



OTIMIZAÇÃO DE CADEIA DE SUPRIMENTOS DE PETRÓLEO SOB INCERTEZA E AVALIAÇÃO DE RISCO

Marcelo Maia F. de Oliveira

Laura S. Bahiense*

Virgílio J. M. Ferreira Filho*

Programa de Engenharia de Produção, Instituto Alberto Luiz Coimbra de Pós Graduação e Pesquisa em Engenharia, Universidade Federal do Rio de Janeiro.
Centro de Tecnologia, Bloco F, Sala 103, Ilha do Fundão. Caixa Postal 68507, Rio de Janeiro RJ 21941-972, Brasil.

E-mails: marcellomaia@gmail.com, laura@pep.ufrj.br, virgilio@pep.ufrj.br

RESUMO

Este artigo trata do planejamento da cadeia de suprimentos de uma empresa integrada de petróleo, considerando operações comerciais, logísticas e industriais – refinaria – em um ambiente de incerteza de demanda, cotações internacionais e produção própria de petróleo, as quais geram mais de 150 mil possíveis realizações. Para solução deste problema, emprega-se um modelo de otimização estocástica de dois estágios em que, inicialmente, utiliza-se um método de aproximação de solução (SAA); posteriormente empregam-se dois métodos de geração de cenários (correspondência de momentos e agregação temporal baseado em cadeia de Markov); em seguida se escolhe o melhor parâmetro de cada método de geração de acordo com medidas de qualidade da solução obtida; e, finalmente, utiliza-se uma medida de risco para avaliar o impacto frente à aversão ao risco. Assim, geram-se soluções com garantias estatísticas a partir de um conjunto de realizações extremamente menor que o conjunto inicial e que podem ser avaliadas segundo o nível de risco desejado.

PALAVRAS-CHAVE: Cadeia de Suprimentos de Petróleo; Programação Estocástica, Aproximação por média amostral, Geração de Cenários, Análise de Risco, CVaR.

Área principal: Planejamento de Cadeia de Suprimentos.

ABSTRACT

This article deals with an oil integrated company supply chain planning, considering commercial, logistic and industrial (refineries) operations under an environment of uncertainty concerning product demand, international prices and its own oil production, which leads up to more than 150 thousand possible realizations. To solve such a problem, a two-stage stochastic model is applied in which, initially, the solution is approximated by the SAA method; afterward two different scenario generation methods are applied – Moment Correspondence and Time Aggregation based on Markov Chain; then, the best parameter of each method is chosen accordingly to solution quality measure; and, finally, a risk measure is applied to evaluate the solution impact due to risk aversion. Thus, solutions with statistical guarantees are generated using a set of realizations extremely smaller than the original one and which can also be evaluated second to a desirable risk level.

PALAVRAS-CHAVE: Oil Supply Chain, Stochastic Programming, Sampling Average Approximation, Scenario Generation, Risk Analysis, CVaR.

Main area: Supply Chain Planning.

I- Introdução

A área de *midstream* de uma empresa de petróleo realiza as operações que englobam o alívio de plataformas de petróleo, transporte deste insumo para terminais, suprimento de petróleo para refinarias, onde é processado e convertido em derivados, importação e exportação de petróleos e derivados. Emprega-se modelos de otimização, geralmente lineares, com intuito de planejar a cadeia logística envolvida de forma a maximizar o resultado para a empresa e gerar diretrizes a serem desdobradas para áreas operacionais (comercial, logística e de refino).

Ao realizar o planejamento desta cadeia, a empresa deve considerar as incertezas inerentes às previsões que utiliza dado o grande impacto que pode ter na geração de valor de suas atividades. Entre estas incertezas, podem-se destacar fatores externos à empresa, como: cotação de petróleo e derivados no mercado internacional e demanda a ser atendida; e fatores internos à empresa, como: produção de petróleo, disponibilidade de equipamentos e rendimentos obtidos nas unidades de processo. O objetivo deste trabalho é analisar o impacto de considerar a incerteza envolvida no processo de planejamento de cadeia de suprimentos de petróleo de uma empresa integrada via programação estocástica, com geração de cenários considerando métodos estatísticos e probabilísticos, e ainda avaliar o impacto da inclusão de uma medida de risco.

II- Revisão Bibliográfica

Segundo Papageorgiou, 2009, a cadeia de suprimentos de empresas industriais modernas envolvem operações de multiprodutos, multipropósito e multifacilidades em diferentes regiões e países, lidando com clientes em todo o globo e, para planejá-la, necessita-se de modelos de otimização ou simulação. Atualmente, diferentes modelos integrados de planejamento de cadeia de suprimentos podem ser elaborados para determinar as ações ao longo de toda a cadeia, sendo que alguns destes modelos têm sido desenvolvidos considerando incertezas, sendo que a maior parte deles na forma de programação estocástica de dois estágios (Zamarripa *et al.*, 2012).

Vários são os trabalhos têm como objetivo otimizar operações da cadeia de suprimentos de petróleo utilizando programação estocástica (Khor *et al.*, 2008; Carneiro *et al.*, 2010; Khor e Nguyenl., 2009; Ribas *et al.*, 2012; Oliveira e Hamacher, 2012; Leiras *et al.*, 2013 e Oliveira *et al.*, 2013). Além da consideração de incertezas, muitos destes trabalhos, tal como este, visam lidar com grandes números de possíveis realizações da incerteza, ou mesmo a tratam como contínua, e com o risco envolvido nas decisões.

Dentre estes e outros trabalhos, verifica-se a predominância da abordagem de dois estágios e da estocástica robusta na resolução do problema estocástico. Aplicações de programação multi-estágio ainda são raras devido ao custo computacional deste tipo de abordagem. Em relação à incerteza considerada, grande maioria a leva em conta a demanda de derivados, seguido do preço de petróleo e derivados.

