

## 4 Resultados

### 4.1. Estatísticas descritivas

Os modelos de previsão de curto prazo encontrados na literatura referem-se ao que se pode chamar de curtíssimo prazo, com horizonte muitas vezes inferior a um dia e chegando, nos casos extremos, a contemplar um par ou uma trinca de dias à frente. Sendo o preço futuro da energia no Brasil determinado mensalmente, um modelo de previsão para um intervalo menor que trinta dias não apresenta grande valor comercial.

Para conseguir gerar previsão da variável da velocidade do vento por métodos estatísticos, se faz necessária uma boa base de dados para que seja possível encontrar o modelo de série temporal mais aderente à série e ao mesmo tempo mais capaz no momento de efetuar a previsão para períodos futuros. Os dados medidos em campo pelo anemômetro da torre TA-8503, localizada no Ceará no complexo de Amontada, se mostraram confiáveis, porém insuficientes para a criação de um modelo robusto, obrigando a utilização de dados de reanálise em conjunto (MERRA<sup>1</sup>). A série original medida foi apresentada como mensuração da velocidade média do vento, em metros por segundo, a cada dez minutos para então ser transformada em mensal.

A série de reanálise escolhida foi a base de dados horária do MERRA a 50m de altura com longitude -39.999 e latitude -3.500 de 30/04/1979 a 29/04/2014, ajustada para 90m de altura. A escolha ocorreu porque estas são as coordenadas onde se encontra o parque eólico de Amontada no mapa. O ajuste da velocidade média do vento de 50m para 90m para cada horário foi calculado segundo a lei de potência, conforme a equação (25), utilizando-se o expoente de perfil vertical do

---

<sup>1</sup>Modern Era Retrospective analysis for Research and Applications

vento (também conhecido como coeficiente de rugosidade) de  $0,27^2$ , obtido no estudo de avaliação do parque e verificado como expoente médio entre as séries de vento para as três alturas com medição no parque (90m, 57,2m e 37,6m).

$$\bar{U}_{h_1} = \left(\frac{h_1}{h_2}\right)^\alpha \times \bar{U}_{h_2} \quad (25)$$

Onde:

$\bar{U}_h$  = velocidade média do vento na altura  $h_i$  (m/s);

$h_i$  = altura acima do nível do solo (m);

$\alpha$  = expoente de perfil vertical do vento;

Em ambas as séries, fez-se necessária uma adequação por meio da criação de médias mensais das bases de dados. Seguem abaixo, nos Gráfico 1 e Gráfico 2, a concatenação entre a série medida e a série MERRA em metros por segundo e o comparativo entre ambas no período onde há concomitância entre as mesmas, indo de maio de 2010 até fevereiro de 2014 com os dados já transformados para geração de potência em MW médio.

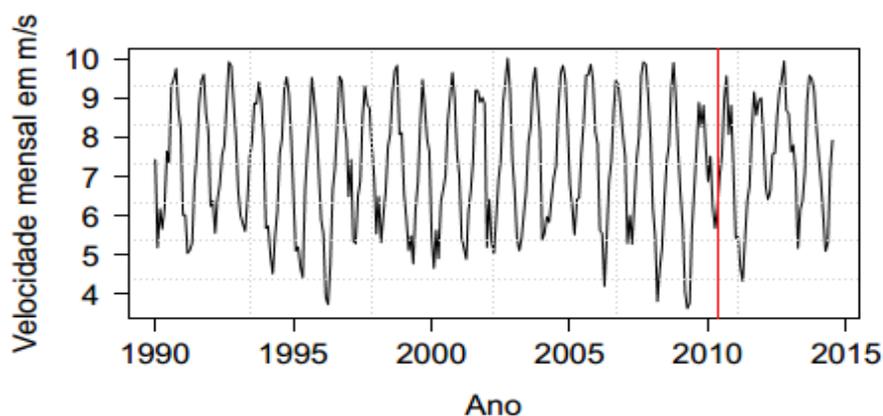


Gráfico 1 – Série MERRA concatenada com medições anemométricas  
Fonte: Própria

<sup>2</sup> Alguns coeficientes de rugosidade para tipos diferentes de terreno: Lago, oceano e solo liso: 0,10; Grama 0,15; Cercas vivas e arbustos 0,20; Florestas 0,25; Pequenas cidades com poucas árvores e arbustos 0,30; Grandes cidades com altos edifícios e construções 0,40.

