

AVALIAÇÃO DE SISTEMÁTICAS PARA DETECÇÃO DE RUPTURAS DE ESTOQUE APLICADAS NO SETOR VAREJISTA

Pedro Silva Stürmer (UFRGS) - pedrosturmer@outlook.com

Michel José Anzanello (UFRGS) - anzanello@producao.ufrgs.br

Resumo

Rupturas de estoque geram perdas relevantes para o varejo e para indústria, mas apesar de serem objeto de estudos desde a década de 1960, a taxa de ruptura observada no varejo não tem diminuído consideravelmente. O primeiro passo para endereçar esse problema reside na correta medição e detecção de rupturas. Dessa forma, o objetivo deste artigo é avaliar e comparar o desempenho de dois métodos de detecção de ruptura parcial em gôndola, que têm como base a análise de dados de venda diária. Foi comparado o método proposto por Hausrucking (2006) e uma adaptação menos suscetível à ocorrência de outliers. Empregando a simulação de Monte Carlo, foram simulados três cenários que modelam o nível de estoque em gôndola de um produto de alto giro ao longo do dia. A simulação gerou os dados utilizados nos métodos e permitiu avaliar seus desempenhos. Concluiu-se que a adaptação proposta teve um maior índice de detecção de rupturas do que o método de Hausrucking (2006). Constatou-se ainda que essa categoria de método de detecção de ruptura se mostrou aplicável apenas a produto com baixa volatilidade de vendas. Por fim, recomenda-se sua utilização de forma complementar a outros métodos de detecção de ruptura.

Palavras-chave: Ruptura de estoque, Varejo, Disponibilidade em Gôndola

1. Introdução

A partir da década de 1980, o setor varejista mundial passou por importantes transformações em seus processos logísticos e de gestão da cadeia de suprimentos. Nos anos 1990, tais transformações culminaram com a criação de programas e a adoção de práticas voltadas ao aumento da eficiência dos processos logísticos, promoção da colaboração na cadeia de suprimentos e redução de perdas (FERNIE e SPARKS, 2004). No contexto brasileiro, o setor varejista registrou em 2016 uma queda de 4% no faturamento em relação ao ano anterior (KEARNEY, 2016), fator que intensifica ainda mais a necessidade de redução de perdas.

Dentre as causas de perdas verificadas nesse setor, destaca-se a ruptura de estoque, problema reconhecido pelo setor varejista e que tem sido objeto de estudos desde a década de 1960 (VASCONCELLOS, 2009). Usualmente, a taxa de ruptura de estoque é calculada como a porcentagem de produtos indisponíveis para o consumidor em uma loja

específica, em um momento específico (GRUEN et al., 2002). Segundo Vasconcellos (2009), a nível mundial, essa taxa posiciona-se em torno de 8% desde os anos 1960. A falta de um produto disponível para o consumidor não gera apenas um custo decorrente da venda perdida, mas também implica em outros custos estratégicos e operacionais para o varejo e para indústria, como a perda de valor percebido da marca e da rede varejista, diminuição da eficácia de promoções e geração de distorções na demanda que prejudicam processos de previsão (GRUEN e CORNSTEN, 2007).

Segundo Hausrucking (2006), para que as empresas possam reduzir a ruptura de estoque, inicialmente é necessário medi-la. Com esse objetivo, o autor propõe uma definição de taxa de ruptura diferente daquela usualmente utilizada, baseando-se na comparação entre as vendas realizadas e as vendas esperadas. Bayle-Tourtoulou e Laurient (2006) propõem uma definição semelhante, pois, segundo os autores, o conceito de taxa de ruptura de estoque usualmente utilizado não permite que se estime a perda econômica causada pela falta de um item, visto que a taxa não considera fatores como a duração e frequência da ruptura em um dado período, bem como as vendas esperadas para cada item.

Dentre os métodos utilizados para detectar situações de ruptura, podem ser empregados métodos analíticos, que buscam detectar rupturas de estoque em gôndola analisando dados de venda e estoque. Hausrucking (2006) e Bayle-Tourtoulou e Laurient (2006) propõem métodos semelhantes, que consistem na análise de dados de venda de um determinado produto e no estabelecimento de limites inferiores de venda, abaixo dos quais pode-se inferir a ocorrência de situações de indisponibilidade do produto na gôndola. Os métodos analíticos de detecção de ruptura podem apresentar acurácia de até 85%, se mostram mais baratos a longo prazo (GRUEN e CORNSTEN, 2007) e permitem que se estime as vendas perdidas em decorrência da ruptura (HAUSRUCKING, 2006; BAYLE-TOURTOULOU e LAURIENT, 2006).

Nesse contexto, o objetivo deste artigo é avaliar e comparar o desempenho de dois métodos de detecção de ruptura parcial em gôndola, que têm como base a análise de dados de venda diária. Para tanto, foram geradas séries de demanda através da simulação de Monte Carlo, que permitiu monitorar a demanda e o nível de estoque em gôndola para um produto de alto giro ao longo do dia, e serviu de insumo para a aplicação e verificação de acurácia do método de detecção.

O restante do presente artigo é composto por quatro seções. Na seção 2 é realizada uma revisão bibliográfica dos conceitos de simulação de Monte Carlo, ruptura de estoque e dos métodos utilizados para sua detecção. A seção 3 explicita os procedimentos metodológicos utilizados na simulação e na aplicação e avaliação dos métodos de detecção, enquanto os resultados são apresentados na seção 4. Por fim, a Seção 5 aborda as considerações finais acerca do trabalho desenvolvido.

2. Referencial teórico

Nesta seção será apresentada uma breve revisão bibliográfica da simulação de Monte Carlo, do conceito de ruptura de estoque e dos métodos usualmente utilizados para sua detecção.

2.1 Ruptura de estoque – definições e perspectivas

O serviço ao cliente é um processo que objetiva oferecer benefícios de valor agregado para a cadeia de suprimentos de uma forma eficiente em termos de custos (LA LONDE e COPPER, 1988). Segundo Bowersox et al. (2006), um dos atributos fundamentais relacionados ao serviço ao cliente é a disponibilidade, que consiste na capacidade de ter o produto no estoque no momento em que ele é desejado pelo consumidor. Relaciona-se com a disponibilidade o conceito de ruptura de estoque, termo que em logística pode ser utilizado como sinônimo de *stockout* ou simplesmente falta de estoque (AGUIAR e SAMPAIO, 2003).

No contexto do varejo, diversos estudos têm abordado a ruptura de estoque pela perspectiva do cliente, através da qual ela é definida como uma situação em que um item usualmente comercializado no ponto de venda em um lugar específico nas gôndolas não pode ser encontrado pelo cliente no momento da compra (VASCONCELLOS, 2009). Gruen e Cornsten (2007) diferenciam a ruptura de estoque no varejo em relação ao local em que ela ocorre: a ruptura na gôndola ocorre quando o produto não está disponível para o cliente, mas está presente na área de estoque da loja; a ruptura na loja ocorre quando não há produto em estoque na loja; já a ruptura no centro de distribuição ocorre quando o produto está em falta na loja e no centro de distribuição que a abastece.

