



**Cristina Pimenta de Mello Spinetti Luz**

**Otimização comercial de um parque eólico no  
Brasil utilizando simulação de Monte Carlo  
com variáveis climáticas exógenas e uma  
nova função de preferência**

**Tese de Doutorado**

Tese apresentada como requisito parcial para obtenção do título de Doutor pelo Programa de Pós-Graduação em Administração de Empresas da PUC-Rio.

Orientador: Prof. Leonardo Lima Gomes

Rio de Janeiro

Julho de 2016



**Cristina Pimenta de Mello Spinetti Luz**

**Otimização comercial de um parque eólico no  
Brasil utilizando simulação de Monte Carlo  
com variáveis climáticas exógenas e uma  
nova função de preferência**

Tese apresentada como requisito parcial para obtenção do título de Doutor pelo Programa de Pós-Graduação em Administração de Empresas da PUC-Rio. Aprovada pela Comissão Examinadora abaixo assinada.

**Prof. Leonardo Lima Gomes**

Orientador  
Departamento de Administração – PUC-Rio

**Prof. Luiz Eduardo Teixeira Brandão**

Departamento de Administração – PUC-Rio

**Prof. Marcelo Cabus Klotzle**

Departamento de Administração – PUC-Rio

**Prof. José Francisco Moreira Pessanha**

CEPEL

**Prof. Juan Guillermo Lazo Lazo**

CEFET-RJ

**Profa. Mônica Hertz**

Vice-Decana de Pós-Graduação do CCS

Rio de Janeiro, 08 de julho de 2016

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização da universidade, da autora e do orientador.

### **Cristina Pimenta de Mello Spinetti Luz**

Cristina Luz é graduada em Matemática Aplicada pela UFRJ (2008), com enfoque em Negócios, e mestre em Administração de Empresas pela PUC-Rio (2011), na área de Finanças, com enfoque no Setor Elétrico Brasileiro. Profissionalmente, estagiou na área de internacionalização de empresas do COPPEAD/UFRJ (2008) e foi funcionária do Banco do Brasil (2008-2010), exercendo atividades comerciais e administrativas. Desde 2011, trabalha com comercialização de energia na Diferencial Energia, acompanhando a dinâmica do mercado e a carteira de energia da empresa. Participa, também, de projetos P&D do setor.

#### Ficha Catalográfica

Luz, Cristina Pimenta de Mello Spinetti

Otimização comercial de um parque eólico no Brasil utilizando simulação de Monte Carlo com variáveis climáticas exógenas e uma nova função de preferência / Cristina Pimenta de Mello Spinetti Luz ; orientador: Leonardo Lima Gomes. – 2016.

170 f. : il. color. ; 30 cm

Tese (doutorado)–Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Administração, 2016.

Inclui referências bibliográficas.

1. Administração – Teses. 2. Simulação de geração eólica. 3. Variáveis climáticas exógenas. 4. Função de preferência. 5. Aversão ao risco. 6. CVaR. I. Gomes, Leonardo Lima. II. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Administração. III. Título.

Dedico esta tese à minha família, especialmente:  
à minha mãe, exemplo de amor e apoio incondicional;  
ao meu esposo, grande amigo e companheiro de jornada;  
aos meus filhos, fontes de amor, inocência e grande estímulo.

## Agradecimentos

Agradeço, primeiramente, a Deus, meu porto seguro, pelo dom da vida e desejo de aprender.

Agradeço à minha família, pelo estímulo, apoio e paciência comigo, especialmente, na fase final de conclusão desta tese. Agradeço, particularmente, àqueles que estiveram mais próximos, minha mãe, esposo, irmão, pai e prima Flavia.

Agradeço a todos os parentes e amigos que estiveram presentes para os meus filhos, enquanto eu estudava.

Agradeço aos meus filhos, Lino e Lídia, pela compreensão, ainda que pequenos, de que as vezes a mamãe precisava estudar.

Agradeço ao professor Leonardo Gomes, por todo incentivo, apoio, discussões sobre o tema, ensinamentos transmitidos e paciência.

Agradeço a todos os professores do departamento, pelos ensinamentos transmitidos e pela convivência. Agradeço, especialmente, ao professor Marcelo Cabús, pelas discussões sobre a simulação de geração eólica.

Agradeço a todos os colegas, pelo incentivo, convivência e troca de conhecimentos ao longo desses quatro anos.

Agradeço o apoio da Aneel e da Queiroz Galvão Energética S/A no âmbito do Projeto de P&D da Aneel nº PD-0622-0213/2013, e a todos os participantes deste projeto, pela troca de ideias e disponibilização de dados.

Agradeço a CAPES e a Vice-Reitoria da PUC-Rio, pelo apoio financeiro.

Agradeço aos colegas da Diferencial Energia, pelo apoio e incentivo e, aos diretores, pelo apoio e liberação parcial para cursar o doutorado.

## Resumo

Luz, Cristina Pimenta de Mello Spinetti; Gomes, Leonardo Lima (Orientador). **Otimização comercial de um parque eólico no Brasil utilizando simulação de Monte Carlo com variáveis climáticas exógenas e uma nova função de preferência.** Rio de Janeiro, 2016. 170p. Tese de Doutorado - Departamento de Administração, Pontifícia Universidade Católica do Rio de Janeiro.

Nos últimos anos, observa-se crescente penetração da energia eólica na matriz energética mundial e brasileira. Em 2015, ela já representava 6% (seis por cento) da capacidade total de geração de energia do país, colocando-o na 10ª (décima) posição entre os países com capacidade eólica instalada. A crescente penetração dessa fonte de energia e suas características de intermitência e forte sazonalidade, passaram a demandar modelos de otimização capazes de auxiliar tanto a gestão dos sistemas elétricos com geração intermitente de energia eólica, quanto a comercialização dessa energia. Avançaram, assim, os estudos de previsões de médias a cada 10 (dez) minutos, horárias e diárias de geração eólica, para atender a sua inserção na programação dos sistemas elétricos e a sua comercialização em mercados diários e horários. Contudo, poucos estudos deram atenção à previsão e simulação de médias mensais de geração eólica, imprescindíveis para gestão e otimização da comercialização dessa energia no Brasil, visto que esta ocorre essencialmente em base mensal. Neste contexto, insere-se esta tese, que busca avaliar a otimização comercial de um parque eólico no mercado livre de energia brasileiro, considerando diferentes modelos de simulação da incerteza de geração eólica e níveis de aversão ao risco do gestor. Para representar diferentes níveis de aversão ao risco do gestor, desenvolveu-se uma nova função de preferência, capaz de modelar a variação do nível de aversão ao risco de um mesmo gestor, para diferentes faixas de preferência, definidas a partir de percentis  $\alpha$ 's de VaR $\alpha$ . A função de preferência desenvolvida é uma ponderação entre o valor esperado e níveis de CVaR dos resultados. De certo modo, ela altera as probabilidades dos resultados, de acordo as preferências do gestor, similar ao efeito dos pesos de decisão na Teoria do Prospecto. Para simulação da geração eólica são adotados modelos autorregressivos com sazonalidade representada por *dummies* mensais

(ARX-11) e periódicos (PAR). Considera-se, ainda, a inclusão de variáveis climáticas exógenas no modelo ARX-11, com ganho de capacidade preditiva. Observou-se que, para um gestor neutro ao risco, as diferentes simulações de geração eólica não alteraram a decisão ótima. O mesmo não é válido para um gestor avesso ao risco, especialmente ao ser considerado o modelo de simulação com variáveis climáticas exógenas. Portanto, é importante a definição de um único modelo de simulação a ser considerado pelo gestor avesso ao risco ou, a adoção de alguma técnica multicritério para ponderação de diferentes modelos. O perfil de risco também altera as decisões ótimas do gestor, observando-se redução do desvio-padrão e da média da distribuição dos resultados e, aumento dos CVaRs e prêmio de risco, à medida que aumenta a aversão ao risco. Assim, é importante a especificação de uma única função de preferência, que represente adequadamente o perfil de risco do gestor ou da empresa, para otimização da comercialização. A flexibilidade da função de preferência desenvolvida, ao permitir a definição de diferentes níveis de aversão ao risco do gestor, para diferentes faixas de preferência, contribui para essa especificação.

### **Palavras-chave**

Comercialização de energia; simulação de Monte Carlo; geração eólica; variáveis climáticas exógenas; ARX; PAR; função de preferência; aversão ao risco; CVaR

## Abstract

Luz, Cristina Pimenta de Mello Spineti; Gomes, Leonardo Lima (Advisor). **Commercial optimization of a wind farm in Brazil using Monte Carlo simulation with exogenous climatic variables and a new preference function.** Rio de Janeiro, 2016. 170p. Doctoral Thesis - Departamento de Administração, Pontifícia Universidade Católica do Rio de Janeiro.

In recent years, we have seen an increased penetration of wind power in the Brazilian energy matrix and also worldwide. In 2015, wind power already accounted for 6% (six percent) of the Brazilian total power capacity and the country was the 10th (tenth) in the world ranking of wind power installed capacity. Due to the growing penetration of the source, its intermittency and strong seasonality, optimization models able to deal with the management of wind power, both in electrical systems operation and in trading environment, are necessary. Thus, we see the growth in the number of studies concerned about wind power forecasts for every ten (10) minutes, hours and days, meeting the electrical systems and international trading schedules. However, few studies have given attention to the forecasting and simulation of wind power monthly averages, which are essential for the management and optimization of energy trading in Brazil, since it occurs essentially on a monthly basis. In this context, we introduce this thesis, which seeks to assess the commercial optimization of a wind farm in the Brazilian energy free market, considering different simulation models for the wind power production uncertainty and different levels of manager's risk aversion. In order to represent the manager's different levels of risk aversion, we developed a new preference function, which is able to model the variation of risk aversion level of the same manager, for different preference groups. These groups are defined by  $\alpha$ 's percentiles of  $VaR\alpha$ . The developed preference function is a weighted average between expected value of results and  $CVaR$  levels. In a way, it changes the odds of the results, according to the manager's preference, similar to the effect of the decision weights on Prospect Theory. We adopted autoregressive models to simulate wind power generation, with seasonality represented by monthly dummies (ARX -11) or periodic model (PAR). Furthermore, we consider the inclusion of climate exogenous variables in the ARX-11 model and obtain predictive gain. We

observed that for a risk neutral manager, different simulations of wind power production do not change the optimal decision. However, this does not apply for risk averse managers, especially when we consider the simulation model with climate exogenous variables. Therefore, it is important that the risk averse manager establishes a single simulation model to consider or adopts some multi-criteria technique for weighting different models. The risk profile also changes the manager optimal decision. We observed that increasing risk aversion, the standard deviation and mean of the results distribution decrease, while risk premium and CVaRs increase. Therefore, to proceed the optimization, it is important to specify a single preference function, which represents adequately the manager or company risk profile. The flexibility of the developed preference function, allowing the definition of different manager's risk aversion levels for different preference groups, contributes to this specification.

