

**Insper Instituto de Ensino e Pesquisa
Faculdade de Economia e Administração**

Luiz Felipe Priolli Fonseca e Carvalho

**MODELOS DE PREVISÃO PARA O PREÇO DO COBRE
ATRAVÉS DE MÉTODOS ECONOMÉTRICOS E REDES
NEURAS ARTIFICIAS DE RETROPROPAGAÇÃO**

**São Paulo
2012**

Luiz Felipe Priolli Fonseca e Carvalho

Modelos de previsão para o preço do cobre através de métodos econométricos e redes neurais artificiais de retropropagação

Monografia apresentada ao curso de Ciências Econômicas, como requisito parcial para obtenção do grau de Bacharel do Insper Instituto de Ensino e Pesquisa.

Orientador:
Prof. Dr. Leonidas Sandoval Junior – Insper

**São Paulo
2012**

Carvalho, Luiz Felipe Priolli Fonseca

Modelos de previsão para o preço do cobre através de métodos econométricos e redes neurais artificiais de retropropagação. – São Paulo: Insper, 2012.

40 f.

Monografia: Faculdade de Economia e Administração.
Insper Instituto de Ensino e Pesquisa.

Orientador: Prof. Dr. Leonidas Sandoval Junior

1.Preço do cobre 2. Modelos de previsão 3. Redes Neurais Artificiais 4. GARCH

Luiz Felipe Priolli Fonseca e Carvalho

Modelos de previsão para o preço do cobre através de métodos econométricos e redes neurais artificiais de retropropagação

Monografia apresentada à Faculdade de Economia do Insper, como parte dos requisitos para conclusão do curso de graduação em Economia.

Aprovado em Dezembro 2012

EXAMINADORES

Prof. Dr. Leonidas Sandoval Junior
Orientador

Prof. Dr. Fernando Ribeiro Leite Neto
Examinador

Prof. Dr. Ricardo Humberto Rocha
Examinador

Agradecimentos

Primeiramente, agradeço ao meu pai, Luiz Fernando Gomes de Carvalho, por me fornecer a centelha do que viria a se tornar o tema deste trabalho após vários momentos de reflexão e breves conversas com algumas pessoas durante meu programa de *trainee* no Itaú BBA, em especial Giovanna Rocca Siniscalchi e Artur Manoel Passos. Também, não posso deixar de agradecer ao meu orientador, Leonidas Sandoval Junior, que estava sempre disponível e pronto para comentar meus resultados e dar suas sugestões.

Agradeço também ao meu amigo e professor, Sérgio Ricardo Martins, por sua ajuda e disposição sempre que precisei. Além, agradeço aos meus amigos Julien Marc Hannigan Pigot, David Chang, George Tan San Chen e Luís Fernando Souza Negrão e Silva pelo apoio que me deram tanto durante este trabalho como anterior a ele.

Por fim, mas talvez o mais importante, agradeço à minha família e namorada, Bruna Tomaidis Soares de Lima, pelo interesse e apoio constante ao meu trabalho.

Dedicatória

Dedico este trabalho a todos que me ajudaram a dar mais um passo à frente em algum momento da minha vida, pois de passo em passo é que se percorre o caminho. Em especial, dedico este trabalho à minha família que sempre me apoiou de todas as formas possíveis ao longo de minha vida, principalmente, durante a faculdade. Dedico também para os meus amigos e namorada com quem troquei muitas ideias tendo *insights* para a resolução de dificuldades encontradas, durante o percurso, em muitas de nossas conversas.

Resumo

CARVALHO, Luiz Felipe Priolli Fonseca. Modelos de previsão para o preço do cobre através de métodos econométricos e redes neurais artificiais de retropropagação. São Paulo, 2012. Monografia – Faculdade de Economia e Administração. Insper Instituto de Ensino e Pesquisa.

Na atualidade, previsão é parte essencial da tomada de decisão de compra e venda em qualquer instituição financeira e até mesmo em companhias. Tendo isso em mente, este trabalho tem como objetivo encontrar, através da experimentação de diferentes técnicas (redes neurais artificiais e modelagem da volatilidade através de GARCHs), o melhor modelo de previsão para a variação da série diária dos preços do cobre na *London Mercantile Exchange*. O trabalho proposto de buscar o melhor GARCH, GARCH-M e Rede Neural Artificial (RNA) para a variação diária do cobre é de grande valor quando analisados os possíveis ganhos que se pode obter com resultados positivos deste trabalho. Espera-se encontrar, como descrito na literatura, um tipo de modelagem como a melhor técnica de previsão, em frequência diária, para a variação diária do cobre.

Palavras-chave: GARCH; Redes Neurais Artificiais; Preço do cobre; Modelos de previsão.

Abstract

Carvalho, Luiz Felipe Priolli Fonseca. Copper prices forecasting models through econometrics methods and backpropagation artificial neural networks. São Paulo, 2012. Monograph – Faculdade de Economia e Administração. Insper Instituto de Ensino e Pesquisa.

Nowadays, forecasting is an essential part of buying or selling decisions of any financial institution or even company. With that in mind, this work aims to find, through the experimentation with different techniques (artificial neural networks and GARCH volatility models), the best forecasting model and technique for the daily change on copper prices in the London Mercantile Exchange. The hard work on finding the best GARCH, GARCH-M and Artificial Neural Network (ANN) for daily frequency is nothing compared to the possible gains of the positive outcome of this paper. It is expected to find the neural network or one of the GARCH models as the best forecasting technique for the daily change on copper prices.

Keywords: GARCH; Artificial Neural Networks; Copper prices; Forecasting models.

Sumário

| | |
|--|----|
| 1. Introdução | 10 |
| 2. Preço do cobre..... | 12 |
| 3. Teoria dos modelos | 15 |
| 3.1. GARCH | 15 |
| 3.2. Redes neurais artificiais..... | 17 |
| 4. Metodologia | 21 |
| 4.1 Variáveis..... | 21 |
| 4.2 Interpolação | 26 |
| 4.3 Medidas de erro | 28 |
| 5. Modelos..... | 31 |
| 5.1 GARCH | 31 |
| 5.2 Rede neural artificial de retropropagação..... | 32 |
| 6. Resultados | 33 |
| 7. Conclusão..... | 36 |
| Referências..... | 38 |

Lista de gráficos, tabelas e figuras

| | |
|--|----|
| Gráfico 2.1 – Preço do cobre na London Mercantile Exchange desde 1993..... | 13 |
| Gráfico 2.2 – Diferencial da variação percentual entre spot e primeiro contrato futuro em função do tempo | 14 |
| Tabela 2.1 – Média do diferencial da variação percentual diária entre spot e primeiro..... | 14 |
| Tabela 2.2 – Correlação da variação percentual entre spot e primeiro contrato futuro..... | 14 |
| Figura 3.2.1 – Explicação rede neural artificial de retropropagação 1..... | 18 |
| Figura 3.2.2 – Explicação rede neural artificial de retropropagação 2..... | 19 |
| Figura 3.2.3 – Explicação rede neural artificial de retropropagação 3..... | 19 |
| Tabela 6.1 – Comparação dos modelos de previsão..... | 33 |
| Tabela 6.2 – Exercício de complementariedade dos modelos..... | 35 |

1. Introdução

No período recente, têm ganhado cada vez mais força, internacionalmente e no Brasil, modelos de previsão para séries temporais através da metodologia de redes neurais artificiais. Segundo Sobreiro *et al* (2008), isso ocorre “por não requerer pré-especificações ou estabelecimento de hipóteses e suposições sobre a distribuição estatística ou propriedade dos dados e por apresentarem a capacidade de aprender sobre o relacionamento das variáveis”. Entre as redes existentes, Freiman e Pamplona (2005) apontam que o modelo de retropropagação trouxe o método de volta à vida após um período de esquecimento, tornando-se a técnica mais popular devido à sua capacidade de aprendizado e treinamento por correção dos erros. Além disso, com a grande e crescente importância das *commodities* nas economias globais, principalmente após o *boom* dos preços verificado entre os anos de 2006-2008 com a forte entrada da China no mercado, o custo de tomada de decisões erradas por produtores, consumidores e especuladores é crescente. No geral, a perspectiva para os preços no longo prazo é de crescimento real, o que confere ainda mais importância à temática de previsão de uma série temporal financeira e ao conteúdo desta obra.

Com base nesse cenário, a discussão sobre o nível de preços se torna cada vez mais presente. Esse meio cria mercados voláteis com oportunidades para consideráveis ganhos de curto, médio e longo prazos no setor financeiro, juntamente com a necessidade cada vez maior das empresas, consumidores e governos de conhecerem os preços futuros dos produtos. No caso do Brasil, uma parte importante da receita do país, tanto no âmbito governamental, através de impostos e formulação de políticas, como das empresas e até mesmo na renda da população geral está atrelada ao preço das *commodities*, uma vez que estas são matéria-prima e o Brasil é um país exportador de muitas delas.