Em relação ao tempo em que um produto fica indisponível para o consumidor, Bayle-Tourtoulou e Laurent (2006) classificam as rupturas em duas categorias: (i) ruptura total, que corresponde à falta de um produto ao longo de um dia inteiro, o que implica em uma quantidade de venda igual a zero; e (ii) ruptura parcial, que corresponde à falta de

um produto em um ou mais períodos do dia, intercalados com períodos em que o produto está disponível, o que implica em um volume de vendas abaixo do esperado.

A análise da ruptura por diferentes perspectivas permite que se encontrem diferentes causas-raízes para esse problema, como pode ser observado nos trabalhos de Ton e Raman (2010) e Aguiar e Sampaio (2014). Ton e Raman (2010) estudaram especificamente a ruptura de estoque que ocorre quando o produto está presente na área de estoque da loja, mas não está exposto para o cliente e indicaram que o aumento dos níveis de estoque e variedade de produtos gera um aumento na porcentagem de produtos em ruptura na gôndola, decorrente do aumento da complexidade logística interna da loja. Aguiar e Sampaio (2014), por outro lado, examinaram a ruptura de estoque de um produto de alto giro do ponto de vista do estoque da loja e indicaram que a principal causa, no contexto brasileiro, está relacionada aos fornecedores.

Um estudo da ECR UK (2004) destaca, ainda, que outra causa comum de ruptura de estoque no varejo é o mal gerenciamento de promoções, que gera picos de demanda que acabam consumindo todo o estoque disponível do produto. Um melhor gerenciamento de promoções depende de uma colaboração eficiente entre os varejos e indústria na definição e planejamento das ações promocionais.

2.2 Medição da ruptura de estoque

Quantitativamente, a ruptura de estoque no varejo costuma ser expressa como a porcentagem de *stock keeping units* (SKUs) faltantes nas gôndolas em uma loja específica l em um momento específico t (GRUEN et al., 2002), conforme expresso na equação (1).

$$\text{Taxa de ruptura de estoque} = \frac{\text{Número de SKUs nas gôndolas}_{t,l}}{\text{Total de SKUs comercializados pela loja}_{t,l}} \quad (1)$$

A análise da ruptura de estoque calculada dessa forma pode, contudo, omitir alguns aspectos importantes na compreensão e quantificação do real impacto da indisponibilidade de produtos.

Lambert et al. (1998) consideram a disponibilidade a medida mais importante de atendimento ao cliente, mas destacam que expressá-la apenas em termos de quantidade de itens em ruptura em relação ao total de itens no estoque resulta em uma medida deficiente, pois não diferencia rupturas de produtos de baixa e de alta rotatividade. Além disso, o nível de serviço somente é afetado por um produto em falta no estoque quando o

mesmo for desejado pelo cliente (BOWERSOX e CLOSS, 2008), aspecto que está contemplado na definição de ruptura de estoque, mas não na quantificação de sua taxa.

A taxa de ruptura de estoque da forma como é usualmente calculada não mede a duração da situação de ruptura, que é uma medida importante do ponto de vista gerencial e do cliente (Gruen et al., 2002). Ademais, segundo Bayle-Tourtoulou e Laurent (2006), por não considerar a duração, frequência, clientes afetados e importância dos produtos indisponíveis, a taxa de ruptura não permite que os varejistas e fornecedores possam quantificar o impacto econômico da indisponibilidade dos produtos.

De forma a contornar essas limitações, diversos autores propõem formas alternativas de cálculo da taxa de ruptura. Hausrueckinger (2006) propõe que a taxa de ruptura seja calculada com base nas vendas perdidas decorrentes da indisponibilidade do produto e nas vendas esperadas, e ressalta que essa taxa poderia ser utilizada para comparações entre diferentes categorias de produtos, canais de vendas, regiões e países. A taxa proposta é calculada de acordo com a equação (2).

$$\text{Taxa de ruptura de estoque} = \frac{\text{Vendas perdidas (em unidades) por período} \times 100}{\text{Vendas esperadas (em unidades) por período}} \quad (2)$$

As vendas perdidas, por sua vez devem ser calculadas como a diferença entre as vendas esperadas e as vendas realizadas.

De forma similar, Bayle-Tourtoulou e Laurent (2006) propõem redefinir a mensuração da ruptura de estoque e medi-la principalmente em termos vendas perdidas em decorrência da indisponibilidade de produtos, através da equação (3).

$$\text{Vendas perdidas} = \text{Vendas esperadas} - \text{Vendas realizadas} \quad (3)$$

As formas de cálculo propostas em ambos os artigos se baseiam em um método de detecção de ruptura e estimativa de vendas esperadas com base na análise de dados de venda, tópico que será discutido na seção 2.4.2.

2.3 Métodos de detecção de rupturas de estoque

Esta seção descreve os principais métodos utilizados para a detecção de ruptura de estoque no varejo.

2.3.1 Auditoria manual

A auditoria manual consiste na contagem física dos produtos em ruptura na gôndola, geralmente executada por funcionários da loja ou terceiros, que inspecionam as

prateleiras buscando produtos faltantes (BERGER, 2003). A partir de múltiplas auditorias, varejistas e fornecedores de produtos são capazes de estimar a taxa de ruptura para produtos específicos (PAPAKIRIAKOPOULOS, 2012). A inspeção manual é a forma mais popular de detecção de ruptura e tem como vantagem permitir que se investigue a causa da ruptura, logo após ela ser notada (Gruen et al., 2002).

A detecção manual, contudo, é um método caro (PAPAKIRIAKOPOULOS, 2012; VASCONCELLOS e SAMPAIO, 2009) e que não necessariamente identifica o efeito da indisponibilidade do produto e não mede a sua duração (Gruen et al., 2002). Ademais, a inspeção manual de produtos indisponíveis refere-se apenas ao horário em que a auditoria foi realizada, é limitada aos produtos vistoriados, e está sujeita ao erro humano (BAYLE-TOURTOULOU, 2006).

Diversos estudos, no entanto, têm buscado propor melhorias nos processos de auditoria manual, a fim de melhorar a performance dos mesmos e superar algumas das limitações existentes. Chuang (2015) desenvolveu um modelo de decisão para orientar a execução de inspeções manuais, tendo como foco auditorias externas promovidas pelas indústrias. Essas auditorias externas, além de serem afetadas pelos erros decorrentes da inspeção em si, também são impactadas pela falta de informações de dados de vendas e de estoque dos produtos que serão inspecionados, o que impede uma priorização adequada dos produtos que serão inspecionados. A partir da consideração desses fatores e quantificação dos custos associados a eles, o autor elaborou um modelo para minimização dos custos de inspeções manuais externas.

2.3.2 Métodos analíticos

Informações de estoque e dados de vendas advindas de sistemas informatizados podem ser empregadas na identificação de situações de ruptura de estoque. A partir de dados de venda, pode-se identificar períodos em que o volume de vendas é atípico, que podem ser interpretados como períodos de ruptura de estoque (ECR UK, 2004). Já as informações relativas ao nível de estoque podem ser utilizadas para identificar produtos cujo nível de estoque registrado no sistema é zero, o que configura uma situação de ruptura do estoque na loja (VASCONCELLOS e SAMPAIO, 2009).