## **Keywords**

Energy trading; Monte Carlo simulation; wind power production; exogenous climate variables; ARX; PAR; preference function; risk aversion; CVaR

## Sumário

1	Introdução	19
1.1.	Objetivos e questão de pesquisa	22
1.2.	Relevância do estudo e delimitação	23
1.3.	Estrutura da Tese	24
2	Comercialização de energia eólica no Brasil	26
2.1.	Ambientes de Contratação: ACR e ACL	29
2.2.	Desconto nas Tarifas de Transmissão e Distribuição	34
2.3.	Formação do Preço de Liquidação das Diferenças (PLD)	36
3	Referencial Teórico	42
3.1.	Previsão e simulação mensal da velocidade dos ventos e geração eólica	42
3.1.1.	Previsão da velocidade dos ventos e geração de energia eólica	42
3.1.2.	Previsão de longo prazo e sazonalidade	49
3.1.3.	Velocidade dos ventos e climatologia no Nordeste	50
3.2.	Funções de preferência e medidas de desempenho	54
3.2.1.	Teoria da Utilidade Esperada	55
3.2.2.	Medidas coerentes de risco	63
3.2.3.	O Equivalente Certo e o cálculo de prêmio de risco	66
3.2.4.	Parametrização de medidas e método AHP de decisão	69
3.3.	Otimização em comercialização de energia eólica	74
3.3.1.	Simulação de Monte Carlo	77
4	Modelagem estocástica da geração eólica: previsão e simulação	79
4.1.	Base de dados	80
4.1.1.	Série histórica de geração de energia eólica	81
4.1.2.	Séries históricas de variáveis climáticas	92
4.2.	Comparação de modelos	95
4.3.	Resultados e discussão	96
4.4.	Conclusão	111

5 Desenvolvimento de uma nova função de preferência	113
5.1. Definição, interpretação e propriedades do ECP_G	115
5.1.1. Cálculo do Equivalente Certo (Eq)	122
5.1.2. Cálculo do Prêmio de Risco (Pr)	124
5.1.3. Aversão ao risco global e local	126
5.1.4. Medida de aversão ao risco	128
5.2. Estimação de parâmetros do ECP_G	129
5.3. Conclusão	133
6 Aplicação da função de preferência estendida do CVaR a um problema de otimização da comercialização de energia eólica no ACL	135
6.1. Modelagem matemática do problema de otimização	138
6.2. Resultados e discussão	141
6.3. Conclusão	153
7 Considerações finais	155
8 Referências bibliográficas	160
9 Anexo A: Pacotes utilizados do R	170

## Lista de tabelas

Tabela 1 – Medidas de desempenho baseadas em momentos parciais da distribuição	60
Tabela 2 – Escala de importância 1-9 de Saaty	72
Tabela 3 – Índices de consistência aleatória (RI)	73
Tabela 4 – Série de velocidade dos ventos medida a 90 m com discretização de 10 minutos: complementação de dados	84
Tabela 5 – Comparação de modelos autorregressivos sem variáveis climáticas	97
Tabela 6 – Comparação de modelos autorregressivos com variáveis climáticas	98
Tabela 7 – Critérios de seleção da ordem p do modelo PAR	99
Tabela 8 – p-valores do teste Diebold-Mariano (H1: Acurácia do modelo da linha i é maior que a do modelo da coluna j)	101
Tabela 9 – p-valores do teste Giacomini-White (H1: Acurácia do modelo da linha i é maior que a do modelo da coluna j)	101
Tabela 10 – p-valores dos testes de Diebold-Mariano e Giacomini-White para acurácia do modelo PAR(3) em relação aos demais (H1: Acurácia do modelo PAR(3) é maior que a do modelo da coluna j)	102
Tabela 11 – Parâmetros do modelo PAR(3) para cada período m	104
Tabela 12 – Valores das variáveis climáticas para previsão e simulação	106

## Lista de figuras

Figura 1 – Capacidade de geração eólica global 2000 a 2015	19
Figura 2 – Dez países com maior capacidade de geração eólica instalada em Dez/2015	20
Figura 3 – Evolução da capacidade eólica instalada no Brasil (2005 a 2019), considerando empreendimentos autorizados até dezembro de 2015	28
Figura 4 – Sistema Interligado Nacional e submercados	31
Figura 5 – Contabilização no Mercado de Curto Prazo	31
Figura 6 – Processo decisório e consequências em um sistema hidrotérmico	38
Figura 7 – Custos imediato (FCI) e futuro (FCF) da operação e decisão ótima	39
Figura 8 – Oceano Pacífico e as regiões do <i>Niño</i>	52
Figura 9 – Circulação dos ventos alísios e <i>El Niño</i> (a esquerda) e <i>La Niña</i> (a direita)	52
Figura 10 – Dipolo Negativo do Atlântico (à direita) e Dipolo Positivo do Atlântico (à esquerda) e o posicionamento da ZCIT	53
Figura 11 – Função utilidade e sua inversa	67
Figura 12 – Função utilidade de investidor avesso ao risco, ( $E\eta; E[U(X)]$ ) e ( $E[X]; U(E[X])$ )	68
Figura 13 – Prêmio de risco e sua relação com $E\eta$ e $E[X]$	68
Figura 14 – Estrutura Geral do Modelo AHP	72
Figura 15 – Número de artigos utilizando algoritmos de otimização aplicados a energias renováveis de 1989 a 2009	74
Figura 16 – Tipo de dados do parque eólico em estudo e ocorrência de <i>El Niño/La Niña</i> (fev/2009 a mar/2016)	82
Figura 17 – Série do MERRA de velocidade horária do vento ajustada para 90 m (01/01/1982 a 31/01/2009)	83
Figura 18 – Média mensal da velocidade do vento: série das medições do parque a 90 m e do MERRA a 50 m e ajustada para 90 m (fevereiro/2009 a janeiro/2014)	84

Figura 19 – Curva de potência do aerogerador	85
Figura 20 – Construção da série temporal final de média mensal de geração teórica do parque	86
Figura 21 – Série temporal de média mensal de geração eólica (jan/1982 a mar/2016) (acima) e funções de autocorrelação - ACF (à esquerda) e autocorrelação parcial - PACF (à direita)	87
Figura 22 – Série temporal periódica de média mensal de geração eólica (jan/1982 a mar/2016) (acima) e <i>box-plot</i> da série periódica (abaixo)	88
Figura 23 – ACF (à esquerda) e PACF (à direita) periódicas da média mensal de geração eólica (jan/1982 a mar/2016)	89
Figura 24 – Densidade de probabilidade ajustada (à esquerda) e histograma (à direita) da média mensal de geração eólica (jan/1982 a mar/2016)	90
Figura 25 – Densidade de probabilidade ajustada à média mensal de geração eólica (jan/1982 a mar/2016) por período (meses)	91
Figura 26 – Histograma da média mensal de geração eólica (jan/1982 a mar/2016) por período (meses)	91
Figura 27 – Histórico de geração eólica (preto), ninoA (azul) e dipA (vermelho); valores do eixo-y referentes a geração eólica (MWmed)	94
Figura 28 – Histórico de geração eólica (centro) e <i>dummies</i> climáticas: nino (vermelho, acima), nina (azul, acima), dipP (vermelho, abaixo) e dipN (azul, abaixo)	94
Figura 29 – Previsão da média mensal de geração eólica de abril/2016 a dezembro/2017 e intervalos de confiança de 95% e 80%, com modelo ARX(2)-11	105
Figura 30 – Previsão da média mensal de geração eólica de abril/2016 a dezembro/2017 e intervalos de confiança de 95% e 80%, com modelo PAR(3)	105
Figura 31 – Previsão da média mensal de geração eólica de abril/2016 a dezembro/2017 e intervalos de confiança de 95% e 80%, com modelo ARX(2)-15 (dez-mai), considerando <i>El Niño</i> (abr/16-mai/16), <i>La Niña</i> (dez/16-dez/17), Dipolo Positivo (mai/16-out/16) e Dipolo Negativo (fev/17-mai/17)	106

Figura 32 – Simulação de 500 séries da média mensal de geração eólica de abril/2016 a dezembro/2017, com modelo ARX(2)-11	107
Figura 33 – Simulação de 500 séries da média mensal de geração eólica de abril/2016 a dezembro/2017, com modelo PAR(3)	107
Figura 34 – Simulação de 500 séries da média mensal de geração eólica de abril/2016 a dezembro/2017, com modelo ARX(2)-15 (dez-mai), considerando <i>El Niño</i> (abr/16-mai/16), <i>La Niña</i> (dez/16-dez/17), Dipolo Positivo (mai/16-out/16) e Dipolo Negativo (fev/17-mai/17)	108
Figura 35 – Estatísticas básicas das simulações por mês e modelo	109
Figura 36 – Média mensal de geração eólica de abril/2014 a março/2016: realizado e previsão com intervalos de confiança de 95% e 80%, pelo modelo ARX(2)-11	110
Figura 37 – Média mensal de geração eólica de abril/2014 a março/2016: realizado e previsão com intervalos de confiança de 95% e 80%, pelo modelo PAR(3)	110
Figura 38 – Média mensal de geração eólica de abril/2014 a março/2016: realizado e previsão com intervalos de confiança de 95% e 80%, pelo modelo ARX(2)-15 (dez-mai)	110
Figura 39 – Função utilidade subjacente ao ECP_G com $N = 2$	116
Figura 40 – Exemplo de estrutura do problema no método AHP com 3 critérios ( $N = 3$ )	132
Figura 41 – Exemplo de Matrizes de Julgamentos e Pesos do método AHP com 3 critérios ( $N = 3$ ) e cálculo dos valores de consistência CI e CR	132
Figura 42 – Histograma do valor médio no horizonte de otimização das variáveis de incerteza para os cenários utilizados e o total de cenários gerados	141
Figura 43 – Volumes sazonalizados de venda otimizados para o caso determinístico e médias mensais das simulações de: geração eólica, PLD do SE/CO e PLD do NE	147
Figura 44 – Histogramas mensais das simulações de PLD do SE/CO no horizonte de otimização	148
Figura 45 – Volumes sazonalizados de venda otimizados para o	

ano de 2017 com simulação de geração pelo modelo ARX(2)-11 e Obj1 a Obj4	149
Figura 46 – Volumes sazonalizados de venda otimizados para o ano de 2017 com simulação de geração pelo modelo PAR(3) e Obj1 a Obj4	150
Figura 47 – Volumes sazonalizados de venda otimizados para o ano de 2017 com simulação de geração pelo modelo ARX(2)-15 (dez-mai) e Obj1 a Obj4	150
Figura 48 – Volumes sazonalizados de venda otimizados para Obj5 e Obj6	151
Figura 49 – <i>Box-plot</i> dos cenários de VPs para as funções objetivo parametrizadas por valores de $\alpha$ 's	152
Figura 50 – <i>Box-plot</i> dos cenários de VPs para as funções objetivo parametrizadas por valores de VaRs	153

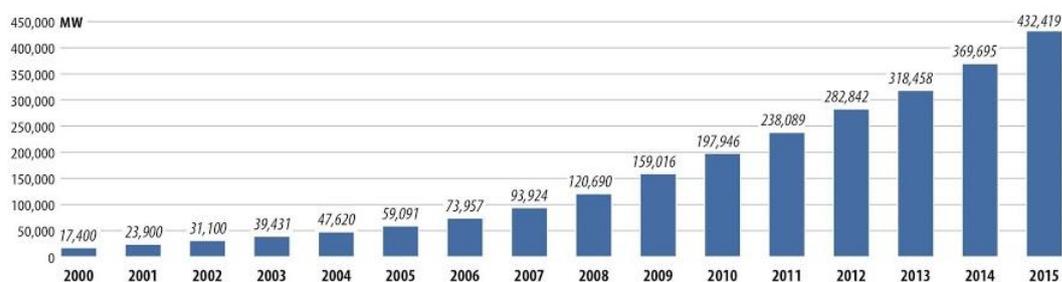
## Lista de siglas e abreviaturas

ACR	Ambiente de Contratação Regulada
ACL	Ambiente de Contratação Livre
AHP	<i>Analytic Hierarchy Process</i>
ANN	<i>Artificial Neural Networks</i>
CCEE	Câmara de Comercialização de Energia Elétrica
CMO	Custo Marginal de Operação
CVaR	<i>Conditional Value at Risk</i>
ECP	<i>Extended CVaR Preference functional</i>
<i>Eq</i>	Equivalente Certo
EPE	Empresa de Pesquisa Energética
ENSO	<i>El Niño Southern Oscillation</i>
LER	Leilão de Energia de Reserva
LFA	Leilão de Fontes Alternativas
MCP	Mercado de Curto Prazo
MCR	Medida Coerente de Risco
MERRA	<i>Modern Era-Retrospective Analysis for Research and Applications</i>
MMR	Medida Monetária de Risco
MRC	Medida Convexa de Risco
MWh	Megawatt-hora
MWmed	Megawatt-médio (média de megawatt por hora)
NCEP	<i>National Centers for Environmental Prediction</i>
NE	Nordeste
NWP	<i>Numerical Weather Prediction</i>
ONI	<i>Oceanic Niño Index</i>
ONS	Operador Nacional do Sistema Elétrico
PDDE	Programação Dinâmica Dual Estocástica
PLD	Preço de Liquidação das Diferenças
PMO	Programa Mensal de Operação Energética

Proinfa	Programa de Incentivo às Fontes Alternativas de Energia Elétrica
RE-SEB	Reestruturação do Setor Elétrico Brasileiro
SE/CO	Sudeste/Centro-Oeste
SEB	Setor Elétrico Brasileiro
SIN	Sistema Interligado Nacional
SMC	Simulação de Monte Carlo
TSM	Temperatura da Superfície do Mar
TUSD/TUST	Tarifas de Uso dos Sistemas de Distribuição e Transmissão
v.a.	Variável aleatória
VaR	<i>Value at Risk</i>
ZCIT	Zona de Convergência Inter Tropical

# 1 Introdução

Desde a Conferência das Nações Unidas sobre o Meio Ambiente e o Desenvolvimento, conhecida como ECO92, observa-se uma crescente demanda mundial por fontes renováveis de energia, criando-se, inclusive, políticas de incentivo para sua viabilização econômica. De acordo com a IEA – *International Energy Agency*, em 2015, a geração de energia global proveniente de fontes renováveis, excluindo-se a hídrica, contribuiu com 7,6% da geração global total, representando um crescimento de 1,0% da participação das energias renováveis, em relação a 2014 (IEA, 2016). Dentre as fontes renováveis, a energia eólica tem apresentado expressivo crescimento da capacidade instalada global, com crescimento de 118% nos últimos 5 (cinco) anos, conforme observa-se na Figura 1 (GWEC, 2016).