2.1 Programação Estocástica

Segundo Hagle, 2005, o modelo de programação estocástica leva em conta um conjunto de dados incertos, ξ , que é uma variável aleatória definida no espaço de probabilidade (Ω, A, P) . Quando ξ é uma variável aleatória discreta, $p_{\xi} = P\{\xi = \xi\}$ para cada cenário $\xi \in \Omega$. Esta abordagem compreende dois tipos de variáveis: x , a variável de decisão de primeiro estágio (variável aqui-e-agora) a qual é determinada antes que qualquer informação sobre a incerteza seja revelada; e y que é determinada somente no segundo estágio e depois de ter sido observada a realização da incerteza de ξ . O problema de programação estocástica de dois estágios pode ser escrito de maneira geral de acordo com as equações 1 a 4 apresentadas a seguir:

$$\begin{array}{ll}
 \text{Min} & c * x + E[h(x, \xi)] & 1 \\
 \text{s.a.} & A * x \geq b & \text{e} & x \geq 0 & 2 \\
 \text{Onde} & h(x, \xi) = \text{Min} g_{\xi} * y & 3 \\
 \text{s.a.} & W_{\xi} * y \geq r_{\xi} - T_{\xi} * x & \text{e} & y \geq 0 & 4
 \end{array}$$

Duas medidas por permitem avaliar o ganho de se considerar as incertezas através de programação estocástica (Birge e Louveaux, 2011): Valor Esperado da Informação Perfeita - *Expected value of perfect information* (EVPI) e Valor da Solução Estocástica – *Value of Stochastic Solution* (VSS). O EVPI mede o máximo valor que um tomador de decisão estaria disposto a pagar pela informação completa sobre o futuro e consiste da diferença entre o valor da solução *Wait-and-See* (WS), onde há completo conhecimento sobre a realização das incertezas, e o valor da solução estocástica (RP), cujo problema é expresso nas equações de 1 a 4, e é calculado conforme equação 5:

$$EVPI = RP - WS = RP - \mathbb{E}_{\xi}[\min_x z(x, \xi)] \quad 5$$

Definindo $\bar{\xi}$ como sendo o valor médio das realizações possíveis do problema estocástico e $\bar{x}(\bar{\xi})$, o valor das variáveis de primeiro estágio da solução do problema determinístico gerado a partir de $\bar{\xi}$, a segunda medida de qualidade – VSS – é diferença ente o valor da solução do problema estocástico obtida igualando-se as variáveis de primeiro estágio a $\bar{x}(\bar{\xi})$, chamado EEV, e a solução do problema determinístico considerando $\bar{\xi}$, chamado EV, *Expected Value Problem*. As equações 6 e 7 apresentam o cálculo do EV, EEV e VSS:

$$\bar{x}(\bar{\xi}) = \text{argmin}(EV) \text{ onde } RV = \min_x z(x, \bar{\xi}) \quad 6$$

$$VSS = EEV - RP = \mathbb{E}_{\xi} \left(z(\bar{x}(\bar{\xi}), \xi) \right) - RP \quad 7$$

2.2 SAA (Aproximação por média amostral)

Segundo Shapiro e Homem-de-Mello (1998), o método SAA (*sampling average approximation*) trata de obter limitantes inferiores e superiores do valor real da função objetivo de um problema de programação estocástica com alto custo computacional (distribuição contínua ou número bastante grande de realizações, como é o caso deste trabalho) a partir de amostragem baseado em Monte Carlo. Diversas replicações são geradas a partir do conjunto inicial de incertezas e obtêm-se intervalos de confiança e o gap de otimalidade entre os limitantes inferior e superior.

Seja um problema estocástico da forma definida pela equação 8 (adaptado da seção 2.1):

$$\text{Min}_x \{g(x) = \mathbb{E}[G(x, \xi)]\} \quad 8$$

Onde $G(x, y)$ é uma função dois vetores de variáveis, x e y , cuja esperança é dada pela equação 9:

$$\mathbb{E}[G(x, \xi)] = \int G(x, y)P(dy) \quad 9$$

Sejam $\xi^1, \xi^2, \xi^3 \dots \xi^M$ amostras aleatórias de tamanho N , independentes e identicamente distribuídas de um vetor aleatório ξ , a função da média amostral é dada pela equação 10:

$$\hat{g}_N(x) = \frac{1}{N} \sum_{j=1}^N G(x, \xi^j) \quad 10$$

$$\text{O problema aproximado pela amostragem é dado então por: } \min_x \hat{g}_N(x) \quad 11$$

Os problemas definidos pelas equações 8 e 11 são, respectivamente, o problema real e o problema por aproximação de média amostral. Sejam v^* e \hat{v}_N os valores ótimos dos respectivos problemas: $v^* = \min_x g(x)$ e $\hat{v}_N = \min_x \hat{g}_N(x)$. Define-se também \hat{x}_N como a solução ótima do problema SAA, conforme a equação 12:

$$\hat{x}_N = \text{argmin}(G(x, \xi^j)) \quad 12$$

Segundo Kleywegt *et al.* (2001): $\mathbb{E}[\hat{v}_N] \leq \mathbb{E}\{\min_x \hat{g}_N(x)\} \leq \min_x \mathbb{E}[\hat{g}_N] = v^*$ e, portanto, o estimador \hat{g}_N possui um viés negativo. Assim, pode-se obter um limitante inferior para o problema original estimando-se $\mathbb{E}[\hat{v}_N]$ da seguinte maneira: geram-se M amostras de tamanho N e resolvendo o problema SAA, se obtém os valores ótimos $\hat{v}_N^1, \hat{v}_N^2 \dots \hat{v}_N^M$, e pode-se calcular um estimador não enviesado de $\mathbb{E}[\hat{v}_N]$ conforme apresentado na equação 13 e cuja variância é dada pela equação 14:

$$\bar{v}_N^M = \frac{1}{M} \sum_{m=1}^M \hat{v}_N^m \quad 13$$

$$S_{\bar{v}_N^M}^2 = \frac{1}{M(M-1)} \sum_{m=1}^M (\hat{v}_N^m - \bar{v}_N^M)^2 \quad 14$$

Considerando uma solução viável $\bar{x} \in X$, como, por exemplo, sendo igual a uma solução ótima \hat{x}_N de um problema SAA, pode-se estimar o valor real de $g(x)$ no ponto \bar{x} pela geração de T amostras $\xi^1, \xi^2, \xi^3 \dots \xi^{N'}$ de tamanho N' e computar conforme a equação 15:

$$g_{N'}^T(\bar{x}) = \frac{1}{T} \sum_{t=1}^T \hat{g}_{N'}^t(\bar{x}) \quad 15$$

Onde $\hat{g}_{N'}^t(\bar{x})$ é o valor da função objetivo da média amostral no ponto \bar{x} da amostra t do SAA, conforme dado pela equação 16, na qual se obtém um estimador não enviesado de $\mathbb{E}[G(\bar{x}, \xi)]$ e gera um limitante superior estatístico para o verdadeiro valor da solução ótima no ponto \bar{x} . A equação 17 apresenta a variância deste estimador:

$$\hat{g}_{N'}^t(\bar{x}) = \frac{1}{N'} \sum_{j=1}^{N'} G(\bar{x}, \xi^{tj}) \quad 16$$

$$S_{\hat{g}_{N'}^T(\bar{x})}^2 = \frac{1}{T(T-1)} \sum_{t=1}^T (\hat{g}_{N'}^t(\bar{x}) - g_{N'}^T(\bar{x}))^2 \quad 17$$

Usando as expressões acima, uma estimativa do gap de otimalidade de uma solução candidatada \bar{x} pode ser calculada por $g_{N'}^T(\bar{x}) - \bar{v}_N^M$ e sua variância é estimada por $S_{\bar{v}_N^M}^2 + S_{\hat{g}_{N'}^T(\bar{x})}^2$.