Aguiar e Sampaio (2014) utilizaram um método que fez uso de dados de venda em conjunto com dados de estoque para identificar rupturas para um produto de alto giro. Nesse estudo, os dias considerados como “em ruptura” foram aqueles cujas vendas e

estoque do item analisado foram zero. A Figura 1 ilustra graficamente o método empregado.




Figura 1: Modelo ilustrativo para identificação de ruptura de estoque. Fonte: Aguiar e Sampaio (2014)

Segundo os autores, a forma de detecção empregada não representa a disponibilidade do produto na gôndola, pois, dentre outras razões, o produto pode estar no estoque da loja, mas não estar na gôndola. Ademais, ao apenas identificar uma situação de ruptura quando o nível de venda é zero, esse modelo não permite detectar a ocorrência de rupturas de estoque parciais na gôndola.

Usman (2008) utilizou apenas dados de venda para detectar situações de ruptura de estoque para produtos de alto giro. A partir de uma análise de sensibilidade dos dados de venda e discussões com o fornecedor, determinou-se que um período de duas semanas consecutivas sem vendas seria identificado como uma situação de ruptura, conforme ilustrado na Figura 2.




Figura 2: Modelo de detecção de ruptura a partir de dados de venda. Fonte: Usman (2008)

Segundo o autor, o modelo adotado tem como vantagem a não utilização de dados de estoque e, por utilizar apenas dados de venda, identifica a ruptura da perspectiva da gôndola, que é aquela percebida pelo cliente. Nota-se, contudo, que esse modelo detecta apenas situações de ruptura total e depende do auxílio do fornecedor para determinar a

duração mínima de um intervalo sem vendas a partir da qual infere-se a ocorrência de uma ruptura.

Hausrucking (2006) e Bayle-Tourtoulou e Laurent (2006) também propõem métodos de detecção de ruptura com base em dados de vendas. No entanto, a metodologia proposta permite a detecção de rupturas parciais e totais e a estimativa de vendas perdidas, métrica utilizada pelos autores em suas próprias definições de taxa de ruptura. Ambos os métodos propostos têm como base a definição de duas métricas-chave: (1) o volume de venda esperado para determinado produto em determinado período e (2) os limites inferiores de venda para cada período, abaixo dos quais considera-se que ocorreu uma situação de ruptura de estoque naquele período. A Figura 3 ilustra esse modelo.

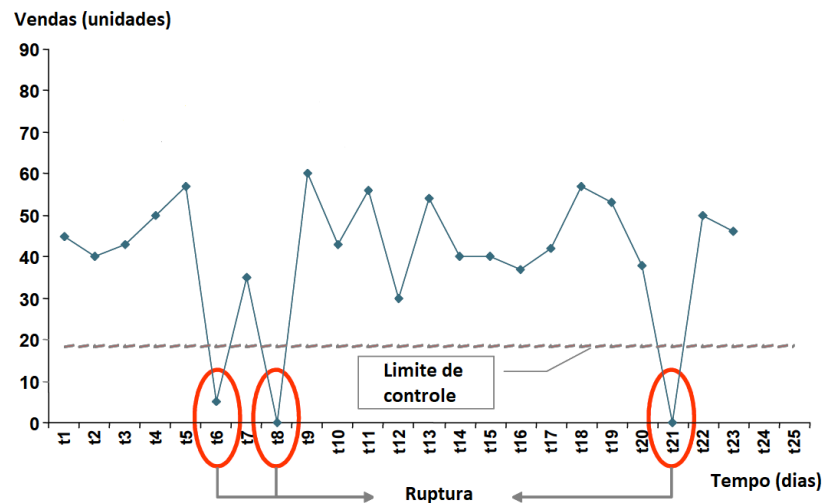


Figura 3: Modelo de detecção de ruptura total e parcial a partir de dados de venda. Adaptado de Hausrucking (2006)

Segundo Hausrucking (2006), dependendo do perfil de venda do produto, pode ser utilizado um limite que varia ao longo do tempo, caso em que o mesmo é calculado com base nas vendas realizadas em períodos similares ao analisado.

O principal aspecto que diferencia os métodos propostos por Hausrucking (2006) e Bayle-Tourtoulou e Laurent (2006) é a forma de cálculo de vendas esperadas e dos limites inferiores de venda e a curva de probabilidade atribuída à demanda dos produtos. Bayle-Tourtoulou e Laurent (2006) utilizam a mediana como base de cálculo das vendas esperadas e limites inferiores e assumem que as vendas seguem uma distribuição de *Poisson*, enquanto Hausrucking (2006) utiliza a média como base de cálculo e pressupõem que as vendas seguem uma distribuição normal.

Segundo Hausrucking (2006) o método proposto se mostra adequados apenas para produtos de alto giro e baixa volatilidade de vendas - o autor recomenda que esta última seja inferior a 80% -, pois esses fatores tornam a curva de volume de vendas mais estável.

Dentre outras desvantagens desse tipo de métodos, Gruen e Corten (2008) citam a dependência de dados de venda precisos e a alta taxa de falsos negativos, em que itens em situação de ruptura não são corretamente identificados. Essa categoria de métodos, contudo, é mais barata a longo prazo do que a auditoria manual, podendo atingir acurácia de até 85% (GRUEN e CORSTEN, 2008). Além disso, permite identificar situações de ruptura total e parcial (BAYLE-TOURTOULOU e LAURENT, 2006) e quantificar as vendas perdidas (HAUSRUCKING, 2006; BAYLE-TOURTOULOU e LAURENT, 2006), o que traduz a ruptura da perspectiva do cliente.

2.3.3 Outros métodos

A utilização de heurísticas também pode ser empregada para detectar rupturas de estoque, como na aplicação proposta por Papakiriakopoulos e Pramataris (2009). Os autores desenvolveram um Sistema de Suporte à Decisão (SSD) utilizando algoritmos de árvores de decisões e aprendizado de máquina para detectar ruptura nas gôndolas de uma loja de varejo. Cruzando dados advindos do sistema informatizado de uma rede varejista como volume de venda, catálogo de produtos, ordens de compra e registro de chegada de produtos com dados provenientes de auditoria manuais para a identificação de rupturas foi possível alimentar um algoritmo de aprendizado de máquina, a partir do qual foi criada uma heurística capaz de detectar situações de ruptura utilizando apenas os dados coletados do sistema da loja.

A heurística desenvolvida mostrou-se adequada para detectar ruptura para itens de alto e baixo giro, mas como sua elaboração reflete aspectos específicos da rede varejista analisada, sua aplicação em redes diferentes exigiria que a coleta de parâmetros e ajuste do algoritmo de aprendizado fosse feito novamente.

Outra ferramenta que auxilia na detecção e redução da ruptura de estoque é utilização de etiquetas de radiofrequência ou RFID (*Radio-frequency identification*) em *pallets* empregados no transporte e reposição de produtos. Bill et al (2008) obtiveram reduções significativas de ruptura de estoque em gôndola em um estudo de caso de implementação de etiquetas RFID no *Walmart*.