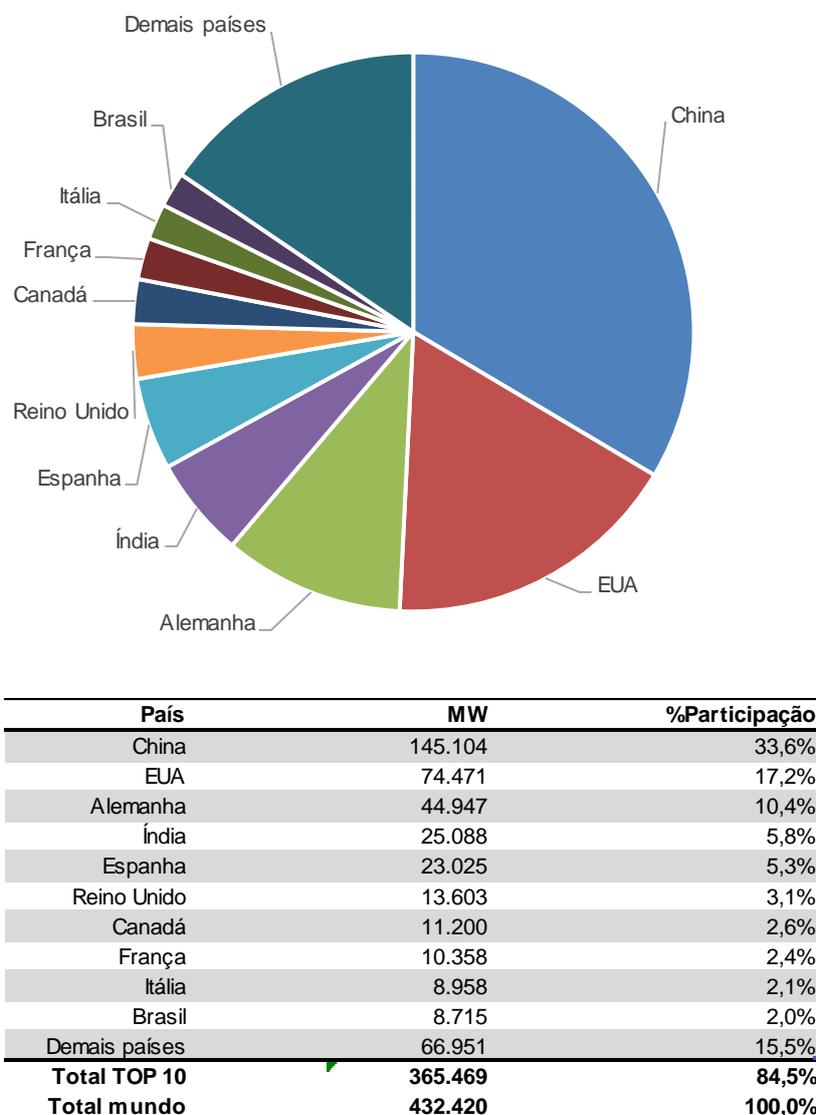


**Figura 1 – Capacidade de geração eólica global 2000 a 2015**

Fonte: GWEC (2016).

No Brasil, a energia eólica foi efetivamente introduzida na matriz energética apenas em 2006, com maior penetração e rápida expansão, a partir de 2011 (DALBEM *et al.*, 2014b). Em dezembro de 2015, o Brasil já era o décimo país em capacidade eólica instalada, conforme *ranking* mostrado na Figura 2 (GWEC, 2016). A maior parte da geração eólica no Brasil está alocada no mercado regulado, comprometida com contratos de venda de energia de 15 a 20 anos. Contudo, ainda há empreendimentos com alguma parcela ou a totalidade da energia disponível para

comercialização no mercado livre (aproximadamente 10% a 20% da capacidade eólica total, segundo boletins mensais da ABEEólica – Associação Brasileira de Energia Eólica).



**Figura 2 – Dez países com maior capacidade de geração eólica instalada em Dez/2015**

Fonte: Adaptado de GWEC (2016).

Ainda sobre a capacidade de geração eólica brasileira, o total de 8.715 MW, já instalado em dezembro de 2015, divide-se entre 354 empreendimentos, localizados nos estados do Sul e Nordeste e representava, na época, 6% da capacidade total de geração de energia do país. Para os próximos anos, há mais de 8.900 MW autorizados para implantação, o que significa dobrar a capacidade de geração eólica verificada em dezembro de 2015.

Esse rápido e expressivo crescimento da geração eólica no país aumenta a demanda por ferramentas de gestão capazes de auxiliar a operação dos parques eólicos e a comercialização de sua energia, em especial, quando se trata da comercialização no mercado livre. Essa demanda cresce, também, em nível mundial, encontrando-se uma vasta literatura sobre modelos de previsão de velocidade dos ventos e de geração de energia eólica para horizontes de curtíssimo prazo, como minutos e poucos dias à frente. Mesmo no Brasil, o ONS – Operador Nacional do Sistema Elétrico, no dia 11 de abril de 2016, realizou uma reunião em sua sede, em que mostrou o início de estudos de previsão de geração eólica para as próximas horas e dias, com foco na otimização da operação do sistema elétrico. Apesar de serem imprescindíveis esses estudos para operação dos sistemas elétricos e dos parques eólicos, eles pouco ou nada contribuem para gestão da comercialização de energia eólica no Brasil.

No mercado brasileiro de energia, os contratos se dão, essencialmente, em base mensal. Portanto, há necessidade de estudos de previsão de longo prazo de geração eólica, com horizonte anual e discretização mensal, por exemplo, bem como a utilização dessas previsões em modelos de gestão das decisões de comercialização de energia eólica, particularmente, no mercado livre. Essas previsões de longo prazo também são uma demanda do ONS para auxiliar o planejamento da operação energética, como foi colocado na reunião, em sua sede, do dia 11 de abril de 2016, mas não são o foco de seus estudos correntes.

Outro ponto importante sobre essas previsões mensais é observar a possível influência de fenômenos climáticos sobre elas, visto que, de modo empírico, especialistas associam alguns fenômenos a maior ou menor geração de energia eólica. Essas associações também estão relacionadas a uma premissa geral de que mais precipitação significa menor geração eólica e vice-versa, tendo-se estudos que mostram a complementariedade entre a geração de energia eólica e hídrica no Brasil. Alguns estudos brasileiros, inclusive, abordam previsões ou simulações de geração eólica conjuntamente com as de vazões de rios, mas sem considerar a atuação de fenômenos climáticos.

Em outra linha de pesquisa e trabalho, no que diz respeito a modelos de otimização de comercialização de energia, é crescente o uso de funções de preferência com aversão ao risco explícita ou através de restrições, o que sugere a presença de aversão ao risco nos gestores de mercados de energia. No Brasil, a

própria função objetivo utilizada no cálculo do PLD – Preço de Liquidação das Diferenças (preço de referência do mercado à vista) representa aversão ao risco. Apesar das propriedades satisfatórias dessas funções, uma crítica comum é o fato de considerarem o mesmo grau de aversão ao risco do gestor, independentemente de seu nível de riqueza ou confiança nos resultados.

Nesse contexto, esta tese vem contribuir de modo a ajudar a cobrir essas lacunas, abordando a otimização comercial de um parque eólico no mercado livre de energia brasileiro, passando pelas seguintes questões: (i) previsão e simulação de Monte Carlo de médias mensais de geração eólica para o horizonte anual, com verificação da influência de variáveis climáticas exógenas; (ii) desenvolvimento de uma nova função de preferência, capaz de capturar diferentes níveis de aversão ao risco de um mesmo gestor.

### **1.1. Objetivos e questão de pesquisa**

A partir do exposto, o principal objetivo desta tese é avaliar a otimização comercial de um parque eólico no mercado livre de energia brasileiro para diferentes perfis de aversão ao risco do gestor e modelos de simulação da geração eólica, ressaltando-se a interferência dos diferentes perfis e modelos na otimização. Para atingí-lo, fez-se necessário estabelecer as premissas do modelo de otimização, notadamente, a modelagem das principais incertezas e a definição da função objetivo. Portanto, definiu-se como objetivos intermediários:

- ✓ especificar modelos adequados para previsão e simulação de Monte Carlo de médias mensais de geração eólica para o horizonte anual, verificando-se, também, a influência de fenômenos climáticos;
- ✓ desenvolver uma nova função de preferência capaz de capturar diferentes níveis de aversão ao risco do gestor.

Uma vez definidos os objetivos, eles podem ser resumidos, respectivamente, nas seguintes questões de pesquisa:

- ✓ Como o perfil de risco do gestor e diferentes modelos de simulação da geração eólica interferem na otimização da comercialização de energia, no mercado livre, de um parque eólico no Brasil?

- ✓ Como modelar a média mensal de geração eólica para horizonte anual e considerar a influência de fenômenos climáticos? Qual a relevância desses fenômenos na previsão e simulação da média mensal de geração eólica? Há outros fatores relevantes a serem considerados?
- ✓ Como modelar diferentes níveis de aversão ao risco do gestor em uma função de preferência? Quais as propriedades e derivações dessa função?

## 1.2.

### Relevância do estudo e delimitação

Em relação à aplicabilidade, a relevância deste estudo é de fácil percepção, visto que tanto o modelo de otimização, quanto a simulação de geração eólica propostos podem ser empregados por geradores eólicos para auxílio à gestão contratual. É importante ressaltar que a otimização em comercialização de energia eólica não é uma inovação (POURSINHO *et al.*, 2011; 2012; MORENO *et al.*, 2012; ZUGNO *et al.*, 2013), contudo, são escassos ou nulos os estudos que tratam o problema em base mensal para o horizonte anual, o que é fundamental para contemplar as características do mercado brasileiro de energia.

Quanto às previsões de velocidade dos ventos e de geração de energia eólica, MILLIGAN *et al.* (1995) e BARTHELMIE *et al.* (2008) são alguns dos autores que mostraram seus benefícios econômicos, seja para empreendedores, seja para os sistemas elétricos. Portanto, encontra-se vasta literatura sobre essas previsões para horizontes de horas ou poucos dias à frente, o que é essencial para mercados horários de energia e para a programação da operação dos sistemas elétricos e dos parques eólicos. Em horizontes de curto prazo, a ocorrência de fenômenos climáticos exerce pouca ou nenhuma influência, contudo, para o horizonte anual, testar a influência destes faz-se necessário. Assim, a previsão e simulação de médias mensais de geração eólica, considerando a influência de fenômenos climáticos, é uma contribuição tanto prática, quanto acadêmica, sendo também útil para órgãos governamentais no contexto do planejamento energético anual. FOLEY *et al.* (2012) corroboram essa relevância, ao apontar a demanda por estudos sobre previsão de longo prazo de geração de energia eólica.