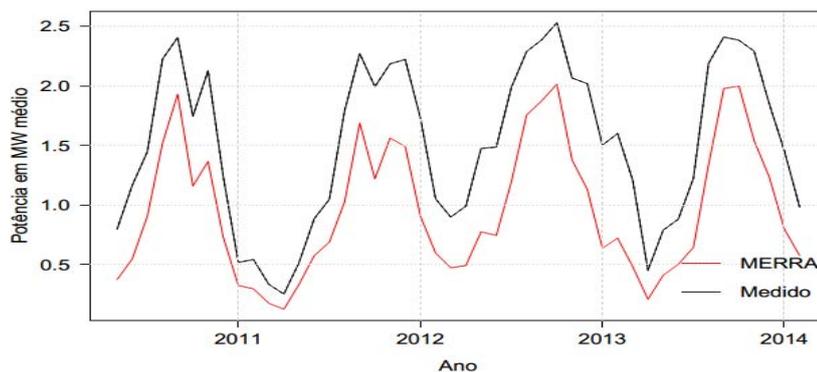


Gráfico 2 – Comparativo entre série MERRA e a medida pelo anemômetro  
Fonte: Própria

Apesar de o Gráfico 2 comparativo já nos indicar uma grande semelhança entre as séries, foi efetuado o teste de Pearson que indicou uma correlação acima de 0,958 entre os dados. O resultado do teste pode ser observado na Tabela 2.

Dada a função de autocorrelação da série do Gráfico 15, apresentada no apêndice, uma sazonalidade de dez a doze meses, aproximadamente, pode ser identificada. Como o ano contém doze meses, esta foi a sazonalidade adotada para a criação de modelos. A partir do gráfico de autocorrelação parcial (PACF) observa-se a relevância de fator autorregressivo (Gráfico 15 no apêndice).

Pearson's product-moment correlation
data: merra and medido
$t = 22.2351, df = 44, p\text{-value} = p\text{-value} < 2.2e-16$
alternative hypothesis: true correlation is not equal to 0
sample estimates: cor 0.9582672

Tabela 2 – Teste de Pearson de correlação  
Fonte: Própria

Em seguida, foi efetuado um teste  $ADF^3$  para detecção da presença, ou não, de uma raiz unitária na série. A presença de raiz unitária exigiria que a série fosse diferenciada. Porém, a hipótese nula de que haveria presença de raiz unitária na série foi rejeitada, com p-valor menor do que 1%. Segue o resultado do teste na Tabela 3.

<sup>3</sup> Augmented Dickey-Fuller

Augmented Dickey-Fuller Test	
data: x	
Dickey-Fuller = -8.901, Lag order = 6, p-value<0.01	
alternative hypothesis: stationary	

Tabela 3 – Teste ADF de raiz unitária  
Fonte: Própria

## 4.2. Análise de resultado

Foram testados três modelos da família ARIMA, de três subcategorias diferentes: um ARMA, um SARMA e um ARX. A Tabela 4 e Gráfico 3 mostram a comparação levando-se em consideração todas as combinações de amostras possíveis a partir do primeiro mês ‘*out-of-sample*’ sem alterar o tamanho destas e todos os horizontes de previsão. É possível observar que o modelo ARMA é o que possui pior capacidade preditiva (maior MAE e maior RMSE); por outro lado o pior BIC é do modelo SARMA por larga vantagem (Tabela 4). O modelo ARX se mostra adequado para previsões, ‘empatando’ com o SARMA no critério de RMSE e superando no de MAE e possui o melhor BIC entre os três modelos. Este foi, por conseguinte, o modelo adotado.