2.3 Métodos de geração de cenários

Os métodos de geração de cenários aplicado neste estudo foram: correspondência de momento e medidas estatística, Hoyland e Wallace (2001) e agregação temporal baseado em cadeia de Markov, Cao *et al.* (2002).

O primeiro método consiste de um modelo de programação não linear (NLP), conforme apresentado nas equações 18 e 19 e Tabela 1, usado para gerar um número limitado de cenários discretos que satisfaça a propriedades estatísticas específicas através da minimização diferença entre a propriedade estatística dos resultados e as propriedades estatísticas do conjunto original de incertezas. No estudo, utilizam-se os quatro primeiros momentos e a matriz de correlação.

$$\min \sum_{i \in I} W_i * (f_i(x_{v,sc}, p_{sc}) - T_i)^2 \quad 18$$

$$\sum_{i \in I} p_{sc} = 1, p_{sc} \geq 0 \quad 19$$

Tabela 1: Conjuntos, parâmetros e variáveis do modelo NLP de geração de cenários por correspondência de momentos e propriedades estatísticas.

Conjuntos		Variáveis	
Variável aleatória (v)	$v \in V$	Valor da variável aleatória	$x_{v,sc}$
Cenário (sc)	$sc \in SC$	Probabilidade	p_{sc}
Propriedade estatística	$i \in I$	Valor da propriedade estatística	$f_i(x_{v,sc}, p_{sc})$
Parâmetros			
Meta da propriedade estatística	T	Peso para propriedade estatística	W_i

O segundo método é baseado no trabalho de Cao *et al.*, 2002, o modelo é baseado em características de Cadeias de Markov ergódicas e no tempo de retorno. A ideia básica que suporta o modelo é: (1) escolhe-se um subconjunto de estados L1 de tal forma que L1 esteja contido em L, conjunto que contém todos os estados possíveis; (2) inicia-se uma cadeia amostrando um elemento de L1; (3) segue-se com amostragem do conjunto L; (4) toda vez que a cadeia de Markov alcança o estado L1, este estado é registrado; (5) a sequência resultante forma uma cadeia de Markov embutida e, portanto, a agregação não é uma aproximação. A amostragem pode ser feita por importância e potenciais desempenhos. Desta forma, pode-se gerar a partir do conjunto inicial de incertezas um conjunto menor que mantém a propriedade markoviana.

A avaliação da qualidade das árvores de cenários geradas neste trabalho segue a proposta feita por Ribas *et al.*, 2012. As seguintes métricas são utilizadas para quantificar a qualidade da geração de cenários: valor da função objetivo, valor das variáveis de primeiro estágio e valor esperado da informação perfeita (EVPI).

2.4 Avaliação de Risco

Neste trabalho, optou-se pela medida CVaR (*Conditional Value at Risk*) proposta por Rockafellar e Uryasev (2000) por ser uma medida coerente de risco, segundo os critérios apresentados por Artzner *et al.* (1999), por não aumentar a complexidade do modelo matemático e por considerar “caudas longas”. Dado um nível de confiança α , Value-at-Risk (VaR) é o valor tal que a probabilidade do lucro obtido ser inferior a este é igual a $1-\alpha$ e o CVaR é definido como o valor médio dos lucros menores que VaR, conforme apresentado pelas equações 20 a 22:

$$\text{Max CVaR}_\alpha = \zeta - \frac{1}{1-\alpha} \sum_{\omega=1}^{N_\Omega} \pi_\omega * \eta_\omega \quad 20$$

$$\text{s.a.} \quad -\text{lucro}_\omega + \zeta - \eta_\omega \leq 0 \quad 21$$

$$\eta_\omega \geq 0 \quad 22$$

Onde lucro_ω é o lucro do cenário ω com uma probabilidade associada igual a π_ω . ζ é uma variável auxiliar cujo valor ótimo corresponde ao valor de VaR. Conforme exposto pelas equações 20 a 22, no valor ótimo, η_ω é a diferença entre o VaR e o valor do lucro para cada um daqueles cenários que tiverem lucro menor que VaR, ou igual a zero caso seja maior que VaR. Como o valor é computado em relação àqueles η_ω diferentes de zero, o somatório deve ser dividido pela soma de probabilidade destes casos, ou seja, $1-\alpha$. No valor ótimo, a diferença entre o VaR e essa média é igual ao CVaR.

Com adoção da medida de risco, a função objetivo é alterada conforme a equação 21, onde β é a aversão ao risco que à qual se permite estar exposto e assume valores entre 0 e 1. Na equação 23, adapta-se a função objetivo para maximização:

$$\text{Max} \quad (1 - \beta) * \{c * x + E[h(x, \xi)]\} + \beta * \text{CVaR} \quad 23$$

III- Métodos e dados de entrada

3.1 Modelo Matemático

O modelo matemático deste trabalho consiste de programação estocástica de dois estágios, cuja função objetivo é maximizar o lucro das operações logísticas, comerciais e de refino da cadeia de uma empresa de petróleo integrada. As decisões de importação e exportação de petróleo são as variáveis de primeiro estágio. As variáveis de segundo estágio são todas as demais. As Tabelas 2, 3 e 4 apresentam, respectivamente, os índices, parâmetros, variáveis de primeiro e segundo estágio do problema.