Idealmente, a utilização de etiquetas RFID individuais em cada produto permitiria monitorar a posição de todos os produtos em tempo real (GRUEN e CORSTEN, 2008). Apesar do custo envolvido na adoção dessa tecnologia, Piramuthu et al. (2014) demonstraram que em algumas circunstâncias é benéfico para o varejo utilizar etiquetas RFID mesmo em itens que custam menos do que o valor da etiqueta si.

2.4 Simulação de Monte Carlo

Segundo Krajewsk e Ritzman (2008), a simulação é o ato de simular o comportamento de um sistema, permitindo manipular variáveis de entrada e observar seu efeito nas demais características do sistema. Segundo os autores, as principais vantagens do emprego da simulação são a possibilidade de analisar sistemas em que há muitas variáveis envolvidas ou cuja relações não são lineares, além da possibilidade de realizar experimentos dispensando grande parte da interação com sistemas reais, que podem ser complexas e ter um custo significativo.

Simulações realizadas a partir de modelagens que envolvam a geração de dados aleatórios a partir de distribuições de probabilidades são chamadas de simulações de Monte Carlo (SHAMBLIN e STEVENS, 1989). Através da utilização de variáveis aleatórias de entrada, a simulação gera os dados de saída que são então analisados (MOORE e WEATHERFORD, 2005).

No contexto de simulação de estoque no setor varejista Liu e Zhou (2007) empregaram a Simulação de Monte Carlo para comparar diferentes políticas de reposição de estoque que podem ser empregadas nos processos de Inventário Gerido pelo Fornecedor (VMI).

3. Procedimentos metodológicos

Nessa seção caracteriza-se o método de pesquisa utilizado neste trabalho e são descritas suas etapas de aplicação.

O método de pesquisa é de natureza aplicada, pois endereça um problema prático, relacionado à ruptura de estoques. Como o modelo proposto baseia-se na análise de dados de venda para detectar situações de ruptura de estoque e na utilização da simulação de Monte Carlo, a pesquisa é explicativa e com abordagem quantitativa. Por fim, em relação aos procedimentos adotados, o trabalho se configura como estudo de caso, pois busca

entender o fenômeno da ruptura de estoque em gôndola de forma detalhada (DA SILVA e MENEZES, 2005).

O método de detecção de ruptura proposto por Hausrueckinger (2006), objeto de estudo do presente trabalho, tem como uma de suas principais vantagens a possibilidade de detectar rupturas parciais de estoque em gôndola. Para aplicação do método é necessária apenas uma base de dados de venda diária de um produto de alto-giro. Contudo, a fim de avaliar a eficiência do método, de forma a confirmar se os pontos detectados de fato correspondem a dias em que houve ruptura parcial, é necessário que se tenha dados detalhados do nível de estoque da gôndola e da venda do produto ao longo de cada dia.

A obtenção desses dados através de uma auditoria manual (ou seja, visitas à gôndola em diferentes momentos para avaliar o estoque disponível) necessitaria, contudo, um monitoramento contínuo da gôndola do produto analisado. Por tanto, optou-se pela geração de uma base de dados com o nível de estoque da gôndola e venda ao longo do dia através uma simulação de Monte Carlo. Além de substituir a auditoria manual na etapa de avaliação do método, a própria base de venda diária resultante da simulação foi utilizada na aplicação dos métodos de detecção de rupturas.

A metodologia é composta das seguintes etapas: (i) desenvolvimento da modelagem, (ii) definição dos valores das variáveis de entrada, (iii) aplicação do método de detecção de ruptura, (iv) simulação e cálculo dos indicadores de acurácia e (v) avaliação dos resultados. Tais etapas são detalhadas na sequência.

3.1 Desenvolvimento da modelagem

O objetivo dessa etapa é estruturar a modelagem utilizada na simulação de Monte Carlo. Para tanto, foi modelado o comportamento do nível de estoque em gôndola e a demanda ao longo do dia para um produto de alto giro em uma loja do varejo de alimentos. O intervalo total da simulação foi de seis meses.

A simulação foi estruturada em períodos, sendo cada dia composto por quatro períodos. Para cada dia foi definida uma demanda total (D_{dia}) que é dividida igualmente nos quatro períodos de cada dia.

Para cada período também é definido o estoque inicial (E_i), o estoque final (E_f), a quantidade de produtos vendidos (V) e a quantidade de produtos abastecidos na gôndola

(A). A quantidade vendida em cada período depende da demanda e da quantidade de produtos disponível na gôndola no início do período, conforme a equação (4).

$$V_{período} = \begin{cases} D_{período}, & \text{se } D_{período} \leq Ei_{período} \\ Ei_{período}, & \text{se } D_{período} > Ei_{período} \end{cases} \quad (4)$$

Quando a venda em determinado período for menor do que a demanda, isso indica uma ruptura do estoque na gôndola, logo define-se que ocorreu uma ruptura parcial no dia que contém esse período. Em um dado período (p), o estoque inicial (Ei) e final (Ef) da gôndola, a venda (V) e o abastecimento (A) se relacionam pela equação (5).

$$Ef_p = Ei_p - V_p + A_p \quad (5)$$

A política de revisão de estoque adotada foi a Revisão Periódica do tipo (R, S) - a cada R unidades de tempo, o estoque é abastecido até o nível S - também empregada por Karabati (2009) em uma modelagem de reabastecimento de gôndola. No caso específico da modelagem, R corresponde ao intervalo de períodos (PE_r) entre cada revisão e S corresponde à capacidade da gôndola (C).

Como o principal objetivo da simulação é avaliar os métodos de detecção de ruptura parcial, o sistema foi modelado de forma a gerar prioritariamente esse tipo de ruptura, que geralmente ocorre quando o produto está indisponível na gôndola, mas está fisicamente presente no estoque da loja. Portanto, na simulação definiu-se que o estoque disponível na loja sempre seria suficiente para repor a gôndola no momento em que fosse feito o reabastecimento.

3.2 Definição dos valores das variáveis de entrada e cenários simulados

Após o desenvolvimento da modelagem, é necessário definir os valores das variáveis de entrada do modelo. Para definir o parâmetro de venda diária, foram analisados dados históricos de demanda de produtos, obtidos junto a uma empresa de inteligência de mercado que possui uma solução de compartilhamento de dados entre varejo e indústria. A determinação dos demais parâmetros foi feita com o auxílio de especialistas em análises de varejo, integrantes da mesma empresa fornecedora dos dados.

Tendo em vista que o método de Hausruckingger (2006) supõe que a demanda diária é uma variável com distribuição normal, foram analisados os dados de venda de um intervalo de seis meses para diversos produtos de alto giro e, com o auxílio do *software* EasyFit foram, realizados testes de aderência dos dados de venda à distribuição

normal. Com auxílio de especialistas, dentre os produtos analisados que apresentaram uma curva de venda com uma aderência significativa à curva normal, foi selecionado um dos produtos para ser utilizado como base na simulação. Dessa forma, a demanda base do dia (d_b) foi modelada como uma variável estocástica que segue uma distribuição normal com média (μ) e desvio-padrão (σ), que resulta em uma volatilidade (v), (calculada como σ dividido por μ). O histórico de vendas do produto selecionado pode ser representado através de uma curva normal com os parâmetros $\mu = 40$ e $\sigma = 16$, resultando em uma volatilidade de 40%. Nos demais cenários simulados, também se utilizou uma volatilidade de 15%, obtida mantendo a média de vendas 40, mas reduzindo o desvio-padrão.