	ARMA	SARMA	ARX
RMSE	0.91	0.83	0.83
MAE	0.80	0.67	0.65
BIC	426.19	439.88	418.06

Tabela 4 – Critérios para escolha de modelo  
Fonte: Própria

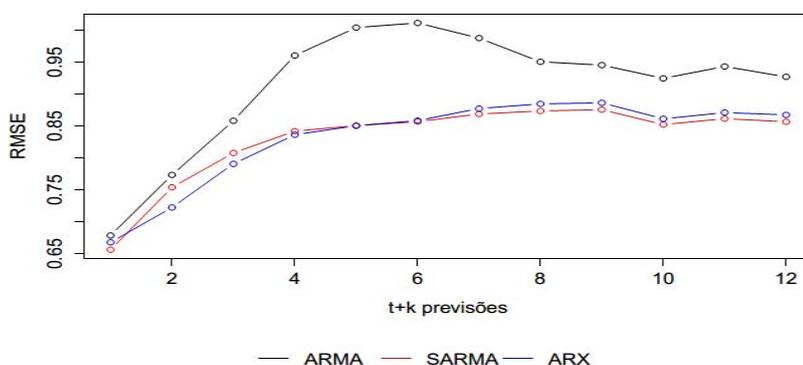


Gráfico 3 – Teste de capacidade preditiva dos modelos  
Fonte: Própria

Segue abaixo a equação (26) representativa do modelo com os coeficientes autorregressivos sem os coeficientes das onze *dummies* mensais:

$$G_t = 0,994 + 0,384 * (G_{t-1} - d_{t-1}) + 0,259 * (G_{t-2} - d_{t-2}) + d_t + \varepsilon_t \quad (16)$$

O valor exato para cada uma das *dummies* está descrito ao final da dissertação no Apêndice 1. Alguns testes foram efetuados para verificar a qualidade do modelo. Primeiramente o teste clássico de Durbin-Watson para verificar se há autocorrelação nos erros, tendo por resultado o valor 1,993165. Este valor indica que não há presença de autocorrelação. Contudo, o teste não é robusto para séries temporais, então observou-se o gráfico dos resíduos ao quadrado (Gráfico 4) que também indicou ausência de autocorrelação. Ainda neste tópico, para que não houvesse dúvidas, foram efetuados dois testes e que também indicaram ausência da autocorrelação serial dos erros sendo apresentados nas Tabela 5 e Tabela 6).

Box-Pierce test
data: resid
X-squared = 2e-04, df = 1, p-value = 0.9878

Tabela 5 – Teste de resíduos  
Fonte: Própria

Box-Ljung test
data: resid
X-squared = 2e-04, df = 1, p-value = 0.9888

Tabela 6 – Teste de resíduos  
Fonte: Própria

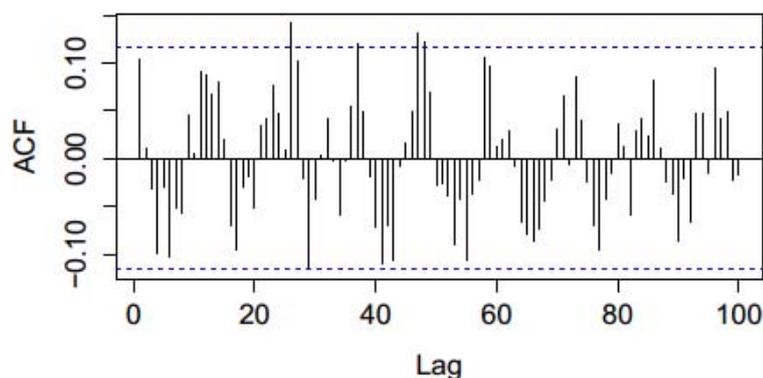


Gráfico 4 – Função de autocorrelação  
Fonte: Própria

Foi feito teste de previsão para observar a capacidade preditiva do modelo. Segue o Gráfico 5 com o resultado visual indicando que o modelo se comporta de forma esperada e possui excelente capacidade preditiva.