Tabela 2: Índices do modelo

Índice	Descrição dos conjuntos
i	Conjunto de petróleos considerado no sistema
j	Conjunto de derivados considerado no sistema
k	Conjunto de intermediários considerado no sistema
l	Conjunto de produtos tipo carga considerado no sistema
m	Conjunto de meses considerado no plano
n	Conjunto de polos considerado no mercado nacional
o	Conjunto de polos considerado no mercado internacional
p	Conjunto de locais de produção de petróleo nacional
q	Conjunto de qualidades considerado no sistema
r	Conjunto de refinarias considerado no sistema
s	Conjunto de cenários de realização de incertezas no segundo estágio
t	Conjunto de terminais de petróleos e derivados considerado no sistema
u	Conjunto de tipos de unidades de processo considerado no sistema

Tabela 3: Parâmetros do modelo

Parâmetro	Índices	Descrição
PetImpMax, PetExpMax	i,m	Máxima importação e exportação de petróleo
PetImpCost, PetExpRec	i,m	Custo de importação e receita de exportação de petróleo
PetImpCostSpot, PetExpRecSpot	i,m	Custo de importação e receita de exportação de petróleo em mercado Spot
PetExpMulta	i,m	Multa de cancelamento de exportação
ProdNac	i,m	Produção de petróleo nacional prevista
DerImpMax, DerExpMax	j,m	Máxima importação e exportação de derivado
DerImpCost, DerExpRec	j,m	Custo de importação e receita de exportação de derivado
DemNac	j,m	Demanda nacional de derivado prevista
DerVendaRec	j,m	Receita de venda de derivado
DerEstoqMax	j,r	Máximo estoque de derivado em refinaria
DerEstoqCost	J	Custo de estoque de derivado
DerQualMin, DerQualMax	q,j	Valor mínimo e máximo de qualidade de derivado
PetIntermRend	j,k	Rendimento de petróleo em intermediário
IntermDerDeg	k,j	Matriz de degradação de intermediário em derivado
IntermQual	k,q	Qualidade de intermediário
IntermCargaDeg	k,l	Matriz de degradação de intermediário em produto carga
CargaIntermRend	l,k,u	Rendimento de produto carga em intermediário
UnidCapMax	u,r	Máxima capacidade de unidade de processamento
UnidCost	U	Custo de processamento
UnidQualMax	q,u	Valor da qualidade máxima para carga de unidade
PetTransfCost	p,o,t,r	Custo de transporte de petróleo
DerTransfCost	o,t,r,n	Custo de transporte de derivado
CenProb	s	Probabilidade do cenário
ProdDesc, CotDesc, DemDesc	s	Valor de correção da produção nacional de petróleo, cotação internacional e mercado nacional de derivados

Tabela 4: Variáveis de primeiro estágio e segundo estágio

Estágio	Variável	Índice	Descrição
Primeiro	PetImp, PetExp	i,m	Volume de petróleo importado e exportado
	PetProc	i,m	Volume de petróleo destinado a processamento
Segundo	PetProdExc	i,m,s	Excesso de produção de petróleo em relação ao previsto
	PetProdDef	i,m,s	Déficit de produção de petróleo em relação ao previsto
	PetExpSpot	i,m,s	Volume de petróleo exportação em mercado Spot
	PetExpCanc	i,m,s	Volume de exportação de petróleo cancelado
	PetProcCanc	i,m,s	Volume de petróleo destinado a processamento cancelado
	PetImpSpot	i,m,s	Volume de petróleo importado em mercado Spot
	PetAloc	i,r,m,s	Volume de petróleo alocado em refinaria
	DerImp	j,m,s	Volume de derivado importado
	DerExp	j,m,s	Volume de derivado exportado
	DerProd	j,r,m,s	Volume de derivado produzido por refinaria
	DerProdTotal	j,m,s	Volume total de derivado produzido
	DerEstoq	j,r,m,s	Volume de derivado estocado
	DerQual	j,q,r,m,s	Qualidade do derivado
	DegIntermDer	k,j,r,m,s	Volume de intermediário degradado para derivado
	DegIntermCarga	k,l,r,m,s	Volume de intermediário degradado para produto carga
	CargaAloc	l,u,r,m,s	Volume de produto carga alocado em unidade
	UnidQual	u,q,r,m,s	Qualidade de produto carga
	PetImpTransf	i,t,o,m,s	Volume de petróleo importado transferido para terminal
	PetExpTransf	i,t,o,m,s	Volume de petróleo exportado transferido de terminal
	PetNacProdTransf	i,p,t,m,s	Volume de petróleo produzido transferido para terminal
	PetAlocTransf	i,t,r,m,s	Volume de petróleo alocado transferido de terminal
	DerImpTransf	j,o,t,m,s	Volume de derivado importado transferido para terminal
	DerExpTransf	j,t,o,m,s	Volume de derivado exportado transferido de terminal
DerTermRefTransf	j,t,r,m,s	Volume de derivado transferido de terminal para refinaria	
DerRefTermTransf	j,r,t,m,s	Volume de derivado transferido de refinaria para terminal	
DerVendaTransf	j,r,n,m,s	Volume de derivado transferido de refinaria para mercado	

A função objetivo busca maximizar o lucro das operações da cadeia, sendo composta de diversas parcelas de receita e custo – como apresentada simplificada na equação 24 – onde somente o primeiro termo se refere ao primeiro estágio:

$$\begin{aligned} \max z = & \\ & \text{LucroComPet} + \sum_s \{ (\text{AjusteCotaçãoComPet}(s) + \text{AjusteVolComPet}(s) + \text{LucroComDer}(s) + \\ & \text{ReceitaVendaDer}(s) - \text{CustoEstoque}(s) - \text{CustoProcesso}(s) - \text{CustoTranspPet}(s) - \\ & \text{CustoTranspDer}(s)) * \text{CenProb}(s) \} \end{aligned} \quad 24$$

As restrições de primeiro estágio são apresentadas pelas equações 25 a 28, as quais representam o balanço de petróleo no primeiro estágio, quando as decisões de importação e exportação de petróleo devem ser tomadas:

$$\begin{aligned} \text{PetImp}(i, m) + \text{ProdNac}(i, m) - \text{PetExp}(i, m) - \text{PetProc}(i, m) &= 0 & 25 \\ \text{PetImp}(i, m), \text{PetExp}(i, m), \text{PetProc}(i, m) &\geq 0 & 26 \\ \text{PetImp}(i, m) &\leq \text{PetImpMax}(i, m) & 27 \\ \text{PetExp}(i, m) &\leq \text{PetExpMax}(i, m) & 28 \end{aligned}$$

As restrições de segundo são dadas pelas equações 29 a 60.

