

Um Comparativo entre o Modelo Autorregressivo Vetorial e o Modelo Computacional Newave-Decomp na Gestão da Previsão do Preço *Spot* de Energia Elétrica no Brasil

Adriano de Amarante – adriano.amarante@udesc.br

Universidade do Estado de Santa Catarina

Anderson Maccarini Coral – anderson.coral@eletrosul.gov.br

Eletrobras Eletrosul

Daniel Augusto de Souza – desouza.esag@gmail.com

Universidade do Estado de Santa Catarina

André Luís da Silva Leite – andre.leite@live.com

Universidade Federal de Santa Catarina

Resumo

Os agentes participantes do mercado brasileiro de energia elétrica atuam em dois ambientes de contratação de energia, agentes que adquirem ou vendem no Ambiente de Contratação Livre – ACL estão motivados em construir cenários e previsões aos preços *spot* de energia para contratar quantidades suficientes a um preço módico evitando risco de variações inesperadas e de alto nível de preços, sobretudo em períodos de escassez hídrica. Este problema também é enfrentado pelas distribuidoras de energia elétrica, que compram energia no Ambiente de Contratação Regulado – ACR, a diferença é que, a variabilidade dos preços afeta diretamente a gestão do fluxo de caixa. O objetivo deste estudo é comparar o Modelo de Vetor Autorregressivo - VAR como um instrumento de previsão dos Preços de Liquidação das Diferenças – PLD, com a tradicional construção de cenários aplicados ao algoritmo dos modelos computacionais Newave-Decomp utilizada pelos gestores de comercialização de energia elétrica. Neste estudo aplicou-se o método quantitativo, onde algumas métricas de ajuste das previsões foram calculadas para efetuar a comparação entre os modelos. Quanto aos dados, a variável que fez parte do quase-experimento foi o PLD do patamar médio. O teste para comparar a eficiência das previsões entre o modelo vetorial autorregressivo e Newave-Decomp *ex-ante* apresentou em algumas regiões menor erro de previsão comparado com o modelo Newave-Decomp para o mês de março de 2016. As métricas utilizadas para verificar a eficiência dos ajustes das previsões foram o cálculo do Erro Percentual Médio - EPM, Erro Percentual Absoluto Médio – EPAM e o teste de *U*-Theil, com dados retirados da amostra. Pode-se concluir que ambos os modelos apresentam baixo ajuste nas previsões. Em estudos posteriores propõem-se aplicar extensões do modelo VAR com 8 e 23 defasagens e inserir variáveis exógenas ao modelo VAR, apresentando alternativas aos profissionais ligados a gestão financeira e de comercialização de energia.

Palavras-chave: Comparação de modelos; métricas de ajuste de previsão; Preço de Liquidação das Diferenças; Modelo autorregressivo vetorial; Newave-Decomp.

1. Introdução

A indústria de energia elétrica, seja ela a do Brasil ou a de qualquer outro país, possui semelhanças e diferenças entre si. As semelhanças concentram-se na parte técnica dos barramentos, linhas de transmissão, geradores de energia, entre outros equipamentos, que apresentam características construtivas e de operação comuns, fruto das leis físicas que regem os fenômenos elétricos. Já as diferenças originam-se do arranjo comercial dado a cada setor de energia, que pode ser influenciado por diversos fatores como econômicos, governamentais e também os ligados às peculiaridades dos agentes que compõem um determinado mercado de energia.

As feições dadas às relações comerciais do Setor Elétrico Brasileiro (SEB) ao longo dos tempos foram conferindo-lhes crescente complexidade. Podem ser apontadas três fases distintas vivenciadas no modelo brasileiro, sendo que as transformações ocorridas foram em busca de maior aprimoramento.

De forma breve, a primeira fase caracteriza-se por forte predominância estatal no setor, compreendendo o período de 1934 a 1995. As empresas exerciam as atividades de geração, transmissão e distribuição de forma verticalizada, com monopólio estatal, ou seja, uma característica marcante era a de que o Estado figurava como o maior financiador do setor. A recessão, o endividamento externo e a estagnação da demanda, vivenciados após a década de 1970, foram os principais fatores que contribuíram para a reestruturação setorial. Em especial, contribuiu sobremaneira o processo de inflação elevada dos anos 1980, que levou o governo da época a utilizar as empresas estatais como instrumento de controle dos preços, o que implicou sérios problemas financeiros para as empresas estatais, especialmente em sua capacidade de investimentos (LEITE & CASTRO, 2014).

No Brasil, na década de 1990, uma emenda constitucional aboliu o monopólio público sobre as indústrias de infra-estrutura. Em segundo lugar, foi eliminada a diferença de tratamento entre o capital doméstico e o capital estrangeiro, o que permitiu que empresas estrangeiras disputassem os leilões de compra de companhias nacionais. Em terceiro lugar, a Lei nº 8.987/95 (BRASIL, 1995), lei das concessões, definiu as condições básicas de entrada, saída e operação nos setores de infra-estrutura. E, por último, as negociações das dívidas dos estados com a União estavam condicionadas a certo nível de amortização, que os estados só tinham condições de cumprir através das vendas de ativos.

A reestruturação setorial caminhou para a desverticalização e privatização das suas empresas, separando os ambientes de geração, transmissão, distribuição e comercialização de energia elétrica, este último criado pela reforma. A Agência Nacional de Energia Elétrica (ANEEL), o Operador Nacional do Sistema Elétrico (ONS) e o então Mercado Atacadista de Energia Elétrica (MAE) foram criados nesta fase. Nesta fase teve início o cálculo do Preço de Liquidação das Diferenças (PLD). O desgaste do modelo implantado evidenciou-se com a crise de abastecimento ocorrida durante o segundo semestre de 2001 e o primeiro semestre de 2002.

O ano de 2003 representou a transição entre o modelo essencialmente de mercado e o que vigora atualmente. O cálculo do PLD foi mantido. Também foram criados o Ambiente de Contratação Regulada (ACR) e o Ambiente de Contratação Livre (ACL). Participam do ACR as concessionárias de distribuição de energia e clientes cativos. Podem participar do ACL agentes de geração, comercialização, importadores e exportadores de energia elétrica, e consumidores livres. Neste ambiente, as operações de compra e venda de energia são negociadas bilateralmente entre vendedores e compradores, caracterizando transações de mercado de balcão. Os preços das transações de compra e venda de energia são diretamente influenciadas pelo PLD. Possui dificuldades típicas de mercados não organizados, entre elas,

assimetria de informação e baixa liquidez (CCEE, 2012). Por outro lado, o ACL é a alternativa para agentes que visam redução de custos no curto prazo, configurando-se numa opção mais competitiva em comparação às tarifas de energia do ACR.

Além de contar com as projeções de PLDs realizadas pelo ONS e CCEE, algumas motivações levam os agentes do setor a utilizar metodologias robustas de previsão e construção de cenários próprios. A opção de escolha de grandes consumidores entre a contratação de energia no ACR ou no ACL depende, entre outros fatores, de expectativas quanto ao valor do PLD ou a diferença entre o PLD e a tarifa média cobrada no ACR. Outra motivação parte dos comercializadores e geradores de energia elétrica, em que traçar previsões e cenários do preço da energia elétrica auxilia na gestão do risco de preço. Tal risco pode ser mitigado com a elaboração de contratos com prazos longos em períodos de alta volatilidade, além de auxiliar nas provisões de recursos financeiros no caso de liquidação de déficits de energia. A percepção do risco financeiro é maior quando os preços são elevados. Pequenas quantidades de energia adquiridas no mercado de curto prazo são valoradas a preços muito altos, gerando desembolsos significativos.