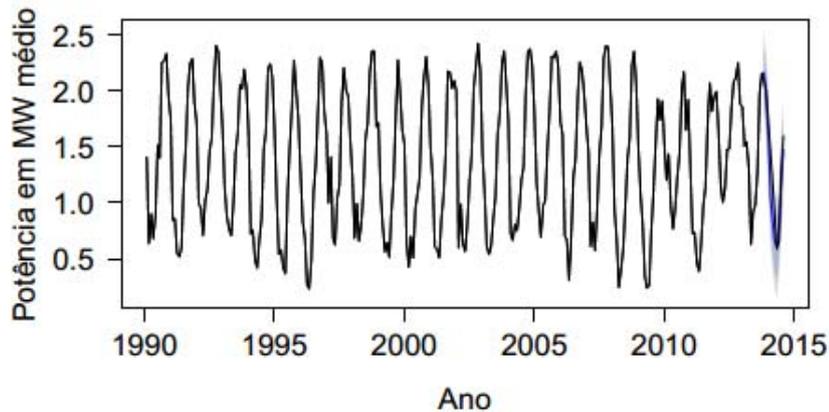


Gráfico 5 – Previsão de geração de energia  
Fonte: Própria

Para uma melhor visualização do comportamento do modelo frente ao realizado no mesmo mês, o Gráfico 6 enfatiza apenas a janela temporal onde ocorrem as previsões do gráfico anterior, apresentando os intervalos de confiança de 80% para as previsões. Esta comparação em dez períodos, dando ênfase à diferença entre o realizado e o previsto, permite observar o quão próximo dos valores reais o modelo atinge, em especial nos três primeiros meses de previsão. O valor para um período à frente é tão próximo que se confunde com o realizado.

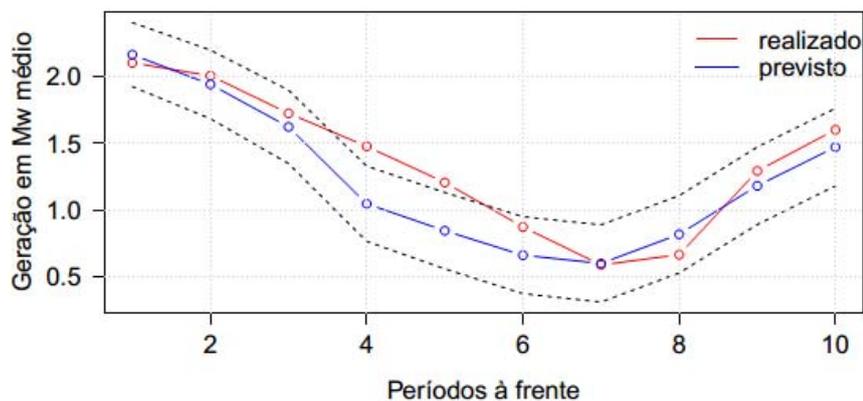


Gráfico 6 – Comparativo entre geração prevista e realizada  
Fonte: Própria

Ao observar que nosso modelo se prova eficaz, o passo seguinte é realizar uma simulação de Monte Carlo com o ARX criado para que seja possível utilizar o modelo em um contexto financeiro. São designadas como simulações de Monte Carlo os métodos estatísticos, que se baseiem em largas amostragens aleatórias para determinar resultados numéricos. Ou seja, as probabilidades são calculadas por meio de realização de sucessivos experimentos. Este tipo de simulação permite levar em consideração o risco em análises quantitativas e tomadas de decisão, pois torna possível quantificar probabilidades de ocorrência dos resultados de acordo com as ações escolhidas como decisões.

A simulação para um período à frente gerou o Gráfico 7 abaixo (e o Gráfico 16 e Gráfico 17 que se encontram no apêndice), um histograma cuja média é 1,955MW médio, mínimo de 1,36 MW médio, máximo de 2,54 MW médio e mediana de 1,96 MW médio.

