a quantidade esperada de rotas, de forma que $Y = \left\lfloor\frac{\bar{\mu}+\alpha\bar{\sigma}}{Q}\right\rfloor$, logo $\bar{L} = \frac{Q}{Y}$.

Por fim, para aproximação do α, vamos supor uma distribuição normal padrão $Z \sim N(0,1)$, e deseja-se obter Z_c tal qual $P(-\infty < Z < Z_c) \leq (1-\varepsilon)$. Neste caso, $\alpha = \sqrt{{Z_c}^2/\bar{L}}$.

4. Geração das Instâncias

As instâncias utilizadas nos testes foram elaboradas com base no apresentado por Uchoa et al. (2017). Nele, são apresentadas algumas possíveis características das instâncias, dentre elas: localização do depósito, método de geração do posicionamento dos clientes, distribuição das demandas, entre outros. Além dessas, foi elaborado pelos próprios autores a geração dos desvios, e o ajuste da demanda para o caso determinístico.

As distâncias são calculdas de maneira euclidiana bidimensional. As coordenadas estão divididas em uma matriz [0, 1000] x [0, 1000]. Neste trabalho todas as instâncias possuem o mesmo tamanho (depósito e 52 clientes).

1) Posicionamento do depósito: posicionamento central, na coordenada (500,500).
2) Posicionamento dos clientes: foram elaborados dois diferentes conjuntos, com 10 instâncias de teste cada.
    a. Conjunto 1: posições aleatoriamente distribuídas na matriz;
    b. Conjunto 2: clientes aleatoriamente clusterizados.
        - Para a clusterização, a matriz foi dividida em 25 quadrantes de igual tamanho, dentre os quais foram sorteados aleatoriamente 5 quadrantes;
        - 75% dos clientes (39 clientes) foram sorteados aleatoriamente dentro desses 5 quadrantes, sendo os 13 clientes restantes distribuídos, também aleatoriamente, dos demais quadrantes.
3) Distribuição das demandas: demandas de baixos valores [1, 15], alto coeficiente de variação.
4) Capacidade da rota: 150 ou 180, variando de forma aleatória. Desta forma, o número médio esperado de K é de 3 rotas, desconsiderando os desvios.
5) O número de veículos na solução do problema não foi fixado.

Além destas características, por se tratar de uma demanda estocástica, foram criados 2 grupos

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

de desvios para as demandas para cada instância:

1) Demandas com baixa variação: os desvios-padrão das demandas dos clientes variaram de forma aleatória [20%, 40%] da demanda do cliente;
2) Demandas com alto desvio: exatamente 2x o desvio da demanda com baixa variação, percentendo ao intervalo [40%, 80%], para permitir a comparação.

5. Resultados Experimentais

Foram geradas 10 instâncias de teste com clientes aleatoriamente clusterizados e 10 com clientes não clusterizados, cada uma com baixo ou alto desvio, num total de 40 instâncias de teste.

Para cada instância, foram testados os modelos de chance constrained com $\varepsilon = 1\%$, 2%, 5%, 10%, 15%, 20% e 25%, e os determinísticos com $\bar{L}_{\text{Nas}}$ e $\bar{L}_{\text{Ned}}$ para cada ε testado, totalizando 840 testes (280 para cada modelo).

Em alguns casos, a solução do CCCVRP determinístico estava muito demorada, e foi utilizada uma aproximação da heurística ILS proposta por Subramanian, A. para obtenção de um resultado. Apenas 39 testes foram resolvidos desta forma (todos para o CCCVRP), todos os demais chegaram à solução ótima.

A tabela 1 abaixo mostra um resumo dos resultados:

Tabela 1 – resultados das instâncias

Instância	Desvio	Modelo	Custo médio	% AC	% C+	%P+	%CM+	MP+
Clusteri-zadas	Baixo	L_{Ned}	5.844,37	81%	4%	16%	0,21%	0,2%
		L_{Nas}	5.825,98	64%	1%	37%	0,00%	0,5%
	Alto	L_{Ned}	5.956,83	63%	14%	24%	0,38%	0,2%
		L_{Nas}	5.953,40	53%	3%	46%	0,50%	0,5%
Não Clusteri-zadas	Baixo	L_{Ned}	6.561,93	84%	3%	14%	0,58%	0,1%
		L_{Nas}	6.551,09	70%	0%	30%	0,00%	0,3%
	Alto	L_{Ned}	6.663,13	63%	16%	24%	0,51%	0,1%
		L_{Nas}	6.661,89	51%	0%	47%	0,00%	0,4%

Onde:
%AC – quantidade percentual de instâncias cujo modelo determinístico encontrou a mesma solução ótima do CCCVRP;
%C+ – quantidade percentual de instâncias que tiveram custo acima do custo do CCVRP;
%P+ – quantidade percentual de instâncias que tiveram probabilidade acima da probabilidade máxima definina pelo CCCVRP;
%CM+ – é o percentual que identifica o tamanho médio dos desvios de custo (para os custos que ultrapassaram o custo máximo (%C+) sobre o custo médio do determinístico
MP+ – é a média das diferenças entre a probabilidade do determinístico e a probabilidade definida para o teste, nos casos em que a probabilidade ultrapassa o limite.