Neste artigo, propõe-se comparar o Modelo de Vetor Autorregressivo (VAR) para previsão dos PLDs no patamar de carga média por submercado ao procedimento de previsão com base no modelo Newave-Decomp por parte de gestores de contratação de energia elétrica. Esta comparação é quantitativa e utiliza medidas de ajuste de previsão. No quase-experimento proposto utilizou-se como amostra o PLD do patamar médio de carga por representar a maior parte do tempo de exposição dos agentes.

O artigo segue com a descrição da previsão de preços utilizada atualmente no SEB e uma breve descrição dos procedimentos de previsão do PLD na gestão da comercialização. Na seção 3, há uma breve revisão da literatura sobre modelos aplicados principalmente à previsão de preços spot de energia elétrica. Na seção 4, apresenta-se uma análise estatística descritiva dos dados. Na seção 5, faz-se a análise dos resultados referentes às estimativas do modelo VAR e o comparativo das previsões deste modelo com as previsões do Newave-Decomp. Por fim, na sexta seção, apresentam-se algumas considerações finais com uma breve agenda de pesquisa.

2. O atual modelo de previsão de preços

No SEB, o PLD é calculado através de modelos computacionais de otimização estocástica. O objetivo é minimizar o custo total esperado da operação do sistema através da combinação ótima entre geração hidráulica e térmica.

A estrutura de mercado do SEB baseia-se no modelo Pool que adota o Preço Marginal do Sistema (PMS) para valorar as transações de compra e venda de energia ocorridas no mercado das diferenças (spot). Uma alternativa ao PMS seria a adoção de Preços Nodais (PNO) que estabelece preços diferenciados para a energia transacionada em função da localização dos geradores no sistema de transmissão (SILVA, 2001).

O modelo Pool implica na existência de um controle centralizado responsável pela determinação ótima de geração hidrelétrica e térmica (processo normalmente denominado de despacho), originando, como consequência, o preço spot (PMS). No SEB, este é denominado de Preço de Liquidação das Diferenças (PLD) e é calculado através dos custos de produção dos geradores termelétricos e do custo do déficit de energia, tornando possível o cálculo do valor da água e, por fim, do PLD. Baseia-se no custo marginal de operação do sistema, conforme definido pela nova regulamentação do modelo setorial, que indica o acréscimo financeiro (custo) para atender uma unidade adicional de energia demandada e é expresso em R\$/MWh.

Dadas às características hidrotérmicas do SEB, a determinação do preço spot torna-se um processo mais complexo em comparação a um sistema puramente termelétrico. Sistemas hidrotérmicos apresentam acoplamento temporal, ou seja, o despacho do sistema deve considerar as consequências futuras de cada decisão em termos de custos futuros de combustíveis e possíveis déficits (SILVA, 2001). Demais características operativas de um sistema hidrotérmico podem ser apontadas: incerteza nas afluências futuras aos reservatórios das usinas hidrelétricas, tornando o problema estocástico; consideração de usos múltiplos da água (irrigação, controle de cheias, navegação, entre outros) na elaboração do despacho de geração; problema de otimização de grande porte dado o elevado número de reservatórios e a consideração de multiperíodo; e, as funções de custos de operação das termelétricas e as funções de produção das hidrelétricas adicionam não linearidades ao problema.

Diante das complexidades operativas associadas ao SEB, a determinação do despacho das usinas decorre da comparação entre o benefício imediato da utilização da água para gerar energia e o benefício futuro de seu armazenamento. Em termos gráficos, a comparação se dá através das Funções de Custo Futuro e Imediato (FCF e FCI, respectivamente), apresentadas na Figura 1.

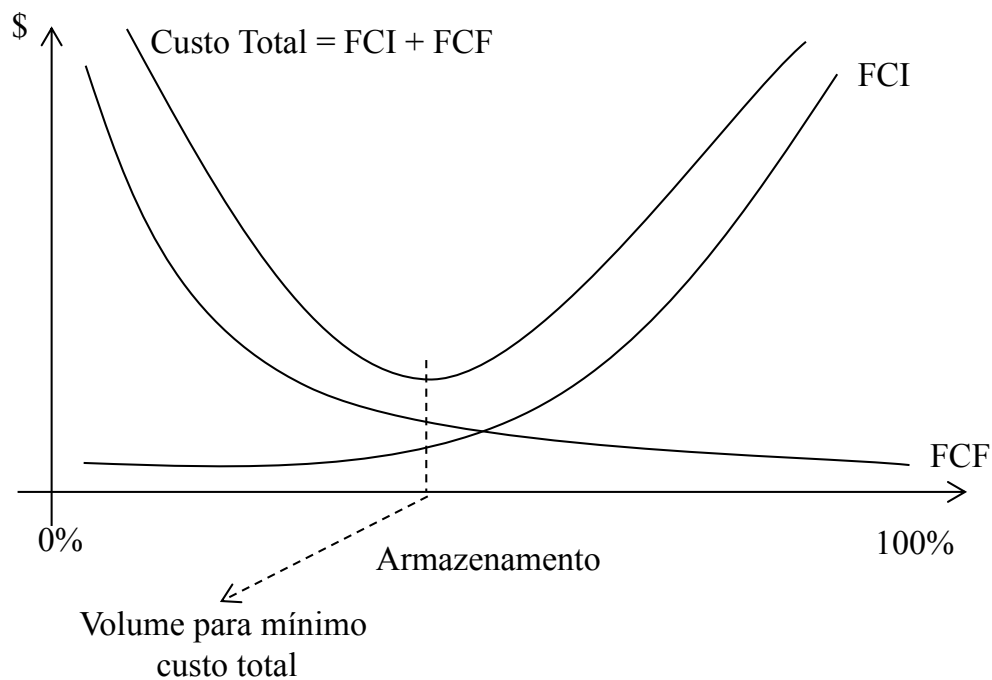


Figura 1 – Definição da política operativa para o atendimento ótimo do consumo. Elaborado pelos Autores

Observa-se que o custo futuro é decrescente em função do volume de água armazenado, ou seja, da água que não foi utilizada para geração de energia no período analisado. Desta forma, o consumo sendo inicialmente suprido com fontes termelétricas diminui o custo futuro, já que o consumo será suprido com maior participação hidrelétrica no período seguinte de análise, enquanto que o custo imediato é alto. Do contrário, se a opção for atender inicialmente o consumo com forte participação hidrelétrica, o custo futuro do próximo período de análise será elevado devido à insuficiência de água para geração hidrelétrica, obrigando o despacho de usinas térmicas. Neste cenário, o custo imediato é reduzido. Por fim, a curva de Custo Total representa a soma das Funções de Custo Futuro e Imediato e indica no seu ponto de mínimo o volume ótimo armazenado para o alcance do mínimo custo de operação do sistema. Neste ponto, as derivadas da FCF e da FCI, em relação ao armazenamento, se igualam em módulo.

Em termos práticos, a função de custo futuro de energia elétrica é calculada pelo programa computacional Newave (CEPEL, 1999b), utilizando a técnica de Programação Dinâmica Dual Estocástica (MACEIRA, 1993). Esta técnica obtém os valores ótimos de geração hidrelétrica e térmica capaz de evidenciar o custo mínimo de operação no horizonte de 5 anos, utilizando diversas combinações de níveis de reservatórios e tendências hidrológicas. Nesta etapa, os resultados são apresentados em termos mensais. Na etapa final do cálculo, a função de custo futuro é utilizada como dado de entrada do modelo computacional Decomp (CEPEL, 1999a) que calcula semanalmente os preços spot. Entre os dados de entrada para o cálculo do PLD, estão: previsão de carga, previsão de afluências, afluências dos meses anteriores, níveis iniciais de armazenamentos dos reservatórios, expansão da oferta de geração, expansão da transmissão, custo de geração térmica e custo do déficit de energia.