Finalmente, a principal contribuição acadêmica desta tese reside na função objetivo proposta para representar as preferências do gestor, cujas propriedades e

função utilidade subjacente são demonstradas. A função proposta é inovadora e representa uma extensão da função objetivo que pondera o valor esperado dos resultados e um dado nível de CVaR – *Conditional Value at Risk* destes, utilizada frequentemente em problemas do setor elétrico (POURSINHO *et al.*, 2011; RUDLOFF *et al.*, 2014; FÂNZERES *et al.*, 2012; LAZO *et al.*, 2012). Essa extensão permite a definição de diferentes níveis de aversão ao risco do gestor em função de níveis de CVaR ou valores de corte, estando alinhada com a ideia de STREET (2008) de cinco ou mais pontos de interesse das empresas para especificação de funções utilidades lineares por partes.

Portanto, as contribuições acadêmicas desta tese são: (i) o desenvolvimento e formalização de uma nova função de preferência que pondera o valor esperado e  $n$  níveis de CVaR dos resultados, sendo a função desenvolvida uma extensão ao funcional ECP de um período (STREET, 2010); (ii) a verificação e incorporação da influência de fenômenos climáticos na modelagem autorregressiva de previsões de médias mensais de geração eólica.

Uma vez explicitada a relevância prática e acadêmica desta tese, faz-se necessário deixar clara sua delimitação. No que diz respeito à modelagem de previsão e simulação da média mensal de geração eólica, a metodologia proposta para construção da série, seleção das variáveis climáticas e testes dos modelos pode ser replicada para qualquer parque eólico, contudo, os parâmetros e demais resultados obtidos no estudo são delimitados ao parque eólico tomado como base, localizado no Brasil, no estado do Ceará. Portanto, generalizações sobre os resultados dos modelos ajustados requerem cautela e precedem de análise das séries de geração eólica para as quais pretende-se fazer as generalizações. Em relação à função de preferência desenvolvida, ela tem ampla aplicabilidade, mas este estudo delimitou-se a apresentá-la e a demonstrar suas propriedades. Um ponto importante da função desenvolvida é sua parametrização, específica de cada gestor ou empresa, em função da aversão ao risco.

### **1.3. Estrutura da Tese**

Neste primeiro capítulo, contextualizou-se a problemática a ser tratada e apresentou-se os objetivos principal e secundários do estudo, bem como suas

delimitações e relevância acadêmica e prática. No segundo capítulo é feita uma breve apresentação dos principais aspectos da comercialização de energia eólica no Brasil, particularmente, no ACL – Ambiente de Contratação Livre, e da formação de preços no mercado. No terceiro capítulo é apresentado o referencial teórico do estudo, incluindo os seguintes assuntos: modelagem de previsão e simulação de geração eólica; influência de variáveis climáticas sobre a velocidade dos ventos no Ceará; funções de preferência e medidas de desempenho; otimização em comercialização de energia eólica. No quarto capítulo realiza-se a modelagem da média mensal de geração eólica, com apresentação da base de dados, dos modelos considerados e dos testes de desempenho. No quinto capítulo é feito o desenvolvimento da nova função de preferência, com demonstração de suas propriedades e breve sugestão de parametrização. No sexto capítulo, a nova função de preferência é aplicada na otimização de um problema de comercialização de energia eólica no Brasil, com realização de sensibilidades em função dos modelos de simulação de média mensal de geração eólica e da parametrização da função. No sétimo capítulo são apresentadas as considerações finais e as sugestões de trabalhos futuros. Por fim, as referências bibliográficas, seguidas do anexo contemplando os pacotes utilizados do programa R (R CORE TEAM, 2015).

## 2 Comercialização de energia eólica no Brasil

Em 1992, entrou em operação comercial o primeiro aerogerador do Brasil, localizado no arquipélago de Fernando de Noronha, com 225 kW de potência. Ele foi resultado de uma parceria entre o Centro Brasileiro de Energia Eólica (CBEE) e a Companhia Energética de Pernambuco (CELPE), com financiamento do instituto de pesquisas dinamarquês *Folkecenter*. Nessa época, o SEB – Setor Elétrico Brasileiro era um oligopólio verticalizado.

Apenas em 1996, teve início o Projeto RE-SEB – Projeto de Reestruturação do Setor Elétrico Brasileiro (1996 a 1998), que concluiu pela necessidade de desverticalização das empresas de energia elétrica, do incentivo à competição na geração e comercialização e, da manutenção sob regulação do Estado dos setores de distribuição e transmissão de energia elétrica, considerados como monopólios naturais. Esse projeto foi aprimorado em 2004, dando origem a configuração atual do SEB, que tem como pilares: (i) garantir a segurança do suprimento de energia elétrica; (ii) promover a inserção social, através de programas de universalização do atendimento e da modicidade tarifária e de preços. Nessa configuração, a comercialização de energia passou a contar com dois ambientes de negociação: o ACR – Ambiente de Contratação Regulada, com agentes de geração e de distribuição de energia e o ACL – Ambiente de Contratação Livre, com geradores, distribuidores, comercializadores, importadores e exportadores, além dos consumidores livres e especiais. Outra característica importante foi a instituição de leilões no ACR para compra de energia elétrica pelas distribuidoras, com o objetivo de alcançar a modicidade tarifária.

Em termos institucionais, o modelo passou a ser constituído por: CCEE – Câmara de Comercialização de Energia Elétrica, que administra os contratos de energia, a liquidação do mercado de curto prazo e a realização dos leilões regulados; ONS – Operador Nacional do Sistema Elétrico, responsável pela operação das instalações de geração e transmissão nos sistemas interligados brasileiros; ANEEL – Agência Nacional de Energia Elétrica, que atua como órgão regulador do setor;

CMSE – Comitê de Monitoramento do Setor Elétrico, que avalia permanentemente a segurança do suprimento de energia elétrica do país; EPE – Empresa de Pesquisa Energética, responsável pelo planejamento do setor elétrico a longo prazo; MME – Ministério de Minas e Energia, que formula e implementa as políticas para o setor elétrico, de acordo com as diretrizes do CNPE – Conselho Nacional de Política Energética, que homologa a política energética em articulação com as demais políticas públicas.

Apesar do primeiro aerogerador no Brasil, de 1992, até o lançamento do Proinfa – Programa de Incentivo às Fontes Alternativas de Energia Elétrica, em 2004, pouco ou nada se investiu em energia eólica no país. Apenas em 2001, em função da crise energética, quando já se falava da complementaridade sazonal do regime de ventos e de vazões nos reservatórios das hidroelétricas, houve uma tentativa de incentivo, mas sem resultados.

O Proinfa, conforme descrito no Decreto nº 5.025/2004, foi instituído com o objetivo de aumentar a participação da energia das fontes renováveis: eólica, biomassa e pequenas centrais hidroelétricas, na matriz energética brasileira. Toda a energia contratada no âmbito do programa foi destinada inicialmente à Eletrobras, por um período de suprimento de 20 (vinte) anos e posterior rateio anual em quotas para todos os consumidores finais do SIN – Sistema Interligado Nacional, quais sejam: distribuidoras, consumidores livres e especiais. De acordo com a Lei nº 11.943/2009, o prazo para o início de funcionamento desses empreendimentos encerrava-se em 30 de dezembro de 2010, porém, ocorreram algumas postergações. O Proinfa impulsionou especialmente a energia eólica, abrindo caminho para a fixação da indústria de componentes e turbinas eólicas no país ao estipular percentuais de nacionalização dos empreendimentos (DALBEM *et al.*, 2014b). Em pouco mais de 3 (três) anos, o país passou de apenas 22 MW para 414 MW instalados de energia eólica.

Posteriormente, passaram a ocorrer leilões no ACR exclusivos para comercialização de energia eólica e, ainda, leilões de fonte mista nos quais a energia eólica ganhou expressividade, graças a redução do seu custo de produção, com consequente ganho de competitividade geral. Dentre esses leilões, encontram-se: em 2009, o 2º LER – Segundo Leilão de Energia Reserva, primeiro leilão exclusivo para a fonte eólica, com contratação de 1,8 GW; em 2010, o 3º LER e o LFA – Leilão de Fontes Alternativas, de fontes mistas, com contratação de 2 GW de

energia eólica; em 2011, o 4º LER, o A-3 e o A-5, com contratação de 2,9 GW de energia eólica e grande destaque para a fonte; em 2012, o A-5, com contratação de 281,9 MW. Além do Proinfa e dos leilões, a energia eólica, também, é comercializada em uma escala menor no ACL, onde as condições contratuais são livremente negociadas entre as contrapartes. Uma imagem da evolução da capacidade eólica instalada no Brasil, passada e futura, com base no que já foi autorizado até dezembro de 2015, consta na Figura 3, bem como a origem da contratação total de energia eólica esperada para 2019 (final do horizonte de início de suprimento dos contratos já celebrados no ACR e de entrada em operação dos empreendimentos autorizados).

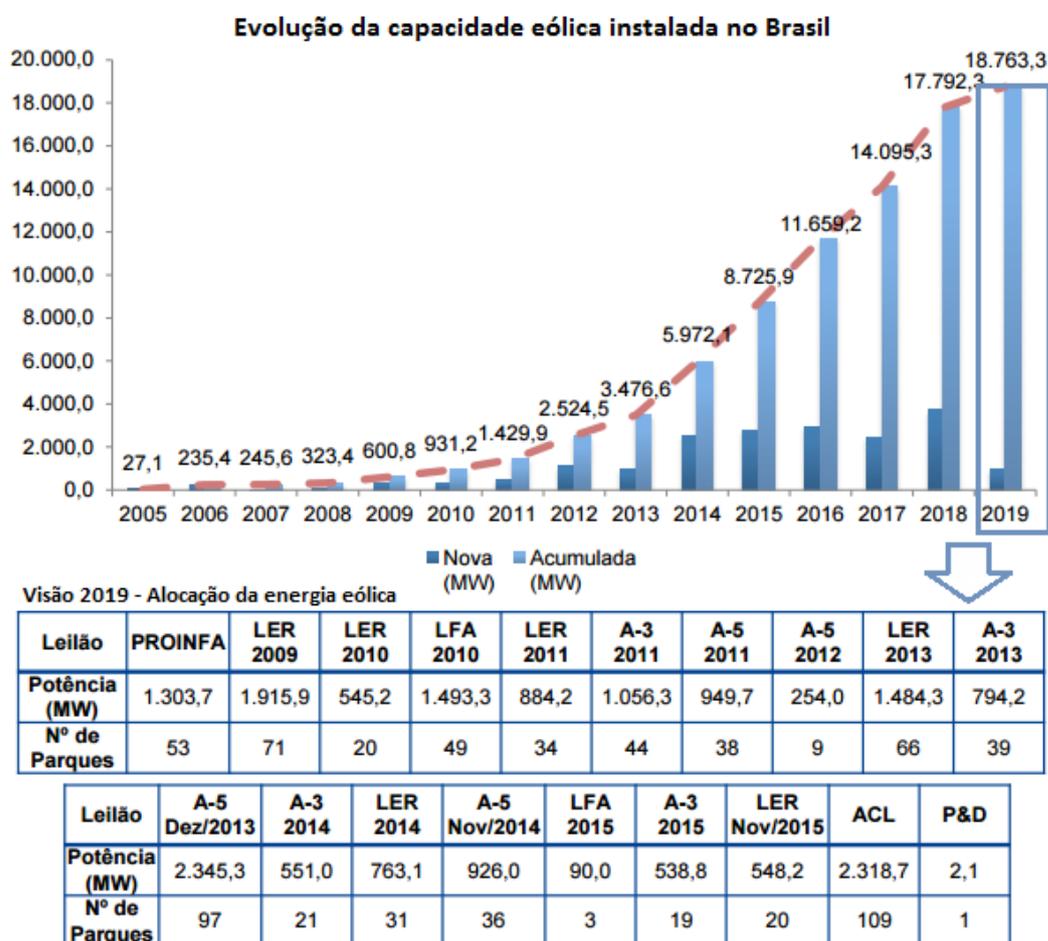


Figura 3 – Evolução da capacidade eólica instalada no Brasil (2005 a 2019), considerando empreendimentos autorizados até dezembro de 2015

Fonte: Adaptado de ABEEÓLICA (2016).

