Redes Bayesianas: uma ferramenta na previsão de preço de *commodity*

Sandra da Cruz Garcia do Espirito Santo Aguiar
Doutoranda do Programa de Doutorado Interinstitucional em Administração – DINTER UNIR/UFRGS
sandrinhamagal@hotmail.com

Denis Borestein
Doutor. Docente do Programa de Doutorado Interinstitucional em Administração – DINTER UNIR/UFRGS
denisb@ea.ufrgs.br

Resumo
Trata-se de um ensaio teórico, cujo objetivo é descrever os fatores que afetam direta e indiretamente os preços de uma *commodity*, no âmbito do mercado internacional, notadamente para a *commodity* do butadieno, um dos derivados do petróleo. A partir do método de pesquisa bibliográfica, demonstra-se que um modelo de precificação baseado em Redes Bayesianas tem a capacidade de representar os fenômeno aleatórios que caracterizam a formação de preços de uma *commodity*, realizando predições adequadas. As teorias que abordam os modelos tradicionais de precificação, baseados em probabilidade e estatística apontam para a obtenção de resultados insatisfatórios, incapazes de agregar de forma adequada e com a dinâmica necessárias os eventos do mundo real. A proposição pode contribuir com as abordagens teóricas consideram o fato de que investir em pesquisas que utilizem de Inteligência Artificial como métodos preditivos, como a utilização de Redes Bayesianas apresenta a vantagem de compreender a relação causa e efeito através da análise de cenários.

Palavras-chave: Previsão. *Commodity*. Inteligência Artificial. Redes Bayesianas.

1 Introdução

No mercado internacional ocorrem diariamente transações entre os inúmeros agentes que negociam diversos tipos de *commodities* em diferentes regiões do planeta. Com o petróleo e seus derivados, não é diferente. Os preços são determinados pelo mercado mundial e não pela oferta doméstica. Assim, as cotações do mercado *spot* podem variar de acordo com a qualidade, quantidade e local de entrega, sendo praticamente impossível calcular um único preço que seja representativo do preço *spot*. Uma das estratégias do mercado de ações para reduzir o impacto destas variações é o uso de técnicas de previsão que minimizem os seus efeitos através de análise dos fatores causadores. Embora não haja um padrão único e universal para a formulação de previsões, faz-se necessário à criação de um esboço para que se possam identificar os agentes

responsáveis pela volatilidade e flutuações dos preços no mercado. Isto se dá a partir da construção correta de modelos estatísticos.

A previsão é um dos objetivos das análises quantitativas em economia, e em conjunto com a teoria econômica, utiliza-se de diversas técnicas de previsão para auxiliar na tomada de decisões por parte dos agentes envolvidos em atividades que necessitam de planejamento, avaliação de políticas e redução da incerteza. As previsões econômicas, por sua vez, objetiva reduzir as incertezas, sobretudo num mercado tão volátil como é o das *commodities.* Assim, visando minimizar o risco, dado aos elevados investimentos, e buscando nestas técnicas os instrumentos necessários para a tomada de decisão.

A partir deste enfoque, este ensaio teórico visa discutir como as técnicas de inteligência artificial, notadamente as Redes Bayesianas (BN), podem ser usadas como uma ferramenta de apoio à decisão, para predição dos valores da *commodity*, reduzindo riscos de investimentos da ordem de bilhões de dólares,e a partir daí dar suporte para a gestão de riscos no mercado, de forma a permitir que ações preventivas sejam tomadas antes que os eventos ocorram.

O petróleo e seus derivados, como símbolo da economia capitalista, exercem um papel relevante no desenvolvimento da economia mundial e brasileira, por conta de sua influência na matriz energética mundial, na geração de emprego e renda, contribuindo de forma dinâmica para os processos de desenvolvimento econômico e social dos países (BARRIGA, 1995). Ainda que hajam diversas pesquisas sendo desenvolvidas no intuito da predição dos preços das *commodities*, constata-se que os modelos propostos fixam uma série de limitações (SOBREIRO *et al*, 2008) que devem ser observadas: primeiramente, ressalta-se que grande parte dos estudos realizados para prever os preços de *commodities* se mostrou ineficiente e os resultados apresentados não são definitivos. Neste sentido há um grande campo de estudo acerca da comparação do desempenho preditivo de modelos de previsão. Em seguida, percebe -se que não há um modelo único validado ou uma abordagem ou teoria que seja capaz de prever o preço das *commodities*. Além disto, segundo Demo (1995), cada pesquisa aborda apenas uma face que busca se aproximar da realidade, no que tange às variáveis que delimitem a amostra e à expectativa de relevância teórica que explique a observação empírica realizada.

Outro aspecto, é que todas as modelagens encontradas para prever o preço das *commodities* não consideraram simultaneamente fatores fundamentais que influenciam no comportamento do preço de uma *commodity*, tais como: oferta e demanda, fatores macroeconômicos e de estruturas relacionadas; pelo fato de muitos destes fatores apresentarem apenas pouca disponibilidade de dados. Por fim, Matias *el al* (2005) constata a existência de um *gap* de pesquisa, dirigida para a análise e compreensão da tendência nos movimentos dos preços das *commodities*, no sentido de antecipar o seu movimento e não apenas predizer o seu valor, o qual não é validado empiricamente.

Chauvet *et al* (2000) destaca que em recentes pesquisas em torno da modelagem de preços de *commodities*, há uma alternância entre estudos que, ora focam-se no risco, ora focam-se na volatilidade do comportamento dos seus preços. As pesquisas são em geral realizadas a partir da utilização de séries de dados de alta frequência. São fracionadas em dias, semanas, meses, horas, e analisam apenas as variações sazonais dos preços das *commodities*.

A partir deste cenário, observa-se a necessidade de explorar quais são as variáveis que influenciam nos preços das *commodities*, com o intuito de monitorar as flutuações dos preços, de modo a fazer previsões, considerando a análise de dados históricos e tendências, úteis para o planejamento estratégico do preço das *commodities*.

2 Método

Nesta pesquisa bibliográfica são utilizadas varias informações sobre previsão de preços e modelos experimentais. Quanto ao objetivo é exploratória/descritiva. Exploratória porque os dados buscam a familiarização com o fenômeno que está sendo investigado, de modo que a pesquisa subsequente possa ser concebida com uma maior compreensão e precisão. É descritiva no sentido de que tem por objetivo descrever as características de, de um fenômeno. Esse tipo de pesquisa estabelece relação entre as variáveis no objeto de estudo analisado.

As variáveis relacionadas à classificação, medida e/ou quantidade que podem se alterar mediante o processo realizado. Dados estes relacionados com as variáveis de previsão de preço das *commodities*. Qualitativa quanto à forma de abordagem, dado que o texto é descritivo, as informações apresentadas não são quantificadas e os dados obtidos são analisados indutivamente.