O PLD é calculado previamente (*ex-ante*) pela CCEE. Semanalmente, a CCEE toma por base o Custo Marginal da Operação (CMO), nos patamares de carga pesada, média e leve, e limita-o entre um valor mínimo e máximo, definidos anualmente pela ANEEL. Este procedimento é adotado para os quatro submercados (Sudeste-SE, Sul-S, Nordeste-NE e Norte-N) que compõem o sistema elétrico brasileiro.

Duas características inerentes aos PLDs referem-se à imprevisibilidade e a volatilidade. Agentes de mercado que atuam principalmente no ACL têm suas percepções de risco aumentadas em função de variações inesperadas e de alta magnitude nos preços, sobretudo em períodos de escassez hídrica. Períodos secos, de baixas afluências, implicam no despacho de usinas térmicas que elevam o custo marginal da operação e, conseqüentemente, o PLD. Por outro lado, períodos úmidos, de grandes afluências, diminuem o PLD porque o consumo é atendido principalmente por usinas hidrelétricas. Conforme defende Mayo (2009), os preços do mercado de curto prazo apresentam alta correlação com as vazões afluentes aos reservatórios, refletindo uma característica estocástica aos preços spot. Isso se deve à operação centralizada realizada no SEB. Por outro lado, a operação centralizada do sistema não leva à estabilidade de preços, sendo uma característica de sistemas hidrotérmicos que, adicionada à existência de vínculos hidráulicos entre usinas de uma mesma cascata, mas pertencentes a proprietários distintos, justificam a adoção do modelo centralizado de despacho (SILVA, 2001).

Dada à expansão de o SEB ocorrer atualmente através de usinas a fio d'água, ou seja, empreendimentos que geram energia com a água do rio sem acumulá-la ou acumulando um volume baixo, espera-se que a volatilidade do PLD aumente no curto prazo. A perda da capacidade de regularização dos reservatórios em relação ao consumo fará os preços refletirem diretamente as oscilações das vazões afluentes (ALVES, 2011).

Do ponto de vista operacional, as projeções de preços envolvem a execução do modelo Newave, ao menos uma vez ao mês, e do modelo Decomp a cada semana do mês. O modelo Newave apresenta os custos marginais do sistema por submercado em base mensal. Seus resultados podem ser utilizados diretamente, visando obter o comportamento dos preços no horizonte de cinco anos. Enquanto que o Decomp calcula os PLDs por semanas e patamar de carga. Para o processamento dos dois modelos é necessário um grupo de arquivos distintos, denominado usualmente de deck de dados. O deck do Newave é formado por 41 arquivos, enquanto que o do Decomp engloba 10 arquivos. Ambos possuem tempos de processamento distintos. O tempo de execução do Newave é na casa de horas, enquanto o Decomp leva minutos para ser processado. Obviamente, a configuração computacional interfere diretamente no desempenho do processamento.

Algumas empresas optam por gerar seus próprios cenários de preços a partir de modificações nos decks dos modelos como, carga, cronograma de entrada em operação de novas usinas, limites de intercâmbio de energia entre regiões, entre outras variáveis. Tanto o Newave

quanto o Decomp podem servir de base para embasar as projeções, ou seja, é possível utilizar os resultados do Newave, sem a necessidade de execução do Decomp, como também é viável projetar preços a partir da execução do Decomp após o Newave. A partir deste deck modificado, é possível fazer as projeções na forma de rodada simples ou prospectiva. A rodada simples é aquela em que a partir de um único processamento dos modelos são apresentados os resultados para todo horizonte de estudo (cinco anos). Na rodada prospectiva, as condições operativas finais do primeiro mês são consideradas como entradas do mês seguinte, fazendo-se nova execução dos modelos, e assim sucessivamente. O objetivo é buscar uma aproximação ao que ocorre na prática que é a execução dos modelos captando as condições do sistema, sobretudo dos níveis dos reservatórios, ao final do mês para prever o mês seguinte. A CCEE utiliza a rodada simples do conjunto de modelos Newave e Decomp para fixar os preços semana a semana. A rodada prospectiva, realizada por alguns agentes, busca antecipar o comportamento dos preços que estarão vigentes no mercado.

A organização dos dados de saída dos modelos de otimização, sobretudo do Newave, demanda tempo considerável das equipes de projeção de preço das empresas que comercializam energia elétrica. Além da função de custo futuro, que é o principal insumo para a execução do modelo Decomp, o Newave apresenta duas mil séries de custos marginais de operação do sistema no horizonte de cinco anos. Assim, a análise pode ir de uma simples média aritmética das duas mil séries para cada mês do estudo até análises estatísticas mais elaboradas. Uma delas é a análise em termos de percentis que busca traçar a excursão do preço dentro de um intervalo pré-definido. Ou seja, são estabelecidas faixas de variação de preço, associadas a probabilidades de ocorrência, nas quais se espera que os preços futuros se localizem.

3. Modelos de previsão e preços spot de energia elétrica

Previsões baseadas em modelos apresentam claras vantagens se comparadas às previsões baseadas apenas em opiniões de especialistas. Porém, mesmo com modelos, o trabalho de previsão de preços no mercado de energia elétrica enfrenta importantes dificuldades, Em primeiro lugar, porque a dinâmica dos preços está sujeita à sazonalidade tanto da demanda quanto da oferta. Em segundo lugar, porque há muitas variáveis exógenas quantificáveis que podem ser consideradas. Em terceiro lugar, porque há também fatores psicossociais que podem causar uma elevação inesperada e irracional da demanda por certos contratos, levando a picos de preços (WERON & MISIOREK, 2005).

As previsões resultantes de modelos estatísticos são mais fáceis de serem replicadas e validadas e possíveis fontes de erros sistemáticos podem ser investigadas formalmente (ROBERTSON & TALLMAN, 1999). O trabalho dos autores é uma aplicação do VAR à área econômica. São utilizadas seis especificações de VAR para prever as taxas de desemprego, inflação e crescimento do PIB entre os anos de 1986 a 1997. A intenção é de demonstrar que a natureza das restrições a priori na especificação do VAR pode influenciar o desempenho das previsões.

A previsão dos preços do mercado de curto prazo, denominados genericamente por spot prices, ou no Brasil, referenciados pela sigla PLDs, tem sido tema de muitos trabalhos utilizando diversas técnicas para predizer o patamar em que os mesmos estarão no futuro.

Andrade & Lobão (1997) aplicaram o modelo VAR para analisar a evolução do consumo de energia elétrica residencial no Brasil no período 1963/95. Estimaram as elasticidades renda e preço desta demanda e utilizaram o modelo econométrico estimado para fazer projeções da demanda de energia no período 1997/2005. Os autores concluíram que a demanda é inelástica em relação à renda e ao preço da energia e que a elasticidade-renda da demanda por energia

capta não apenas o efeito direto da renda, mas também o seu efeito indireto via impacto sobre a quantidade de eletrodomésticos.

Kristiansen (2012) desenvolve um modelo de previsão de preços de energia elétrica “para o dia seguinte” (day-ahead) no mercado Nord Pool. Trata-se de um modelo autorregressivo de previsão horária dos preços de um determinado dia. Também são consideradas a previsão de consumo no mercado nórdico e a oferta de geração eólica da Dinamarca como variáveis exógenas. A previsão de preço de uma determinada hora para o dia seguinte depende do preço na mesma hora do dia anterior, dois dias atrás e uma semana atrás, defasagens de 24, 48 e 168 horas. Os resultados demonstram que o Erro Absoluto Médio Semanal (EAMS) varia entre 6-7% e que o Erro Percentual Absoluto Médio (EPAM) calculado em base horária varia de 8% a 11%. Previsões “fora da amostra” apresentam EAMS e EPAM semelhantes em torno de 5%. Ainda segundo o autor, a previsão de consumo de energia e preços é uma das ferramentas mais importantes utilizadas por tomadores de decisão em todo mundo. Modelos de previsão de alta qualidade com bons níveis de desempenho tornam-se fator importante no desenvolvimento de políticas energéticas.