Observa-se na Figura 3 que, a partir de 2011, a capacidade eólica cresce expressivamente com incrementos de 1.000 MW a 3.000 MW por ano, o que

possibilitou ao Brasil atingir a posição de 10º (décimo) país em capacidade eólica instalada global em dezembro de 2015.

O crescimento da capacidade eólica brasileira dá-se em função:

- ✓ do desenvolvimento tecnológico, principalmente, no que tange à melhoria dos sistemas de transmissão, da aerodinâmica e das estratégias de controle e operação das turbinas, que possibilita a redução de custos e melhoria do desempenho e da confiabilidade dos equipamentos;
- ✓ do favorecimento do Brasil em termos de ventos, que têm uma presença duas vezes superior à média mundial e uma volatilidade de apenas 5%, garantindo maior previsibilidade ao volume de geração eólica;
- ✓ do fato da velocidade dos ventos costumar ser maior em períodos de estiagem, possibilitando a operação de usinas eólicas em complementariedade com usinas hidroelétricas, de forma a preservar a água dos reservatórios em períodos de pouca precipitação.

No Atlas do Potencial Eólico Brasileiro de 2010, elaborado pela Eletrobras, as estimativas do potencial de geração de energia eólica no Brasil eram de 143,5 mil MW, tendo as regiões Nordeste e Sul os maiores potenciais medidos. Todo esse potencial respalda o crescimento recente dessa fonte na matriz energética brasileira, seja no ACR ou ACL.

## **2.1. Ambientes de Contratação: ACR e ACL**

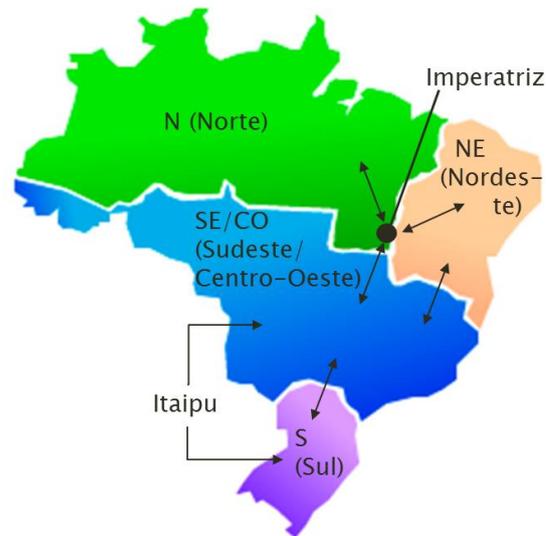
Conforme mencionado anteriormente, com a reestruturação do SEB foram instituídos dois ambientes de mercado para celebração de contratos de compra e venda de energia elétrica:

- ✓ ACR – Ambiente de Contratação Regulada: contratação formalizada através de contratos bilaterais regulados, denominados Contratos de Comercialização de Energia Elétrica no Ambiente Regulado (CCEAR), celebrados entre agentes vendedores (geradores ou comercializadores) e distribuidores que participam dos leilões de compra e venda de energia elétrica;

- ✓ ACL – Ambiente de Contratação Livre: contratação formalizada através de contratos bilaterais oriundos da livre negociação entre os agentes geradores, comercializadores, consumidores livres e especiais.

No ACR, os leilões são realizados pela CCEE, por delegação da ANEEL, e utilizam o critério de menor tarifa, visando redução do custo de aquisição da energia elétrica a ser repassado às distribuidoras e, conseqüentemente, aos consumidores cativos. O volume de energia vendido por empreendimentos eólicos nesses leilões é a totalidade ou uma parcela da garantia física calculada pela EPE para cada empreendimento, de acordo com as regras vigentes. A garantia física constitui uma *proxy* da média de geração do empreendimento ao longo do período de vigência de sua outorga e é importante a nível contratual, por ser o lastro disponível para venda do empreendimento. Diferenças entre geração efetiva e a garantia física são contabilizadas e liquidadas na CCEE, no chamado MCP – Mercado de Curto Prazo.

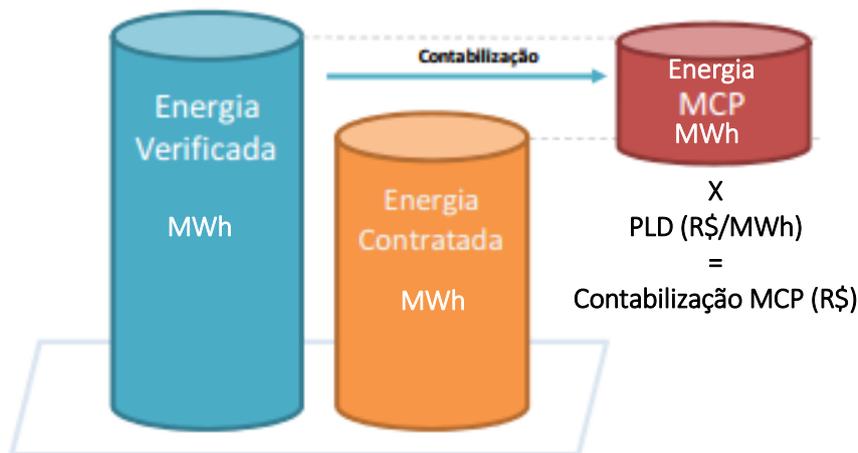
O MCP é conhecido como mercado de diferenças, pois nele promove-se a contabilização e liquidação das diferenças entre os volumes contratuais de energia elétrica e os volumes efetivamente medidos de geração e consumo. Com efeito, todos os contratos celebrados entre os agentes no âmbito do SIN, sejam contratos do ACR ou do ACL, devem ser registrados na CCEE e servem de base para a contabilização e liquidação das diferenças no MCP. Esse registro inclui obrigatoriamente: as partes envolvidas, o período de vigência, o volume e o tipo de energia, cujas modalidades são explicitadas na seção 2.2. Da mesma forma, os valores das medições verificadas de geração e consumo de energia são registrados na CCEE pelos agentes ou coletados diretamente através do Sistema de Coleta de Dados de Energia (SCDE), administrado pela CCEE e responsável pela coleta e tratamento dos dados de geração e consumo de energia do SIN. Parte do tratamento dos dados consiste em ratear as perdas de transmissão entre geradores e consumidores, de modo que toda a energia contabilizada na CCEE esteja no CG – centro de gravidade do respectivo submercado. O centro de gravidade é o ponto virtual, no qual a geração total e o consumo total do submercado são iguais, enquanto submercados são regiões do SIN, definidas em função da capacidade de transmissão de energia elétrica dentro e entre elas. O SIN está dividido em 4 (quatro) submercados, quais sejam: SE/CO – Sudeste/Centro-Oeste, S – Sul, NE – Nordeste e N – Norte (Figura 4).



**Figura 4 – Sistema Interligado Nacional e submercados**

Fonte: elaboração própria.

Com base nos contratos e dados de medição registrados, contabilizam-se as diferenças entre a energia verificada (produzida ou consumida) e a energia contratada, sendo as diferenças positivas ou negativas liquidadas ao PLD – Preço de Liquidação das Diferenças correspondente, cujo cálculo é detalhado na seção 2.4. Na Figura 5, resume-se o MCP.



**Figura 5 – Contabilização no Mercado de Curto Prazo**

Fonte: Adaptado de CCEE (2012).

Outros valores provenientes de inadimplências, encargos e mecanismos específicos, que afetam determinados agentes, são acrescidos à contabilização do MCP.

Um ponto de diferença importante entre os contratos do ACR e do ACL é que os preços e as condições daqueles são informações públicas, ao passo que os destes são de conhecimento apenas das contrapartes e utilizados em suas liquidações bilaterais, fora do ambiente de operações da CCEE e, de acordo com as condições contratuais específicas. Outra diferença é que os contratos do ACR possuem suprimento por períodos extensos, sendo 20 (vinte) anos no caso da energia eólica, o que facilita a obtenção de financiamento dos novos empreendimentos, uma vez que os contratos podem ser vistos como garantias. Já no ACL, são raros os contratos de suprimento por períodos superiores a 5 (cinco) anos, o que justifica a menor participação da fonte eólica no ACL em relação ao ACR. Contudo, algumas medidas foram adotadas visando estimular a participação das fontes renováveis no ACL, como é apresentado na seção 2.2.

Apesar de estritamente bilaterais entre agentes da CCEE, as condições contratuais dos contratos de compra e venda de energia elétrica negociados no ACL, buscam suas bases nos contratos regulados e têm como características básicas:

- ✓ o MWh – megawatt-hora como unidade básica do volume negociado (alternativamente, o volume negociado é expresso em MWmed, ou seja, a média de MW para cada hora do período de suprimento, também conhecida como MWh/h);
- ✓ o preço negociado expresso em reais por megawatt-hora (R\$/MWh), para todo o período de suprimento ou diferente por subperíodos, sendo comum o reajuste a cada 12 (doze) meses, ou a cada janeiro do período de suprimento (para contratos de um mês de suprimento é comum o preço ser definido como o PLD acrescido ou decrescido de um ágio);
- ✓ o volume total ou médio de energia a ser entregue por todo o período de suprimento ou subperíodos;
- ✓ o submercado de entrega da energia;
- ✓ a entrega no CG do respectivo submercado;
- ✓ o período de suprimento (geralmente, o período mínimo é de um mês e máximo de cinco anos);
- ✓ o tipo de energia contratada, que pode ser convencional, convencional especial ou incentivada especial, conforme abordado na seção 2.2 (no caso de energia incentivada especial é necessário informar o percentual de

desconto na TUSD/TUST – Tarifas de Uso dos Sistemas de Distribuição e Transmissão);

- ✓ a data de vencimento das faturas;
- ✓ o momento em que será feito o registro do volume de energia na CCEE.

Para exemplificar, considere um contrato com as características abaixo:

- ✓ Tipo de energia: Incentivada com 50% de desconto
- ✓ Entrega: CG do SE/CO
- ✓ Período de suprimento: 00:00 hs de 01/07/2016 às 24:00 hs de 31/12/2016
- ✓ Volume: 10 MWmed
- ✓ Preço: 120,00 R\$/MWh
- ✓ Vencimento: 6º dia útil do mês subsequente ao suprimento
- ✓ Registro na CCEE: registro contra pagamento

Nesse caso, a energia com direito ao desconto de 50% na TUSD/TUST é entregue no centro de gravidade do submercado Sudeste/Centro-Oeste, de julho a dezembro de 2016, ao preço fixo de 120,00 R\$/MWh (cento e vinte reais por megawatt-hora). Os volumes em MWh são calculadas mensalmente pelo produto: 10 MWmed X número de horas do mês. O faturamento é dado pelo produto: 10 MWmed X número de horas do mês X 120,00, sendo o vencimento no 6º (sexto) dia útil do mês subsequente ao de fornecimento. O registro do volume contratado na CCEE é feito mensalmente, mediante confirmação do pagamento da fatura.

Um ponto interessante é que o limite para registro de volumes de energia de um mês é o 8º (oitavo) dia útil do mês subsequente, portanto, antes da contabilização e liquidação do MCP pela CCEE, ocorrem negociações bilaterais para ajuste de sobras e déficits de energia do mês anterior entre os agentes do ACL. Essas negociações bilaterais são importantes, pois auxiliam o cumprimento da exigência do modelo vigente de contratação da totalidade da demanda por parte das distribuidoras (ACR) e dos consumidores livres e especiais (ACL), não sendo permitida, também, a venda de energia sem a comprovação de lastro (garantia física ou geração efetiva, conforme o caso, ou cobertura contratual de compra de energia). Esta determinação visa assegurar o suprimento do sistema, em acordo com as bases do modelo: Leis nº 10.847/2004 e 10.848/2004 e o Decreto nº 5.163/2004.