3 Referencial Teórico
3.1 Risco X Volatilidade

O risco é inerente a qualquer economia, onde os cenários são dinâmicos e as circunstâncias se alternam entre equilíbrio e desequilíbrios temporários. Essas variações são característica da economia onde ocorrem variações dos preços dos bens e dos ativos de forma inesperada, tornando necessários modelos associados a instrumentos financeiros que permitam um melhor gerenciamento deste risco.

O risco deriva da incerteza. Incerteza origina-se de alguma deficiência da informação. A informação pode estar incompleta, ser vaga, imprecisa ou contraditória. Para lidar com o problema da incerteza e incompletude nos modelos do mundo real, precisa-se de uma linguagem apropriada e uma representação adequada (formalmente e computacionalmente) de um modelo. A linguagem mais apropriada para lidar com a incerteza é a linguagem da probabilidade, fazendo assim, uso do Raciocínio Probabilístico. Através deste pode-se atribuir um grau de crença às relações do domínio real, reduzindo a incerteza.

Na esfera empresarial, prever os preços futuros das *commodities* pode significar a diferença, entre o sucesso e o fracasso, entre o êxito e a ruína de qualquer investidor. Dispor, portanto, de uma ferramenta capaz de identificar o melhor período para se investir em *commodities*, ou mesmo para nortear futuros investimentos que ofereçam um grau razoável de precisão, de modo a não gerar estoque desnecessário, pode representar um incremento significativo de conhecimento e consequente vantagem competitiva de um investidor frente aos demais.

Esta intensa volatilidade de preço é extremamente prejudicial para empresas e países dependentes de petróleo (objeto deste trabalho), tanto consumidores quanto produtores. Existem diversas formas pelas quais um agente pode tentar se proteger destas oscilações no preço. A mais comum é a utilização de instrumentos de *hedge*. A forma mais usual de se fazer um *hedge* é utilizando os mercados futuros, a partir de um "contrato a termo", no qual ambas as partes, comprador e negociador, se comprometem a, no período determinado em contrato, manter o preço da *commodity* sem as possíveis flutuações de mercado (HULL, 2008).

As abordagens, mais utilizadas para análise e gerenciamento dos riscos são compostas por técnicas estatísticas e de simulação. Em pesquisas mais recentes, os pesquisadores têm procurado associar técnicas como a Inteligência Artificial aliada à simulação, visando desenvolver novos

sistemas de apoio para a tomada de decisões em trabalhos que possuam fenômenos estocásticos, como é o caso das *commodities*.

O uso crescente de um ramo da ciência da computação que busca elaborar dispositivos que simulem a capacidade humana de raciocinar, perceber, tomar decisões e resolver problemas é a Inteligência Artificial (IA), que tenta compreender e construir entidades inteligentes. Russel *et. al*. (2004) e Guerrero *et. al.* (2002) afirmam que as técnicas de IA apresentam três características principais que as diferenciam de outros métodos: 1. **A busca**: que procura explorar as diversas possibilidades nas quais os próximos passos ainda não foram claramente definidos; 2. **O uso do conhecimento adquirido** que explora a estrutura e as relações exteriores, reduzindo o volume de alternativas a serem consideradas, conforme faz o cérebro humano e 3. **A abstração** que permite a generalização para os passos similares já percorridos.

Entre os métodos e técnicas provenientes da Inteligência Artificial estão as Redes Neurais e o Sistema de Especialistas, onde se inclui as Redes Bayesianas. Dentre as distintas aplicações da Inteligência Artificial encontram-se: administração de projetos de investimentos, análise do risco de investimentos em moeda estrangeira, análise de cartas do presidente aos acionistas, avaliação do risco de ações da Bolsa e de debêntures, previsão do comportamento dos preços de *commodities*, previsão de crises econômicas, previsão da cotação das ações na Bolsa, previsão de falência de associações de poupança e empréstimo, entre outras.

3.2 Caracterização de uma *Commodity*

Commodity é uma palavra que vem do inglês cujo significado expressa "um artigo em comércio". Uma mercadoria padronizada, de baixo valor agregado, produzida por diferentes produtores, e comercializada em nível mundial (WILLIAMSON, 2009). O Novo Dicionário de Economia define como sendo um tipo particular de mercadoria em estado bruto ou produto primário de importância comercial (SANDRONI, 1994). Mas, também é atribuída, segundo Pereira (2009) a insumos ou matérias-primas.

Pereira (2009) afirma que a nomenclatura *commodity* pode ser atribuída aos insumos ou matérias-primas. Contudo, em relação à sua tipologia, existem quatro principais tipos de *commodities*: (1) *commodities* agrícolas, tais como: açúcar, soja, suco de laranja congelado, trigo, algodão, borracha, café, etc.; (2) *commodities* minerais, tais como: minério de ferro, alumínio, ouro, níquel, prata, petróleo, gasolina, etanol etc.; (3) *commodities* financeiras, tais como: moedas negociadas em vários mercados, títulos públicos de governos federais, etc. e (4) *commodities* ambientais, tais como os créditos de carbono (RIBEIRO; GODINHO, 2009). Há ainda considerações a respeito de outras categorias de *Commodities* como os Recursos Energéticos e as *commodities* Químicas, que é objeto deste estudo.

Quanto às transações, as *commodities* apresentam as de mercado *spot* e de mercado futuro. Mercado de *spot*, é definido por Azevedo (1997), é aquele em que as transações se resolvem em um único instante de tempo. Já o mercado futuro, as transações são referenciadas em dois ou mais instantes de tempo. O autor propõe que os contratos futuros são aqueles em que as transações podem ocorrer no futuro, assim, há a realização de um contrato entre comprador/vendedor, com a especificação da mercadoria, data de entrega, local, meio de transporte, forma de pagamento, entre outras questões que as partes queiram abordar.

A compra/venda futura não é uma obrigação das partes. Há a volatilização que se dá por conta da flutuação dos preços dos produtos. Assim, Santos (2005) reconhece que de forma isolada, o mercado spot não aparenta ser a melhor proposta quando é necessária a estabilidade dos preços e

fornecimento, o que é refutado pelo mercado futuro. Autores como Taylor (1986) sugerem a possibilidade de ocorrência de autocorrelação da volatilidade e heterocedasticidade da maioria das séries financeiras.

O primeiro pode ser chamado de tradicional, onde a fixação do preço do ativo coincide com o momento de sua transação e o pagamento pelo bem adquirido é coincidente com sua entrega. Já o mercado a termo é a negociação realizada com base na compra ou venda de um ativo em uma data futura, por preço previamente estabelecido.

O contrato futuro é padronizado e negociado em bolsa com ajustes diários. Um contrato futuro pode ser genericamente descrito como um acordo realizado em uma data inicial entre as partes para trocar, em uma data futura, uma dada quantidade de uma *commodity* por uma determinada quantia de uma moeda. Além de assegurar preços para produtores, é ser um facilitador para a negociação de *commodities* como instrumentos financeiros. Este mercado pode ser ampliado para outros tipos de investidores que desejam tomar posições sobre ele, como fundos de investimentos, tesourarias de *commodities* e qualquer outro tipo de atores *de* mercado.