O trabalho de Weron & Misiorek (2008) compara a precisão de 12 métodos de previsão de séries temporais “para o dia seguinte” dos preços spot. Os métodos abordados vão desde a autorregressão padrão (AR) e suas extensões. Os resultados das previsões demonstram que os modelos que consideram a carga como variável exógena possuem maior precisão em comparação aos modelos puros. Porém, a mesma afirmativa não é verdadeira quando a temperatura ambiente é considerada como variável exógena. Embora a temperatura seja a maior influenciadora de todas as variáveis climáticas, o mesmo não ocorre sobre os preços da energia, em que a carga é a influência mais importante. Outra evidência é a de que modelos semiparamétricos geralmente apresentam melhor precisão de previsão em comparação aos demais modelos testados.

Uma abordagem possível para previsão de preços no mercado spot é analisar sua relação com os preços no mercado futuro de energia. Nesse sentido, Fritz (2012) investigou a formação de preços de futuros de eletricidade no European Energy Exchange (EEX) e procurou compreender a formação de preços em relação aos mercados de futuros inter-relacionados, como o carvão na Intercontinental Exchange (ICE), o gás natural na Title Transfer Exchange (TTF) e de CO₂. Os resultados obtidos com o uso de um modelo de vetor de correção de erros (VEC) sugeriram que a dinâmica dos preços dos futuros de energia elétrica mostra dependência dos custos marginais de geração. Os resultados também indicam um equilíbrio estável em longo prazo entre os preços dos futuros de eletricidade e os custos marginais das licenças de carvão, gás natural e CO₂.

Mazengia (2008) propôs a abordagem de regressão linear múltipla para prever o preço da energia elétrica de mercado do dia seguinte nos mercados de Ontario e Nord Pool. A análise foi feita com base em dados anuais de preço e nível de reservatórios dos mercados. Descobriu-se que durante o inverno o preço do sistema está positivamente correlacionado com o nível do reservatório, enquanto que para as outras estações do ano uma forte correlação negativa é observada. No último caso, ao contrário da estação do inverno, o preço cai com um aumento no nível do reservatório e vice-versa. Destaca-se que em um mercado em que a geração de energia hidrelétrica contribui para uma quantidade considerável no fornecimento de energia, a quantidade de água disponível no reservatório desempenha um papel significativo no preço de mercado.

De Vany & Walls (1999) estimaram um modelo com vetor de correção de erros (VEC) baseado em preços spot de pico e fora-de-pico de eletricidade durante 1994-1996 cobrindo 11 mercados regionais no oeste dos Estados Unidos e testaram esses preços para evidenciar a

cointegração dos preços nesses mercados. Os resultados mostram a existência de um mercado de energia por atacado eficiente e previsível no período do estudo.

Janczura & Weron (2010) afirmam que uma das características mais peculiares dos preços spot são os picos que eles podem alcançar. Assim, modelos markovianos com mudanças de regime (MRS) tornam-se as melhores opções para modelar este comportamento. Os autores calibram e testam uma série de modelos MRS visando não apenas encontrar parâmetros para modelar corretamente o comportamento dos preços, mas também deixá-los bem ajustados estatisticamente. Os autores testam modelos com 2 e 3 regimes: base-pico e base-pico-queda. Os resultados mostram que o modelo de três regimes e probabilidades de transição definidas como função dos dados foi o que apresentou melhor desempenho em modelar a dependência temporal dos picos de preços.

Autores	Técnica de Previsão	Objetivo	Local	Medida de Desempenho
Weron & Misiorek (2005)	Modelos ARMA e AR-MAX	Previsão horária de preços para o dia seguinte (<i>day-ahead</i>), com e sem variável exógena (carga).	CalPX: Califórnia	MDE e MWE
Robertson & Tallman (1999)	Vetor Autorregressivo (VAR) (6 modelos)	Previsão de taxas de desemprego, inflação e PIB, entre (1986-1997).	EUA	RMSE
Andrade & Lobão (1997)	Modelo Econométrico e Vetor Autorregressivo (VAR)	Analisar e prever o consumo residencial de energia elétrica entre 1963/95.	Brasil	R ² e testes F, LM, Normalidade, ARCH e White
Kristiansen (2012)	Modelo Autorregressivo	Previsão horária de preços para o dia seguinte (<i>day-ahead</i>).	Nord Pool: Dinamarca, Finlândia, Noruega e Suécia	MAPE e WMAE
Weron & Misiorek (2008)	Modelos de Séries Temporais (12 métodos, com e sem variável exógena)	Previsão horária de preços para o dia seguinte (<i>day-ahead</i>).	CalPX: Califórnia Nord Pool: Dinamarca, Finlândia, Noruega e Suécia	WMAE
Fritz (2012)	Modelo de Vetor de Correção de Erros (VECM)	Investigar a formação de preços de futuros de eletricidade em relação aos mercados de futuros inter-relacionados, como carvão, gás natural e CO ₂ .	EEX: Alemanha	Testes ADF, KPSS, DF GLS
Mazengia (2008)	Regressão Linear Múltipla	Previsão horária de preços para o dia seguinte (<i>day-ahead</i>).	Ontario e Nord Pool: Dinamarca, Finlândia, Noruega e Suécia	MAPE diário e semanal
De Vany & Walls (1999)	Modelo de Vetor de Correção de Erros (VECM)	Examinar o comportamento dos preços em momentos de pico e fora de pico, evidenciando ou não a integração dos mercados.	EUA: 11 mercados (Western Systems Coordinating Council)	Análise de Cointegração de Johansen
Janczura & Weron (2010)	Modelos Markovianos com Mudança de Regime (MRS): base-pico e	Calibrar e testar os modelos MRS: encontrar parâmetros para modelar o comportamento dos preços e deixar modelos bem	EEX: Alemanha PJM Interconnection: EUA	Baseada em quantil (IQR, IDR) e valor-p do teste K-S

Autores	Técnica de Previsão	Objetivo	Local	Medida de Desempenho
	base-pico-queda	ajustados estatisticamente.	NEPOOL: EUA	
Haldrup <i>et al.</i> (2010)	Vetor Autorregressivo (VAR) sem e com mudança de regime (restrições de transmissão) Modelo Univariado	Previsão horária de preços para o dia seguinte (<i>day-ahead</i>).	Nord Pool: Dinamarca, Finlândia, Noruega e Suécia	MAFE

Quadro 1 – Bibliografia pesquisada. Elaborado pelos Autores

Por fim, voltado para a previsão de preços spot, Haldrup et al. (2010) formulam um modelo VAR e outro univariado para a previsão horária de preços no mercado Nord Pool. Em função das suas características, os autores simulam ambos os modelos com e sem a representação dos congestionamentos no sistema de transmissão. As previsões dos modelos VAR e univariado demonstram que o modelo VAR habilitado para representar as restrições de transmissão supera em 7 dos 10 casos simulados o modelo VAR sem a modelagem das restrições de transmissão. Analogamente, o VAR representando as restrições de transmissão supera em 10 dos 10 casos simulados quando comparado ao modelo univariado com representação das restrições de transmissão.

4. Metodologia

Neste estudo, utilizaram-se as séries de PLDs do patamar médio de carga nos submercados Sudeste/Centro-Oeste (PLD-SE/CO), Sul (PLD-S), Nordeste (PLD-NE) e Norte (PLD-N). Este compreende as horas entre 8-18h e 22-23h de segunda-feira a sábado e entre 18-22h nos domingos e feriados nacionais. As observações de PLDs abrangem o período de 30/06/2001 a 25/03/2016, totalizando 774 observações. As semanas iniciam-se nos sábados e finalizam nas sextas-feiras. Os dados foram coletados na base de dados da Câmara de Comercialização de Energia Elétrica, conforme CCEE (2016). Na Figura 2, pode-se observar a evolução dos PLDs, no Brasil, em cada submercado.