Outras características comuns aos contratos são: sazonalização (divisão de volumes de energia contratados em diferentes montantes mensais) e modulação (divisão de volume de energia mensal em diferentes montantes horários). Porém, a menos que explícito de modo diferente, a sazonalização e a modulação são consideradas *flat* (volumes anuais e mensais contratados alocados igualmente por mês e horário, respectivamente). Além dessas particularidades, podem existir cláusulas de flexibilidades de mais ou menos um percentual do volume médio contratado por mês (+/- X% do volume contrato em MWmed), bem como *take-or-pay* (isto é, o estabelecimento de quantidades mínimas de energia a serem consumidas em determinado período, sendo obrigatório o pagamento da quantidade estipulada, independentemente do consumo). Normalmente, inclui-se cláusula de *take-or-pay* junto a cláusulas de flexibilidade de volume, havendo, por exemplo, a possibilidade de flexibilidade mensal, mas a obrigatoriedade de consumo de determinado volume mínimo anual.

Outra cláusula habitual dos contratos, particularmente nos de longo prazo (período de suprimento igual ou superior a seis meses), é a exigência de garantias contratuais, como: fiança bancária, seguro garantia, carta corporativa, nota promissória, entre outras. Essas garantias visam assegurar o pagamento do comprador e costumam ter valor equivalente a um, dois ou três meses de faturamento, com validade por todo o período de suprimento. Contratos que requerem garantia costumam estipular o registro integral do volume contratado na CCEE uma vez recebida a garantia pelo vendedor, enquanto contratos sem garantia, geralmente estabelecem o registro da energia na CCEE, mediante confirmação do pagamento da fatura de energia correspondente.

## 2.2.

### **Desconto nas Tarifas de Transmissão e Distribuição**

Na seção 2.1, mencionou-se a existência de diferentes tipos de energia para contratação no ACL. Primeiramente, é importante esclarecer que a energia que chega a nossas residências e fábricas não tem diferença e, nem mesmo, é possível informar com precisão de qual usina ela é oriunda. Portanto, os diferentes tipos de energia surgem de vantagens comerciais concedidas a alguns empreendimentos de geração, visando fomentar sua inserção na matriz elétrica brasileira. Deste modo,

contratos firmados com esses empreendimentos direta ou indiretamente, por meio de sucessivas negociações, e registrados na CCEE passam a ser classificados de acordo com o tipo de energia definido na outorga do empreendimento.

Outra importância dos diferentes tipos de energia diz respeito à vedação de contratação de energia do tipo convencional por consumidores especiais, que são aqueles com demanda entre 500 kW e 3 MW. Esses consumidores têm o direito de adquirir energia de qualquer fornecedor, desde que a energia adquirida seja oriunda de fontes convencionais especiais ou incentivadas especiais, o que significa de pequenas centrais hidroelétricas (PCHs), eólica, biomassa ou solar. Enquanto isso, consumidores livres, ou seja, aqueles com demanda mínima de 3 MW, podem escolher livremente seu fornecedor de energia elétrica, seja ele vendedor de energia convencional, convencional especial ou incentivada especial.

A energia incentivada especial é aquela proveniente de geração eólica, solar, térmica à biomassa e de pequenas centrais hidroelétricas (PCHs), com potência injetada igual ou inferior a 30 MW, na forma da Resolução Normativa nº 247/2006 da ANEEL, sendo concedidos descontos de 50%, 80% ou 100% na TUSD/TUST, quando da comercialização dessa energia. O cálculo do desconto final para cada agente que participa da comercialização de energia incentivada especial depende do desconto original concedido na outorga do empreendimento e pode ser diferente de 50%, 80% ou 100%, pois são aplicados os cálculos algébricos previstos nas Regras de Comercialização. Em função do benefício do desconto na TUSD/TUST para o consumidor final, a energia incentivada especial é comercializada a preços mais elevados do que os da energia convencional, dependendo este acréscimo de preço do percentual de desconto oferecido. Ademais, é comum os contratos estipularem valores de ressarcimento a serem pagos pelo vendedor, caso a energia incentivada especial entregue tenha desconto inferior ao contratado.

Já a energia convencional especial é proveniente, também, de empreendimentos de fonte solar, eólica e biomassa, porém, com potência injetada entre 30 MW e 50 MW, na forma da Lei nº 11.943/2009, não sendo concedido qualquer desconto na TUSD/TUSD, quando da comercialização dessa energia, mas sendo permitida sua destinação para suprimento de consumidores especiais. Apesar de não ter um benefício adicional para o consumidor como a energia incentivada especial, a energia convencional especial pode ser comercializada com um público não atendido pela energia convencional. Portanto, a energia convencional especial

também costuma ser comercializada a preços ligeiramente mais elevados do que a energia convencional, mas inferiores aos da energia incentivada especial.

Finalmente, a energia convencional é toda aquela que não se enquadra nas definições das demais.

Como pode ser observado, a energia eólica é habitualmente enquadrada como energia incentivada especial ou convencional especial, possibilitando a negociação de valores mais elevados na sua comercialização no ACL, em relação à energia convencional. Mesmo empreendimentos eólicos com capacidade instalada superior a 30 e 50 MWmed, costumam ser divididos em empreendimentos menores, a fim de serem enquadrados como energia especial (DALBEM *et al.*, 2014b). Na comercialização de energia eólica nos leilões do ACR, contudo, esta diferença é desconsiderada, pois os contratos são vistos como de energia convencional.

### 2.3.

#### **Formação do Preço de Liquidação das Diferenças (PLD)**

Na seção 2.1, mencionou-se a utilização do PLD – Preço de Liquidação das Diferenças para valorar as exposições de energia no MCP, resultando na contabilização e liquidação no âmbito da CCEE. Com efeito, ele é o preço de liquidação das diferenças apuradas pela CCEE entre energia medida verificada e energia contratada, a cada mês, por submercado.

O PLD é, também, o balizador dos preços à vista negociados pelo mercado, que, em geral, são formados pelo PLD médio do mês do submercado de entrega da energia acrescido ou deduzido de um ágio. Esse ágio ou deságio surge da necessidade dos agentes de fecharem seus balanços de lastro de energia mês a mês, sob pena do pagamento de penalidades (em 2016, de acordo com as Regras e Procedimentos de Comercialização, o valor de penalidade era o máximo entre o PLD médio R\$/MWh e 123,64 R\$/MWh) e do receio de inadimplência na liquidação do MCP na CCEE.

O cálculo e a divulgação do PLD são realizados semanalmente pela CCEE, a partir dos dados previstos considerados pelo ONS para a otimização *ex-ante* da operação do SIN e cálculo do CMO – Custo Marginal de Operação. Ressalta-se, contudo, que ele não é um valor de mercado obtido pela livre comercialização de energia entre os agentes e, tampouco, o preço à vista negociado no mercado,

conforme explicado. Na verdade, o cálculo do PLD é feito por semana, submercado e patamar de carga (leve, médio e pesado) e seu valor está limitado a um piso e teto anual, sendo os valores em 2016, respectivamente, 30,25 R\$/MWh e 422,56 R\$/MWh.

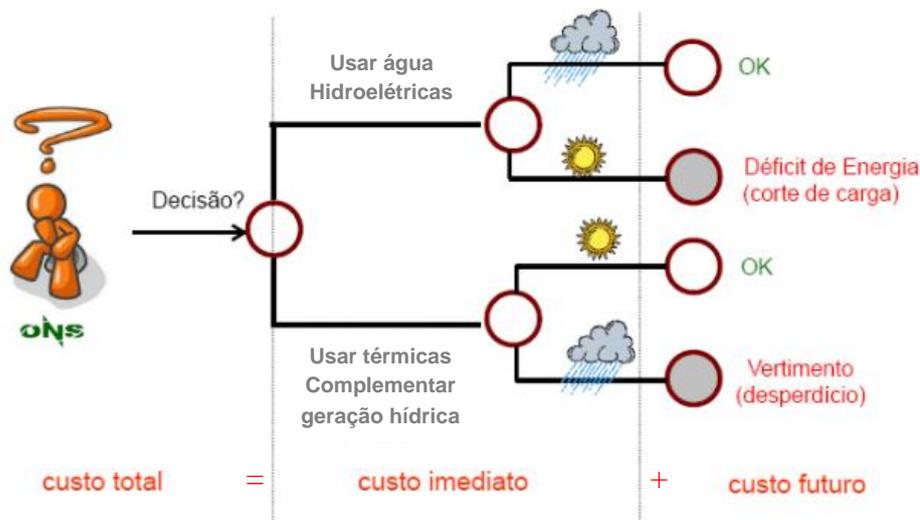
Apesar de utilizar os mesmos modelos que o ONS adota para otimização da operação do SIN, a CCEE, ao calcular o PLD, realiza pequenas adaptações, quais sejam: não são consideradas as restrições de transmissão internas a cada submercado, nem as usinas em teste. Adotam-se essas modificações para que a energia comercializada seja tratada como igualmente disponível em todos os seus pontos de consumo e, conseqüentemente, o preço seja único dentro de cada um dos submercados. O processo completo de cálculo do CMO ou PLD consiste na utilização dos modelos computacionais Newave® e Decomp®, que produzem como resultado, respectivamente, a FCF – Função de Custo Futuro e o CMO ou PLD (sem piso e teto) de cada submercado por patamar e semana (CCEE, 2016). O Newave® produz, ainda, 2.000 simulações de PLDs médios mensais para o horizonte de até 5 (cinco) anos, com base em séries sintéticas de vazões simuladas. Essas séries de PLDs médios mensais serão utilizadas como base para simulação de preços no capítulo 6.

Uma vez definida a função do PLD e as bases para seu cálculo, resta entender sua origem econômica, ou, melhor, a interpretação econômica do CMO.

Quando da reforma do SEB, adotou-se um esquema de decisão de operação (geração de energia elétrica) centralizado, baseado em modelos de otimização (um modelo de curto prazo (Decomp®) acoplado a um de longo prazo (Newave®)), cujo objetivo, até agosto de 2013, era minimizar o valor esperado do custo total de operação do sistema hidrotérmico ao longo de um horizonte de planejamento. Esses modelos utilizam PDDE – Programação Dinâmica Dual Estocástica (PEREIRA; PINTO, 1991). A partir de agosto de 2013, conforme formulado por COSTA *et al.* (2013) e, PHILPOTT e MATOS (2012), foi incluída a aversão ao risco do operador na função objetivo do problema de otimização da operação do SIN, que passou a ser especificada como uma ponderação entre o valor esperado do custo futuro de operação do sistema hidrotérmico e o  $CVaR_\alpha$  (definido na seção 3.2) do custo futuro. Apesar dessa alteração, para clarificar o conceito econômico do CMO, ainda será considerado como objetivo minimizar o valor esperado do custo total de operação do sistema hidrotérmico ao longo de um horizonte de planejamento, que,

no caso do planejamento da operação do SIN, é a semana seguinte até dezembro do 4º (quarto) ano subsequente.

O planejamento da operação de um sistema hidrotérmico consiste em determinar, para cada etapa do período de planejamento, as metas de geração para cada usina que atendam a demanda e minimizem o custo esperado de operação ao longo do período (PENNA *et al.*, 2013). Esse valor é composto pelo custo variável de combustível das usinas termoeletricas e pelo custo atribuído às interrupções de fornecimento de energia (PENNA *et al.*, 2013). Sob a ótica econômica, a característica mais marcante desses sistemas é a possibilidade do uso da água armazenada nos reservatórios para geração de energia, minimizando os custos com combustíveis. Contudo, a geração hidroelétrica é limitada pela capacidade e o nível de armazenamento dos reservatórios, o que gera uma dependência entre a decisão operativa do presente e os custos operativos no futuro.



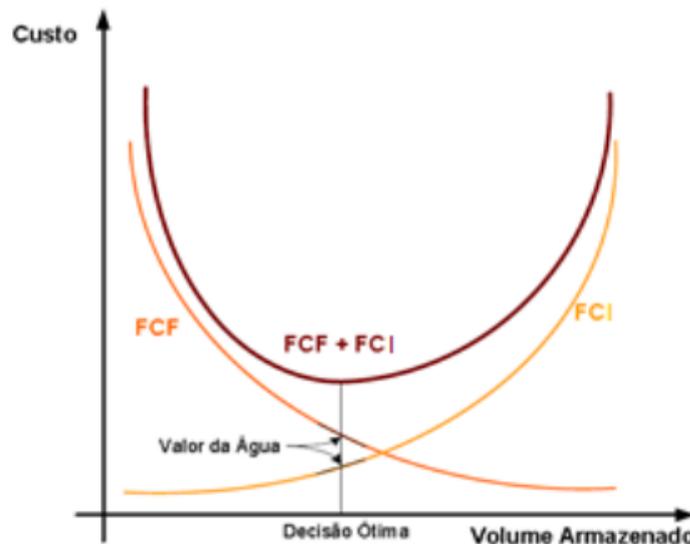
**Figura 6 – Processo decisório e consequências em um sistema hidrotérmico**

Fonte: Adaptado de OLIVEIRA (2013).