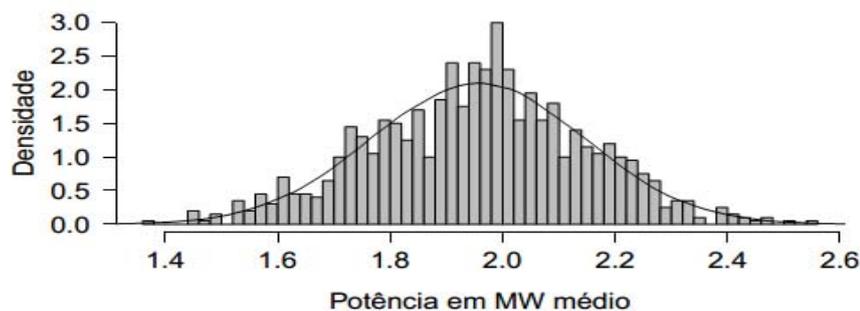


Gráfico 7 – Histograma de simulação de potência gerada para um período à frente por um aerogerador  
Fonte: Própria

A partir daí simulações para um número maior de períodos foram geradas. Como o intuito é financeiro, estas foram efetuadas sobre a série de vento já apresentada, mas também sobre uma série de geração de energia. Esta série, ainda a ser trabalhada com relação a fatores de efeito esteira e outros tipos de perda referentes à eficiência, já permite uma visão geral sobre a produção média de uma torre dentro de um complexo eólico. A conversão foi efetuada a partir da curva de potência teórica do aerogerador e a simulação já incorpora as impossibilidades práticas de geração negativa ou geração acima do limite teórico da máquina. Mil simulações para dezessete períodos à frente, até o final de 2015, foram efetuadas com o modelo ARX e podem ser observadas no Gráfico 8 (e no Gráfico 18 para simulações de vento no apêndice).

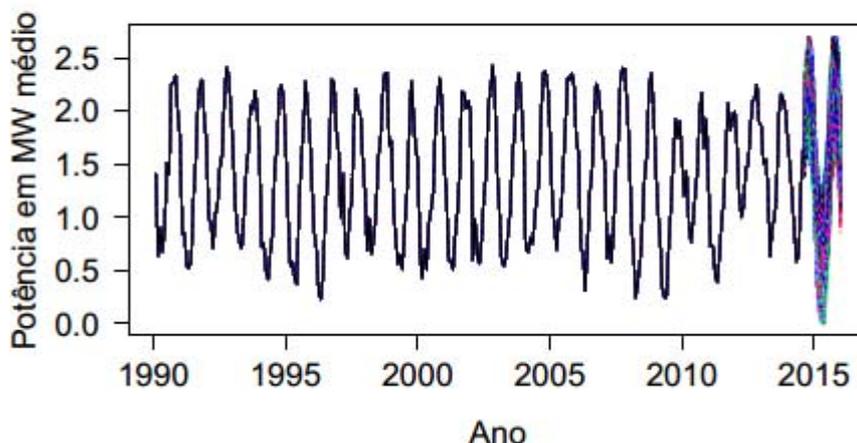


Gráfico 8 – Simulação de potência gerada por um aerogerador  
Fonte: Própria

Então passou-se à otimização. A otimização foi implementada na linguagem de programação Julia como afirmado anteriormente. Sua implementação encontra-se no apêndice desta dissertação.