Definiu-se que a periodicidade de revisão do nível de estoque em gôndola (PE_r) é dois períodos, por se tratar de produtos de alto giro; de tal forma, a revisão ocorre sempre no final do segundo e quarto período de cada dia. Como problemas de logística interna também causam de rupturas de estoque em gôndola, também se modelou uma probabilidade de falha da revisão programada (P_{fr}). A probabilidade de falha na verificação foi modelada de forma independente para cada período do dia. Nos cenários simulados P_{fr} foram utilizados os valores 2,5% e 5%.

Um aspecto que se desejou-se simular foram aumentos atípicos de demanda causados por promoções ou por uma ação de marketing, por exemplo. Para tanto, foi introduzida uma variável estocástica de aumento atípico de demanda (d_a), compondo a demanda esperada para o dia (D_{dia}). Dessa forma, a demanda total de um dia específico se dá pela equação (6).

$$D_{dia} = d_b + d_a \quad (6)$$

O valor do aumento atípico de demanda foi definido como sendo igual à demanda base do dia em que ocorreu a demanda atípica, dessa forma um dia com aumento atípico de demanda terá a demanda total igual ao dobro da demanda base. A probabilidade de ocorrência da demanda atípica (P_{da}) adotada nos cenários simulados foi de 2,5% e 5% por dia.

Em cada cenário simulado, os eventos de aumento atípico de demanda foram classificados como previstos ou não previstos. Aumentos atípicos de demanda previstos são eventos que o varejo previu ou planejou a ocorrência e, por consequência, aumentou a capacidade da gôndola de forma a minimizar as rupturas, o que pode ocorrer em uma

promoção promovida pelo próprio varejo, por exemplo. Já aumentos atípicos não previstos são eventos para os quais o varejo não aumentou a capacidade da gôndola, por erro de planejamento ou falta de informações, o que pode ocorrer quando o fabricante faz uma campanha publicitária de determinado produto sem comunicar o varejo, por exemplo.

De forma geral, podem ser aplicados diversos modelos de otimização a fim de encontrar a capacidade adequada da gôndola, pois essa variável depende de fatores como a participação do produto no faturamento da loja, o espaço total disponível na loja, custos de estoque e reposição, políticas de preço e relações de elasticidade entre o espaço ocupado pelo produto e sua demanda (HÜBNER, 2011).

Portanto, a fim de simplificar a modelagem, nos cenários em que os aumentos de demanda não foram previstos, a capacidade da gôndola foi definida em termos de nível de serviço (NS) diário com relação à venda base (d_b) e seus parâmetros de média (μ) e desvio-padrão (σ). A periodicidade de reposição do estoque (PE_r) também foi considerada no cálculo, visto que quanto maior a frequência de reposição da gôndola, menor deve ser sua capacidade para um dado NS. A capacidade da gôndola (C) para os cenários com aumento de demanda não planejada foi calculada conforme a equação (7), em que Z_{NS} é o número de desvios-padrões para qual a função normal acumulada resultante é igual ao nível de serviço especificado (NS), μ é a média de vendas adotada, σ é o desvio-padrão adotado e PE_r é a periodicidade da revisão do estoque em gôndola.

$$C = \frac{\mu + Z_{NS} \cdot \sigma}{PE_r} \quad (7)$$

Já para os cenários em que os aumentos atípicos de demanda foram previstos, a capacidade da gôndola foi calculada de forma diferente. O planejamento do varejo foi traduzido em termos de aumento da capacidade da gôndola. Como a demanda total de um dia com demanda atipicamente alta foi definida como o dobro da demanda base do dia, a capacidade da gôndola quando o varejo se preparou para um aumento de demanda foi definida como o dobro da existente quando não se previu o pico de demanda, conforme mostra a equação (8).

$$C = 2 \frac{\mu + Z_{NS} \cdot \sigma}{PE_r} \quad (8)$$

Definiu-se que a capacidade da gôndola seria aumentada sempre no último reabastecimento de cada dia anterior a um dia com pico previsto de demanda e também no abastecimento que ocorre no meio de um dia com pico de demanda. Por fim, nos cenários simulados, assumiu-se $NS= 0,95$, o que significa que a gôndola deve ser capaz de suportar a demanda base diária em 95% dos dias.

3.3 Aplicação do método de detecção de ruptura

Para cada rodada da simulação de Monte Carlo, os dados de venda de cada período foram agregados por dia e então aplicado o método de detecção de ruptura proposto por Hausruckingner (2006) (MH) e uma alternativa adaptada do método (MA), detalhados a seguir.

Para a aplicação do método de Hausruckingner (2006) (MH), a métrica de vendas esperadas foi calculada como a média de vendas do período. Já o limite inferior de venda (LI_{MH}) foi calculado como a média de vendas (μ) subtraída de dois desvios padrões (σ), como ilustra a equação (9).

$$LI_{MH} = \mu - 2\sigma \quad (9)$$

Já para o método adaptado (MA), a venda esperada foi calculada como a mediana das vendas observadas, como sugerido por Bayle-Tourtoulou e Laurent (2006). Para o cálculo do limite inferior de venda, não foi utilizada a forma empregada por Bayle-Tourtoulou e Laurent (2006), pois a distribuição de venda assumidas pelos autores foi a distribuição de Poisson. Portanto, foi adotada outra forma de detecção de *outliers* que assim como a mediana, também é pouco suscetível a distorções causadas pela presença de *outliers* na amostra. O cálculo do limite inferior (LI_{MA}) tem como base a recomendação de Christophe Ley et al. (2013), que sugerem a adoção do desvio absoluto mediano (MAD), como medida de dispersão da amostra. O MAD apoia-se no cálculo do desvio absoluto de cada valor da amostra (x_i) em relação à mediana do conjunto de valores (M_j) e então na avaliação da mediana dos valores resultantes (M_i) multiplicada por um coeficiente de ajuste (b), como ilustra a equação 10.

$$MAD = b M_i(|x_i - M_j(x_j)|) \quad (10)$$

O valor do coeficiente b deve ser 1,4826, assumindo uma distribuição normal, o que é o caso da modelagem adotada. Segundo os autores, um ponto x é detectado como

outlier quando está inserido no intervalo (11), em que M é a mediana dos valores da amostra, MAD é o desvio mediano absoluto calculado e β é um coeficiente de ajuste.

$$M - \beta MAD < x > M + \beta MAD \quad (11)$$

Segundo os mesmos autores, o coeficiente β adotado pode ser 3 (conservativo), 2,5 (moderadamente conservativo) e 2 (pouco conservativo). O coeficiente adotado foi 2, visto que Hausrucking (2006) também sugere a adoção de um coeficiente pouco conservativo no seu cálculo do limite inferior. Por fim, no contexto da modelagem, o limite inferior alternativo (LI_{MA}) é calculado pela equação 12, em que M é a mediana dos dados de venda e MAD é o desvio mediano absoluto calculado.

$$LI_{MA} = M - 2MAD \quad (12)$$

Para ambas as formas de cálculo do limite inferior de venda, entende-se como ruptura parcial no estoque da gôndola cada evento (na base diária) em que o volume de vendas observado foi menor do que o limite inferior.