Dentre a extensa variedade de *commodities* existente, foi escolhido para este trabalho o grupo das metálicas não preciosas, mais precisamente o cobre, para uma modelagem mais específica, com o intuito de se obter maior precisão na previsão dos modelos através da minimização de erros. Segundo o relatório do Deutsche Bank (2011), o cobre é uma commodity metálica de extrema importância para a economia mundial, sendo 66% de seu uso concentrado principalmente nos setores de construção e produtos eletrônicos, setores chave no consumo de qualquer economia. Ainda, segundo o Deutsche Bank (2011), a China, não muito diferente do que ocorre com as demais *commodities* metálicas, é a maior importadora e consumidora do cobre refinado, atingindo o consumo de quase 7,5 milhões de toneladas

(quase 40% do consumo mundial), segundo dados de 2010 extraídos do *World Bureau of Metal Statistics*. Entre os produtores do minério, o maior é o Chile, com quase 35% da produção mundial segundo a mesma fonte. Analisando o mercado de negociação, destaca-se a negociação do cobre na *London Metal Exchange* (LME), na divisão de *COMEX* da *New York Mercantile Exchange* (NYMEX) e também na *Shanghai Futures Exchange* (SFE), dada a importância da China apresentada nesse mercado.

Para a construção dos modelos de previsão, usam-se, neste trabalho, dois métodos de modelagem: GARCH e Redes Neurais. A modelagem econométrica GARCH foi escolhida como a mais adequada para o preço devido à alta volatilidade existente nos preços das *commodities* metálicas, como discute McMahon *et al* (2005), sendo necessário, portanto, modelar não apenas a média, mas também a variância dessa série temporal financeira como apresentado em Morettin (2008). A modelagem por Redes Neurais difere-se da anterior por envolver algoritmos de aprendizado, não ser um modelo paramétrico (LIMA *et al*, 2009) e não necessitar de pré-especificações ou hipóteses sobre a distribuição estatística (SOBREIRO *et al*, 2008).

Com os modelos GARCH e Redes Neurais, espera-se que sejam encontrados resultados semelhantes aos apresentados em Freiman e Pamplona (2005), onde há momentos em que modelos econométricos são superiores aos de Redes Neurais e vice-versa. Entretanto, como apontado ainda em Freiman e Pamplona (2005), os modelos econométricos e de Redes Neurais são complementares, não concorrentes. Desse modo, dependendo da intensidade da não linearidade entre as variáveis, há uma tendência para a previsão através do modelo de Redes Neurais Artificiais (RNA) mostrar-se superior à regressão quando a não linearidade entre as variáveis for maior.

2. Preço do cobre

Com este trabalho pretende-se encontrar bons modelos de previsão para o preço do cobre. Entretanto, como discutido, por exemplo, em Machmahon *et al* (2010), Lima *et al* (2010), Sobreiro *et al* (2008), há uma grande diferença na qualidade da previsão e emprego da melhor técnica de modelagem de acordo com a periodicidade da série em questão. Por esse motivo, é necessário especificar o campo de atuação deste trabalho, uma vez que o custo de modelagem para as diferentes periodicidades é significativo.

Pretende-se, nesta obra, buscar bons modelos de previsão para a série de preços do cobre *spot* de frequência diária na *London Mercantile Exchange* (LME), pois essa bolsa, como afirma Geman e Smith (2012) é, desde 1977, o principal centro de trocas para *commodities* metálicas e o mais líquido para metais de base. A escolha da periodicidade se deu através da crença de que a periodicidade diária é pouco explorada e de grande valor para o mercado financeiro, de *day-trade*, e empresas que operam diretamente com a matéria prima, o cobre.

O cobre, negociado na *London Mercantile Exchange* (LME), possui diversos contratos. Neste trabalho, será usado o contrato *spot* cotado em dólares por tonelada e tamanho de 25 toneladas por contrato. Por esse motivo, não será abordada a discussão de retorno de conveniência que gira ao redor dos preços futuros apresentada em Geman e Smith (2012) e Pereira (2009).

Ao coletar a série de preços do cobre mencionada, podemos ver pelo Gráfico 2.1 uma clara mudança de patamar devido à entrada da China no mercado. Por esta razão e o fato de se trabalhar com a periodicidade diária, foi escolhida para este trabalho uma amostra de aproximadamente cinco anos. Com isso, ao começar a análise e construção dos modelos em agosto de 2007 não há problemas referentes ao tamanho amostral. Além disso, a nova dinâmica de mercado já está consolidada para os principais *players* do mercado e incorporada nas variáveis explicativas utilizadas nos modelos de previsão.

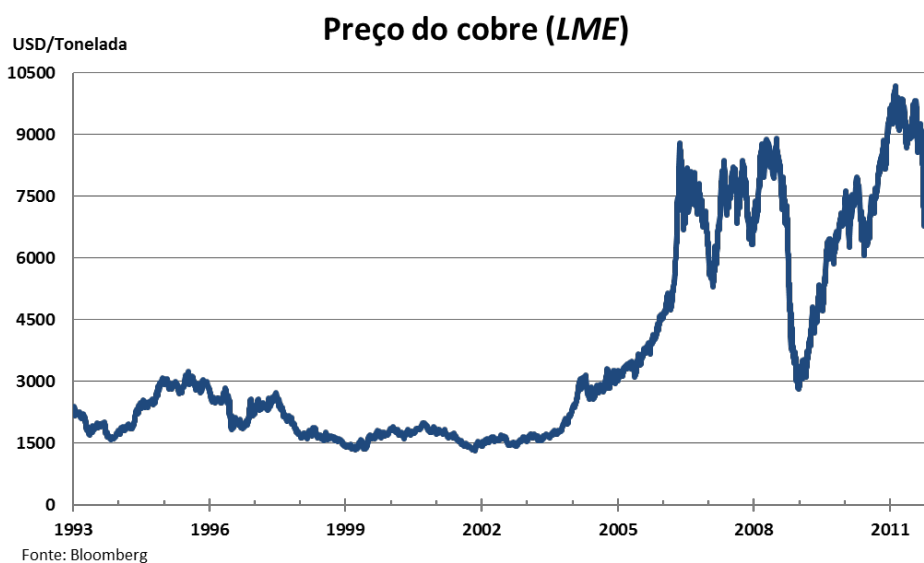


Gráfico 2.1 – Preço do cobre na *London Mercantile Exchange* desde 1993.

Entretanto, ao pensar na construção de posições especulativas, existiriam muito mais opções caso os modelos pudessem ser generalizados para o primeiro futuro, uma vez que o preço *spot* é parte importante da equação de precificação dos futuros (Geman e Smith, 2012 e Pereira, 2009). Através desta motivação, foi feita uma rápida análise do diferencial entre o preço *spot* e o primeiro futuro do contrato de cobre na bolsa de Londres.

Como se pode observar no Gráfico 2.2 e nas tabelas 2.1 e 2.2 abaixo, o mercado do primeiro contrato futuro e *spot* se aproximaram muito no período analisado neste trabalho, provavelmente, entre outros fatos, pelos integrantes do mercado de cobre terem internalizado a nova dinâmica de preços. Sendo assim, ao observar as tabelas, podemos ver que a correlação entre a variação diária dos preços é maior, no período analisado neste trabalho, e a média do diferencial da variação diária entre os dois contratos é praticamente zero. Deste modo, é possível pensar, em termos práticos, na variação diária do preço *spot* como sendo a variação do primeiro contrato futuro e abrir um leque maior de aplicações para os resultados aqui encontrados.

Diferencial da variação percentual entre *spot* e primeiro futuro*




Gráfico 2.2 – Diferencial da variação percentual entre *spot* e primeiro contrato futuro em função do tempo.

| Média do diferencial da variação percentual diária entre <i>spot</i> e primeiro futuro* | |
|---|----------|
| Período: | Média |
| 03/01/2000 - 16/11/2012 | -0.0005% |
| 03/01/2000 - 30/07/2007 | -0.0009% |
| 01/08/2007 - 16/11/2012 | 0.0001% |

* Valores negativos indicam a magnitude (em pontos percentuais) da maior variação média do preço *spot* em relação ao primeiro futuro.

Tabela 2.2 – Média do diferencial da variação percentual diária entre *spot* e primeiro futuro.

| Correlação da variação percentual diária entre <i>spot</i> e primeiro futuro | |
|--|------------|
| Período: | Correlação |
| 03/01/2000 - 16/11/2012 | 99.40% |
| 03/01/2000 - 30/07/2007 | 98.69% |
| 01/08/2007 - 16/11/2012 | 99.92% |

Tabela 2.1 – Correlação da variação percentual entre *spot* e primeiro contrato futuro.