Como é possível observar, não há uma diferença relevante em termos de desempenho do determinístico para instâncias clusterizadas ou não clusterizadas. A grande diferença é no custo das instâncias não clusterizadas, que foram em média 12,6% maiores.

O desempenho do modelo determinístico para aproximação do CCCVRP foi bem representativo, tendo encontrado a mesma solução ótima em aproximadamente 73% dos casos para os testes com o número médio de clientes na rota. Dos que encontraram solução ótima diferentes, em torno de 9% ultrapassou o custo do resultado do CCVRP, e 18% ultrapassou o percentil máximo definido pelo modelo. Entretanto, a média do valor do custo ultrapassado foi menos de 1%, e a média do percentil ultrapassado também foi pequena.

Já o modelo utilizando a rota máxima teve um índice de acertividade menor, girando em torno de 60%. Este modelo tende a estourar mais o percentil máximo definido e mais raramente ultrapassa o custo ótimo do CCCVRP, como era de se esperar.

Galoá { Este trabalho foi publicado utilizando o Galoá proceedings

Em relação ao comparativo baixo x alto desvio, é possível perceber que intâncias com baixo desvio apresentaram um % de acerto maior do determinístico.

6. Conclusões e Trabalhos Futuros

A partir dos resultados apresentados é possível concluir que é possível aproximar o resultado do CCVRP pelo determinístico, quando a situção não requiser uma grande precisão na resposta. Este modelo é de mais simples resolução computacional e apresentou resultados representativos.

Os desvios médios em relação ao CCVRP, em ambos os casos, não foram expressivos, o que reforça a hipótese levantada acima.

Outro ponto a se considerar é que o modelo com a rota média possui uma acertividade maior e ultrapassa em menos vezes o percentil máximo determinado pelo CCCVRP, entretanto, quando a restrição de custo for maior e for possível aceitar com mais frequência percentis um pouco acima do determinado, a rota máxima se mostrou uma solução interessante.

Finalmente, como sugestão de trabalho futuro, temos:

- Testar aproximações da normal para o modelo robusto, e verificar seu desempenho comparado aos modelos aqui apresentados;
- Ampliar o estudo para outras distribuições que não somente a normal com independencia de desvios.

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

Referências

Baldacci R, Toth P, Vigo, D. (2010). Exact algorithms for routing problems under vehicle capacity constraints. Ann Oper Res 175, 213–245 (2010). https://doi.org/10.1007/s10479-009-0650-0

Bertsimas D, Sim M (2003). Robust discrete optimization and network flows. Mathematical Programming., Ser. B 98, 49–71. https://doi.org/10.1007/s10107-003-0396-4

Dantzig, G. B. e Ramser, J. H. (1959). The truck dispatching problem. Management Science, Vol. 6, No. 1, pp. 80-91. https://doi.org/10.1287/mnsc.6.1.80

Dinh, T., Fukasawa, R. & Luedtke, J. Exact algorithms for the chance-constrained vehicle routing problem. Math. Program. 172, 105–138 (2018). https://doi.org/10.1007/s10107-017-1151-6

Fukasawa, R., Longo, H., Lysgaard, J. et al. (2006). Robust Branch-and-Cut-and-Price for the Capacitated Vehicle Routing Problem. Math. Program. 106, 491–511. https://doi.org/10.1007/s10107-005-0644-x

Golden B, Raghavan S, Wasil E, eds. (2008). The Vehicle Routing Problem: Latest Advances and New Challenges (Springer, New York).

Gounaris, E., Wiesemann, W., Floudas, C. (2013). The Robust Capacitated Vehicle Routing Problem Under Demand Uncertainty. Operations Research, Vol. 61, No. 3. https://doi.org/10.1287/opre.1120.1136

Laporte, G., Louveaux, F., Mercure, H. (1989). Models and exact solutions for a class of stochastic locationrouting problems. European Journal of Operational Research, Volume 39, Issue 1, Pages 71-78. https://doi.org/10.1016/0377-2217(89)90354-8.

Pecin, D., Pessoa, A., Poggi, M. et al. (2017). Improved branch-cut-and-price for capacitated vehicle routing. Math. Prog. Comp. 9, 61–100. https://doi.org/10.1007/s12532-016-0108-8

Pessoa, A., Poss, M., Vanderbeck, F. et al. (2019). Branch-and-cut-and-price for the robust capacitated vehicle routing problem with knapsack uncertainty. Operations Research. No prelo 2020.

Shapiro A, Dentcheva D, Ruszczynski A (2009). Lectures on Stochastic Programming: Modeling and Theory MPS-SIAM Series on Optimiation (SIAM, Philadelphia).

Subramanian, Anand (2012). Heuristic, Exact and Hybrid Approaches for Vehicle Routing Problems.Tese (Doutorado em Computação) – Faculdade de Computação, Universidade Federal Fluminense

Toth P, Vigo D, eds. (2002) The Vehicle Routing Problem. SIAM Monographs on Discrete Mathematics and Applications (SIAM, Philadelphia).

Uchoa, E. Pecin, D., Pessoa, A. et al. (2017). New benchmark instances for the capacitated vehicle routing problem. European Journal of Operational Research 257 (3), 845-858. https://doi.org/10.1016/j.ejor.2016.08.012

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