$$\begin{aligned} \text{PetNacProd}(i, m, s) - \text{ProdNac}(i, m) &= \text{PetProdExc}(i, m, s) - \text{PetProdDef}(i, m, s) & 29 \\ \text{PetNacProd}(i, m, s) &= \text{ProdNac}(i, m) * (1 + \text{ProdDesc}(i, m, s)) & 30 \\ \text{PetProdExc}(i, m, s), \text{PetProdDef}(i, m, s) &\geq 0 & 31 \\ \text{PetExpCanc}(i, m, s) + \text{PetProcCanc}(i, m, s) &\geq \text{PetProdDef}(i, m) & 32 \\ \text{PetExpSpot}(i, m, s) &\leq \text{PetProdExc}(i, m, s) & 33 \\ \text{PetImpSpot}(i, m, s) &\leq \text{PetImpSpotMax}(i, m) & 34 \\ \text{PetExpCanc}(i, m, s), \text{PetProcCanc}(i, m, s), \text{PetExpSpot}(i, m, s), \text{PetImpSpot}(i, m, s) &\geq 0 & 35 \\ \sum_r \text{PetAloc}(i, r, m, s) &\leq \\ \text{PetProc}(i, m) - \text{PetProcCanc}(i, m, s) - \text{PetExpSpot}(i, m, s) + \text{PetImpSpot}(i, m, s) + \\ \text{PetExpCanc}(i, m, s) & & 36 \\ \sum_{p,t} \text{PetNacProdTransf}(i, p, t, m, s) + \sum_{o,t} \text{PetImpTransf}(i, o, t, m, s) &= \\ \sum_{t,o} \text{PetExpTransf}(i, t, o, m, s) + \sum_{t,r} \text{PetAlocTransf}(i, t, r, m, s) & & 37 \\ \sum_p \text{PetNacProdTransf}(i, p, t, m, s) + \sum_o \text{PetImpTransf}(i, o, t, m, s) &= \\ \sum_o \text{PetExpTransf}(i, t, o, m, s) + \sum_t \text{PetAlocTransf}(i, t, r, m, s) & & 38 \\ \sum_{p,t} \text{PetNacProdTransf}(i, p, t, m, s) &\leq \text{PetNacProd}(i, m, s) & 39 \\ \sum_{o,t} \text{PetImpTransf}(i, o, t, m, s) &\leq \text{PetImp}(i, m) + \text{PetImpSpot}(i, m, s) & 40 \\ \sum_{t,o} \text{PetExpTransf}(i, t, o, m, s) &\leq \text{PetExp}(i, m) + \text{PetExpSpot}(i, m, s) - \text{PetExpCanc}(i, m, s) & 41 \\ \text{PetAloc}(i, r, m, s) &\leq \sum_t \text{PetAlocTransf}(i, t, r, m, s) & 42 \\ \text{DerImp}(j, m, s) + \text{DerProdTotal}(j, m, s) - \text{DerExp}(j, m, s) - \text{DemNacReal}(j, m, s) &= 0 & 43 \\ \text{DerImp}(j, m, s) &\leq \text{DerImpMax}(j, m) & 44 \\ \text{DerExp}(j, m, s) &\leq \text{DerExpMax}(j, m) & 45 \\ \text{DerProdTotal}(j, m, s) &= \sum_r \text{DerProd}(j, r, m, s) & 46 \\ \text{DemNacReal}(j, m, s) &= \text{DemNac}(j, m) * (1 + \text{DemDesc}(s)) & 47 \\ \sum_{r,n} \text{DerVendaTransf}(j, r, n, m, s) &\geq \text{DemNacReal}(j, m, s) & 48 \\ \text{DerImp}(i, m, s) &= \sum_{o,t} \text{DerImpTransf}(j, o, t, m, s) & 49 \\ \text{DerExp}(i, m, s) &= \sum_{o,t} \text{DerExpTransf}(j, t, o, m, s) & 50 \\ \sum_o \text{DerImpTransf}(j, o, t, m, s) + \sum_r \text{DerRefTermTransf}(j, r, t, m, s) &= \\ \sum_o \text{DerExpTransf}(j, t, o, m, s) + \sum_r \text{DerTermRefTransf}(j, t, r, m, s) & & 51 \\ \sum_t (\text{DerTermRefTransf}(j, t, r, m, s) - \text{DerRefTermTransf}(j, r, t, m, s)) - \\ \sum_n \text{DerVendaTransf}(j, r, n, m, s) + \text{DerProd}(j, r, m, s) &= 0 & 52 \\ \text{DerProd}(j, r, m, s) &= \\ \sum_l \text{DegIntermDer}(k, j, r, m, s) + \text{DerEstoq}(j, r, m - 1, s) - \text{DerEstoq}(j, r, m, s) & & 53 \\ \sum_i \text{PetAloc}(i, r, m, s) * \text{PetIntermRend}(i, k) + \\ \sum_{l,u} \text{CargaAloc}(l, u, r, m, s) * \text{CargaIntermRend}(l, k, u) - \\ \sum_l \text{DegIntermCarga}(k, l, r, m, s) - \sum_l \text{DegIntermDer}(k, j, r, m, s) &= 0 & 54 \\ \sum_k \text{DegIntermCarga}(k, l, r, m, s) &= \sum_u \text{CargaAloc}(l, u, r, m, s) & 55 \\ (\sum_k \text{DegIntermDer}(k, j, r, m, s)) * \text{DerQualMin}(j, q) &\leq \sum_k (\text{DegIntermDer}(k, j, r, m, s) * \\ \text{InterQual}(k, q)) &\leq (\sum_k \text{DegIntermDer}(k, j, r, m, s)) * \text{DerQualMax}(j, q) & 56 \end{aligned}$$

$$\begin{aligned} \sum_i (DegIntermCarga(k, l, r, m, s) * InterQual(k, q)) &\leq (\sum_k DegIntermCarga(k, l, r, m, s)) * & 57 \\ UnidQualMax(j, q) & & \\ \sum_l CargaAloc(l, u, r, m, s) &\leq UnidCapMax(u, r) & 58 \\ \sum_i PetAloc(i, r, m, s) &\leq UnidCapMax('Destilação', r) & 59 \\ DerEstoq(j, r, m, s) &\leq DerEstoqMax(j, r) & 60 \end{aligned}$$

As equações 29 a 35, representam as correções que podem ser feitas nas decisões de importação (mercado Spot), exportação (cancelamento e mercado Spot) e alocação (cancelamento) frente ao conhecimento da produção de cada cenário e o excesso ou déficit de produção de petróleo em relação ao previsto. A equação 36 representa o balanço de petróleo de segundo estágio, considerando as decisões tomadas no primeiro estágio e nas equações de 29 a 35. As equações 37 e 38 representam, respectivamente, os balanços de petróleo em cada terminal e para todos os terminais, neste trabalho considera-se somente um terminal. As equações de 39 a 42 relacionam, nesta sequência, cada variável de fluxo de petróleo aos volumes de produção, importação exportação e alocação.