3. Teoria dos modelos

3.1. GARCH

Ao buscar prever os valores da série de preço do cobre, não se pode admitir, como na maioria dos modelos, variância constante (homocedasticidade) para a série. Isso ocorre, pois, como apontado em Heij *et al* (2004), a variância é uma medida de risco e incerteza para os valores futuros da série. Como explicado em seu livro, a variância de ativos financeiros depende da volatilidade dos preços de mercado, ou seja, altera-se ao longo do tempo. Machmahon *et al* (2010) também acrescenta a essa discussão que, por serem expostos a altos níveis especulativos, os preços das *commodities* metálicas da *London Mercantile Exchange*, por exemplo, têm sua volatilidade acentuada e até mesmo picos momentâneos com choques de informação. Para tanto, surge a necessidade, como será feito neste trabalho, de modelar a variância condicional da série do cobre através de um modelo apropriado para se obter medidas de previsões mais acuradas, capturando os diferentes momentos do mercado.

Primeiramente, foi escolhido um modelo GARCH (*Generalized ARCH*) por este ser mais parcimonioso e apresentar menos parâmetros MA (*Moving-Average*) e AR (*Autoregressive*) que um modelo ARCH. Além disso, também será testado um modelo GARCH-M, uma vez que este foi sugerido como um dos melhores modelos de previsão por Machmahon *et al* (2010) devido à variância condicional também afetar a equação da média. Vale ressaltar que se espera um aumento significativo da eficiência de previsão para o GARCH-M devido a uma aparente alteração estrutural no mercado do cobre após a entrada da China.

Segundo apresentado em Heij *et al* (2004), uma série possui heterocedasticidade condicional quando sua variância depende do passado. Caso essa dependência possa ser representada por um processo *autoregressivo*, chama-se o modelo de *autoregressive conditional heteroscedasticity* ou, de forma abreviada, ARCH.

Por exemplo, um modelo ARCH de ordem 1 para uma série y_t , ruído branco, pode ser representado pela seguinte expressão:

$$y_t = \mu + \varepsilon_t, \quad \varepsilon_t | Y_{t-1} \sim N(0, \sigma_t^2), \quad \sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 .$$

Vale ressaltar que todos os parâmetros da equação da variância são não-negativos, pois a variância não assume valores negativos. Na equação anterior, vemos que a variância de y_t é condicionada, pois depende do passado da série, no caso, um período anterior.

Com o modelo GARCH (*Generalized ARCH*), como explica Morettin (2008), é possível obter um modelo para volatilidade mais parcimonioso (menor número de parâmetros) que um modelo ARCH. Isso ocorre, como demonstrado em Heij *et al* (2004), pois a série de inovações ao quadrado (ε_t^2) de um ARCH(1), por exemplo, pode ser representada por um modelo AR(1), enquanto, em um GARCH(1,1), essa mesma série segue um ARMA(1,1), permitindo a criação de modelos mais parcimoniosos.

Por exemplo, um modelo GARCH(1,1) pode ser representado pela seguinte expressão:

$$y_t = \mu + \varepsilon_t, \quad \varepsilon_t | Y_{t-1} \sim N(0, \sigma_t^2), \quad \sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \alpha_2 \sigma_{t-1}^2,$$

onde se observa o termo ARCH (quadrado do resíduo, na primeira defasagem, da equação da média) e a inclusão do termo GARCH (a variância prevista no *lag* anterior, no caso da primeira defasagem). Novamente, vale acrescentar que todos os parâmetros da equação da variância são não-negativos pelos mesmos motivos.

De forma geral, define-se um modelo GARCH(q, p) através da escolha da ordem de defasagens q do termo GARCH (σ_t^2) e p do termo ARCH (ε_t^2). Dessa forma, um processo GARCH(0, p) equivale a um ARCH (p) e a equação da variância de um GARCH(q, p) pode ser representada por

$$\sigma_t^2 = \alpha_0 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2 + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2.$$

Segundo Enders (2004), um modelo GARCH-*in-Mean* (GARCH-M) permite que a média da série dependa de sua própria variância condicional. O autor também destaca que esse tipo de modelo é adequado para capturar o prêmio pelo risco exigido pelos agentes avessos ao risco, pois quanto maior a variância condicional dos retornos, maior a compensação que os agentes irão requerer para reter os ativos no longo prazo. Portanto, a partir da descrição anterior, é possível entender alguns motivos que podem conceder ao modelo GARCH-M uma qualidade de previsão superior, como encontrado por Machmahon *et al* (2010) ao modelar a volatilidade da variância com impacto na equação da média.

Como exemplo, é interessante observar abaixo a equação da média para um GARCH-M clássico, onde a variância tem impacto na equação da média,

$$y_t = \mu + \gamma \sigma_t^2 + \varepsilon_t.$$

Entretanto, existem variações do modelo GARCH-M onde o desvio padrão ou até mesmo o log da variância condicional têm impacto na equação da média. As equações da média para o impacto do desvio padrão e do log da variância condicional, respectivamente, podem ser representadas da seguinte forma:

$$y_t = \mu + \gamma\sigma_t + \varepsilon_t ,$$

$$y_t = \mu + \gamma\ln(\sigma_t^2) + \varepsilon_t .$$

Logo, esta obra pretende, com as teorias apresentadas, construir modelos de previsão que modelem a média e a volatilidade das séries através de diferentes modos para um dado vetor de variáveis explicativas detalhado na seção Metodologia deste trabalho.

3.2. Redes neurais artificiais

A ideia de redes neurais surgiu na década de 40 com a intenção de criar máquinas com capacidade de aprendizado através de modelos matemáticos que replicassem um neurônio humano de forma artificial. Com o passar do tempo, foram desenvolvidos modelos e até neurocomputadores. Entretanto, com a crítica realizada no final da década de 70 aos modelos devido à impossibilidade de solução da função lógica XOR (*Exclusive Or*), as pesquisas perderam força.

Na década de 80 emergiu uma solução para o problema através de neurônios com aprendizado não supervisionado. Essa técnica permitiu o ressurgimento das redes neurais e de técnicas como a retropropagação, múltiplas camadas, aprendizado competitivo, auto-organização da rede neural e até mesmo *clusters* (criação de um protótipo do padrão aprendido).¹

Abdi, Valentin e Edelman (1999) definem redes neurais como modelos estatísticos adaptativos baseados na estrutura do cérebro. Segundo os autores, esses modelos podem ser considerados adaptativos devido à sua capacidade de aprendizado, ou seja, eles podem aprender a estimar parâmetros de uma população através de uma amostra. Contudo, Marquez *et al.*² vão mais além e apresentam as redes neurais artificiais (RNA) como uma alternativa viável às regressões econométricas, pois os modelos são capazes de aprender com a experiência, podem generalizar e “enxergar” através de ruídos e distorções, podendo até mesmo abstrair características essenciais na presença de dados irrelevantes. Os autores também destacam que esses modelos são capazes de fornecer um alto grau de robustez e encontrar as transformações corretas para as variáveis, detectar relações de linearidade fracas e inclusive tratar *outliers*.

¹ A história das redes neurais é apresentada com maior riqueza de detalhes em Freiman e Pamplona (2005).

² Autores do capítulo 26 do livro “Neural networks in finance and investing: using artificial intelligence to improve real-world performance”

Para ilustrar uma rede neural de retropropagação, pode-se usar como exemplo uma RNA com três camadas, ou seja, uma camada de entrada, uma camada oculta (com três neurônios no exemplo) e uma camada de saída. Na camada de entrada, como explica Freiman e Pamplona (2005), alimenta-se a rede neural artificial com o conjunto de variáveis relevantes para o estudo. Em seguida, como demonstrado detalhadamente em Abdi, Valentin e Edelman (1999), toda essa informação da camada de entrada é “ativada” através da ponderação por diferentes pesos para cada neurônio e, então, transformada por uma função de transformação não linear (com o intuito de permitir soluções para todos os tipos problemas). Logo, como se pode ver na Figura 3.2.1, essa informação é transferida para a camada de saída, onde recebe novos pesos para cada valor proveniente dos neurônios da camada oculta e transformada pela mesma função de transformação anterior, gerando um valor de saída.

Entretanto, por ser uma rede de retropropagação, ela é capaz de aprender e se aprimorar retroativamente. Para isso, os dados da camada de saída são comparados com o valor esperado e, então, esse erro é retropropagado para a camada oculta, gerando novos pesos, como exemplificado na Figura 3.2.2. Em seguida, com os novos pesos, calculam-se os novos valores da camada oculta para uma nova previsão, como é possível observar na Figura 3.2.3. Esse processo repete-se até que o erro seja minimizado e os pesos adequados sejam identificados.