Estas características tornam as *commodities* uma mercadoria de grande flutuação de preço em curto espaço de tempo. Neste cenário, a alta volatilidade de preços, os movimentos especulativos, sobretudo àqueles referentes à formação de estoques, pode apresentar-se como obstáculos a operações de grande transação, tornando-se motivo para inspiração desenvolver estratégias para antecipar-se às variações nos preços de produtos no mercado, uma vez que a incerteza não pode ser eliminada, pode ao menos tornar-se inconsequente ou reduzida.

Os maiores desafios em relação ao uso de previsão, como apoio à tomada de decisões, conforme Lindberg e Zackrisson (1991) são: a incerteza em relação ao futuro, que define o grau de precisão da previsão; a seleção do método a ser aplicado para a previsão; a qualidade e confiabilidade dos dados de entrada e a correta interpretação da previsão.

3.3 Butadieno e as variantes determinantes do preço

O butadieno é um gás incolor e aromatizado, utilizado na produção de vários tipos de polímeros e copolímeros, e intermediário na produção de várias substâncias químicas de uso industrial, sendo que mais de 75% da produção em produtos de borracha sintética (CETESB, 2012).

Por ser uma das principais *commodities* petroquímicas, e pelas recentes descobertas de seu uso como substitutos imediatos da madeira e aços, o seu crescimento no mercado internacional está em expansão. As novas tecnologias, utilizadas para desenvolverem plásticos e borrachas, apresentam um *boom*, cuja capacidade superou as atuais plantas produtoras, como é o caso da *commodity* em estudo. Uma das principais aplicações do butadieno é como elastômero ou borracha sintética. Nesta forma é consumida pela indústria e pneus, fabricação de mangueiras industriais, bens de consumo e perfis de carro (GOBBO, 2010).

Acredita-se, baseado em dados históricos, que, a *commodity* do butadieno, por ser um derivado do petróleo, sofra influência na variação do preço, que acompanhe a influência das mesmas variáveis da evolução dos preços internacionais do deste. É possível perceber através da Figura 1 – Gráfico da evolução da Variação dos preços do Petróleo e butadieno, que este último, é mais sensível às variações do mercado.

Figura 1 -Variação percentual do preço do Petróleo e Butadieno no período entre maio/2007 e maio/2009.

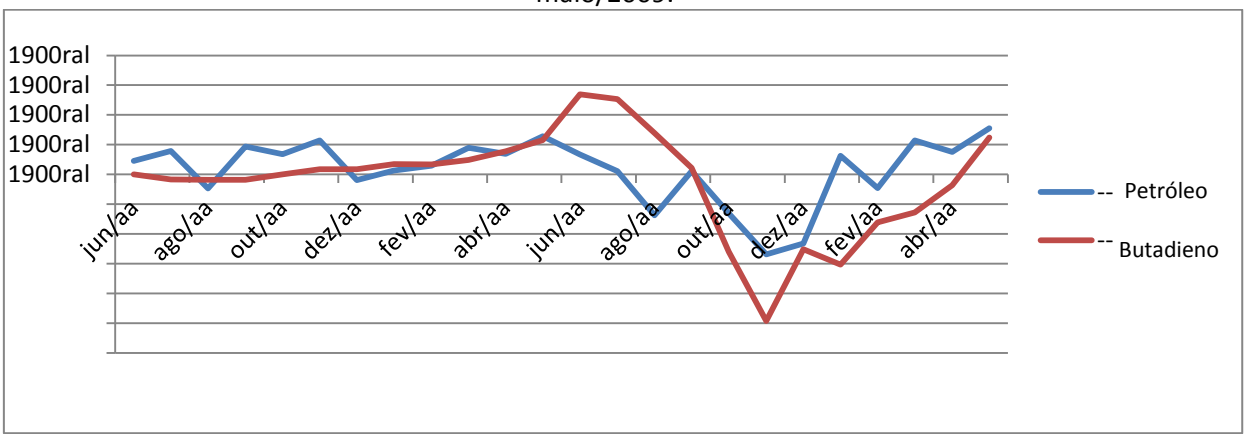

Fonte: Elaborado a partir dos dados da Index Mundi (2012)) e ICIS Princing (2010)

A volatilidade de trajetórias destas variáveis, nem sempre colaboram para uma projeção mais acertada, uma vez que o comportamento daquelas mais relevantes são as que mais sofrem variação. Diante destes fatos, torna-se mais interessante estudar a variação dos preços por cenários. Estes cenários também são estudados com uma faixa ampla entre os preços altos e baixos. Assim, foram pesquisadas na bibliografia publicada, algumas variáveis de modo que se caracterizassem como variáveis empiricamente confiáveis para a determinação do preço da *commodity,* com maior correlação, de modo a classifica-la como própria para a predição do preço. A variável **Cenário**, apresenta, quando há um quadro conflituoso em determinado país produtor do óleo, uma tendência de aumento de preço, ocorrendo o oposto numa situação não-conflituosa (GUIDI et al, 2006).

A **Política Endógena** de determinado país é responsável por parte do efeito da volatilidade do preço do petróleo (BERNANKE *et al*., 1997). Lescaroux e Mignon (2008) propõem que haja uma relação entre a variação do preço do petróleo e a **atividade econômica**, isto é, havendo menos insumos, haverá menos produção. Hamilton (2003) aponta outra variável e estabelece que há grande correlação entre o preço do petróleo e **variáveis econômicas** como o **PIB**, **taxa de câmbio** e **inflação**.

A variável de controle **crise financeira**, poderá ser incluída, dado que nos períodos em que ocorra este evento, esta variável binária, seria 1, e zero nos outros períodos, a exemplo de RANGEL (2012).

Outra importante variável no estudo de preços de *commodities* é o **custo de carregamento**, ou seja, é o custo de armazenagem somado ao custo de "depreciação primária", menos o retorno do ativo, sendo a depreciação primária a perda de valor do ativo com a mera passagem do tempo (KALDOR, 1939). Não obstante, visando representar as vantagens associadas à propriedade do bem físico, Working (1948) define a noção de custo de carregamento como um benefício atrelado ao proprietário da matéria física.

Ainda como variável determinante do preço de uma *commodity* observa-se diretamente relacionado a **demanda e a oferta do ativo**, e consequentemente os **volumes de estoque**. Quanto maior o estoque disponível para vendas, maior a oferta do produto e assim existe uma tendência de queda nos preços. Por outro lado, estoques baixos significam um maior risco de escassez da mercadoria e, portanto, os vendedores tendem a elevar seus preços para aumentar seus retornos e consequentemente reduzir a demanda pelo bem. Seguindo esta mesma lógica, os estoques também representam uma forma de reduzir variações nos preços das mercadorias.

3.4 Modelos de Previsão

A preocupação com a previsão de preços de *commodities* data de tempos remotos. Objetivando dar uma visão ampliada de como estes trabalhos se desenvolveram nos últimos anos, traçando alguns comentários e críticas, busca-se elaborar um panorama geral dos modelos desenvolvidos, de forma a apresentar as oportunidades de pesquisa para este trabalho.