Foram calculados mil cenários para se chegar aos resultados. Uma série com PLDs simulados, disponibilizada pelo ONS, foi utilizada. A potência simulada utilizada como *input* foi multiplicada pelas vinte e oito torres no parque, por vinte e quatro horas em um dia e por trinta dias em um mês. Assim pode-se ter um resultado financeiro mensal para o parque de Amontada. O preço a termo foi dimensionado como sendo a expectativa do PLD multiplicado por uma distribuição uniforme  $U(0.8,1.2)^4$ . O preço em contrato pode variar também, geralmente para se adaptar às sazonalidades já esperadas pelos gestores do parque. Por este motivo, o preço em contrato foi determinado também como sendo o valor esperado do PLD multiplicado por uma distribuição uniforme, esta porém, com um intervalo um pouco maior  $U(0.6,1.2)$ . Para a quantidade em contrato foi considerada a média de geração do mês em questão. O CVaR escolhido inicialmente foi de zero, para um  $\alpha$  de 5% ( $\beta$  de 95%). Os resultados foram calculados para cinco meses à frente. A série de vento ia até julho de 2014 e,

---

<sup>4</sup> Os valores entre parênteses representam os limites inferior e superior onde a uniforme varia. A distribuição uniforme foi escolhida por não se ter encontrado os valores do preço a termo e não se ter acesso aos valores em contrato. Assumiu-se, portanto, que estes preços variavam de maneira similar ao PLD dando mais liberdade de flutuação ao preço de contrato pois há mais flutuações possíveis.

portanto, a otimização financeira foi calculada para os meses de agosto, setembro, outubro, novembro e dezembro de 2014<sup>5</sup>. No Gráfico 9 pode-se observar o resultado da função objetivo mês a mês com resultados satisfatórios. O resultado da função objetivo é comparado para cada um dos meses com o resultado que seria obtido se o operador do parque vendesse toda a energia produzida no mesmo a “preço de contrato”. O rendimento extra aportado pela otimização do modelo proposto comparado ao modelo ‘ingênuo’ soma 2,3 milhões de reais em cinco meses, ou quatro centos e sessenta mil reais médios. Apesar de esta comparação não ser definitiva por não levar em consideração os riscos no caso do modelo ‘ingênuo’, é uma exemplificação que ajuda a dimensionar os ganhos obtidos pela otimização. O Gráfico 10 compara a geração do parque no período com a quantidade comprada ou vendida no mercado a termo para que se tenha uma ideia de escala de ação neste mercado. Observa-se que ocorre venda líquida de energia no mês de novembro de 2014, único dos cinco meses em que esta decisão é a ótima.

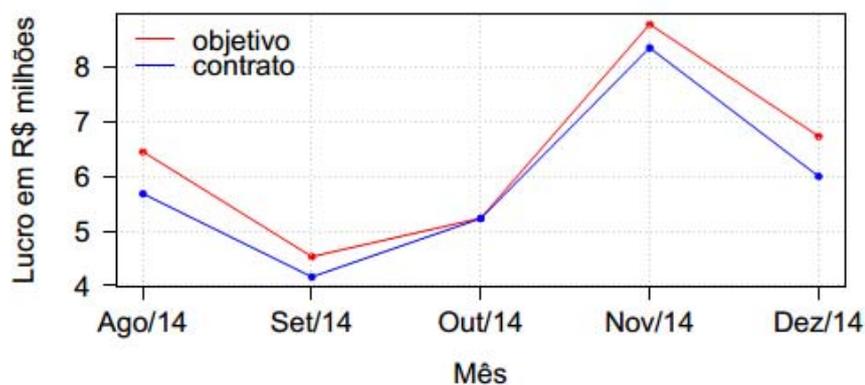


Gráfico 9 – Comparativo de lucro entre modelo ‘ingênuo’ e resultado da otimização  
Fonte: Própria

<sup>5</sup> Um ARMA(p,q) tem capacidade preditiva de p+q períodos pela literatura formal. Porém, é comum observar em ambientes menos teóricos o ARMA sendo utilizado para prever períodos além do que a rigidez da teoria permite. Em especial, em ambientes empresariais.