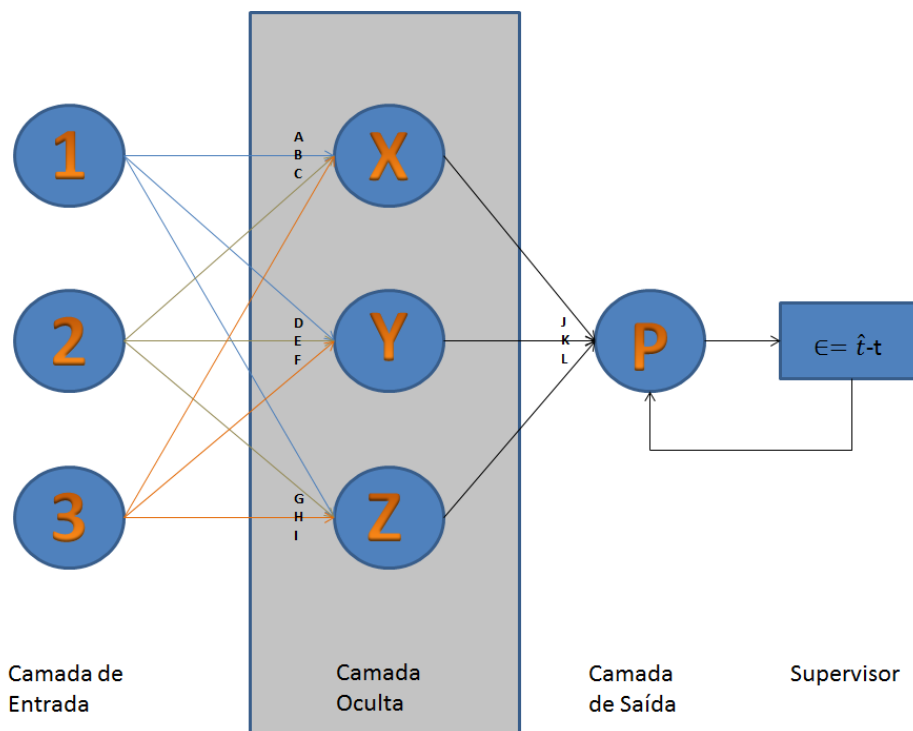


Figura 3.2.1 – Explicação rede neural artificial de retropropagação 1

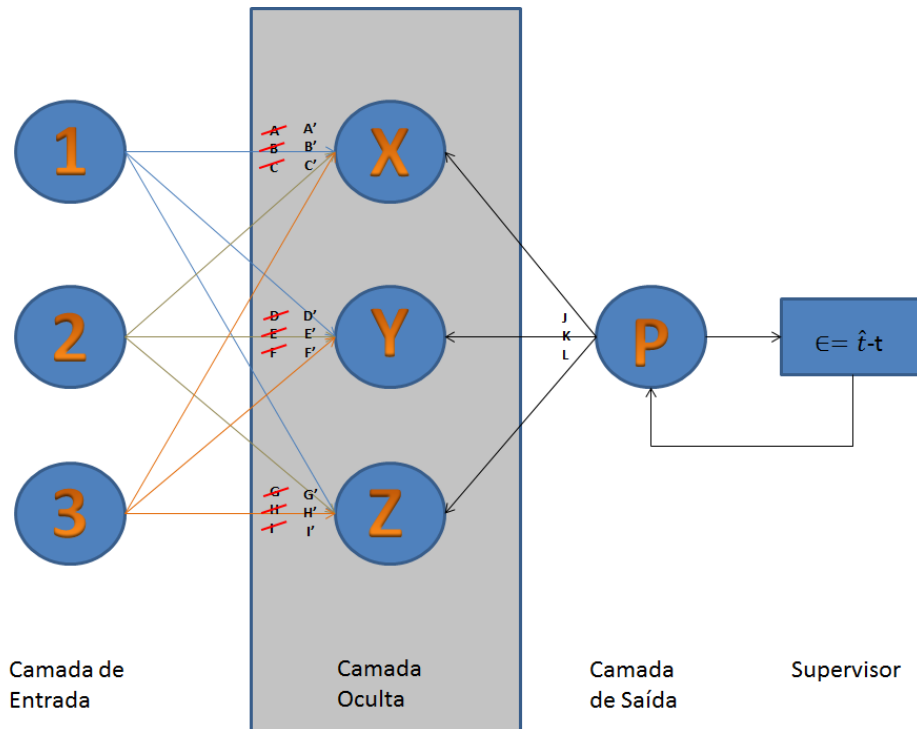


Figura 3.2.2 - Explicação rede neural artificial de retropropagação 2

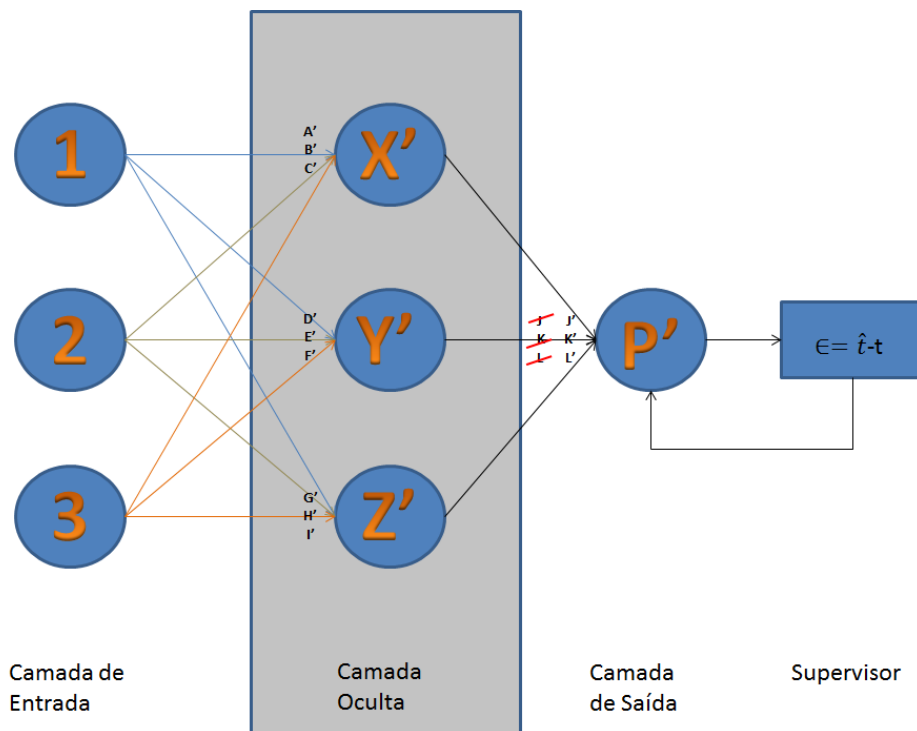


Figura 3.2.3 - Explicação rede neural artificial de retropropagação 3

Portanto, através da aplicação da teoria de RNA de retropropagação, espera-se construir modelos de previsão precisos para a variação diária da série do preço do cobre na *London Mercantile Exchange*. Para calibrar o modelo, devem ser testadas as mesmas variáveis explicativas dos modelos econométricos descritas em maiores detalhes na seção 4.1 do trabalho.

4. Metodologia

Para a realização dos modelos propostos, será necessário o uso de alguns dados, a realização da interpolação, como explicado em detalhes adiante, e algumas medidas de comparação entre os resultados. Primeiramente, entre os dados coletados, se encontram as séries de preço e volume diários de negociação na *London Mercantile Exchange* (Bloomberg *Ticker*: LMCADY Comdty). Em seguida, os demais dados e suas defasagens, os quais são discutidos em detalhes mais à frente.

Utilizando as séries consideradas relevantes para modelagem, o processo de identificação dos melhores modelos de previsão será realizado com a aplicação das técnicas de modelagem descritas em suas respectivas seções. Para a realização dos modelos GARCH e GARCH-M, será usado o software Eviews 7.0 (incluindo sua programação) e, para a elaboração da RNA, será usado o Matlab R2010a.

Finalmente, com todos os modelos em mãos e os valores previstos, os resultados parciais serão discutidos individualmente e, em seguida, comparados entre si. Após a comparação, espera-se chegar a uma conclusão positiva, agregando conhecimento à literatura de previsão de commodities.

4.1 Variáveis

Para a realização deste trabalho, é de extrema importância a escolha das variáveis, pois através delas espera-se modelar parte do ruído presente na série diária, que ocorre devido às correlações com os movimentos de mercado, divulgações e a alta frequência de *trading*. Para tanto, foram escolhidos alguns tipos de séries como: preços, que carregam bastante informação em si e não possuem muitos *lags* de correlação com seu passado; custos, para capturar aumentos de custo de produção; oferta e demanda, pois juntos os dois têm a capacidade de encontrar variações no preço; estoques, altamente relevantes para *commodities*; economia, para capturar a intensidade dos crescimentos; riscos, com o intuito de capturar níveis de aversão ao risco e aumentos de prêmio exigidos; câmbio, pois traz informações importantes sobre os termos de troca dos principais produtores e compradores.