Por fim, para ambos os métodos foi calculada a taxa de ruptura em termos de vendas perdidas e esperadas, como sugerido por Hausrucking (2006), expresso pela equação 2.

3.4 Simulação e cálculo dos indicadores

A Simulação de Monte Carlo foi executada no *software* Excel, para três cenários distintos, compostos de 2500 rodadas cada. Para cada cenário foram calculadas as seguintes métricas, resultantes da simulação da demanda, venda e nível de estoque em gôndola: total de dias, dias com ruptura, porcentagem de dias com ruptura, demanda e vendas perdidas (tendo como base a demanda e as vendas realizadas).

Para cada cenário também foram calculados quatro indicadores de acurácia para cada um dos métodos de detecção de ruptura: porcentagem de rupturas que ocorreram e foram detectadas; porcentagem de pontos de ruptura não detectados; porcentagem de pontos de ruptura incorretamente detectados; erro percentual de estimativa de venda perdida. Os dois primeiros indicadores são complementares. Os indicadores resultantes de cada cenário foram calculados como a média do indicador em cada uma das 2500 rodadas que compõem o cenário.

Em cada rodada também foi gerado um gráfico resultante da simulação, ilustrando as vendas, demanda, a ocorrência de ruptura, falha na verificação do estoque em gôndola e aumento atípico de demanda para cada dia do horizonte simulado.

3.5 Avaliação de resultados

Após a execução da simulação de Monte Carlo foram comparados os indicadores de acurácia dos métodos de detecção de ruptura utilizado nos diferentes cenários, de forma a avaliar o desempenho de cada método e o efeito das variáveis de entradas nos resultados obtidos. Em conjuntos com as métricas e indicadores do cenário, a análise do gráfico de algumas de suas rodadas deu suporte à análise dos resultados.

4. Resultados

Esta seção descreve os resultados obtidos a partir das Simulações de Monte Carlo realizada para os três cenários propostos, elaborados a partir dos valores das variáveis de entrada previamente definidos. Os cenários são exibidos na Tabela 1. Os valores de demanda atípica, periodicidade de revisão de estoque e nível de serviço foram mantidos iguais para todos os cenários, conforme explicado na seção 3.2.

Tabela 1: Cenários simulados

Cenário	V	P_{da}	d_a Planejada	P_{fr}
1	15%	2,50%	Sim	5,00%
2	15%	5,00%	Não	2,50%
3	40%	2,50%	Sim	5,00%

4.1 Cenário 1

Esse cenário simula o comportamento do nível da gôndola para um produto de volatilidade de vendas relativamente baixa (quando comparado com os produtos cujos históricos foram avaliados). Além disso, nesse cenário, os aumentos atípicos de demanda foram previstos.

A Tabela 2 exhibe as métricas resultantes desse cenário e a Tabela 3 exhibe os indicadores de acurácia para MH e MA, além das métricas de venda esperada e limite inferior calculados de acordo com cada método. A Figura 1 ilustra o gráfico gerado em uma das rodadas simuladas no cenário 1.

Tabela 2: Métricas resultantes do cenário 1

Métrica	Valor médio
Total de dias	181
Dias com rupturas	21
% de dias com ruptura	11,66%
Demanda	7.060
Vendas perdidas	258
% de vendas perdidas	3,66%

Tabela 3: Indicadores de acurácia dos métodos no cenário 1

Indicador	MH	MA
% Rupturas detectadas	6,36%	28,29%
% Rupturas não detectadas	93,64%	71,71%
% Detecções incorretas	11,80%	48,51%
% Vendas perdidas estimadas	0,50%	2,40%
Erro de estimativa de perda	-86,04%	-29,76%
Vendas esperadas	38	37
Limite Inferior	19	25




Figura 1: Gráfico resultante de uma das rodadas do cenário 1

Os indicadores de acurácia de cada método mostram que, nesse cenário, o método proposto por Hausrucking (2006) (MH) apresentou um desempenho inferior ao método

alternativo proposto (MA) em relação à porcentagem de detecções corretas e erro de estimativa de perda. Pela análise do gráfico em conjunto com os demais indicadores, verifica-se que o MA detectou uma quantidade maior de rupturas parciais do que o MH, pois LI MH ficou abaixo do que LI MA. Tal resultado pode ser explicado pelo fato de LI MH ter como base de cálculo desvio-padrão, enquanto LI MA tem como base o MAD, indicador menor suscetível a *outliers*, que nesse cenário correspondem aos picos de venda ocorridos nos dias em que houve aumento atípico de demanda.

Ambos os métodos subestimaram a perda percentual e falharam em detectar uma quantidade significativa de pontos de rupturas. Pelo gráfico observa-se que, nesses dias, apesar de ter havido uma ruptura parcial, a venda do dia permaneceu acima de LI MH e LI MA, o que decorre de duas razões distintas. Houve dias em que ocorreram rupturas, mas que tiveram impacto pouco significativo nas vendas realizadas (ilustrado no gráfico pela distância entre a linha de demanda e a linha de venda), que se mantiveram acima dos limites inferiores estabelecidos. Isso pode ocorrer, por exemplo, quando há uma pequena ruptura apenas no final do dia.

Em outros casos, houve rupturas que, apesar de impactarem nas vendas realizadas de forma mais significativa, também não foram detectadas pelos métodos propostos. Isso pode ocorrer quando a demanda do dia é alta e, mesmo ocorrendo indisponibilidade temporária do produto, a venda ocorrida no restante do dia já é suficiente para manter o nível total de vendas do dia acima dos limites estabelecidos.

Alguns pontos de ruptura ficaram ligeiramente acima dos limites estabelecidos, de forma que limites mais altos resultariam na detecção dessas ocorrências. Esta modificação, contudo, também implicaria no aumento de pontos incorretamente detectados como rupturas.

Em relação às causas das rupturas, observa-se que como os aumentos atípicos de demanda foram previstos, eles não geraram rupturas de estoque. Dessa forma, as rupturas ocorridas tiveram como causa principal a falha na verificação do estoque em gôndola, visto que a maior parte das rupturas ocorreu no mesmo dia ou no dia posterior à ocorrência de falha na verificação, o que pode ser observado na Figura 1. As demais ocorrências de ruptura podem ser atribuídas à variabilidade normal da demanda, que eventualmente supera o Nível de Serviço estabelecido.

4.2 Cenário 2

Nesse cenário a volatilidade de venda foi mantida igual à do cenário 1, mas os aumentos atípicos de demanda não foram planejados. Além disso, a probabilidade de ocorrência desse evento foi aumentada de 2,5% para 5%, enquanto que a probabilidade de falha na verificação do nível de estoque em gôndola foi reduzida de 5% para 2,5%.