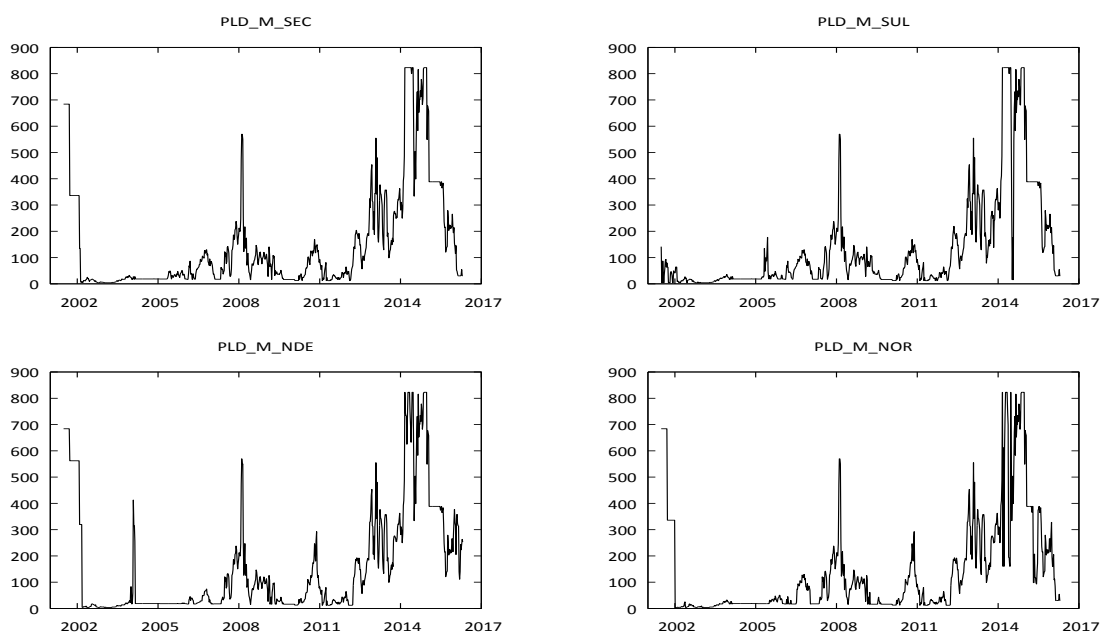


Figura 2 – PLDs médios semanais em cada submercado (dados semanais de 30/06/2001 a 25/03/2016). Elaborado pelos Autores. Fonte: ONS

Na Tabela 1, apresenta-se um quadro resumo das estatísticas descritivas dos PLDs médios semanais em cada submercado. Cabe destacar que as séries não são normalmente distribuídas e as estatísticas de LB mostram que os dados são fortemente autocorrelacionados.

Tabela 1 – Estatísticas descritivas (dados semanais de 30/06/2001 a 25/03/2016).

	PLD-SE/CO	PLD-S	PLD-NE	PLD-N
Média	150,49	131,36	159,44	138,39
Mediana	56,89	49,94	48,55	42,37
Mínimo	4,00	4,00	4,00	4,00
Máximo	822,83	822,83	822,83	822,83
Desv. Padrão	202,30	188,21	209,45	190,33
Variância	40924,4	35422	43871,2	36226
C.V.	1,3442	1,4327	1,3137	1,3754
Assimetria	1,944	2,311	1,637	2,004
Curtose	3,145	5,018	1,798	3,532
Perc. 5%	7,20	5,41	5,67	5,48
Perc. 95%	684,00	653,95	684,00	678,81
Interv. IQ	172,63	128,65	225,62	163,66
JB	806,582	1501,06	450,16	920,454
AR(1)	0,9711	0,9660	0,9682	0,9312
LB(10) para PLD	5820,47	5644,56	5864,20	5007,09
LB(10) para PLD ²	5015,34	4955,54	5192,73	4042,50

Obs.: LB(n) é a estatística Ljung-Box para até n defasagens, distribuída conforme χ^2 com n graus de liberdade; JB é o teste de normalidade de Jarque e Bera; AR(1) é o coeficiente de autocorrelação de primeira ordem. Elaborado pelos Autores. Fonte: ONS.

A matriz de correlação, apresentada na Tabela 2, é significativamente elevada, o que por hipótese pode-se sugerir uma forte integração entre os submercados. Uma breve análise da Tabela 2 mostra uma correlação forte e acima de 0,9 entre o PLD-SE/CO e o PLD-NE (0,9576). Em seguida, observa-se uma correlação forte entre o PLD-SE/CO e o PLD-N (0,9378) e entre o PLD-NE e o PLD-N (0,9077).

Tabela 2 – Matriz de correlações dos PLDs médios semanais em cada submercado (dados semanais de 30/06/2001 a 25/03/2016).

	PLD-SE/CO	PLD-S	PLD-NE	PLD-N
PLD-SE/CO	1	0,8884	0,9576	0,9378
PLD-S		1	0,8095	0,8174
PLD-NE			1	0,9077
PLD-N				1

Elaborado pelos Autores. Fonte: ONS

O menor coeficiente de correlação foi de 0,8095 entre o PLD-S e o PLD-NE. Esta análise exploratória mostra que o PLD-SE tem uma relação importante na determinação dos preços em outros submercados, principalmente no Norte e no Nordeste.

Neste artigo seguiu uma linha metodológica quantitativa. Para efetuar as previsões utilizou-se a metodologia econométrica para estimar modelos autorregressivos vetoriais (VAR). A partir

dos resultados das previsões dos modelos, VAR e Newave-Decomp ex-ante, aplicados a variável quase-experimental PLD do patamar médio, obteve-se informações para o cálculo das métricas de ajuste das previsões para efetuar a comparação entre os modelos, estabelecida na seção 5.

Modelos baseados no vetor autorregressivo são úteis para descrever a estrutura dinâmica de variáveis de séries temporais. Normalmente tratam todas as variáveis como endógenas. Porém, variáveis exógenas podem ser impostas aos modelos. Tradicionalmente, modelos VAR são elaborados para variáveis estacionárias sem tendências temporais. Mas, descobertas recentes com o desenvolvimento do conceito de cointegração, indicam a importância de tendências estocásticas em variáveis, como os testes de cointegração de Engle-Granger (ENGLE & GRANGER, 1987) e de Johansen (JOHANSEN, 1995), mostram que a tendência estocástica pode ser capturada por modelos VAR.

Antes de estimar um modelo de Vetor Autoregressivo calculam-se estatísticas com a finalidade de definir o número adequado de defasagens que são utilizadas no modelo. Os valores mínimos das estatísticas de critério de informação foram AIC (Akaike) = 38,372166, BIC (Bayesiano de Schwarz) = 39,475265, e HQC (Hannan-Quinn) = 39,107444, os quais indicam a aplicação de 23, 4 e 8 defasagens para cada variável endógena, respectivamente. Neste caso, optou-se pela parcimônia com a escolha do modelo VAR com 4 defasagens.

Como o vetor autorregressivo é composto por 4 variáveis, opta-se pelo teste de cointegração de Johansen que indica o teste de Johansen para as equações do modelo autorregressivo vetorial com 4 defasagens, VAR(4), indicam integração dinâmica entre os PLDs de cada submercado.

Tabela 3 – Estatísticas de Johansen para o traço dos autovalores e para o autovalor máximo.