É importante ressaltar que todas as variáveis estão disponíveis em qualquer terminal Bloomberg, de modo que a constituição do modelo é completamente acessível a qualquer instituição financeira. Além disso, o modelo pode ser atualizado com os novos dados diariamente e sem altos custos ou perda de tempo, ativos valiosos.

A seguir, serão apresentadas e discutidas as variáveis testadas nos modelos para explicar sua relevância e o porquê das escolhas.

1) Preço do cobre *spot* (*London Mercantile Exchange*) & Volume

O preço do cobre é uma importante variável para o modelo, pois seus *lags* e o volume de negociação podem trazer informações relevantes sobre o passado e a liquidez implícita no preço. Desse modo, espera-se capturar o movimento intenso de *players* do mercado (instituições financeiras e empresas) que possam estar causando *stress* e aumentando a volatilidade.

2) Índice de fretes do mar báltico (*Baltic Dry Index*)

O *Baltic Dry Index* é calculado diariamente pela *Baltic Exchange* através de uma enquete com os mais de 600 membros sobre os preços de frete para quatro diferentes tamanhos de embarcações e ponderado com pesos iguais.

O índice de fretes do mar báltico para as diferentes partes do mundo é amplamente usado na literatura como indicador dos custos de transporte de matéria-prima. Espera-se que com esse índice capture-se antecipadamente um aumento nos custos da *commodity* e ele sirva também como variável *leading* para movimentos da economia, pois é um indicador de oferta e demanda do início da cadeia de produção.

É importante ressaltar que existem algumas críticas ao índice, por ele ser demasiadamente volátil, indicando “falsos” movimentos na economia. Entretanto, o fato de existirem outras variáveis no modelo com o mesmo intuito de controle, o extenso histórico da série, a dificuldade de se encontrar indicadores diários com baixo ruído e o fato de não haver especulação sobre ele, ou seja, apenas aqueles que buscam a *commodity* física atuarem nesse mercado, acredito que esse índice de fretes agregue bastante informação e seja capaz de explicar parte do ruído na variação diária do preço *spot* do cobre.

3) Estoque de cobre na *London Mercantile Exchange*

O nível de estoques na bolsa de Londres é um indicador adequado da disponibilidade de cobre em Londres, gerando um prêmio pela *commodity* física e afetando o preço *spot*, como demonstram Geman e Smith (2012).

4) Estoques de cobre na COMEX

O nível de estoques na *COMEX* é outro indicador de estoque adequado devido à importância dessa bolsa no mercado de cobre. Além disso, com a adição de outras bolsas além da *LME*, é possível “criar” um nível global de estoques com pesos diferentes de acordo com a localidade do estoque e a importância da bolsa.

5) Cobre depositado como garantia nos contratos futuros na *Shanghai Futures*

Exchange

Como discutido anteriormente neste trabalho, a China é o mais importante comprador do cobre, de modo que a bolsa de Shanghai é altamente relevante para a *commodity*. Sendo assim, os estoques de cobre depositados como garantia devem indicar a falta e a sobreoferta do bem, impactando diretamente no preço.

Além disso, como apresentado por Geman e Smith (2012), os estoques metálicos da China são capazes de agregar informação e fortalecer as relações de volatilidade do mercado *spot* e estoques, de modo que a tese de números não confiáveis do país é refutada para este caso.

6) Câmbio – China

Como os contratos de cobre são cotados em dólar, o câmbio chinês é relevante, pois reflete o preço da *commodity* no mercado do principal consumidor global, a China, indicando assim o melhor momento de atuação do país no mercado *spot* do cobre.

7) Câmbio – Chile

Por ser o Chile o país com as maiores reservas de cobre (23,6% das reservas mundiais segundo o Deutsche Bank (2011)) e também o principal exportador, o país andino tem grande parte de sua receita e atenção voltadas para o mercado de cobre. Desse modo seu câmbio é um candidato relevante para o preço.

8) Câmbio – Austrália

A Austrália possui a terceira maior reserva de cobre, aproximadamente 12,6% das reservas mundiais segundo o Deutsche Bank (2011). Sendo assim, seu câmbio também é um candidato relevante para o preço.

9) Câmbio – Peru

O Peru possui a segunda maior reserva de cobre, aproximadamente 14,2% das reservas mundiais segundo o mesmo relatório do Deutsche Bank (2011). Portanto, como grande exportador, também deve ser considerado seu câmbio.

10) Preço do cobre *spot* na bolsa chinesa de *Shanghai Changjiang*

A variação diária do mercado chinês de cobre deve trazer informações relevantes para o preço, pois representa o maior consumidor desse bem e opera em um fuso que, muitas vezes, comercializa com um conjunto de informações diferentes dos mercados americano e europeu, podendo agregar informações.

11) Preço *spot* do cobre na *COMEX*

Como mencionado anteriormente neste trabalho e em Geman e Smith (2012), a *COMEX* é um mercado livre e importante para a *commodity* metálica em análise. Desse modo, existe certa paridade entre os preços que podem acrescentar informações aos modelos.

12) VIX

O VIX é um índice que representa a volatilidade do mercado de futuros na bolsa de opções de Chicago. Ele é calculado através de uma média ponderada da volatilidade de diversos preços de *strike* no primeiro e segundo futuros.

Esse índice de volatilidade é capaz de capturar o *stress* e a exigência de um maior prêmio para os mercados. Além disso, o *stress* é um indicador que define as decisões de compra e venda no mercado, alterando a volatilidade dos ativos.

13) Índice de volatilidade chinês *AlphaShares* (*CHIX*)

O “*AlphaShares Chinese Volatility Index*” ou *CHIX* é um índice de autoria da AlphaShares que tem como objetivo medir a volatilidade no mercado chinês. O teórico por trás de sua inclusão neste trabalho é o mesmo do VIX, entretanto, espera-se capturar uma volatilidade mais localizada no principal comprador da *commodity*, uma vez que pequenas variações na China, ou até rumores têm forte impacto para o cobre.

14) Índice da bolsa de Shanghai & Volume

Com o índice da bolsa de Shanghai espera-se capturar a saúde do mercado chinês e uma maior demanda pelos produtos. Com o volume pode-se capturar alterações na liquidez e mudanças no interesse e especulação.

15) S&P500 & Volume (SPX)

Através do índice S&P 500 e seu volume de negociações espera-se que estas variáveis representem comportamento de humor do mercado, tendência, aquecimento e demanda.

16) S&P 500 das empresas da indústria de equipamento elétrico & Volume

Assim como o SPX, o intuito da inclusão de empresas de equipamento elétrico é para capturar mudanças na demanda por cobre, uma vez que elas são demandantes do cobre em estágios posteriores à *commodity* bruta.

17) S&P 500 das empresas de equipamentos eletrônicos e instrumentos & Volume

Assim como o SPX, o intuito da inclusão de empresas de equipamento elétrico é para capturar mudanças na demanda por cobre, uma vez que elas são demandantes do cobre em estágios posteriores a *commodity* bruta. Produtos eletrônicos representam, segundo relatório do Deutsche Bank (2011), 33% do consumo final do cobre.

18) Índice global de bolsas & Volume

O “*FTSE-All World Index*” é um índice ponderado que inclui empresas *Large* e *Mid cap* de diferentes bolsas ao redor do mundo de mercados desenvolvidos e emergentes. Com a inclusão dessa variável, espera-se capturar movimentos de demanda globais.

19) Índice de bolsas dos mercados desenvolvidos & Volume

Esse índice é composto por empresas imobiliárias de capital aberto na América do Norte, Europa e Ásia. Com ele, espera-se capturar valores do mercado imobiliário, o qual corresponde a aproximadamente 33% da demanda pelo produto final do cobre segundo o Deutsche Bank (2011). Acredita-se em sua relevância devido à correlação do valor das empresas imobiliárias com a venda de imóveis, a qual, por sua vez, está correlacionada à oferta de novos empreendimentos e ao consumo de cobre na construção.

20) Câmbio – Dólar (DXY)

Como os contratos são cotados em dólar, pode-se pensar no cobre como uma moeda alternativa. Desse modo, com a depreciação do dólar contra uma cesta de moedas, o preço do cobre deve se valorizar como explica Geman (2012).

21) Índice de preços *spot* de metais preciosos

De acordo com Geman (2012), diferentes commodities são correlacionadas, devido à existência de *ETFs*, efeitos macroeconômicos, competição por recursos, dependência na cadeia de produção e substitutibilidade. Dessa forma, é de extrema importância analisar o impacto de variações nos preços de metais preciosos no cobre.