Na década de 80, do século XX, observa-se o desenvolvimento do primeiro Modelo de Previsão, cujo cerne foi englobar em uma única classe de modelos, e baseado na ideia de uma série temporal não-estacionária. O método busca uma representação do processo estocástico gerador da série temporal a partir do Modelo Regressivo de Médias Móveis (ARMA). Em 1982, Engle desenvolveu um modelo paramétrico, cujo pressuposto era esquematizar um modelo para previsão da inflação, tendo propriedades úteis para a análise dos dados de finanças.

No entanto, o estudo considerado um marco em relação à modelagem de preços em commodities agrícolas, com base em processos estocásticos de preços, foi desenvolvido por Brennan e Schwartz (1985), que apresentaram um modelo de um único fator estocástico para prever o preço futuro da *commodity* cobre: o preço à vista. Os autores investigam o valor, o gerenciamento e otimizam o 'instante' de investir em um projeto de desenvolvimento de uma mina de cobre. Pouco depois Fama e French (1987) desenvolvem o primeiro dos modelos guiados por mais de um fator para preços de *commodities*. Baseados na Teoria do Estoque, os autores desenvolveram uma pesquisa com 21 *commodities*, de modo a identificar alguns elementos que influenciavam nos preços futuros. Primeiramente os autores determinaram uma equação linear na qual a dependente "preços futuros" era função dos preços a vista mais uma determinada taxa de juros e de variável *dummy*. Assim, identificaram se o produto possuía ou não sazonalidade. Posteriormente, os autores estabeleceram outra equação linear cuja variável dependente "preços de contratos futuros" era resultados da função dos preços a vista e "prêmio pela expectativa de variação no tempo". Segundo os autores, o modelo mostrou baixa capacidade de previsão.

A partir daí, já no início dos anos 90, Gibson e Schwartz (1990) desenvolveram um modelo de dois fatores para projeção dos preços de contratos futuros da *commodity* petróleo. Os autores informam que os resultados mostraram que o retorno de conveniência tem a tendência de reverter para a sua média de longo prazo, sendo a variável de estado de maior volatilidade, enquanto o preço à vista é menos volátil e sua evolução assemelha-se a um passeio aleatório. O modelo também foi capaz de mostrar a diferença entre a volatilidade dos preços à vista e aquela dos contratos futuros, evidenciando que quanto maior a maturidade menor a volatilidade.

Em 1993, um novo horizonte se mostrava. Day e Lewis (1993) comparam previsões da volatilidade do preço do petróleo utilizando os Modelos General *Autoregressive Conditional Heterocedasticity* (GARCH) e Modelos Exponential GARCH (EGARCH).

Num estudo sobre equilíbrio de preços de ativos, Bessembinder et al (1995) mostraram um resultado insatisfatório para a previsão de preços, utilizando petróleo, produtos agrícolas e metais. Duffie e Gray (2003) usando *commodities* como gás natural, petróleo e *heatingoil*, perceberam melhoria nas projeções dentro e fora das amostras a partir da volatilidade implícita, utilizando os métodos GARCH (1,1), EGARCH (1,1), e GARCH bivariado. Victor e Pirrong (1996), também utilizando modelos da família GARCH, constataram que 96% da variação na volatilidade condicional é explicada pela variação no *spread* entre preços à vista e futuros conhecida como base.

Schwartz (1997), utilizando o Filtro de Kalman, analisou o comportamento estocástico dos preços das *commodities*. Investigou o desempenho de três modelos distintos. O primeiro modelo usando logaritmo do preço à vista, o segundo considerando os fatores: preço à vista e retorno de conveniência e o terceiro modelo de três fatores agrega ao segundo a taxa de juros como variável

estocástica. Segundo o autor, nos três casos, os modelos apresentaram desempenhos fracos. Schwartz explica que a principal dificuldade na aplicação empírica dos modelos de preços de *commodities* é que, frequentemente, as variáveis de estado, tais como o preço à vista, por exemplo, não são diretamente observáveis.

Em 1998, utilizando modelos autorregressivos, Ntungo e Boyd (1998) estudaram o desempenho de Modelos Autorregressivos Integrados de Médias Móveis (ARIMA) e de Redes Neurais em estratégias de negociação nos mercados futuros de milho, prata e marco alemão. Os resultados foram equivalentes em termos de retornos financeiros para os dois modelos, com resultados positivos nos mercados de milho e prata.

Por sua vez, ao considerar a analogia existente entre o comportamento de séries históricas de preços de *commodities* e o comportamento de outros ativos financeiros, destacaram-se as pesquisas sobre risco e volatilidade de séries históricas desenvolvidas de Alexander (1998; 1999). Em trabalho publicado no ano de 1998, o autor faz uma retrospectiva das metodologias utilizadas para análise do risco e volatilidade de comportamento de preços, no qual avalia os métodos de estimação por correlação entre séries e metodologia de modelagem com base em modelos de integração GARCH.

Pouco depois, Routledge, Seppi e Spatt (2000), estudando um modelo microeconômico de equilíbrio em mercados financeiros, incorporaram oferta, demanda e estoques. Perceberam que a volatilidade aumenta à medida que se aproxima a data de vencimento. Em seguida, Schwartz e Smith (2000) propuseram um modelo de máxima verossimilhança e métodos dos mínimos quadrados não-linear em um modelo de dois fatores, um fator de curto prazo; modelado por um processo de reversão à média e um fator de longo prazo modelado por um movimento browniano geométrico, que permitiu a reversão para a média dos preços de curto prazo e incerteza no nível de equilíbrio dos preços que reverter. Embora esses dois fatores não fossem diretamente observáveis, poderia ser estimado a partir da descriçãodo uso dos preços spot das *commodities* como uma soma dos desvios de curto prazo sobre o padrão em longo prazo. Além disso, os autores implementaram o modelo com dados dos contratos futuros de petróleo. Os resultados mostraram aderência para os dados empíricos nos curtos e longos prazos.

Pindick (2004), usando dados do gás natural e petróleo, demonstrou que os choques tem pouca persistência, e afetam principalmente as posições especulativas em curto prazo, não exercendo efeitos sobre as decisões em longo prazo em ativos reais.

Ampliando este vasto panorama, Aiube *et al.* (2006) propõem uma extensão do modelo de Schwartz e Smith (2000), incorporando saltos nas variações de curto prazo para analisar os preços da *commodity* petróleo, utilizando modelo de 3 fatores. Observaram que o petróleo apresenta um comportamento transitório, e que não houve aumento na volatilidade condicional. Ainda neste ano, Chicralla (2006) apresentou algumas alternativas de previsão do preço futuro do aço a partir do emprego de modelos de previsão autorregressivos (ARIMA e VAR). Estes modelos foram definidos em função da análise do comportamento, no longo prazo, entre as séries de preços do aço no Brasil *vis-à-vis* seus respectivos preços no exterior. O modelo VAR gerou previsões melhores do que o modelo ARIMA.