A máxima utilização da energia hidroelétrica disponível em cada período é a premissa mais econômica do ponto de vista imediato, por minimizar os custos de combustível. Porém, ela acarreta maiores riscos de déficits futuros e, no caso de uma seca severa, por exemplo, pode levar ao racionamento, com um alto custo para sociedade. Por sua vez, a máxima confiabilidade de fornecimento é obtida conservando o nível dos reservatórios o mais elevado possível, o que significa utilizar mais geração térmica e, portanto, aumentar os custos de operação. Ademais,

caso as afluências futuras sejam elevadas, pode ocorrer um vertimento (escoamento de água acumulada em excesso) nos reservatórios do sistema, o que representa um desperdício de energia. A Figura 6 ilustra ambas as situações.

Portanto, na operação de um sistema hidrotérmico, deve-se comparar o benefício presente (imediato) do uso da água e o benefício futuro de seu armazenamento, conforme ilustrado na Figura 7.



**Figura 7 – Custos imediato (FCI) e futuro (FCF) da operação e decisão ótima**

Fonte: OLIVEIRA (2013).

A função de custo imediato (FCI) representa os custos de geração térmica no estágio  $t$  imediato, ou seja, no estágio presente. Observa-se que o custo imediato aumenta à medida que diminui a energia hídrica disponível nos reservatórios, pois, quanto menor for a decisão de geração hídrica, maior será a de geração térmica. Já a função de custo futuro (FCF) está associada ao custo esperado de geração térmica e ao racionamento desde o final do estágio  $t$  (início do próximo estágio,  $t+1$ ) até o final do período de estudo e diminui à medida que aumenta o volume final armazenado, em função da maior disponibilidade de energia hidroelétrica no futuro. Nesse contexto, o uso ótimo da água armazenada é aquele que minimiza a soma dos custos imediato e futuro. Observa-se na Figura 7 que o ponto de mínimo custo global (imediato + futuro) é, também, aquele em que as derivadas da FCI e FCF em relação ao volume final dos reservatórios se igualam.

As funções de custo imediato e futuro são compostas por inúmeras variáveis, o que torna necessário adotar um modelo matemático para obtenção da decisão ótima da operação. Dentre essas variáveis destacam-se: as condições hidrológicas presente e futura, a demanda de energia, os preços de combustível, o custo de déficit, a entrada de novos projetos e a disponibilidade de equipamentos de geração e transmissão.

Conforme já mencionado, o planejamento da operação de um sistema hidrotérmico visa determinar, para cada etapa do período de estudo, as metas de geração para cada usina, de modo a atender a demanda e minimizar o custo esperado de operação ao longo do período. Portanto, o problema de decisão da operação hidrotérmica para o estágio  $t$  pode ser formulado como na eq. (1), onde  $p_t$  é o preço da energia quando da decisão operativa ótima, estando o sistema sujeito às seguintes restrições: balanço hídrico, armazenamento, turbinamento, geração térmica e atendimento à demanda.

$$p_t = \min \left( c_j \times g_{j,t} + FCF(v_{t+1}) \right) \quad (1)$$

A função objetivo é minimizar a soma de duas classes de custos:

- ✓ custo operativo imediato, dado pelos custos térmicos ( $c_j \times g_{j,t}$ ) no estágio  $t$ , onde  $c_j$  é o custo variável da térmica  $j$  e  $g_{j,t}$  é a geração da térmica  $j$  no estágio  $t$ , e de racionamento, representado por uma térmica fictícia de capacidade infinita e custo operativo igual ao custo de interrupção;
- ✓ valor esperado do custo operativo futuro, dado pela função de custo futuro  $FCF(v_{t+1})$ , que, como discutido anteriormente, depende dos volumes armazenados ao final do estágio, representados pelo vetor  $v_{t+1}$ .

Assim, o problema de otimização pode ser resolvido por um algoritmo de programação linear. O esquema de programação obtém, além do despacho (gerações hídrica e térmica) ótimo para o período de estudo, os multiplicadores *simplex*, ou preços sombra, associados a cada restrição. Em particular, o CMO do sistema é o multiplicador *simplex* associado à restrição de atendimento à demanda, significando o custo de produção de 1 MWh (um megawatt-hora) adicional no ponto ótimo de minimização de custos (em R\$/MWh).

Com a inclusão da aversão ao risco do operador na função objetivo do problema de otimização da operação do SIN, pode-se ainda considerar a eq. (1) válida. Contudo, a parcela  $FCF(v_{t+1})$  deixa de ser o valor esperado do custo operativo futuro, passando a ser  $(1 - \lambda)$  vezes esse valor esperado acrescido de  $\lambda$  vezes o  $CVaR_\alpha$  do custo operativo futuro (CPAMP, 2013).

### 3 Referencial Teórico

O Referencial Teórico desta tese subdivide-se em três temas principais, quais sejam: previsão e simulação mensal da velocidade dos ventos e geração eólica; funções de preferência e medidas de desempenho; otimização em comercialização de energia eólica. As referências foram pesquisadas em bases de dados de periódicos e teses, através da busca de palavras-chaves em português e inglês de cada assunto, sendo alguns exemplos: “*wind power forecast*”; “*wind power trading optimization*”; “*utility functions*”; “utilidade esperada”; “aversão ao risco”; “medidas de desempenho”; “equivalente certo e CVaR”, “Dipolo do Atlântico”; “climatologia no Nordeste”, entre outros. Realizou-se também a revisão das referências de estudos considerados relevantes.

#### 3.1. **Previsão e simulação mensal da velocidade dos ventos e geração eólica**

Nesta seção encontra-se o referencial teórico para definição do modelo de previsão e simulação de geração eólica adotado. Ela começa revendo o estado da arte de previsões de velocidade dos ventos e geração eólica, focando nos pontos mais pertinentes à previsão de médias mensais, notadamente, nos modelos autorregressivos. Na sequência, é abordada a modelagem da sazonalidade e aspectos da previsão de longo prazo. Por fim, são apresentados resultados de estudos que buscam relacionar variáveis climáticas à precipitação e velocidade dos ventos no Ceará.

##### 3.1.1. **Previsão da velocidade dos ventos e geração de energia eólica**

Diversos trabalhos propõem modelos para previsão de velocidade dos ventos e de geração de energia eólica. Em FOLEY *et al.* (2012), JUNG e BROADWATER (2014) e LEI *et al.* (2009) são revistos mais de 120 trabalhos sobre o tema,

agrupados, em linhas gerais, em três categorias segundo o tipo de modelagem: (i) física, (ii) estatística e (iii) mista. A modelagem física considera modelos meteorológicos numéricos de previsão de vento (NWP – *Numerical Weather Prediction*) e os princípios físicos para conversão do vento em geração eólica. A modelagem estatística abrange tanto modelos autorregressivos, como de inteligência artificial, redes neurais (ANN – *Artificial Neural Network*) e lógica *fuzzy*. Os modelos mistos costumam associar a previsão de ventos com modelos ANN e *fuzzy* para obtenção da previsão de geração. Outra abordagem de modelo misto realiza a conversão de previsões de velocidade dos ventos, advindas de modelos numéricos, em densidades de geração eólica, através de modelos não paramétricos para representação estatística da curva de potência do aerogerador (VARGAS, 2015).

Dentre as diversas categorias, modelos estatísticos apresentam bons resultados de previsão tanto para horizontes de curto, médio e longo prazo (algumas horas a uma semana) (JUNG; BROADWATER, 2014), como para horizontes mais longos e discretizações mais esparsas, como médias mensais, trimestrais e anuais (FOLEY *et al.*, 2012).

Os modelos estatísticos clássicos são os modelos autorregressivos de média móvel ARMA, cuja formulação geral para variável Y consta na eq. (2) (TSAY, 2010).

$$Y_j = c + \sum_{i=1}^p \varphi_i \times Y_{j-i} + \sum_{i=1}^q \theta_i \times \varepsilon_{j-i} + \varepsilon_j; \varepsilon_j \sim N(0; \delta) \quad (2)$$

Onde:

$Y_j$  = variável sob estudo no período j;

c = constante;

$\varphi_i$  = parâmetro de ordem i da parte AR (autorregressiva);

$\theta_i$  = parâmetro de ordem i da parte MA (média móvel);

$\varepsilon_j$  = erro no período j (ruído branco com distribuição Normal);

$\delta$  = desvio-padrão dos erros.

Variações dos modelos ARMA são os modelos ARIMA (ARMA com integração), SARMA (ARMA sazonal) e ARMAX (ARMA com variáveis exógenas). Os modelos ARMA pressupõem volatilidade constante, portanto, na presença de heteroscedasticidade deve-se utilizar modelos ARCH, GARCH e demais derivados (TSAY, 2010). PENG e YUE (2011) e WANG *et al.* (2012) obtiveram menores erros de previsão no curto prazo ao utilizar modelos ARCH na previsão de velocidade dos ventos. Outras categorias de modelos autorregressivos são os que consideram não linearidade da série, através da atribuição de diferentes modelos para diferentes períodos ou níveis da série, sendo os mais comuns, respectivamente, PARMA (ARMA periódico) e TAR (*threshold* AR). Tem-se, ainda, os modelos multivariados, que consideram a previsão conjunta de diferentes séries, sendo os modelos principais VAR (autorregressivo vetorial) e VECM (autorregressivo vetorial com correção de erros). Uma revisão completa sobre a formulação de modelos autorregressivos pode ser obtida em TSAY (2010).

No Brasil, o modelo ARMA já foi utilizado para previsão de médias horárias de velocidade dos ventos no Ceará (CAMELO *et al.*, 2015), enquanto o modelo PAR e variações dele foram utilizados para previsão de médias mensais de velocidade dos ventos (MENEZES *et al.*, 2014) e o modelo VAR com variações foi utilizado para simulação conjunta de geração eólica e vazões de rio (AMARAL, 2011; FÂNZERES *et al.*, 2012).

Com efeito, os modelos estatísticos, incluindo os autorregressivos, podem ser utilizados para diferentes horizontes e discretizações de previsão, mas a maior parte da literatura foca na previsão horária, para horizontes que variam de algumas horas a uma semana. Com esta visão, JUNG e BROADWATER (2014) enfatizam a importância da previsão no horizonte das próximas 6 (seis) a 24 (vinte e quatro) horas para o gerenciamento de sistemas elétricos e negociações de energia no caso de mercados diários e intra-diários. Como o mercado brasileiro é essencialmente mensal (LUZ *et al.*, 2012), horizontes de previsões mais extensos, como um mês a um ano (com discretização mensal) tornam-se mais relevantes para negociações de energia eólica, encontrando-se trabalhos como os de AMARAL (2011) e FÂNZERES *et al.* (2012) com este enfoque.

Uma alternativa a modelos estatísticos para discretizações esparsas, utilizada em estudos de certificação e avaliação de futuros parques eólicos, é o ajuste de parâmetros da distribuição *Weibul* à série medida de vento que exista para a

localidade ou às séries obtidas para próximo da localidade a partir de dados de reanálise, a fim de determinar a velocidade média do vento no local (AJAYI *et al.*, 2011). Os dados de reanálise são dados de variáveis atmosféricas e meteorológicos obtidos através da assimilação e reanálise de dados observados e medidos com auxílio de modelos numéricos de previsão do tempo (SONDEREGGER, 2011). A principal vantagem desses dados é tratarem de períodos razoavelmente longos e sem falhas para qualquer ponto do planeta.

Entre os estudos que tratam de previsão de vento em horizontes anuais encontram-se GUO *et al.* (2011), CAPORIN e PRÉS (2012) e MENEZES *et al.* (2014).