22) Índice de preços *spot* de commodities agrícolas

Assim como o efeito de metais preciosos pode ser significativo, é importante levar em consideração *commodities* agrícolas, pois aumentos nos preços de alimento podem impactar no cobre por diversos canais.

23) Índice de preços *spot* de metais industriais

Como explicado anteriormente, Geman (2012) argumenta que existe efeito de substitutibilidade entre as *commodities*. Portanto, deve-se testar um índice de metais industriais, pois o alumínio, por exemplo, é um substituto para o cobre em diversos usos como equipamentos elétricos, radiadores de automóveis e até mesmo cabos de força.

24) Índice de preços *spot* de commodities energéticas

Parte dos motivos trazidos por Geman (2012) em sua apresentação para a correlação entre as *commodities* é o fato de estas serem usadas na cadeia de produção. Logo, não existe motivo para não acreditar que *commodities* energéticas não devam impactar nos preços de cobre, uma vez que são utilizadas na mineração e até mesmo no transporte do bem em seus diversos estágios.

4.2 Interpolação

Como pode ser observado, as séries descritas no item anterior estão claramente espalhadas ao redor do mundo, ou seja, não estão sujeitas aos mesmos feriados e dias úteis.

Em razão deste fato, existe um problema na incorporação assimétrica das novas informações disponíveis naquele dia. Para lidar com esta situação existem duas alternativas.

Primeiro, poderiam ser excluídos da amostra, de todas as variáveis, os dias úteis em que a bolsa de Londres não estivesse aberta para negociação dos contratos de cobre. Todavia, ao realizar este procedimento, as séries não estariam incorporando toda a informação disponível até o dia anterior e os modelos perderiam qualidade de previsão, uma vez que fatos relevantes poderiam estar ocorrendo e não sendo levados em consideração.

Em segundo lugar, que é o método escolhido neste trabalho, é possível considerar todos os dias entre segunda-feira e sexta-feira como dias úteis em que novas informações podem ser incorporadas ao mercado mesmo quando não há negociações. Para isso, deve-se fazer uso de técnicas de interpolação que possam “suavizar”, da melhor maneira possível, as quebras nas séries e melhorar a qualidade de previsão dos modelos.

Nesta obra optou-se por duas técnicas de interpolação para todas as séries, aplicadas através do software Eviews 7.0. Inicialmente, é realizada uma interpolação não linear, pela crença de que a informação disponível entre dois períodos não é incorporada de modo linear, e, em um segundo momento, uma interpolação linear para os casos em que não é possível realizar a interpolação não linear por não haver dois dias de trocas consecutivas antes e depois do período de feriados ou quebra na série utilizada.

A interpolação não linear é feita através da técnica *Catmull-Rom Spline* (CRS), um caso especial da *Cardinal Spline* (CS), onde não se altera a curvatura do *spline*, ou seja, o parâmetro de tensão K é zero. Esse método foi escolhido por representar melhor a realidade ao incorporar informação de modo não linear, mesmo que para um período curto de apenas alguns dias, e, por não haver grandes ganhos em buscar o melhor parâmetro de curvatura do *spline* para um período tão curto.

Em seguida, é realizada a interpolação linear (lin) para que as séries não possuam valores omitidos devido a feriados e afins. É necessária a utilização desta técnica em sequência à anterior, pois não é possível realizar a interpolação por *Catmull-Rom Spline* caso não haja dois valores não observados em sequência antes e depois do número em que se está realizando a interpolação.

Os métodos mencionados acima podem ser detalhados pelas seguintes equações

$$X_{iCS} = (2\lambda^3 - 3\lambda^2 + 1)X_{i-1} + (1 - K)(\lambda^3 - 2\lambda^2 + \lambda)(X_{i+1} - X_{i-2}) - (2\lambda^3 - 3\lambda^2)X_{i+1} + (1 - K)(\lambda^3 - \lambda^2)(X_{i+2} - X_{i-1}) ,$$

$$X_{i\text{CRS}} = (2\lambda^3 - 3\lambda^2 + 1)X_{i-1} + (\lambda^3 - 2\lambda^2 + \lambda)(X_{i+1} - X_{i-2}) - (2\lambda^3 - 3\lambda^2)X_{i+1} \\ + (\lambda^3 - \lambda^2)(X_{i+2} - X_{i-1}) ,$$

$$X_{i\text{lin}} = (1 - \lambda)X_{i-1} + \lambda X_{i+1} ,$$

onde X_{i+m} e X_{i-m} representam o m-ésimo número não observado após e antes, respectivamente, ao valor que se busca interpolar e λ é igual à posição relativa do valor não observado em relação ao total de valores não disponíveis em sequência.

4.3 Medidas de erro

Para medir a qualidade dos modelos gerados e seu potencial serão usadas as medidas de erro descritas nesta seção para comparar os resultados gerados pelo GARCH, GARCH-M e a rede neural artificial.

1) Erro quadrático médio (EQM)

O erro quadrático médio (EQM) é uma medida de erro clássica e amplamente utilizada para comparação entre modelos. Esta medida penaliza grandes desvios do real valor observado independente de o erro ser para mais ou para menos devido ao termo quadrático. A equação é dada por:

$$EQM = \frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{n} ,$$

onde y_t é a série de preços *spot* do cobre no instante t, \hat{y}_t é o valor previsto no mesmo instante pelo modelo e n é o horizonte de previsão (69 dias).

2) Erro absoluto médio (EAM)

A medida de erro absoluto médio (EAM) é interessante de se observar, por trazer, através de uma ótica diferente, um resultado na mesma unidade da série do cobre, ou seja, dólares por tonelada. Além disso, este método não irá penalizar tanto um modelo como o EQM. Caso este incorra em um grande erro de previsão em apenas um dia, esse valor será menor. O erro absoluto médio (EAM) pode ser calculado pela seguinte equação:

$$EAM = \frac{\sum_{t=1}^n |y_t - \hat{y}_t|}{n},$$

onde y_t é o preço *spot* do cobre observado na LME no instante t , \hat{y}_t é o valor previsto no mesmo instante pelo modelo e n é o horizonte de previsão (69 dias).

3) Percentual de acerto da direção da variação diária do preço (PADV)

Muito importante, também, para comparar a qualidade dos modelos é medir a porcentagem de vezes que este é capaz de acertar corretamente o sinal da variação diária do preço. Com isso, podem-se usar, no mercado financeiro, os modelos como auxiliares para operações de *day-trading* e indicadores da variação diária. Para tanto, foi utilizada a seguinte medida:

$$f(y_t) = \begin{cases} 1, & \text{se } \text{sinal}\left(\frac{y_t - y_{t-1}}{y_t}\right) = \text{sinal}\left(\frac{\hat{y}_t - \hat{y}_{t-1}}{\hat{y}_t}\right) \\ 0, & \text{se } \text{sinal}\left(\frac{y_t - y_{t-1}}{y_t}\right) \neq \text{sinal}\left(\frac{\hat{y}_t - \hat{y}_{t-1}}{\hat{y}_t}\right) \end{cases},$$

$$PADV = 100 \times \frac{\sum_{t=1}^n [f(y_t)]}{n},$$

onde y_t é o preço *spot* do cobre observado na LME no instante t , \hat{y}_t é o valor previsto no mesmo instante pelo modelo e n é o horizonte de previsão (69 dias).

Logo, com as medidas descritas acima é possível quantificar o erro do modelo. Porém, como o preço por tonelada de cobre é relativamente elevado, é interessante observar a porcentagem do erro sobre o preço médio do período de previsão. Pensando nisso, foram usadas as seguintes derivações do EQM e EAM.

1) Raiz do erro quadrático médio relativo ao preço médio (REQM/ P_M)

A raiz do erro quadrático médio (REQM) tornará a unidade de medida do erro quadrático médio (EQM) a mesma que a série de preços, sendo assim, comparável. Isto capacita o cálculo do erro em porcentagem do preço. A equação é dada por

$$\frac{REQM}{P_M} = 100 \times \frac{\sqrt{\frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{n}}}{\frac{\sum_{t=1}^n (y_t)}{n}},$$

onde as nomenclaturas seguem o mesmo padrão já mencionado.

2) Erro absoluto médio relativo ao preço médio (EAM/ P_M)

Como explicado anteriormente nesta seção, o erro absoluto médio (EAM) é capaz de abordar a temática do erro de previsão com uma menor penalização para altos erros pontuais. Além disso, o EAM, por se encontrar na mesma unidade de medida que a série de preços, não necessita de transformação para o cálculo da representatividade do valor em relação ao preço médio praticado no mercado durante o horizonte de previsão. Logo, a equação é dada por

$$\frac{EAM}{P_M} = 100 \times \frac{\frac{\sum_{t=1}^n |y_t - \hat{y}_t|}{n}}{\frac{\sum_{t=1}^n (y_t)}{n}},$$

com as nomenclaturas seguindo o mesmo padrão já descrito.