Cifarelli *et al* (2009) avaliaram empiricamente a dinâmica da especulação do preço do petróleo, e utilizando do modelo GARCH-M, encontraram fortes indícios de que as mudanças do preço do petróleo está negativamente relacionada ao preço das ações e ao intercâmbio das alterações da taxa e que uma complexa teia de variáveis no tempo primeira e segunda ordem interações momento condicional afeta tanto os componentes do CAPM e feedback comercial do modelo.

Em que pesem o volume de estudos desenvolvidos com a finalidade de previsão de preços das *commodities*, supracitados, Demo (1995) aponta que não há um único modelo validado ou teoria

capaz de prever o preço das *commodities*. No entanto, as pesquisas não solidificam nenhum modelo como ideal para a previsão da flutuação de preços de uma *commodity*.

3.5 Formação de preço

O entendimento sobre a formação de preços de *commodities* é objeto de inúmeras pesquisas nos estudos de Gestão de Empresas. Os estudos sobre as possíveis direções destes preços, em sua maioria, têm a finalidade de buscar antecipar informações sobre a formação dos preços, de forma que os participantes do mercado possam dispor de estratégias, com o objetivo de maximizarem o valor esperado do fluxo de caixa em relação aos preços do ativo. A previsão dos preços de um dado ativo depende do estudo de processos estocásticos e de variáveis exógenas, que pode resultar na elaboração de um modelo que venha descrever a trajetória dos preços e que seja ao mesmo tempo parcimonioso.

Quando estes estudos se referem à formação de preços no mercado de *commodities*, o investigador se vê diante de um contexto parecido com os estudos aplicados ao mercado de ativos financeiros. No entanto, o mercado de *commodities* possui características únicas, que obrigam o pesquisador/investigador a examinar os processos clássicos de formação de preços, e ponderar sobre conceitos próprios deste mercado. A teoria da estocagem, a teoria de paridade de preços, os preços no mercado de derivativos de *commodities* e as distorções de observação do preço à vista das *commodities* físicas, são exemplos de estudos próprios deste mercado.

O preço à vista das *commodities* depende da geografia onde estas são negociadas. Neles estão inclusos custos de frete, entrega física e armazenagem. Os preços à vista de *commodities* publicados são, portanto, médias dos preços negociados em diversas partes do mundo, podendo haver variações na observação dessa variável.

Indústrias e governos se interessam pela liquidação física dos contratos e entrega dos bens, sem atrasos e a baixos custos de entrega. Porém, devido às grandes distâncias entre produtor e consumidor, é praticamente impossível a liquidação de *commodities* tais como metal, agrícolas ou de energia com entrega em mercados *spot*, obrigando que os contratos sejam feitos para entrega futura ou de liquidação financeira.

3.6 Redes Bayesianas

Segundo Jensen (2001), uma Rede Bayesiana (RB) é por definição composta dos seguintes elementos: 1. Um conjunto de variáveis e um conjunto de arestas direcionadas entre as variáveis. 2. Cada variável tem estados finitos e mutuamente exclusivos. 3. Os vértices representam uma variável aleatória e as arestas direcionadas representam dependências entre as variáveis aleatórias, formando um grafo acíclico direcionado, onde 4. Cada variável *A*, com pais B_1, B_2, ... B_n, possui uma tabela de probabilidades condicionais conjuntas $P(A | B_1, B_2, ... B_n)$, associada.

Em uma RB, se há uma aresta direcionada entre os nós A e B, então diz-se que A é pai de B e B é filho de A.

Figura 2 – Rede Bayesiana a partir de variáveis e suas relações

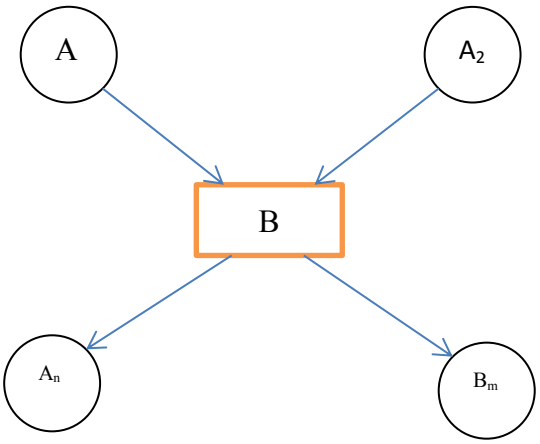

Fonte: Elaboração dos autores

Hecherman (1966) afirma que quando usadas em conjunto com técnicas estatísticas o modelo apresenta vários atributos para a análise de dados que são:

1- Por apresentar probabilidades condicionais entre as variáveis, o modelo lida com situações nas quais alguns valores para as variáveis estão ausentes;

2- A Rede Bayesiana pode ser usada para se aprender relações causais entre as variáveis e pode ser usada para se incrementar o aprendizado sobre o domínio do problema e prever consequências ao se intervir no problema;

3- Com o modelo possuindo a relação semântica causal e probabilística é ideal para se combinar conhecimento anterior (que frequentemente vem na forma causal) com os dados presentes;

4- A estatística Bayesiana em conjunto com a RB oferece uma abordagem eficiente para que seja evitado um super aprendizado.

Quanto a estrutura, uma Rede Bayesiana, pode ser decomposta em duas partes complementares entre si (NASSAR 2002):

1. **Qualitativa**, é um modelo gráfico no qual cada variável aleatória é representada por um nó e as relações causais entre as variáveis são representados por arcos direcionados. Assim caso exista uma seta partindo de 'A' em direção a 'B', isto estará indicando que o primeiro tem influência direta na probabilidade do segundo, ou seja, 'A' significará uma causa enquanto 'B' desempenhará o papel de consequência, estabelecendo assim a dependência entre estas duas variáveis.
2. **Quantitativa**, é formada por probabilidades condicionais associadas aos arcos presentes no modelo gráfico e probabilidades *a priori* que são os valores estimados para os estados de cada nó de saída. Esta parte reflete o quão fortemente as variáveis estão associadas através dos valores de probabilidade, e as relações causais existentes entre os nós de entrada e saída. Todos estes valores de probabilidade representam o conhecimento de um especialista ou provém de uma base de dados (SIMÕES, 2001).

Uma das grandes barreiras encontradas nestas pesquisas, ou seja, uma das partes mais difíceis é a geração de grafos (de maneira controlada), uma vez que apresenta elevada dimensão da dificuldade. A quantidade de estruturas de grafos possíveis cresce super-exponencialmente em função do número de nós, conforme Tabela 2 abaixo. Outra dificuldade são os métodos heurísticos que são propostos para geração de Redes Bayesianas. Não garante sobre a distribuição dos grafos gerados. Além disto, é desejável que se possua controle sobre a geração do grafo. E ainda a "geração

uniforme de grafos" significa que cada grafo tem a mesma probabilidade de ser gerado, dentro do domínio de todos os grafos possíveis.