Hipótese Nula	Hipótese alternativa	Valor calculado λ traço	Valor Crítico (99%)
$r = 0$	$r > 0$	292,480	54,46
$r \leq 1$	$r > 1$	82,623	35,65
$r \leq 2$	$r > 2$	40,527	20,04
$r \leq 3$	$r > 3$	6,883	6,65
Hipótese Nula	Hipótese alternativa	Valor calculado λ max	Valor Crítico (99%)
$r = 0$	$r = 1$	209,860	32,34
$r = 1$	$r = 2$	42,096	25,52
$r = 2$	$r = 3$	33,644	18,63
$r = 3$	$r = 4$	6,883	6,65

Elaborado pelos Autores. Fonte: ONS

As estatísticas do traço e do autovalor máximo são expressas como: $\lambda_{traço}(r) = -T \sum_{i=r+1}^n \ln(1 - \hat{\lambda}_i)$ e $\lambda_{max}(r, r+1) = -T \ln(1 - \hat{\lambda}_{r+1})$, respectivamente. A metodologia do teste de Johansen e a apresentação dos valores críticos dos testes podem ser obtidas em Bueno (2011) e Enders (2010).

O modelo Auto Regressivo Vetorial com 4 defasagens VAR(4) pode indicar precedência na relação de causa e efeito entre o PLD da maioria das regiões do sistema elétrico brasileiro, quando verifica-se a importância do conjunto das defasagens de uma variável na equação da variável dependente em questão, o que demonstra o teste F para 4 defasagens, nas quatro linhas anteriores à última linha da Tabela 4. Pode-se destacar a relação causal entre PLD-SE/CO, PLD-S e PLD-N sobre o PLD das diferentes regiões. De acordo com o teste F as defasagens do PLD-NE não têm efeito significativo sobre os PLDs das outras regiões.

Tabela 4 – Parâmetros estimados por Mínimos Quadrados Ordinários do Modelo Vetorial Auto Regressivo (dados semanais de 30/06/2001 a 25/03/2016).

	PLD-SE/CO		PLD-S		PLD-NE		PLD-N	
	Coefficientes	p-valor	Coefficientes	p-valor	Coefficientes	p-valor	Coefficientes	p-valor
β_0	3,1171	0,12	3,9320	0,06	3,8588	0,08	5,1429	0,07
PLD-SE/CO(1)	0,9132	0,00	0,0882	0,33	0,0200	0,83	0,2623	0,03
PLD-SE/CO(2)	0,0608	0,58	0,0519	0,66	0,0918	0,45	-0,3103	0,05
PLD-SE/CO(3)	-0,0080	0,94	0,1548	0,19	0,1338	0,27	0,1669	0,29
PLD-SE/CO(4)	-0,0414	0,63	-0,3121	0,00	-0,1176	0,21	0,2196	0,07
PLD-S(1)	0,0478	0,45	0,8687	0,00	0,0373	0,59	0,0390	0,67
PLD-S(2)	0,1393	0,09	0,2485	0,00	0,1389	0,12	0,1312	0,26
PLD-S(3)	-0,3462	0,00	-0,5328	0,00	-0,3904	0,00	-0,3742	0,00
PLD-S(4)	0,1862	0,00	0,3617	0,00	0,1843	0,01	0,2057	0,02
PLD-NE(1)	0,0600	0,30	0,0759	0,22	0,9242	0,00	0,0200	0,81
PLD-NE(2)	-0,0818	0,29	-0,1063	0,19	-0,0957	0,26	0,0645	0,56
PLD-NE(3)	0,0253	0,74	0,0654	0,42	-0,0567	0,50	-0,0084	0,94
PLD-NE(4)	-0,0388	0,50	-0,0634	0,30	0,0654	0,30	-0,1501	0,07
PLD-N(1)	-0,0684	0,05	-0,0414	0,26	-0,0479	0,20	0,5039	0,00
PLD-N(2)	-0,0437	0,26	-0,0974	0,02	-0,0849	0,05	0,3145	0,00
PLD-N(3)	0,1648	0,00	0,0944	0,02	0,1855	0,00	-0,0251	0,65
PLD-N(4)	0,0136	0,69	0,1195	0,00	-0,0098	0,80	-0,1241	0,01
R ² -Ajustado	0,953517		0,941004		0,947501		0,891203	
F(16,753)	986,9278		767,614		868,4363		394,7011	
DW	1,96825		1,961238		1,984872		1,978522	
ρ	0,015872		0,015364		0,007042		0,010711	
Teste F(4,753) e seu [p-valor] para 4 defasagens das variáveis em cada equação, respectivamente:								
PLD-SE/CO	109,5 [0,000]		3,7512 [0,005]		2,4823 [0,042]		6,9476 [0,000]	
PLD-S	4,8757 [0,000]		440,55 [0,000]		5,3687 [0,000]		2,6302 [0,033]	
PLD-NE	0,8309 [0,506]		0,931 [0,445]		176,08 [0,000]		1,8465 [0,118]	
PLD-N	7,7921 [0,000]		8,6467 [0,000]		6,2422 [0,000]		104,83 [0,000]	
Portmanteau	LB(48) =		1308,15		gl = 704		[0,0000]	

Obs: Teste Portmanteau a partir da abordagem de Ljung-Box para verificar que não existem evidências para rejeitar a hipótese de independência dos resíduos. Fonte: Autores

O modelo VAR configura-se num instrumento robusto para previsão de preços spot de energia elétrica. Neste caso, cabe destacar a importância de gerar previsões do PLD para cada região e comparar com a tradicional construção de cenários aplicados ao algoritmo dos modelos computacionais Newave e Decomp.

Um instrumento importante para analisar os efeitos precedentes de uma variável sobre outra é a utilização da função de Impulso-Resposta, a função mostra a trajetória do efeito de uma mudança em uma variável, por meio de um choque de 1 erro padrão, sobre outra variável. As funções da Figura 3 mostram que existe um canal de transferência de um choque em uma das variáveis em determinada equação do sistema VAR sobre outras variáveis desse sistema.

Ao observar as funções de Impulso-Resposta, um choque equivalente a um desvio padrão na variável (dependente) PLD de dada região (1 desvio padrão equivale em média a R\$ 200,00) afeta o PLD desta ou de outra região, em cada uma das dez semanas, no valor equivalente ao eixo das ordenadas. Na diagonal da Figura 3, observa-se o efeito autorregressivo, que afeta de maneira quase que imediatamente o valor corrente e apresenta um ajustamento lento ao PLD

das Regiões SE/CO e PLD da Região Sul, e verifica-se ajustamento pleno após dez semanas aproximadamente dos PLDs das Regiões Nordeste e Norte. Como esperado, o PLD da Região Sudeste-Centro-Oeste afeta de maneira significativa o PLD das outras Regiões, equivalente a R\$ 40 em média, isto pode ser observado nos 4 gráficos da 1ª coluna da Figura 3. As mudanças no PLD das Regiões Sul, Nordeste e Norte não afetam de modo relevante o PLD de outras regiões, tendo um impacto máximo de R\$ 11,50, referente ao efeito do PLD da Região Norte sobre a Região Sul, na 9ª semana, o que não compensa os efeitos negativos anteriores.