A Tabela 4 exibe as métricas resultantes desse cenário e a Tabela 5 exibe os indicadores de acurácia para MH e MA, além das métricas de venda esperada e limite inferior calculados de acordo com cada método. A Figura 2 ilustra o gráfico gerado em uma das rodadas simuladas no cenário 2.

Tabela 4: Métricas resultantes do cenário 2

Métrica	Valor médio
Total de dias	181
Dias com rupturas	21
% de dias com ruptura	11,62%
Demanda	7.241
Vendas perdidas	388
% de vendas perdidas	5,36%

Tabela 5: Indicadores de acurácia dos métodos no cenário 2

Indicador	MH	MA
% Rupturas detectadas	11,56%	21,73%
% Rupturas não detectadas	88,44%	78,27%
% Detecções incorretas	43,03%	66,21%
% Vendas perdidas estimadas	0,99%	2,69%
Erro de estimativa de perda	-79,76%	-47,19%
Vendas esperadas	38	38
Limite Inferior	24	26




Figura 2: Gráfico resultante de uma das rodadas do cenário 2

Os indicadores de acurácia de cada método mostram que nesse cenário, assim como no cenário 1, o método proposto por Hausruckingner (2006) (MH) teve um desempenho inferior ao método alternativo proposto (MA) em relação à porcentagem de detecções corretas e erro de estimativa de perda. Contudo, nesse cenário MH teve um desempenho melhor do que no cenário 1, enquanto MA teve um desempenho pior.

Verificou-se, no cenário 2, que a diferença média entre LI MH e LI MA foi menor do que a ocorrida no cenário 1, o que resultou em uma menor diferença entre a porcentagem de detecções corretas de MH e de MA. A justificativa de tal comportamento reside no fato de os aumentos de demanda não terem sido previstos. De tal forma, devido à indisponibilidade do produto na gôndola, não foram gerados *outliers* de venda aos quais LI MH é mais sensível - conforme observado no cenário 1.

Outro reflexo da ocorrência dos aumentos não planejados de demanda é que as rupturas ocorridas nesses dias, de forma geral, não foram detectadas, pois apesar de a ruptura ter ocorrido, a alta demanda nos demais períodos do dia resultou em um total de vendas relativamente elevado, que ficou acima de LI MH e LI MA.

Assim como no cenário 1, verificou-se que as falhas na verificação do nível de estoque também resultaram em rupturas no mesmo dia ou no dia posterior a sua

ocorrência. Os pontos de ruptura resultantes dessas falhas se mostraram mais facilmente identificados pelos métodos do que aqueles causados por aumentos atípicos de demanda.

Em relação ao erro de estimativa de perda, apesar desse indicador ter sido melhor no cenário 1 para MA e melhor no cenário 2 para MH, ele indica que as perdas foram significativamente subestimadas. Outro ponto relacionado ao indicador de estimativa de perda é que, se por um lado, rupturas não detectadas não são consideradas como perda, por outro lado, detecções incorretas são consideradas como tal, o que causa uma distorção no indicador.

4.3 Cenário 3

Nesse cenário a volatilidade de venda foi de 40% e os aumentos atípicos de demanda foram previstos. Além disso, a probabilidade de ocorrência desse evento foi 2,5% e a probabilidade de falha na verificação do nível de estoque em gôndola foi de 5%.

A Tabela 6 exibe as métricas resultantes desse cenário e a Tabela 7 exibe os indicadores de acurácia para MH e MA, além das métricas de venda esperada e limite inferior calculados de acordo com cada método. A Figura 3 ilustra o gráfico gerado em uma das rodadas simuladas no cenário 3.

Tabela 6: Métricas resultantes do cenário 3

Métrica	Valor médio
Total de dias	181
Dias com rupturas	14
% de dias com ruptura	8,00%
Demanda	7.065
Vendas perdidas	183
% de vendas perdidas	2,59%

Tabela 7: Indicadores de acurácia dos métodos no cenário 2

Indicador	MH	MA
% Rupturas detectadas	0,53%	0,92%
% Rupturas não detectadas	99,47%	99,08%
% Detecções incorretas	97,50%	97,88%
% Vendas perdidas estimadas	1,60%	2,34%
Erro de estimativa de perda	-29,85%	1,49%
Vendas esperadas	38	37
Limite Inferior	4	5




Figura 3: Gráfico resultante de uma das rodadas do cenário 3

Nesse cenário observou-se que ambos os métodos de detecção de ruptura tiveram um alto índice de ruptura não detectadas, bem como um alto índice de detecções incorretas. Em razão da grande variabilidade das vendas, ambos os limites inferiores ficaram muito mais baixos do que nos demais cenários. Como a variabilidade se manifestou em todo o conjunto de dados, LI MA (calculado a partir do MAD) também apresentou um valor próximo de zero.

Quanto mais próximo de zero estão LI MA e LI MH, menor é a faixa de detecção e menor a capacidade de detecção de rupturas parciais. No cenário simulado, percebe-se, inclusive, que a ocorrência de dias sem vendas não pode ser diretamente atribuída à indisponibilidade do produto na gôndola, pois a variabilidade da demanda eventualmente leva a dias com demanda zero.

Nesse cenário observou-se de forma ainda mais evidente que poucas rupturas se traduziram em vales de vendas (pontos notavelmente abaixo do demais). Em dias com alta demanda a indisponibilidade temporária do produto não implica necessariamente em uma venda total baixa quando comparado com dias em que a demanda naturalmente foi mais baixa.

Em razão do aumento atípico de demanda terem sido previstos - como no cenário 1 - as rupturas observadas foram resultado das falhas de verificação do nível e estoque em gôndola e do Nível de Serviço projetado, com a diferença de que, nesse cenário, em geral, elas não foram detectadas pelos métodos empregados.

Esse cenário também permite avaliar a relevância do erro de estimativa de perda como indicador de desempenho dos métodos de ruptura. No presente cenário, tanto para o MH quanto para o MA, esse indicador levou ao melhor desempenho dentre os três cenários analisados - com MA apresentando um erro de apenas 1,49%. Percebe-se, contudo, que houve um alto índice de detecções incorretas e rupturas não detectadas, de forma que as detecções incorretas foram contabilizadas como perdas que não ocorreram. Dessa forma, analisando o indicador de erro de estimativa de vendas em conjunto com os demais, nota-se que esse indicador não mede corretamente o desempenho dos métodos de detecção de ruptura empregados.

5. Conclusões

Considerando a relevância das perdas decorrentes da ruptura de estoque em gôndola no setor varejista e os métodos que podem ser empregados para sua detecção, o propósito do trabalho foi avaliar duas sistemáticas de detecção e ruptura que têm como base a análise de dados diários de venda.

A partir da avaliação do desempenho dos dois métodos analisados, que foram aplicados nos dados gerados através da simulação de Monte Carlo, verificou-se que o método alternativo proposto teve um maior índice de detecções de rupturas do que o método proposto por Hausrucking (2006). Contudo, o desempenho observado indica que essa categoria de método de detecção tem aplicação restrita a produtos com uma volatilidade inferior à recomendada por Hausrucking (2006). O melhor desempenho do método alternativo proposto é atribuído à sua maior robustez à existência de *outliers*, através do emprego do MAD no cálculo do limite inferior de venda.