Tabela 2 – Número total de combinações possíveis

Número de nós(*n*)	1	2	3	4	5	6	7	8
Combinações possíveis (c_n)	1	3	25	543	29281	3781503	1138779265	783702329343

Fonte: Ghaffari, Zari (2009)

3.7 Capacidade preditiva e acurácia dos modelos

Em um estudo empírico, ao se comparar a variação prevista dos preços do petróleo, a partir dospreços diários WTI (West Texas Intermediate), que é a referência do preço da *commodity* petróleo, para os mercados de derivados dos EUA, com a sua variação real, a porcentagem de predição correta (PCP) é calculada para ser inferior a 55% (GHAFFARI, ZARI, 2009).

Outros autores, usando diversos métodos de previsão, conseguiram resultados menores, conforme apontado na tabela 1, abaixo:

Tabela 1: Desempenho da previsão do petróleo

Autor	Ano	Período	Desempenho
Morana	2001	2 meses	46,67%
Fan et. al.	2006	1 mês	54,54%

Fonte: Ghaffari, Zari(2009)

Futuros estudos devem ser focados no desenvolvimento de estratégias mais lógicas para manter as características da dinâmica de sistemas no modelo proposto por um período mais longo de tempo, o que ainda não foi alcançado.

Inúmeros autores como Ashton; Ashton (1985); Flores; White (1988); Winkler (1989), Makridakis; Winkler (1986); Hibon; Evgeniou (2005) sugerem em suas pesquisas que a combinação de métodos de previsão aumenta a acurácia destas, reduzindo, por conseguinte, a sua variação, através da agregação de informações independentes ao processo de previsão. Assim, os erros inerentes aos modelos são suavizados, minimizando o risco da previsão em relação à seleção de um método de previsão individual. A vantagem de se combinar métodos, é a utilização de diferentes dados históricos e diferentes técnicas de coleta e interpretação de dados e/ou métodos diferentes (ARMSTRONG, 2001b). Sanders (1997) afirma que quanto menor a correlação entre as previsões, maior a possibilidade de melhoria na precisão da combinação das previsões individuais.

Para Wright *et al*. (1996), a combinação de previsão depende de fatores como: o método de combinação, a natureza das previsões e o volume de previsões combinadas. Webby, O'Connor (1996) alertam, que este método pode resultar em perda de precisão se a variável a ser prevista for instável.

Para que a combinação de previsões alcance o seu objetivo, ou seja, auxiliem na melhoria de desempenho dos métodos de previsão, neste caso específico, na melhoria das redes, podem-se utilizar técnicas diferentes, quais sejam:

1. Técnica qualitativa ou subjetiva, que se caracteriza pelo controle de um grupo de especialistas preferencialmente, sobre a previsão final, e são encorajados pela robustez desta estratégia de combinação;

2. Técnica quantitativa que utiliza algum tipo de modelo estatístico que se caracteriza pela previsão final obtida por uma previsão independente, combinado com uma previsão qualitativa (WRIGHT *et al.*, 1996). A combinação quantitativa obtém resultados mais precisos que a combinação subjetiva.

No desenvolvimento de sua metodologia, Armstrong (2001a) obteve evidências de que métodos quantitativos são mais precisos que métodos qualitativos para situações em que dados encontram-se disponíveis. Também verificou que métodos simples devem ser priorizados em relação a métodos complexos, pois os primeiros são de fácil entendimento, têm menor custo e raramente são menos acurados que os métodos complexos. Os estudiosos, no entanto, ainda não chegaram a um consenso em relação ao número de métodos a serem combinados. Armstrong (2001b) sugere uma combinação de pelo menos cinco métodos, sendo que a taxa de melhoria de acurácia diminui com a adição de mais métodos na combinação. Flores e White (1988) sugerem a combinação de duas a quatro previsões para a obtenção de maiores ganhos no processo de previsão.

Para Ashton, Ashton (1985), na quantidade de previsões a serem agregadas deve-se sempre considerar o *trade-off* entre o aumento da acurácia e os custos associados à obtenção das previsões individuais. Há a redução de acurácia quando a correlação entre as previsões individuais aumenta e pouca informação nova é adicionada a previsão combinada (WRIGHT, 1994).

Makridakis e Winkler (1983) advertem que a média aritmética obtém previsões mais precisas do que médias ponderadas, exceto quando uma previsão é muito mais precisa que a outra, pois a combinação vai gerar uma previsão com acurácia inferior à da melhor previsão. No entanto, Flores; White (1988) advertem que a otimização matemática dos pesos para médias ponderadas requer previsões individuais não tendenciosas, padrão estacionário dos erros das previsões e dados históricos suficientes para estimar pesos ótimos confiáveis, o que, geralmente, não ocorre nas situações reais.

A combinação de previsões deve ser usada quando há incerteza sobre qual é o melhor método de previsão para determinada situação ou quando grandes erros de previsão devem ser evitados. Frequentemente uma combinação de procedimentos é utilizada para obter a lista final de variáveis explanatórias (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998). Se a influência das variáveis independentes listadas sobre os preços for confirmada, estas poderão ser usadas para prever valores futuros de preços, ou serem excluídas, se contribuem pouco na previsão de demanda (MENTZER; GOMES, 1989).

4 Considerações finais

A dinâmica do mundo moderno, com constantes transformações econômicas, políticas e sociais que caracterizam os dias atuais têm despertado, no mundo acadêmico e empresarial, a preocupação em buscar novas abordagens e metodologias diferenciadas para a construção do conhecimento da realidade que se apresenta, sobretudo quando o aspecto a ser analisado são os preços das *commodities*, os quais são definidos pelo mercado e caracterizados por sua natureza cíclica e elevada flutuação e alta volatilidade.

Por diversos pontos de vista, foi apresentada ao longo deste trabalho, algumas variáveis de previsão de preço e uma variedade dos estudos teóricos que abordam a previsão de preços de *commodities*. Desde as técnicas iniciais como as desenvolvidas por Engle (1982); a teoria dos estoques (FAMA; FRENCH, 1987), métodos por processos estocásticos, com base em modelos de um, dois ou três fatores (BRENNAN; SCHWARTZ, 1985; FAMA; FRENCH, 1987; GIBSON; SCHWARTZ, 1990; SCHWARTZ, 1997; SCHWARTZ; SMITH, 2000; AIUBE *e BAIDYA*, 2006; PEREIRA, 2009), ou ainda sob a

ótica de métodos autorregressivos, utilizando, por exemplo, a técnica de Redes Neurais Artificiais, Ntungo e Boyd (1998), CIFARELLI e PALADINO (2009) na especulação do mercado de petróleo.

Na tentativa de previsão do preço de petróleo, usado como balizador do preço da *commodity* apresentada, observa-se que esta, é função de inúmeras variáveis, que se distribuem entre diversas dimensões: políticas, estratégicas e sociais. Muitos são os interesses e os fatores envolvidos: crescimento econômico mundial, evolução das reservas e da produção mundial em contraposição à fraca expansão da produção, variação de estoques, evolução do perfil de demanda, eficiência energética, preços dos produtos substitutos, condições climáticas, ocorrência de eventos de geopolítica, estratégias de mercado dos produtores (em particular, da OPEP) e dos grandes países consumidores (política energética etc.), especulação nos mercado futuros e suas implicações sobre o mercado spot etc. (EPE, 2008). Isto é, as variáveis envolvidas são inúmeras e com uma extensa abrangência de possibilidades de evolução, resultando em muitas incertezas, as quais são explanadas abaixo.