As equações 43 a 53 se referem ao balanço de derivados. A equação 43 apresenta o balanço global de derivado em cada cenário, enquanto as equações 44 e 45 limitam a importação e exportação de derivado, respectivamente. As equações 46 e 47 tratam da produção total de derivados e ajuste da demanda em cada cenário, respectivamente. As equações 48 a 50 vinculam, nesta sequência, os fluxos de derivado aos volumes de demanda real, importação e exportação. As equações 51 e 52 representam o balanço de derivado em cada terminal e refinaria, respectivamente. Finalmente, a equação 53 define a produção líquida de derivado por refinaria.

Por fim, as equações 54 a 60 representam o funcionamento da refinaria e as transformações do tipo processamento e degradação que ocorrem em todo mês e cenário com os tipos de produto: petróleo, derivado, intermediário e produto carga, e possuem as respectivas funções: (54) balanço de intermediário por refinaria; (55) balanço de produto carga por refinaria; (56) limites de qualidade de derivado produzido por degradação a partir de intermediários; (57) limite de qualidade de produto carga produzido por degradação a partir de intermediários; (58) e (59) limite de capacidade de unidade de processo; e (60) limite de capacidade de estoque.

A instância trabalhada considera horizonte de 2 meses, 13 petróleos (Tabela 5, cada petróleo possui um perfil de rendimentos e qualidades nos diversos cortes de destilação considerados no modelo), 1 terminal, 1 local de produção de petróleo, 1 mercado consumidor, 4 refinarias (as quais representam as refinarias presentes nas regiões Norte-Nordeste, Rio de Janeiro-Minas Gerais, São Paulo e Sul), 5 tipos de unidades de processo (destilação, craqueamento, coque, HDT Diesel e HDT Nafta), 8 derivados comercializáveis e 49 produtos intermediários. O volume das operações é dado em mil m³/mês e custos e receitas são dados em uma unidade fictícia: u.m..

Tabela 5: Petróleo, tipo e origem (N- nacional, I- importado).

Petróleo	Tipo	Petróleo	Tipo	Petróleo	Tipo
A1 (N)	Condensado	C2 (I)	Leve	E2 (I)	Médio
A2 (I)	Condensado	D1 (N)	Rat-Craq	F1 (N)	Pesado
B1 (N)	Extra-Leve	D2 (I)	Rat-Craq	G1 (N)	Extra-Pesado
B2 (I)	Extra-Leve	E1 (N)	Médio	G2 (I)	Extra-Pesado
C1 (N)	Leve				

3.2 Parâmetros Incertos

Os parâmetros incertos são: produção nacional, cotação internacional e demanda de mercado e suas possíveis realizações foram baseadas em erros de planejamento (diferença relativa entre o valor estimado e o valor real) de um horizonte de 54 meses, o que uma combinação de 54³ ~ 160 mil possíveis realizações. As figuras 1 a 3 apresentam o histograma de frequência e a probabilidade acumulada dos parâmetros incertos. A Tabela 6 apresenta os quatro primeiros momentos das distribuições construídas (média, variância, kurtosis e skewness) e a Tabela 7 apresenta a matriz de correlação entre os parâmetros.




Figura 1: Produção Nacional

Figura 2: Demanda de derivados

Figura 3: Cotação de Petróleo

Tabela 6: Valor dos quatro primeiros momentos do erro de planejamento dos parâmetros incertos

Momento	Produção	Demanda	Cotação
Media	-0.0145	-0.0036	0.0419
variância	0.0010	0.0013	0.0102
kurtosis	-0.5065	-0.5058	0.1721
skewness	-0.2512	0.2283	0.1890

Tabela 7: Matriz de correlação dos parâmetros incertos

	Produção	Demanda	Cotação
Produção	1		
Demanda	-0.13355	1	
Cotação	-0.06793	-0.10964	1

3.3 Planejamento experimental

Os parâmetros incertos do modelo são: produção nacional, cotação internacional e demanda de mercado e suas possíveis realizações foram baseadas em erros de planejamento (diferença relativa entre o valor estimado e o valor real) de um horizonte de 54 meses (4 anos e meio). Isso gera uma combinação de $54^3 \sim 160$ mil possíveis realizações.

Para geração dos limitantes inferior e superior via método SAA, considerou-se $N: 5, 10, 20$ e 30 . Por ser tratar de um problema de maximização, os limitantes gerados possuem sentido inverso do apresentado na seção 2.2. O limitante superior foi, para cada valor de N , gerado a partir de 100 amostras independentes e foram escolhidas aleatoriamente 10 soluções das 100 geradas para obtenção do limitante inferior. A solução entre todas as testadas que gerasse o menor gap de otimalidade foi escolhida como referência para os próximos passos.

Para cada método de geração de cenários e parâmetro testado, foram geradas 5 replicações na geração das árvores de cenários. No caso do método por correspondência, utilizou-se tamanho de árvores de cenários iguais a 5, 10, 20, 30, 50 e 100. Para a geração de cenários por agregação temporal de Cadeia de Markov, escolheu-se um grupo L1 que gerasse trajetórias médias de 10 elementos e os seguintes erros do tamanho da trajetória média (parâmetro do método) para geração de cenários: 2, 1, 0,5 e 0,2.

Para determinação da qualidade da geração de cenários, utilizou-se o valor da função objetivo, das variáveis de primeiro estágio e do EVPI em comparação com a solução de referência do SAA. A comparação da função objetivo e do EVPI foram feitas por subtração e a comparação das variáveis de primeiro estágio, pela soma das diferenças absolutas, conforme equação 61, onde $PetImp_A(i, n)$ e $PetImp_B(i, n)$ são os volumes importação de petróleo i no mês n de referência e obtido pela solução das árvores de cenários dos métodos de geração, respectivamente; e $PetExp_A(i, n)$ e $PetExp_B(i, n)$ se referem ao petróleos exportados.

$$\Delta PET = \sum_{i,n} \sqrt{(PetImp_A(i, n) - PetImp_B(i, n))^2} + \sum_{i,n} \sqrt{(PetExp_A(i, n) - PetExp_B(i, n))^2} \quad 61$$

Finalmente, agregou-se à função objetivo um termo relacionado ao risco para avaliar o impacto de diferentes níveis de aversão ao risco (β) e de nível de confiança (α). Os valores utilizados de aversão foram de 10, 50 e 90% e os valores de nível de confiança foram de 90, 95 e 99%.