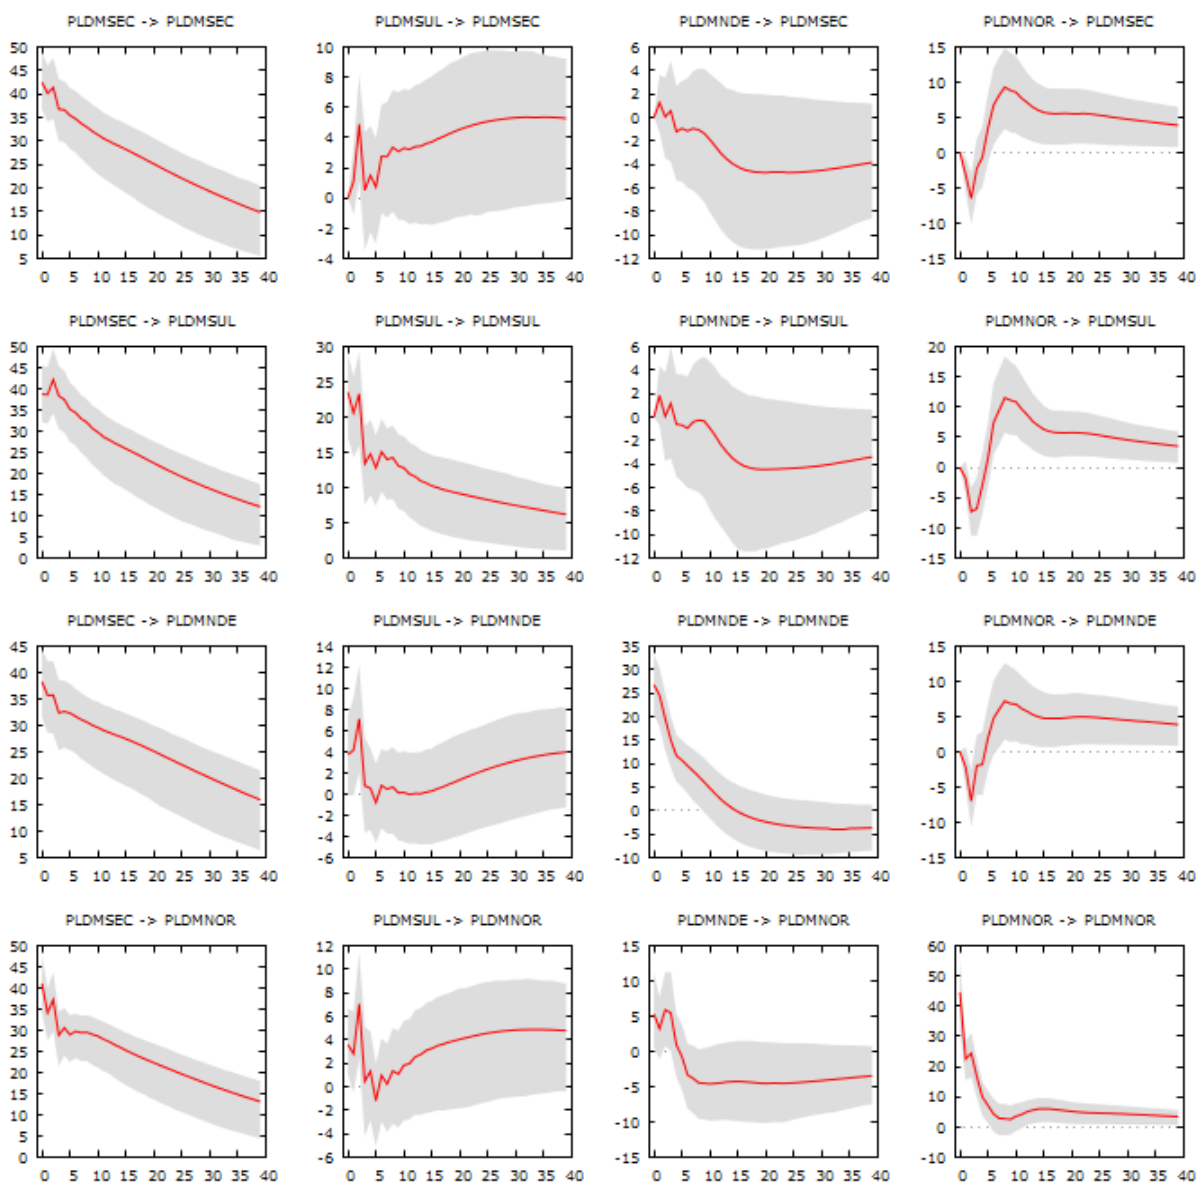


Figura 3 – Funções de Impulso-Resposta para o período de 10 semanas. Fonte: Autores

Como o objeto de estudo é a comparação das previsões do modelo VAR, estabelecido acima e as previsões resultantes do procedimento de construção de cenários com base no modelo Newave-Decomp e escolha de valores do PLD médio por parte dos agentes do setor elétrico brasileiro se faz necessário a definição de medidas que aferem o ajustamento de tais previsões.

Algumas métricas de comparação entre os modelos podem ser destacadas: a métrica do 1) erro percentual médio – EPM que tem como algoritmo a média dos desvios percentuais da

previsão, $EPM = \frac{1}{\tau} \sum_1^{\tau} \left(\frac{p_{t+1} - \hat{p}_{t+1}}{p_{t+1}} \right)$, 2) erro percentual absoluto médio – EPAM que tem como algoritmo a média dos desvios absolutos percentuais da previsão, $EPAM = \frac{1}{\tau} \sum_1^{\tau} \left| \frac{p_{t+1} - \hat{p}_{t+1}}{p_{t+1}} \right|$, e do 3) U de Theil que compara a soma do quadrado dos desvios das previsões apresentadas pelos modelos com a média aritmética do quadrado das taxas de variação observadas no histórico, conforme apresentado em (1):

$$U\text{-Theil} = \sqrt{\frac{\sum_1^{\tau-1} \left(\frac{\hat{p}_{t+1} - p_{t+1}}{p_t} \right)^2}{\sum_1^{\tau-1} \left(\frac{p_{t+1} - p_t}{p_t} \right)^2}} \quad (1)$$

onde, p_t e p_{t-1} são os valores da série de preços observados nos períodos t e $t + 1$ respectivamente, \hat{p}_{t+1} é o valor previsto pelo modelo no período $t + 1$, e τ é o intervalo da amostra requerido para o teste, neste caso utilizou-se cinco semanas do mês de março de 2016. Neste caso as previsões são comparadas à parcela da amostra referente ao mês de março, chamado de teste “fora da amostra”.

5. Análise dos resultados das métricas de comparação

Na Tabela 5, pode-se verificar que as previsões geradas pelo modelo VAR(4) para todas as regiões não superam o desempenho das previsões com o modelo Newave-Decomp. No entanto, é necessário ressaltar que a política energética de determinação de um preço mínimo, R\$ 30,25 (trinta reais e vinte e cinco centavos), faz com que as previsões geradas pelo modelo VAR sem restrição sigam uma tendência no sentido de romper o preço mínimo. Assim, o modelo VAR(4) com restrição, leva em conta a barreira do preço mínimo pré-estipulado e apresenta previsões com desempenho superior em ao menos uma das medida de EPM e EPAM. Nas previsões do PLD-SE/CO e do PLD-N o erro percentual absoluto médio do modelo VAR(4) com restrição é menor que do Newave-Decomp, e nas previsões do PLD-S o EPM sugere que o modelo VAR(4) com restrição tem previsões melhores que do Newave-Decomp, pois apresenta um desvio percentualmente menor, mas com sentidos opostos.

Tabela 5 – Erro Percentual Médio (EPM) e Erro Percentual Absoluto Médio (EPAM) de cada Modelo de Previsão (em %, para as semanas do mês de março de 2014).

	PLD-SE/CO		PLD-S		PLD-NE		PLD-N	
	EPM	EPAM	EPM	EPAM	EPM	EPAM	EPM	EPAM
Newave-Decomp	11,72	18,69	11,72	18,69	29,32	29,32	11,72	18,69
VAR(4)	27,67	29,03	13,24	24,89	34,14	34,14	35,96	39,28
VAR(4) c/ restrição de preço (R\$ 30,25)	-15,56	16,92	-9,19	20,84	-34,14	34,14	-13,50	16,82

Fonte: Autores

Na Tabela 6, quando a métrica do U-Theil apresenta valores superiores a 1, nos informa que uma previsão ingênua, com base nas taxas de crescimentos anteriores, tem desempenho superior à previsão com base nos modelos propostos.