As abordagens gerais para determinação de preços de *commodities* consolidadas pela literatura refletem, de maneira estática, situações possíveis em mercados que, provavelmente, não se aproximam da realidade competitiva encontrada pelas *commodities*, no seu mercado de atuação. Nesse sentido, a tarefa de precificar torna-se mais complexa e arriscada, pois os fatores que interferem na política de preços da *commodity* não são somente aqueles idealmente apontados pela literatura.

Outros fatores conjunturais devem ser considerados e os agentes necessitam de ferramentas e metodologias que permitam a manipulação desses vários fatores, que atuam de forma interdependente nos preços. É imbuído deste sentimento, que se encontra o cenário que se configura, pois se apresenta e se desenvolve uma modelagem alternativa às tradicionalmente utilizadas para o monitoramento e previsão dos preços das *commodities*.

Pela descrição realizada neste trabalho, demonstrou-se a técnica e o uso de Redes Bayesianas, e espera-se a partir de resultados encontrados em outras aplicações, que esta técnica possa encontrar resultados melhores que os já encontrados para a previsão de preços em curto e médio prazo. Observado este *gap*, ressalta-se que a técnica proposta apresenta a vantagem de entender a relação causa e efeito, trazendo um atrativo extra, na análise dos cenários.

Redes Bayesianas constituem uma forma natural para representação de informações condicionalmente independentes. E ainda, possibilitam a representação compacta de uma tabela de conjunção de probabilidades. Em outras palavras, busca oferecer uma solução assertiva para problemas onde conclusões não podem ser obtidas apenas do domínio do problema, onde o uso de probabilidades é exigido.

5 Referências

AIUBE, F. A. L., BAIDYA, T. K. N. **Analysis of the behavior of volatilily in crude oil prices**. VI Brazilian Finance Conference, 2006.

ALEXANDER, C. **Risk Management and Analysis: measuring and modeling financial risk. London**. Ed. Alexander Carol, v. 1, Chapter 4. 1998.

ALEXANDER, C. **Optimal hedging using cointegration.The Royal Society London,** v. 357, p. 2039-2058, 1999.

ARMSTRONG, J. S. **Selecting Forecasting Methods**. In: ARMSTRONG, J. Principles of Forecasting: a Handbook for Researchers and Practitioners. Boston: Kluwer Academic Publishers, 2001a.

ARMSTRONG, J. S. **Combinig Forecasts**. In: ARMSTRONG, J. Principles of Forecasting: a Handbook for Researchers and Practitioners. Boston: Kluwer Academic Publishers, 2001b.

ASHTON, A. H.; ASHTON, R. H. **Aggregating Subjective Forecasts: Some Empirical Results. Management Science,** v. 31, n. 12, p. 1499-1508, 1985.

AZEVEDO, P. F. **Comercialização de Produtos Agroindustriais.**In: BATALHA, M. O. (Coord.); GEPAI - Grupo de Estudos e Pesquisas Agroindustriais. Gestão Agroindustrial. São Paulo: Atlas, 1997.

BARRIGA, C. **Tecnologia e competitividade em agronegócios**. Revista da Administração. São Paulo, v. 30, n. 4, p. 83-90, out-dez, 1995.

BERNANKE, B. S. **The economic outlook.Remarks before the National Italian American Foundation**.Nova York, 28 de Novembro. Disponível em: <http://www.federalreserve.gov/newsevents/speech/bernanke20061128a.htm>. Acessado em 06 de novembro de 2012. 2006

BESSEMBINDER, H. et al. ***Mean Reversion and equilibrium asset price: evidence from the futures term structure.****The Journal of Finance, v. 50 n. 1, mar/ 1995.*

BRENNAN M., e SCHWARTZ, E. S. ***"Evaluating Natural Resource Investments".****Journal of Business 58 (January): 135-157. 1985.*

CETESB. **Companhia de Tecnologia de Saneamento Ambiental.** Disponível em <http://www.cetesb.sp.gov.br/userfiles/file/laboratorios/fit/butadieno.pdf> Acessado em 30 de outubro de 2012. 2012.

CHAUVET *et al* (2000). **Two methodologies to build inflation leading indicators for Brazil**.Research and Studies Department Central Brank of Brazil. Disponível em <http:// www. bcb.gov.br/?SEMETAS00/>.Acesso em 25 de outubro de 2012. 2000.

CHICRALLA, M. R. **Antecipação do movimento do preço da *commodity* aço, em contratos a preço firme no Mercado de engenharia industrial no Brasil.** Dissertação. Programa de Pós-graduação em Economia. Rio de Janeiro. 2006.

CIFARELLI, G.; PALADINO, G. **Oil price dynamics and speculation: A multivariate financial approach.**Disponível em <http://www.elsevier.com/locate/eneco>. P. 363-372. Acessado em 20 de outubro de 2012. 2009.

DAY, T.E.; LEWIS, C.M. **Forecasting futures markets volatility.Journal of Derivatives**, v. 1, p. 33-50, 1993.

DEMO, P. **Metodologia Científica em Ciências Sociais**. São Paulo. Ed. Atlas. 1995.

DUFFIE, D.; GRAY, S. **Volatility in energy prices. In: Managing Energy Price Risk. Risk Publications**, p. 39-55, 1995. ENDERS, Walter. Applied Econometrics Time Series.Danvers: John Wiley &Sons, 2003.

ENGLE, R. F. **Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation.**Econometrica 50, No 4, pp. 987-1007, July. 1982.

EPE. Empresa de Pesquisa Energética. **Contexto Mundial e Preço do Petróleo: Uma visão de longo prazo.** Disponível em <http://www.epe.gov.br/Petroleo/Documents/Estudos_29/Contexto%20Mundial%20e%20Pre%C3%A7o%20do%20Petr%C3%B3leo%20Uma%20Vis%C3%A3o%20de%20Longo%20Prazo.pdf>. Acessado em 01 de novembro de 2012.**2008**.

FAMA E. F. e FRENCH, K. R. **Commodity future prices: Some evidence on forecast Power, premiuns and the theory of storage.**Journal of Business. v. 60, n. 1. P. 55-73. 1987.

FLORES, B. E.; WHITE, E. M. A. **Framework for the Combination of Forecasts.Journal of the Academy of Marketing Science.**v. 16 n. 3-4, p. 95-103, 1988.

GHAFFARI, ZARI. **A novel algorithm for prediction of crude oil price variation based on soft computing**.Energy Economics 31. p. 531–536. 2009.

GEMAN, H. **Commodities and Commodity Derivatives**, (Chichester: John Wiley & Sons). 2005.

GIBSON R. and SCHWARTZ E. S., **Stochastic convenience yield and the pricing of oil contingent claims, Journal of Finance.**XLV(3), 959-976. 1990.