IV- Resultados

A Figura 4 apresenta como varia o lucro de cada cenário em função da variação de cada parâmetro incerto. A Tabela 8 apresenta os limitantes superior e inferior do método SAA para cada valor de N. O melhor gap de otimalidade foi gerado com N=20 e a Tabela 9 apresenta a indicação de importação e exportação desta solução. A Tabela 10 apresenta a função objetivo (F.O.), as medidas de ganho de abordagem estocástica (EVPI e VSS) e as medidas de qualidade de geração de cenários para os métodos aplicados.

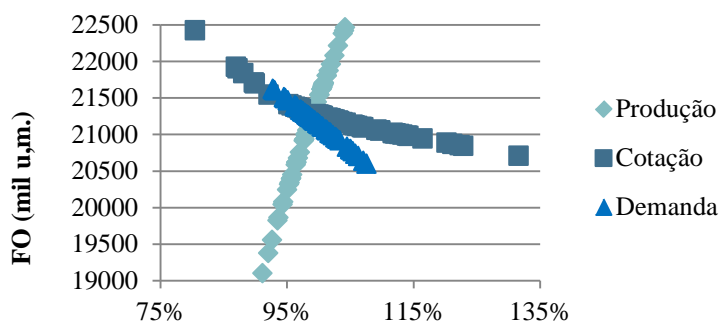


Figura 4: Variação do lucro de cada cenário em função da produção própria, cotação e demanda.

Tabela 8: Limitante Superior, melhor limitante inferior e gap de otimalidade do método SAA

N	Limitante Superior	Melhor Limitante Inferior	Gap Otimalidade
5	21026	20178	848
10	21001	20124	877
20	21185	20340	845
30	21027	20101	927

Tabela 9: valor das variáveis de primeiro estágio da solução referência obtida pelo método SAA

Petróleo	A1	A2	B1	B2	C1	C2	D1	D2	E1	E2	F1	G1	G2
Mês 1	-15090	0	-888	0	0	0	0	17788	-39698	34156	0	-1623	0
Mês 2	0	0	-3126	0	0	0	0	17106	-16397	0	0	-2857	0

Tabela 10: valor das variáveis de primeiro estágio da solução referência obtida pelo método SAA

Método	Parâmetro	Valor	F.O. (mil u.m.)	Delta F.O. (mil u.m.)	EVPI (mil u.m.)	Delta EVPI (mil u.m.)	VSS (mil u.m.)	Delta primeiro estágio – ΔPET (mil m³)
Correspondência de momento	Tamanho da árvore de cenários	5	21074	-111	129	65	59	6153
		10	21047	-138	172	23	144	2742
		20	21069	-117	128	67	137	5358
		30	21115	-70	77	118	79	6124
		50	21101	-84	82	112	86	6126
		100	21159	-27	23	171	57	5757
Agregação temporal	Desvio de tamanho médio de trajetória	2	21091	-94	325	-130	55	4727
		1	21019	-166	226	-31	73	3238
		0.5	21009	-176	222	-27	74	1382
		0.2	21067	-118	246	-52	65	2733

Baseado nos critérios de qualidade de geração de cenários, os parâmetros de cada tipo de geração de cenários escolhidos foram: tamanho da árvore igual a 100, para o caso de geração por correspondência de momento e erro da trajetória média de no máximo 0,2, para o método de agregação temporal. A Tabela 11 e 12 apresenta o valor médio de receita e custo e suas parcelas para cada método de geração de cenários, respectivamente, e a Tabela 13 apresenta as decisões de segundo estágio referentes ao déficit de petróleo gerado pela realização de produção menor que a esperada.

Tabela 11: Receita média e parcelas de venda de derivados, exportação de petróleo e derivados.

Método	Receita (mil u.m.)	Venda de Derivados	Exportação de Petróleo	Exportação de Derivados
Corresp. de Momento	35620.8	70%	23%	7%
Agregação Temporal	36421.4	70%	22%	8%

Tabela 12: Custo médio e parcelas de imp. de petróleo e derivados, custo de refino e custo logístico.

Método	Custo Total (mil u.m.)	Importação de Petróleo	Importação de Derivados	Custo de Refino	Custo Logístico
Corresp. de Momento	14509.4	61%	29%	6%	4%
Agregação Temporal	15455.2	57%	33%	6%	4%

Tabela 13: Déficit médio de petróleo por mês, frequência nos cenários e parcela ajustada com cancelamento de alocação

Método	Mês	Parcela	A2	B2	C2	D2	E2	F1	G2
Corresp. de Momento	1	Deficit (mil m ³)	6	29	50	251	500	203	603
		% Cenários	97%	97%	97%	97%	97%	97%	97%
		% Ajuste Alocação	100%	100%	100%	94%	95%	100%	100%
	2	Deficit (mil m ³)	6	29	50	251	500	203	603
		% Cenários	97%	97%	97%	97%	97%	97%	97%
		% Ajuste Alocação	100%	100%	100%	95%	100%	100%	100%
Agregação Temporal	1	Deficit (mil m ³)	18	81	139	699	1396	566	1683
		% Cenários	40%	40%	40%	40%	40%	40%	40%
		% Ajuste Alocação	100%	100%	100%	83%	96%	100%	100%
	2	Deficit (mil m ³)	18	81	139	699	1396	566	1683
		% Cenários	40%	40%	40%	40%	40%	40%	40%
		% Ajuste Alocação	100%	100%	100%	97%	100%	100%	100%

Como se pode observar pelas Tabelas 11 e 12, os valores de receita e custo são muito parecidos nas soluções geradas por ambos os métodos de geração de cenários, porém, no método de Agregação Temporal há menor participação da parcela de importação de petróleo no custo total e aumento da parcela de importação de derivados. Já em relação ao ajuste em relação à incerteza de produção de petróleo, verifica-se pela Tabela 13 que no método de correspondência de momentos, é mais frequente a ocorrência de déficit, porém com volumes geralmente menores. A figura 5 apresenta o impacto da consideração de risco (nível de aversão β e nível de confiança α) no valor da função objetivo médio das replicações de cada método geração de cenários.