Ao se observar as métricas referentes às previsões com o modelo Newave-Decomp, apenas a previsão do PLD-NE não supera uma previsão simples com base nas taxas de crescimentos passadas. O Modelo VAR(4) não apresenta desempenho requerido. O modelo VAR(4) com restrição apresenta previsões mais eficientes que a previsão ingênua para o PLD-SE/CO, PLD-S e PLD-N, comparáveis àquelas que resultaram do modelo Newave-Decomp. O

desempenho do modelo VAR(4) com restrição foi superior apenas nas previsões do PLD da região Norte.

Tabela 6 – *U-Theil* (para as semanas do mês de março de 2014).

	PLD-SE/CO	PLD-S	PLD-NE	PLD-N
Newave-Decomp	0,82	0,82	4,17	0,82
VAR(4)	1,27	1,04	5,50	1,62
VAR(4) com restrição de preço (R\$ 30,25)	0,96	0,91	5,50	0,80

Fonte: Autores

6. Considerações Finais

No Sistema Elétrico Brasileiro, aproximadamente um quarto de toda energia elétrica utilizada é adquirida no mercado livre (ACL). As quantidades comercializadas são valoradas a preços e prazos variados, podendo gerar desembolsos significativos.

Por isso, neste trabalho procurou-se apresentar um procedimento de previsão alternativo com o objetivo de complementar as previsões obtidas dos modelos Newave-Decomp, utilizado por ampla maioria dos analistas do setor. Assim, neste estudo, verificou-se que o modelo VAR(4) com restrição obteve desempenho superior em ao menos uma das medidas de EPM e EPAM em cada submercado, se comparado com o modelo Newave-Decomp. Nas previsões do PLD-NE o modelo Newave-Decomp leva vantagem nas duas métricas. Apesar do comparativo os dois modelos apresentam uma baixa eficiência no ajuste das previsões, com erros percentuais elevados. A medida de *U-Theil* também revela um desempenho fraco para os dois modelos, ainda que em relação às previsões dos PLD-SE/CO, PLD-S e PLD-N sua medida seja inferior a 1, o que supera uma previsão ingênua com bases na taxa de variação de semanas anteriores.

Em estudos posteriores, sugere-se que para captar as quedas de preços recentes e melhorar a previsão dos preços sejam utilizadas modelos VAR com defasagens maiores e com utilização de variáveis exógenas tais como: carga, vazões afluentes aos reservatórios e a energia armazenada. Além da proposta anterior, como agenda de pesquisa, o modelo VAR possibilita estimativas e análises sobre a função de custo hidrotérmico por submercado e do custo da restrição de transmissão.

Referências bibliográficas

- ALVES, M. J. *Determinação do preço no mercado de energia elétrica brasileiro e valoração de um derivativo de energia por simulação Monte Carlo com aproximação por algoritmo genético*. (Dissertação de Mestrado). PUC-RJ, Rio de Janeiro, 2011.
- ANDRADE, T.; LOBÃO, W. Elasticidade-renda e preço da demanda residencial de energia elétrica no Brasil. *Texto para discussão* (489). Rio de Janeiro: IPEA, 1997.
- Brasil. *Lei nº. 8.987, de 13 de fevereiro de 1995*. Diário Oficial da Rep. Fed. do Brasil, 1995.
- BUENO, R. L. S. *Econometria de Séries Temporais*. 2 ed., São Paulo: Cengage, 2011.
- CÂMARA DE COMERCIALIZAÇÃO DE ENERGIA – CCEE. *White Paper: construindo um mercado inteligente de energia elétrica no Brasil*. (Novembro), São Paulo: CCEE, 2012.
- CÂMARA DE COMERCIALIZAÇÃO DE ENERGIA ELÉTRICA – CCEE. *Preços em formato CSV*, 2016. Recuperado em 10 de março de 2016, de http://www.ccee.org.br/portal/faces/pages_publico/o-que-fazemos/como_ccee_atua/precos_csv?_afLoop=2103249607638040#403F_afLoop3D210324960763804026_adf.ctrl-state3Dgi14z5vhx_120.

- CEPEL. *DECOMP: Determinação da Coordenação da Operação a Curto Prazo*. Manual do Usuário 7.1 e Manual de referência, 1999a.
- CEPEL. *NEWAVE I e II: Planejamento da Operação a Longo Prazo de Subsistemas Hidrotérmicos Interligados*. Manual do Usuário. Especificação Funcional e Manual de Metodologia, 1999b.
- DE VANY, A. S., WALLS, W.D. Cointegration analysis of spot electricity prices: insights on transmission efficiency in the western US. *Energy Economics*, 21(5), 435–448, 1999.
- ENDERS, W. *Applied Econometric Time Series*. 3 ed., New Jersey: J. Wiley & Sons, 2010.
- ENGEL, R. F.; GRANGER, C. W. J. Co-integration and error correction: representation, estimation and testing. *Econometrica*, 55(2), 251-276, 1987.
- FRITZ, A. European Electricity and interrelated Futures Markets: A cointegrated Vector Autoregressive Analysis. *EWL Working Paper 05/2012*, 2012.
- HALDRUP, N.; NIELSEN, F. S.; NIELSEN, M. Ø. A vector autoregressive model for electricity prices subject to long memory and regime switching. *Energy Economics*, 32(5), 1044-1058, 2010. <http://doi.org/10.1016/j.eneco.2010.02.012>.
- JANCZURA, J.; WERON, R. An empirical comparison of alternate regime-switching models for electricity spot prices. *Energy Economics*, 32(5), 1059-1073, 2010. <http://doi.org/10.1016/j.eneco.2010.05.008>.
- JOHANSEN, S. *Likelihood-based inference in cointegration vector autoregressive models*. Oxford: Oxford University Press, 1995.
- KRISTIANSEN, T. Forecasting Nord Pool day-ahead prices with an autoregressive model. *Energy Policy*, 49(9), 328-332, 2012. <http://doi.org/10.1016/j.enpol.2012.06.028>.
- LEITE, A. L. S.; CASTRO, N. J. Crescimento e estruturação das firmas: A formação dos conglomerados do setor elétrico brasileiro. *REGE Revista de Gestão*, 21(3), 343-359, 2014. <http://dx.doi.org/10.5700/rege534>.
- MACEIRA, M.E.P. *Programação Dinâmica Dual Estocástica Aplicada ao Planejamento da Operação Energética de Sistemas Hidrotérmicos com Representação do Processo Estocástico de Afluências por Modelos Auto-Regressivos Periódicos*. Relatório Técnico CEPEL DPP/PEL 237/93. Rio de Janeiro: CEPEL, 1993.
- MAYO, R. *Derivativos de Eletricidade & Gerenc. de Riscos*. Rio de Janeiro: Synergia, 2009.
- MAZENGA, D. H. *Forecasting Spot Electricity Market Prices Using Time Series Models*. A Thesis Presented to Chalmers University of Technology for the partial fulfillment of the degree of Master of Science (MSc) in Electric Power Engineering Gothenburg, Sweden, June, 2008. Recuperado em 06 de abril de 2017, de <https://goo.gl/msfT0c>.
- ROBERTSON, J. C.; TALLMAN, E. W. Vector autoregressions: forecasting and reality. *Economic Review* (Atlanta, Ga.), 84(1), 4-18, 1999.
- SILVA, E. L. *Formação de Preços em Mercados de Energia Elétrica*. Porto Alegre: Sagra Luzzatto, 2001.
- WERON, R.; MISIOREK, A. *Forecasting spot electricity prices with time series models*. International Conference. The European Electricity Market EEM-05. May 10-12, 2005, Lodz, Poland. Proceedings Volume, 133-141, 2005.
- WERON, R.; MISIOREK, A. Forecasting spot electricity prices: a comparison of parametric and semiparametric time series model. *Int. Journal of Forecasting*, 24(4), 744-763, 2008.