GOBBO, L. G. **Fabricação de borracha. Engenharia de Controle e Automação**. FAC. Anhanguera Educacional. Disponível em <http://www.ebah.com.br/content/ABAAAApnYAI/fabricacao-borracha>. Acessado em 02 de novembro de 2012. 2010.

GUERRERO, M.F.; PUEBLA, P.; CARRÓN, R.; MARTIN, M.L.; ARTEAGA, L.; SAN ROMÁN, L. **Assessment of the anti-hypertensive and vasodilator effects of ethanolic extracts of some Colombian medicinal plants.**J. Ethnopharmacol., v.80, n.1, p.37-42, 2002.

GUIDI, M. G. D., RUSSELL, A., TARBERT, Heather. **The effect of OPEC policy decisions on oil and stock prices**. OPEC Review 30: 1–18. 2006.

HAMILTON, J. D. **What is an oil shock?**Journal of Econometrics v.113, p. 363–398. 2003.

HECHERMAN, D.**A tutorial on learning with Bayesian Networks**. Readmond: Microsoft Research Advanced Technology Division, 1996.

HIBON, M.; EVGENIOU, T.**To Combine or Notto Combine: Selecting among Forecasts and their Combinations.** International Journal of Forecasting**.** v. 21, n. 1, p. 15-24, 2005.

HULL, J. C., **Options, Futures and Other Derivatives.**(7th Edition). Prentice Hall, May, 2008.

JENSEN, F.V. **Bayesian Networks and Decision Graphs**. New York: Springer-Verlag, 294p. 2001.

KALDOR, N., 1939, **"Speculation and Economic Stability"**, Review of Economic Studies, v. 7, n. 1, p. 1-27.

LESCAROUX, F., MIGNON, V.**On the influence of oil prices on economic activity and other macroeconomic and financial variables**. OPEC Energy Review 32 (4): p. 343−380. 2008.

LINDBERG, E.; ZACKRISSON, U. **Deciding about uncertain: The use of forecasts as an aid to decision-making.**Scandinavian Journal of Managment. v. 7. n. 4, p. 271-283, 1991.

MAKRIDAKIS, S.; WINKLER, R. **Averages of Forecasts: Some Empirical Results. Management Science**. v. 29, n. 9, p. 987-996, 1983.

MAKRIDAKIS, S.; WHEELWRIGHT, S.; HYNDMAN, R. **Forecasting: Methods and Applications.** 3. ed., New York: John Wiley& Sons, 1998.

MATIAS, M. A. *et al*. **Análise de padrões de comportamento de preços com fins de projeção de receita: testes estatísticos em uma série temporal de preços da *commodity* cobre**. Brazilian Business Review.Vitória, v. 2, n. 2, p. 113-130, jul/dez, 2005.

MENTZER, J. T.; GOMES, R. **Evaluating a Decision Support Forecasting System.Industrial Marketing Management**. v. 18, n. 4, p. 313 -323, 1989.

NASSAR, S. M. **Tratamento de Incerteza: Sistemas Especialistas Probabilísticos.** Curso de Pós Graduação em Ciência da Computação. Departamento de Informática e de Estatística. Universidade Federal de Santa Catarina. 2002.

NTUNGO, C.; BOYD, M. **Commodity Futures Trading Performance Using Neural Network Models versus ARIMA Models**. in.: Journal of Futures Markets, v. 18, n. 8, p. 965-983, 1998.

PEREIRA, L. M., **Modelo de formação de preço de *commodities* agrícolas, aplicado Mercado de açúcar e álcool**. São Paulo. Tese. Doutorado em Administração – Faculdade de Economia, Administração e Contabilidade de São Paulo. Universidade de São Paulo. 2009.

PINDYCK, R. S. **Volatility in natural gas and oil markets**. Massachusetts Institute of Technology Cambridge, MA 02142. 2004.

ROUTLEDGE, B.R.; SEPPI, D.J.; SPATT, C.S. **Equilibrium forward curves for commodities.**The Journal of Finance, v. 55, p. 1297-1338, 2000.

RUSSEL, S.; NORVIG, P. **Inteligência Artificial**. 2nd. ed. [S.l.]: Ed. Campus, 2004.

RIBEIRO, M. A.; GODINHO, L. A. **Utilização de estratégias de marketing como diferencial dos fornecedores de asfaltos na região metropolitana de Belo Horizonte.** Disponível em: <http://www.webartigos.com/articles/20409>. Acesso em: 27 de outubro de 2012. 2009.

SANDERS, N. R. **The Status of Forecasting in Manufacturing Firms.Production and Inventory.**Management Journal. v. 25, n. 5, p. 32-35, 1997.

SANDRONI, P. **Novo Dicionário de Economia**. 2ª edição, Ed. Best Seller: São Paulo, 375 p. 1994.

SANTOS. T. C., **Identificação de fatores inibidores à realização de negócios de arroz em casca, na bolsa brasileira de mercadorias no Rio Grande do Sul**. Dissertação.UFRGS. 2005.

SCHWARTZ, Eduardo S. **The stochastic behavior of commodity prices: implications for valuation and hedging.**The Journal of Finance, v. 52, p. 923-973, 1997.

SCHWARTZ Eduardo S. and James E. SMITH.**Short-term variations and long-termdynamics in commodity prices.**Management. Science, 46(7): p. 893-911, 2000.

SIMÕES, Priscyla Waleska Targino de Azevedo; NASSAR, Silvia Modesto; PIRES, Maria Marlene de Souza. **Sistema de Apoio na Avaliação da Falência do Crescimento Infantil.** In: CONGRESSO BRASILEIRO DE COMPUTAÇÃO, Workshop de Informática Aplicada à Saúde, 2001.

SOBREIRO, V. A. *et al*. **Precificação do etanol utilizando técnicas de Redes Neurais Artificiais.** Revista de Administração da USP. São Paulo, v. 44 n. 1. p. 46-58. Jan/fev./mar., 2008.

TAYLOR, S. J. "**Modeling Financial Times Séries**". UK: John Wiley & Sons, 1986.

VICTOR, K.; PIRRONG, Stephen Craig.**Price dynamics in refined petroleum spot and futures markets.**Journal of Empirical Finance, p. 359-388. 1996.

WEBBY, R.; O'CONNOR, M. **Judgmental and Statistical Time Series Forecasting: a Review of the Literature. International Journal of Forecasting**. v. 12, n. 1, p. 91-118, 1996.

WILLIAMSON, O. E. – **Las instituciones económicas del capitalismo**. México: Fondo de Cultura Económica. 1989.

WINKLER, W. E., **"Methods for Adjusting for Lack of Independence in an Application of the Fellegi-Sunter Model of Record Linkage," Survey Methodology**, **15**, p. 101-117. 1989.

WORKING, H.**The theory of price of storage.**The American Economic Review. v. 39, n. 6, p. 1254-1262, Dec. 1949.

WRIGHT *et al*.**The role and validity of judgment I forecasting**. International Journal of Forecasting. v. 12, n. 1, p. 1-8, 1996.