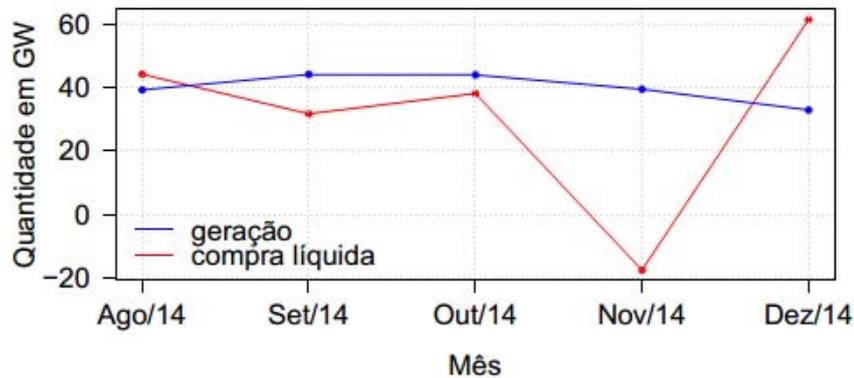


Gráfico 10 – Comparativo entre quantidade gerada e atuação no mercado a termo  
Fonte: Própria

Em seguida, alguns testes de sensibilidade foram efetuados. Primeiramente, mantendo o valor do CVaR constante e modificando a percentagem aceita de cenários ruins modificando  $\alpha$  (Gráfico 11). Pode-se observar que a principal diferença nos cenários se encontra no mês de novembro que é o único mês onde ocorre venda de energia no mercado a termo.

A diferença de lucro médio entre o cenário mais conservador e o mais propenso ao risco é da ordem de um milhão de reais. Já no Gráfico 12, observa-se a quantidade total comprada ou vendida no mercado a termo. Novamente, no cenário mais conservador e no menos conservador é possível observar uma diferença enorme. A média de operação do cenário mais conservador é de 36GW ao mês para estes cinco meses de 2014, já no caso menos conservador este número praticamente dobra, chegando a 58GW comercializados em média.

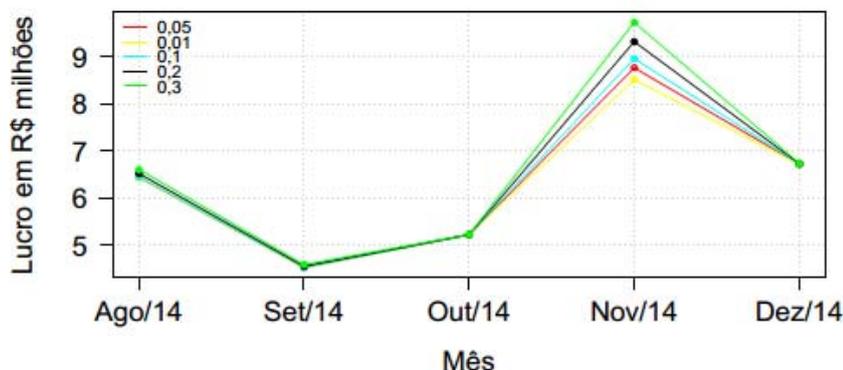


Gráfico 11 – Análise de sensibilidade do lucro -

Fonte: Própria

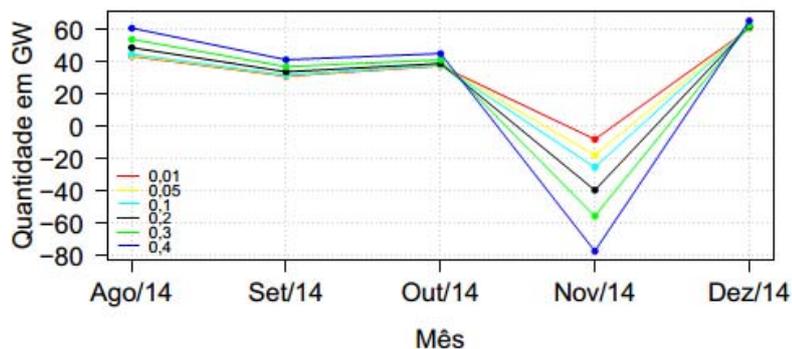


Gráfico 12 – Quantidade comprada líquida – sensibilidade em

Fonte: Própria

No Gráfico 14 observam-se os preços em cada período de cada ‘mercado’, ou seja, o preço no mercado a termo, o preço simulado de contrato e o preço médio simulado dos PLDs. Uma característica interessante a ser observada é que o único mês em que a decisão ótima é de venda de energia por parte do operador do parque é também o único mês onde a média do preço a termo supera o PLD médio. Esta decisão parece racional, tendo em vista que o operador vende no mercado futuro por um preço maior do que ele compra a PLD no mercado à vista.