Com o auxílio das Simulações de Monte Carlo, observou-se que a indisponibilidade temporária do produto ao longo do dia nem sempre gera uma queda de vendas detectável através do estabelecimento de limites inferiores. Enquanto rupturas causadas por falhas na verificação do estoque em gôndola parecem ser mais facilmente detectadas, as rupturas causadas por aumentos atípicos de demanda não previstos mostraram-se mais difíceis de serem detectadas pelos métodos analisados.

Devido ao desempenho observado e à relativa facilidade de concepção e aplicação, a utilização do método de detecção alternativo proposto se mostra mais indicada para uma análise preliminar de indisponibilidade do produto em gôndola. De tal

forma, recomenda-se sua integração a outras técnicas de detecção de ruptura de estoque em gôndola, como a auditoria manual.

Para trabalhos futuros, recomenda-se a análise do desempenho dessa categoria de métodos de detecção para produtos cujas curvas de distribuição não sejam normais. Além disso, a incorporação de outros elementos na simulação, como o custo de reposição de estoque em gôndola e relações de elasticidade entre espaço em gôndola e demanda, poderia gerar uma modelagem mais precisa. Ressalta-se, contudo, que para avaliar o desempenho dos métodos analisados uma alternativa mais adequada à simulação seria a coleta dados através do monitoramento contínuo do nível de estoque em gôndola dos produtos analisados.

6. Referências

AGUIAR, Fernando Henrique Oliveira; SAMPAIO, Mauro. Definição de processo para tratar a ruptura de estoque no varejo de alimentos. **GEPROS. Gestão da Produção, Operações e Sistemas**, Bauru, Ano 8, nº 2, p. 67-82, abr-jun/2013.

AGUIAR, Fernando Henrique Oliveira de; SAMPAIO, Mauro. Identificação dos fatores que afetam a ruptura de estoque utilizando análise de agrupamentos. **Prod.**, São Paulo, v. 24, n. 1, p. 57-70, mar. 2014.

A. T. KEARNEY LTDA. MANAGEMENT CONSULTANTS. **The 2016 Global Retail Development Index**. 2016.

BAYLE-TOURTOULOU, Annie-Sophie; LAURENT, Gilles; MACÉ, Sandrine. Assessing frequency and causes of out-of-stock events through store scanner data. **Les Cahiers de Recherche**, HEC Paris, nº 830. 2006.

BERGER, Roland. **Optimal shelf availability: increasing shopper satisfaction at the moment of truth**. ECR Europe and Roland Berger, 2003.

BOWERSOX, Donald J.; CLOSS, David J. **Logística empresarial: o processo de integração da cadeia de suprimento**. 1 ed. São Paulo: Atlas, 2008.

DA SILVA, E.D; MENEZES, E.M. **Metodologia de Pesquisa e Elaboração de Dissertação**. 4. Ed. Ver. Atual. Florianópolis: UFSC. 2005.

FERNIE, John; SPARKS, Leigh. **Logistics and Retail Management: Insights Into Current Practice and Trends from Leading Experts**. 2. ed. Kogan Page Publishers, p 6-17, 2004.

- ECR, U. K. Availability - a UK perspective. **IGD, Watford**, 2004.
- GRUEN, Thomas W. ; CORSTEN, Daniel S.. **A Comprehensive Guide to Retail Out-of-Stock Reduction in the Fast-Moving Consumer Goods Industry**. Grocery Manufacturers of America, Washington, 2007.
- GRUEN, Thomas W. ; CORSTEN, Daniel S. ; BHARADWAJ, Sundar. **Retail out-of-stocks: a worldwide examination of extent, causes and consumer responses**. . Grocery Manufacturers of America, Washington, 2002.
- HARDGRAVE, Bill C.; LANGFORD, Simon; WALLER, Matthew; MILLER, Robert. Measuring the impact of RFID on out of stocks at Wal-Mart. **MIS Quarterly Executive**, v. 7, n. 4, 2008.
- HAUSRUCKINGER, Gerhard. **Approaches to measuring on-shelf availability at the point of sale**. Roland Berger Strategy Consultants and ECR Europe, 2006.
- ECR, U. K. **Availability—a UK perspective**. IGD, Watford, 2004.
- KARABATI, Selcuk; TAN, Bariş; ÖZTÜRK, Ömer Cem. A method for estimating stock-out-based substitution rates by using point-of-sale data. **IIE Transactions**, v. 41, n. 5, p. 408-420, 2009.
- KRAJEWSKI, Lee J.; RITZMAN, Larry P. **Administração de produção e operações**. 8. ed. São Paulo: Pearson Prentice Hall, 2008
- LA LONDE, Bernard J.; COOPER, Martha C.; NOORDEWIER, Thomas G. **Customer service: a management perspective**. Oak Brook, IL: Council of Logistics Management, 1988.
- LAMBERT, Douglas M.; STOCK, James R.; ELLRAM, Lisa M. **Fundamentals of logistics management**. McGraw-Hill/Irwin, 1998.
- LEYS, Christophe et al. Detecting outliers: Do not use standard deviation around the mean, use absolute deviation around the median. **Journal of Experimental Social Psychology**, v. 49, n. 4, p. 764-766, 2013.
- LIU, Lanjuan; ZHOU, Xinyan. A dynamic (s, S) replenishment policy for suppliers engaged in VMI agreement with retailers. In: **Service Operations and Logistics, and Informatics**, 2007. SOLI 2007. IEEE International Conference on. IEEE, 2007. p. 1-6.

MOORE, J. H.; WEATHERFORD, L. R. **Tomada de decisão em administração com planilhas eletrônicas**. 6 ed. Porto Alegre: Bookman, 2005.

PAPAKIRIAKOPOULOS, Dimitris. Predict on-shelf product availability in grocery retailing with classification methods. **Expert Systems with Applications**, v. 39, n. 4, p. 4473-4482, 2012.

PAPAKIRIAKOPOULOS, Dimitrios; PRAMATARI, Katerina; DOUKIDIS, Georgios. A decision support system for detecting products missing from the shelf based on heuristic rules. **Decision Support Systems**, v. 46, n. 3, p. 685-694, 2009.

PIRAMUTHU, Selwyn; WOCHNER, Sina; GRUNOW, Martin. Should retail stores also RFID-tag 'cheap' items?. **European Journal of Operational Research**, v. 233, n. 1, p. 281-291, 2014.

SHAMBLIN, James E.; STEVENS, G. T. **Pesquisa Operacional: uma abordagem básica**. 1. ed. São Paulo: Atlas, 1989.

TON, Zeynep; RAMAN, Ananth. The effect of product variety and inventory levels on retail store sales: A longitudinal study. **Production and Operations Management**, v. 19, n. 5, p. 546-560, 2010.

USMAN, K.. **Determination os Drivers of Stock-out performace of retail stores using data mining techniques**. Dissertação (Mestrado em Engenharia Logística) MIT, Boston, USA,2008.

VASCONCELLOS, Luis Henrique Rigato; SAMPAIO, Mauro. The stockouts study: an examination of the extent and the causes in the São Paulo supermarket sector. **Brazilian Administration Review**, 6(3), 263-279. 2009.