5. Modelos

Os modelos testados podem ser separados em duas categorias para explicação mais detalhada de suas peculiaridades. A primeira categoria, pertencente aos modelos GARCH, com o modelo GARCH(1,1) e o GARCH-M(1,1). E, em segundo lugar, a categoria da rede neural artificial (RNA), onde é descrita a rede neural artificial de retropropagação eleita entre as testadas.

5.1 GARCH

Ambos os modelos GARCH e GARCH-M seguem a teoria já mencionada. Entretanto, eles possuem algumas características que devem ser mencionadas antes da discussão dos resultados obtidos.

Primeiramente, deve-se destacar que ambos os modelos são reestimados diariamente dentro de uma janela amostral móvel com alteração dos coeficientes e possível alteração das variáveis explicativas consideradas relevantes no modelo da média. Ou seja, os modelos GARCH possuem parâmetros e coeficientes que variam diariamente.

As regressões econométricas foram construídas desta maneira para dar uma maior flexibilidade ao modelo de se adequar rapidamente às novas dinâmicas de mercado através da escolha das variáveis relevantes para a média e reduzindo o impacto da antiga dinâmica de mercado através o deslocamento da janela amostral utilizada. Através disso, espera-se obter um menor erro de previsão e, também, um modelo com capacidade de se perpetuar sem que tenha que incorrer em grandes perdas monetárias antes de ser reestimado.

A janela amostral escolhida tem como base os critérios já discutidos na Seção 2 e um período residual considerado adequado para se obter e comparar os resultados de previsão. Portanto, os modelos GARCH(1,1) e GARCH-M(1,1) possuem uma janela móvel de previsão com 1263 observações constante e, começando no ponto inicial, no intervalo entre 01/08/2007 e 01/06/2012. A partir de então, a janela amostral para cada modelo move-se de um em um dia para cada vez que a regressão é reestimada. Além disso, restam 69 observações na amostra para análise e comparação com os valores previstos.

Para as variáveis utilizadas, são testadas, com possibilidade de inclusão no modelo da média, todas as variáveis descritas (ver seção 4.1) com até sete *lags* de defasagem. Para a modelagem da variância são utilizadas variáveis de volume de negociação de ativos, por exemplo, o contrato de cobre, com até dois *lags* de defasagem sem alteração entre os modelos

ou ao longo do tempo. Isto, porque séries financeiras não costumam possuir muitos *lags* de correlação com o passado.

Para o modelo da média é testada uma maior quantidade de *lags* por haver séries não financeiras envolvidas, como, por exemplo, estoques de cobre, que podem ter uma maior dependência de *lags*.

5.2 Rede neural artificial de retropropagação

A rede neural artificial de retropropagação (RNA) (ver seção 3.2) foi construída no software Matlab R2010a com a utilização de todas as variáveis descritas (ver seção 4.1). Durante a construção da rede foram tomadas precauções para que o modelo não utilizasse variáveis contemporâneas, ou seja, apenas variáveis com um *lag* de defasagem são utilizadas como *input*.

Devido à maior flexibilidade dos modelos de redes neurais e relações não lineares, a construção da RNA envolveu um período amostral distinto, por ter capacidade de reconhecer a diferente dinâmica de mercado. Além disso, com esta técnica foi possível obter um horizonte de previsão maior (280 dias), dos quais foram utilizados para comparação com o GARCH e GARCH-M apenas os últimos 69 dias comuns aos três modelos.

A rede neural deste trabalho trabalhou com o período amostral compreendido entre 08/07/2005 e 14/07/2010 (1309 observações). Além disso, foi utilizada a amostra entre 15/07/2010 e 10/08/2011 (280 observações) para calibrar a rede, restando, desta forma, o intervalo entre 11/08/2011 e 06/09/2012 (280 observações) como horizonte de previsão.

A rede neural final utilizada neste trabalho foi construída com 80 neurônios e treinada através da função de treinamento *Levenberg-Marquardt Backpropagation* (trainlm). Com isso, foram obtidos resultados preliminares satisfatórios demonstrados posteriormente.

6. Resultados

A partir da construção dos modelos descritos na seção anterior é possível comparar seus resultados ao longo do horizonte de previsão comum de 69 dias. A rede neural artificial (RNA) criada, como explicado anteriormente, possui um horizonte de previsão total maior que os modelos econométricos, sendo desprezado da comparação o período não comum a todos os modelos deste trabalho.

Como mostra a tabela 6.1, os modelos econométricos possuem erro menor que a RNA tanto para o erro quadrático médio (EQM) como para o erro absoluto médio (EAM). Entre eles, destaca-se o GARCH-M, pois o fator de reversão à média diminuiu a variância do erro, mantendo praticamente o mesmo EAM que no modelo em que não há reversão à média.

| Horizonte de previsão: 69 dias | | | | | |
|-------------------------------------|-----------------|----------|-------|------------------------|-------------------|
| Modelos de previsão | Medidas de erro | | | Erro relativo ao preço | |
| | EQM | EAM | PADV | $\frac{REQM}{P_M}$ | $\frac{EAM}{P_M}$ |
| GARCH(1,1) | 9,014 | USD 72.4 | 55.1% | 1.26% | 0.96% |
| GARCH-M(1,1) | 8,825 | USD 72.3 | 53.6% | 1.25% | 0.96% |
| Rede Neural Artificial (RNA) | 11,470 | USD 79.7 | 62.3% | 1.42% | 1.06% |

Tabela 6.1 – Comparação dos modelos de previsão

À primeira vista, o erro encontrado pode parecer alto, mas, quando comparado à magnitude do preço médio praticado por contrato, observa-se algo interessante. Mesmo para a RNA, as medidas de erro utilizadas não passam de 1,5% do preço médio do contrato.

Contudo, mais importante, no mercado financeiro, que o conhecimento da magnitude do preço de fechamento do dia seguinte, é conhecer o real sinal da variação diária do preço. Para isso, foi utilizada a medida de percentual de acerto da direção da variação diária do preço (PADV) com o intuito de comparar o desempenho dos modelos neste quesito.

Pelos resultados apresentados na tabela anterior, é possível ver que o modelo de RNA apresentou um melhor desempenho na previsão do sentido da variação percentual diária. O modelo de RNA foi capaz de acertar o sentido da variação da cotação dos contratos em 43 dos 69 dias previstos. Enquanto isso, os modelos GARCH(1,1) e GARCH-M(1,1) apresentaram um desempenho inferior, apesar do menor erro de previsão. Entre eles, o GARCH-M, modelo com regressão à média e com melhor desempenho do EQM e EAM, possui o pior desempenho entre os três avaliados no quesito PADV.

Este interessante resultado, onde o modelo de maior EQM e EAM apresenta o melhor PADV, motivou a busca de sinergia entre eles para que perdas possam ser reduzidas e o risco de operar sobre os resultados também diminua. Ao invés de tratá-los como modelos concorrentes e buscar a superioridade de apenas um, passa-se a trabalhar com a complementariedade entre os modelos econométricos e de redes neurais.

No seguinte exercício, assume-se que sendo possível operar na abertura do dia com o mesmo preço de fechamento do dia anterior e liquidar a posição montada, com base na direção de variação do preço indicada por um ou dois modelos, no preço de fechamento do dia pode-se ganhar a variação do preço contrato de cobre naquele dia caso o modelo preveja corretamente a subida ou queda dos preços. Caso contrário, perde-se a quantia monetária equivalente à variação de preço, uma posição diária de alto risco e exposta a volumosas perdas dado o valor individual de cada contrato (188.020 dólares por contrato na média do período utilizado para previsão).

A ideia por trás desse exercício é realizar um experimento simples onde a suposição de preço de abertura igual ao fechamento do dia anterior e a capacidade de liquidação da posição pelo preço de fechamento do dia são válidas. Com isso, caso todos os modelos sob análise indiquem o mesmo sentido da variação diária, para cima, por exemplo, monta-se uma posição com compra de X contratos na abertura e venda de X contratos ao final do dia, realizando assim a variação diária e terminando o dia com a “posição zerada”. Caso os modelos indiquem uma variação negativa, monta-se a posição contrária. E, quando há divergência (no caso do uso dos modelos como complementares), abstem-se de negociações naquele dia, podendo ter a divergência impedido uma perda ou ganho monetário.

Foi escolhido como principal modelo a rede neural artificial (RNA) por apresentar o maior PADV. Logo, com a combinação do GARCH(1,1) ou GARCH-M(1,1), espera-se que tanto as perdas como os lucros sejam reduzidos, mas em magnitudes diferentes para cada combinação.