Outra variável onde se pode testar e efetuar análise de sensibilidade é no valor do CVaR. No exemplo acima identificado a análise ocorreu no  $\alpha$ , ou seja, na quantidade relativa de cenários que seria admitido que ocorressem. No Gráfico 13, pode-se observar uma modificação no valor monetário da média dos cenários ruins. Neste caso, todas as linhas do gráfico são de otimizações com apenas cinco por cento de cenários negativos, porém o valor médio destes cenários varia. Como era de se esperar, quanto mais a média é 'afrouxada', no sentido de ser menos restritiva, maior é o lucro médio. Apenas em outubro de 2014 a variação do CVaR parece não representar diferença significativa de lucro para nenhum dos casos testados.

Abordando comparativamente a sensibilidade no CVaR e na porcentagem  $\alpha$  de cenários ruins, observa-se que ao se afrouxar a restrição de CVaR para menos um milhão de reais o lucro esperado aumenta em 1,4 milhão de reais no período de cinco meses. Por outro lado, ao aumentarmos o percentual de cenários ruins para 20% do total, o lucro aumenta apenas 672 mil reais. Ademais, este valor encontra-se concentrado praticamente todo em novembro (554 mil reais em novembro). Ou seja, modificar a restrição de CVaR parece uma opção menos arriscada a se tomar.

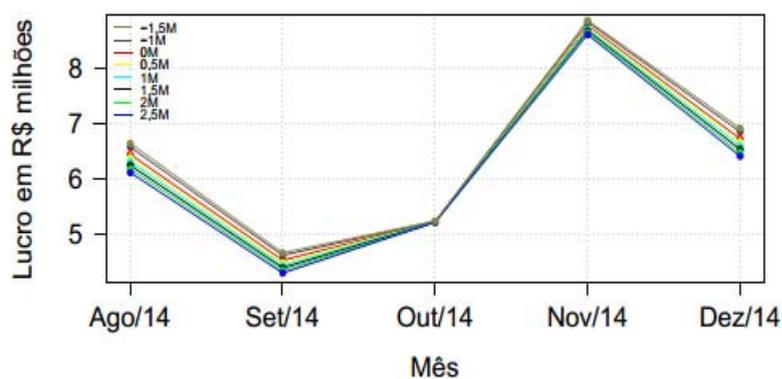


Gráfico 13 – Análise de sensibilidade do lucro - CVaR

Fonte: Própria

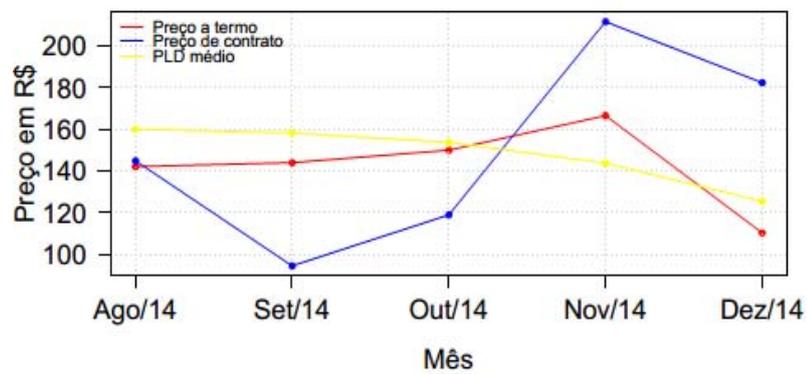


Gráfico 14 – Comparativo de preços  
Fonte: Própria