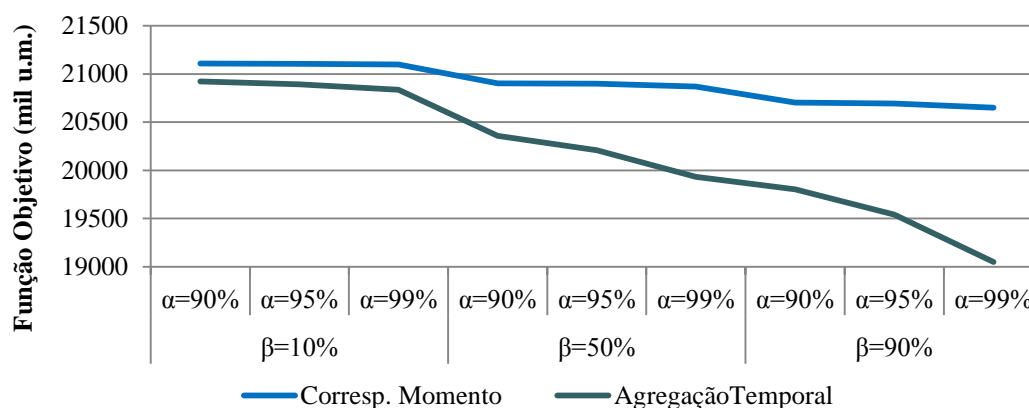


Figura 5: Impacto de medida de risco (nível de aversão β e nível de confiança α) no valor da função

Verifica-se na Figura 2 que o impacto da medida de risco é maior nas soluções geradas com cenários do método de Agregação Temporal, o que é explicado pelo fato de este método não ser de aproximação, mais sim de agregação e manter características importantes do conjunto inicial. Em contraponto, observa-se pouca influência da medida de risco nos resultados gerados com árvores do método de correspondência de momento. Tal qualidade pode ser indesejada, visto que o tomador de decisão pode ter uma avaliação neutra em relação ao risco.

V- Conclusões

O uso de técnicas destinadas à solução de problemas estocásticos mostrou-se bastante útil para a o problema de grande porte estudado: planejamento de uma cadeia de suprimentos de uma empresa de petróleo integrada. É evidente o impacto dos fatores incertos considerados neste trabalho no lucro da cadeia de suprimentos de uma empresa de petróleo integrada, como apresentado na Figura 4. Ficou claro o ganho da geração de limitantes da função objetivo pelo método SAA e que, mesmo com pequenos tamanhos de amostra, obtêm-se limitantes bem estabelecidos. Em relação aos métodos de geração de cenários, verificou-se que as soluções obtidas pelo método de agregação temporal possuem menor custo de importação de petróleo e maior de derivados e que possuem melhor percepção do impacto do aumento da aversão ao risco. Verificou-se que, no caso de realização de produção de petróleo menor que prevista ou déficit, a indicação de cancelamento de alocação em refinarias da cadeia é bastante robusta.

VI- Referências Bibliográficas

- ARTZNER, P., DELBAEN, F., EBER, J., HEALTH, D., Coherent Measures of Risk, *Math. Finance*, 1999, Volume 9, pag. 203-228.
- BIRGE, J., LOUVEAUX, F., *Introduction to Stochastic Programming*, 2011, Editora Springer, Nova York, EUA.
- CAO, X., REN, Z., BHATNAGAR, S., FU, M., MARCUS, S., A Time Aggregation Approach to Markov Decision Processes, *Automatica*, 2002, volume 38, Edição 6, pag. 929-943.
- CARNEIRO, M. C., RIBAS, G. P., HAMACHER, S., Risk Management in Oil Supply Chain: a CVAR Approach, *I&EC Research*, 2010, volume 49, pag. 3286-3294.
- HIGLE, J. L., Stochastic Programming: Optimization when Uncertainty Matters, *Operational Research Tutorials*, Chapter 1, INFORMS, 2005.
- HOYLAND, K., WALLACE, S.W., Generating Scenario Trees for Multistage Decision Problems, 2001, *Management Science*, Volume 47, pag. 295-307.
- KAUT, M., and WALLACE, S., Evaluation of scenario-generation methods for stochastic programming, 2003, Stochastic Programming E-Print Series, <http://www.speps.org>
- KHOR, C. S., ELKAMEL, A., PONNAMBALAM, K., DOUGLAS, P. L., Two-Stages Programming with Fixed Recourse via Scenario Planning with Economic and Operational Risk Management for Petroleum Refinery Planning Under Uncertainty, *Chem. Eng. Process.*, 2008, Volume 47, pag. 1744-1764.
- KHOR, C. S., NGUYEN, T. H. N., Stochastic Programming with Tractable Mean-Risk Objectives for Refinery Planning Under Uncertainty, 2009, *10th Intern. Symp. on Process System Engineering*, PSE2009, Computer Aided Chemical Engineering, Volume 27.
- LEIRAS, A., RIBAS, G., HAMACHER, S., Tactical and Operational Planning of Multirefinery Networks under Uncertainty, *I&EC Research*, 2013, Volume 52, pag. 8507-8517.
- OLIVEIRA, F., HAMACHER, S., Operation of the Petroleum Product Supply Chain under Uncertainty: a Case Study in Northern Brazil, *I&EC Research*, 2012, Volume 51, 4279-4287.
- OLIVEIRA, F., GUPTA, V., HAMACHER, S., GROSSMANN, I. E., A Lagrangean Decomposition Approach for Oil Supply Chain Investment Planning under Uncertainty with Risk Considerations, *Comput. Chem. Eng.*, 2013, Volume 50, pag. 184-195.
- PAPAGEORGIU, L. G., Supply Chain Optimization for the Process Industries: Advances and Opportunities, *Comput. Chem. Eng.*, 2009, Volume 33, pag. 1931-1938.
- RIBAS, G., LEIRAS, A., HAMACHER, S., Operacional Planning of Oil Refineries Under Uncertainty Special Issue: Applied Stochastic Optimization, *IMA Journal of Management Math.*, 2012, Volume 23, pag. 397-412.
- ROCKAFELLAR, R., URYASEV, S., Optimization of Conditional Value-at-Risk, *Journal of Risk*, 2000, Volume 2, pag. 21-42.
- SHAPIRO, A., HOMEM-DE-MELLO, T., A Simulation-Based Approach to Two-Stage Stochastic Programming with Recourse, *Math. Programming*, 1998, Volume 81, pag. 301-325.
- ZAMARRIPA, M., SILVENTE, J., ESPUÑA, A., Supply Chain Planning under Uncertainty Using Genetic Algorithms, *22nd European Symp. on Computer Aided Process Eng.*, 2012.