Como é possível perceber na tabela 6.2, a porcentagem de dias onde há ganhos nos modelos individuais é igual ao seu PADV. As perdas representam a porcentagem dos dias restantes, pois, não há uma divergência de resultados imposta por um modelo auxiliar que indique quando se deve abster de negociações.

Quando se realiza a combinação do modelo de RNA com um dos modelos econométricos, ocorre, como esperado, a redução de perdas e lucros. Isto porque não se negocia os contratos tanto em dias em que a rede neural estaria correta, evitando ganhos,

quanto em dias em que ela induziria ao erro. Mas, graças à divergência do modelo auxiliar, evitou-se uma perda nesse dia.

| Horizonte de previsão: 69 dias | | | | | |
|--------------------------------|------------------------|--------|------------------------------|------------------------------|-------|
| Modelos de previsão | Day-Trading - (% dias) | | | | |
| | Ganhos | Perdas | Modelo auxiliar evita perdas | Modelo auxiliar evita ganhos | Total |
| Rede Neural Artificial (RNA) | 62.3% | 37.7% | - | - | 100% |
| GARCH(1,1) | 55.1% | 44.9% | - | - | 100% |
| GARCH-M(1,1) | 53.6% | 46.4% | - | - | 100% |
| RNA + GARCH(1,1) | 42.0% | 21.7% | 13.0% | 23.2% | 100% |
| RNA + GARCH-M(1,1) | 42.0% | 23.2% | 11.6% | 23.2% | 100% |

Tabela 6.2 – Exercício de complementariedade dos modelos

Ao olhar para a combinação dos modelos, vemos que a principal diferença entre a combinação da RNA e dos modelos GARCH está na capacidade do modelo auxiliar evitar perdas. O uso do modelo GARCH-M(1,1) como auxiliar, sob a ótica levantada, é inferior como modelo auxiliar à RNA que o modelo GARCH(1,1). O modelo GARCH(1,1) é capaz de evitar mais perdas mantendo o mesmo percentual de ganhos e impacto “negativo” de reduzir os dias de lucros que o modelo de RNA obteria sem a intervenção deste.

Através da comparação do modelo RNA com a combinação deste com o GARCH(1,1), a razão de dias de perdas relativa aos dias de lucros (Perdas/Ganhos) se reduziu de 60,47%, considerando apenas a rede neural, e 81,58%, considerando apenas o GARCH(1,1), para 51,72% quando combinados os dois modelos.

Desta forma, o tratamento do GARCH(1,1) como modelo complementar à rede neural artificial é capaz de reduzir os dias de perdas relativos aos dias onde há ganhos, diminuindo o risco das posições propostas neste breve exercício ainda mais que a combinação com o modelo de reversão à média.

7. Conclusão

A partir da análise dos modelos criados, pode-se concluir que é possível modelar com qualidade a variação do preço *spot* diário do contrato de cobre ao controlar pelas variáveis discutidas neste trabalho. Também, como visto, o modelo criado para o preço *spot* pode ser estendido, sem grandes perdas, para o primeiro futuro do contrato de cobre da LME, aumentando o leque de oportunidades gerado com os resultados deste trabalho.

Em uma primeira observação das medidas de erro quadrático médio (EQM) e erro absoluto médio (EAM), pode-se pensar que os valores são elevados e o modelo GARCH-M(1,1) é o mais adequado. Entretanto, quando comparados com o preço médio dos contratos de cobre no período, nenhum modelo possui um erro que ultrapasse a marca de 1,5% do preço médio de cotação do contrato em nenhuma das medidas, sendo os erros relativos ao preço médio do cobre dos modelos econométricos praticamente idênticos.

Através das medidas utilizadas para comparação dos resultados entre o modelo de redes neurais artificiais de retropropagação (RNA), GARCH(1,1) e GARCH-M(1,1), pode-se concluir que, apesar do modelo RNA possuir o maior EQM e EAM, este é capaz de prever o sinal da variação diária do preço do contrato de cobre com melhor precisão que os modelos econométricos. O modelo de RNA é capaz de antecipar corretamente o sentido da variação diária em 62,3% dos 69 dias utilizados no horizonte de previsão, enquanto os modelos econométricos ficam com valores abaixo de 56% neste mesmo quesito.

Esta divergência entre as medidas de desempenho escolhidas motivou a realização de um rápido exercício de comparação (detalhado na seção 6) do desempenho prático individual dos modelos juntamente com o desempenho do RNA com cada um dos modelos econométricos como auxiliar na tomada de decisões de *day-trading*. Nesse exercício, concluiu-se que a combinação da RNA com o modelos GARCH(1,1) ou GARCH-M(1,1) é capaz de reduzir a porcentagem de dias de perda em relação aos dias de lucros. Entretanto, o resultado obtido pela combinação do modelo de redes neurais artificiais de retropropagação (RNA) com o GARCH(1,1) traz os melhores resultados de redução da volatilidade dos dias de perdas em relação aos dias de ganhos financeiros. É claro que esse resultado não provém apenas da redução das perdas, mas de uma redução nos dias de perdas maior que a redução nos dias de lucros.

Por fim, pode-se concluir deste trabalho que as técnicas utilizadas são positivas e apresentam ganhos financeiros, valendo o investimento de tempo em aprimoramento dos modelos, tanto de RNA como econométricos. Isto porque a utilização da RNA com o

GARCH(1,1) como modelos complementares se provou superior, através da ótica escolhida, no controle de risco. Além disso, o modelo de reversão à média mostrou ser o que melhor se aproxima do nível diário de preços, apesar do pior desempenho na identificação do sentido da variação de preços diários.

Referências

ABDI, Herve; VALENTIN, Dominique; EDELMAN, Betty. **Neural networks**. Thousand Oaks: SAGE, 1999. 90 p.

DEUTSCHE BANK. Global Market Research. Commodities. **A User Guide To Commodities**. London, 2011. 135 p.

ENDERS, Walter, 2004. **Applied econometric time series**. 3rd ed. Hoboken, NJ: Wiley, c2010. 517 p.

FREIMAN, José Paulo e PAMPLONA, Edson de O. Redes Neurais Artificiais na Previsão do Valor de Commodity do Agronegócio. V **Encuentro Internacional de Finanzas**. Santiago, Chile, 19 a 21 de janeiro de 2005

GEMAN, Hélyette. Theory of Storage and the Dynamics of Metals Forward Curves. **The Economics and Econometrics of Commodity Prices**. Rio de Janeiro, Brasil, 16 e 17 de agosto de 2012. Disponível em: < <http://www.epge.fgv.br/conferencias/commodity-prices/files/HelyetteGemanSlides.pdf> >. Acesso em: 22 set. 2012.

GEMAN, Hélyette; SMITH, William. **Theory of Storage, Inventory and Volatility in the LME Base Metals**. Forthcoming in Resources Policy, 2012. 37p. Disponível em: <<http://www.epge.fgv.br/conferencias/commodity-prices/files/HelyetteGeman.pdf>>. Acesso em: 22 set. 2012.

HEIJ, Christiaan; BOER, Paul de; FRANSES, Philip Hans, 1963; KLOEK, Teun; VAN DIJK, Herman K. **Econometric methods with applications in business and economics**. Oxford; New York: Oxford University Press, 2004. 787 p.

LIMA, Fabiano Guasti et al. Previsão de preços de commodities com modelos ARIMA-GARCH e redes neurais com ondaletas: velhas tecnologias - novos resultados. **Revista de Administração**, São Paulo, v. 45, n. 2, p.188-202, abr./jun. 2010.

LNCC. **Introdução às Redes Neurais**. Disponível em: <http://www.lncc.br/~labinfo/tutorialRN/frm1_introducao.htm>. Acesso em: 11 abr. 2012

MCMAHON, Sebastien et al. **Forecasting Aluminum Prices: GARCH, Jumps, and Mean-Reversion**. Quebec: GREEN, 2005. 15 p. Disponível em: <<http://www.green.ecn.ulaval.ca/chaire/2005/2005-5.pdf>>. Acesso em: 11 abr. 2012.

MORETTIN, Pedro A. **Econometria financeira: um curso em séries temporais financeiras**. São Paulo: Blucher, 2008. 319 p.

NEURAL networks in finance and investing: using artificial intelligence to improve real-world performance. New York: Irwin, c1993. xxviii, 513 p.

PEREIRA, Leonel M. **Modelo de formação de preços de commodities agrícolas aplicado ao mercado de açúcar e álcool**. São Paulo, 2009. 209 p. Tese (Doutorado) – Faculdade de Economia, Administração e Contabilidade, Universidade de São Paulo, São Paulo, 2009.

SOBREIRO, Vinicius Amorim et al. Uma estimação do valor da commodity de açúcar utilizando redes neurais artificiais. **Revista P&D em Engenharia de Produção**, São Paulo, n. 7, p.36-52, 2008.