Sabe-se que qualquer modelo de previsão carrega um erro associado e que este aumenta à medida que aumenta o horizonte de previsão (GOOIJER; HYNDMAN, 2006; FOLEY *et al.*, 2012). Esse fato é particularmente verdadeiro ao tratar-se de modelos autorregressivos, onde ocorre a propagação do erro. Uma das possibilidades para lidar com a questão é a modelagem a parte do erro, como em GUO *et al.* (2011), em que é realizada correção do erro do modelo SARIMA através do modelo LSSVM – *Least-Square Support Vector Machine* para previsão de médias mensais de vento. De modo geral, a utilização de abordagens mistas visa integrar e maximizar a informação capturada por cada modelo, a fim de reduzir o erro de previsão (DONGMEI *et al.*, 2011) ou, mesmo, reduzir riscos associados a eventos extremos não capturados por alguns modelos (JUNG; BROADWATER, 2014). Apesar de alternativas como essas, ao prever-se médias mensais de geração eólica, a maior preocupação não é acertar a geração, mas sim a sua tendência e ser capaz de simular essa geração, a fim de obter diferentes realizações plausíveis para avaliação de riscos. FOLEY *et al.* (2012) alertam, ainda, que a acurácia da previsão da velocidade dos ventos ou da geração eólica é fortemente dependente: (i) da precisão dos modelos numéricos meteorológicos no caso de modelos físicos; (ii) da coleta e tratamento dos dados no caso de modelos estatísticos. JUNG e BROADWATER (2014) complementam que a precisão de modelos estatísticos clássicos pode ser melhorada através da seleção dos parâmetros do modelo.

Portanto, com o foco em simulações de geração eólica, duas vantagens dos modelos autorregressivos são: a simplicidade computacional e a relação evidente entre *inputs* e *outputs*, o que não ocorre em modelos do tipo ANN e *fuzzy*. BOX *et*

*al.* (2015) e TSAY (2010) são guias para ajuste de modelos autorregressivos a séries temporais.

De modo resumido, o ajuste de modelos autorregressivos segue a clássica abordagem de Box-Jenkis (BOX *et al.*, 2015) para modelagem matemática de séries, que se baseia nas seguintes etapas: (i) identificação da classe de modelo a partir da teoria, (ii) identificação da subclasse e modelo a ser ajustado aos dados, (iii) estimação dos parâmetros, (iv) diagnóstico e verificação da adequação do modelo aos pressupostos, devendo-se retornar à etapa (ii) em caso de rejeição (BOX *et al.* 2015). Uma vez ajustado o modelo, passa-se à previsão.

Os principais pressupostos a serem verificados na etapa (iii) em relação aos erros são: estacionariedade, inexistência de autocorrelação, inexistência de autocorrelação entre seus quadrados, ou seja, homocendasticidade e normalidade (TSAY, 2010). O não atendimento a estes pressupostos torna os resultados estatísticos de desempenho do modelo duvidosos e pode resultar em simulações distantes da realidade.

Como a modelagem autorregressiva de séries temporais não é única (GOOIJER; HYNDMAN, 2006), há duas abordagens principais para comparação e seleção de modelos: (i) avaliação da capacidade preditiva com base em medidas de erros de previsão e (ii) avaliação da adequação e parcimônia com base nos critérios de informação (BOX *et al.*, 2015; TSAY, 2010). Para ambas abordagens, o melhor modelo é sempre o que apresenta as menores medidas. As principais medidas de erro utilizadas são apresentadas na eq. (3) à eq. (5).

MAE – Erro médio absoluto:

$$MAE = \frac{\sum_{i=1}^n |o_i - p_i|}{n} \quad (3)$$

RMSE – Erro médio quadrático:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (o_i - p_i)^2}{n}} \quad (4)$$

MAPE – Erro médio absoluto percentual:

$$MAPE = \frac{\sum_{i=1}^n \left| \frac{o_i - p_i}{p_i} \right|}{n} \quad (5)$$

Onde:

$o_i$  = valores observados;

$p_i$  = valores previstos;

$n$  = total de previsões.

Os dois principais critérios de informação são o de AKAIKE (1974), conhecido como AIC, e o *Baysiano*, conhecido como BIC (SCHWARTZ, 1978), conforme descritos, respectivamente, nas eq. (6) e eq. (7). Ambos consideram a relação entre a adequação do modelo, medida pela função de máxima verossimilhança, e a parcimônia, medida através de diferentes funções de penalidade para o número de parâmetros. A principal diferença entre o AIC e o BIC é que o BIC penaliza mais a complexidade do modelo (número de parâmetros), do que o AIC.

$$AIC = -2 \times \ln(L) + k \times 2 \quad (6)$$

$$BIC = -2 \times \ln(L) + k \times \ln(N) \quad (7)$$

Onde:

$k$  = número de graus de liberdade, ou seja, o número de parâmetros no modelo;

$L$  = máxima verossimilhança;

$N$  = total de observações.

Existem ainda testes que permitem a comparação paritária da acurácia das previsões dos modelos. Nesses testes a hipótese nula ( $H_0$ ) é: “As previsões dos dois modelos têm a mesma acurácia.” e a hipótese alternativa ( $H_1$ ) pode ser uma das seguintes: (i) “As previsões dos dois modelos têm acurácias diferentes.” (teste bicaudal); (ii) “A acurácia da previsão do modelo A é maior do que a acurácia da

previsão do modelo B.” (teste unicaudal). Exemplos desses testes são os de Diebold-Mariano (DIEBOLD; MARIANO, 1995) e Giacomini-White (GIACOMINI; WHITE, 2006), nos quais a obtenção de p-valores pequenos indica a existência de diferença de acurácia das previsões dos modelos testados.

Outros testes também utilizados na verificação de modelos são os testes ANOVA e de Turkey. Na ANOVA, a hipótese nula ( $H_0$ ) é: “As amostras possuem médias iguais.” e a hipótese alternativa ( $H_1$ ) é: “As amostras possuem médias diferentes.”. Um exemplo de sua aplicação é encontrado no trabalho de GUO *et al.* (2011), com comparação da média real e da dos modelos desenvolvidos. No teste de Turkey (TURKEY, 1953) também é realizada a comparação das médias das amostras, contudo, a comparação é feita par a par entre as amostras testadas. Enquanto o teste ANOVA pressupõe variância igual para as amostras, o teste de Turkey não prevê essa exigência.

Trabalhos como os de BROWN *et al.* (1984) e KARKI *et al.* (2006) utilizam modelos AR e ARMA para modelagem da velocidade média do vento e posterior conversão em geração de energia eólica pela curva de potência. Enquanto aquele fornece um exemplo ilustrativo do ajuste do modelo AR(2) a dados horários de velocidade dos ventos para posterior conversão em energia, este utiliza o ajuste do modelo ARMA(3,2) para simulações horárias e obtenção da distribuição da média anual da velocidade dos ventos em três localidades. CAPORIN e PRÉS (2012) utilizam abordagem semelhante, contudo, modelam primeiramente a sazonalidade da série histórica de vento e, posteriormente, ajustam o modelo ARFIMA-FIGARCH aos dados. Finalmente, transformam a velocidade dos ventos em geração eólica pela curva de potência para precificação de derivativos climáticos.

Uma questão recorrente na modelagem de velocidade de ventos e geração eólica, é a evidente sazonalidade das séries, perceptível por uma simples inspeção visual, podendo ser horária, diária, mensal, dividida entre dia e noite, entre outros. Essa sazonalidade requer tratamento apropriado, sobretudo, em função da discretização e horizontes de previsão considerados.

### 3.1.2. Previsão de longo prazo e sazonalidade

GOOIJER e HYNDMAN (2006) fazem uma ampla revisão sobre a previsão de séries temporais. Dentre os modelos revistos encontram-se os modelos autorregressivos clássicos (ARIMA) e chama atenção a variabilidade de horizontes de previsão e discretização temporal das séries estudadas. Apesar de ter maior respaldo na literatura o uso de modelos autorregressivos para previsão de um ou poucos passos futuros, estudos como os de GRAMBSCH e STAHEL (1990), PREEZ e WITT (2003), WELLER (1989) e HARRIS e LIU (1993) tratam de horizontes de 12 (doze) a 36 (trinta e seis) passos futuros, com discretização mensal das séries. Contudo, nenhum desses estudos trata da modelagem de séries temporais de variáveis climáticas ou derivadas do clima, como é o caso da velocidade dos ventos.

As séries temporais de velocidade dos ventos parecem sofrer influência de variáveis climáticas e meteorológicas, além de possuírem sazonalidade marcante. Caso semelhante é observado para as séries de vazões de rios, particularmente, ao serem consideradas médias mensais no Brasil. Para modelagem de sazonalidade, algumas das alternativas estudadas são: (i) decomposição sazonal, como o método X-11 e similares; (ii) modelos autorregressivos sazonais, como SARMA; (iii) métodos para ajuste sazonal paramétricos, não-paramétricos e modelagem harmônica; (iv) modelos de séries temporais periódicas, como PAR. Referências completas sobre esses modelos, podem ser obtidas em GOOIJER e HYNDMAN (2006).

Quanto aos modelos autorregressivos periódicos, conhecidos como PAR e PARMA, observa-se que resultam em melhores previsões que modelos não periódicos sob certas condições (FRANSES; VAN DIJK, 2005; WELLS, 1997; NOVALES; FRUTO, 1997). De fato, não há um consenso sobre o melhor modelo para representação de sazonalidade de modo global, a seleção depende dos modelos avaliados em estudo e da natureza dos dados (GOOIJER; HYNDMAN, 2006). Enquanto MENEZES *et al.* (2014) encontram resultados satisfatórios para modelagem de médias mensais de velocidade dos ventos com modelo PAR e variações, AMARAL (2011) afirma que a modelagem PAR para geração eólica não retornou resultados satisfatórios.

Em FRANSES e VAN DIJK (2005), são avaliados 9 (nove) modelos para previsão da produção industrial trimestral em diferentes países e a principal conclusão é que para horizontes curtos de previsão (um a dois passos), modelos simples de sazonalidade, como AR com *dummies* sazonais e SARIMA obtêm melhor performance, enquanto, para horizontes maiores (3 a 12 passos), a modelagem explícita da variação temporal da sazonalidade e da variação periódica, como em modelos PAR, melhora a capacidade preditiva.

NOAKES *et al.* (1985) avaliam a performance dos modelos SARIMA, ARMA dessazonalizado e PAR para 30 séries mensais de vazões de rios, dentre as quais a do Rio Grande, no Brasil. Eles concluem que apesar da existência de modelos mais parcimoniosos, o modelo PAR/PACF (seleção da ordem  $p$  pela observação do gráfico PACF) é o mais adequado para modelagem das séries, dada a correlação da sazonalidade e sua precisão. Com efeito, ainda hoje a modelagem e simulação de séries de vazões de rios por modelos PAR é utilizada no SEB – Setor Elétrico Brasileiro para otimização do despacho hidrotérmico e cálculo dos preços de referência.

### **3.1.3. Velocidade dos ventos e climatologia no Nordeste**

Os modelos numéricos de previsão meteorológica (NWP), já mencionados, consideram a previsão de parâmetros do tempo como dados de entrada para previsão da velocidade dos ventos ou geração eólica e são considerados mais importantes para horizontes de previsão de curtíssimo e curto prazo (até 6 (seis) horas a frente) (JUNG; BROADWATER, 2014). Parâmetros do tempo referem-se às condições meteorológicas em um dado momento e local, sendo exemplos: precipitação; temperatura; umidade; pressão atmosférica; nevoeiro; nebulosidade e vento.

No entanto, a maioria desses modelos não considera explicitamente a modelagem oceânica ou mesmo a TSM - Temperatura da Superfície do Mar, pois essas são variáveis climáticas (FOLEY *et al.*, 2012) e não variam no horizonte de curto prazo.

De fato, variáveis climáticas persistem, pelo menos, de um a três meses. Embora elas possam ser ignoradas nas previsões de curto prazo, até mesmo por já

estarem incorporadas aos dados observados, elas parecem ser importantes no contexto de médias mensais de velocidades de vento e de geração eólica (ZHANG *et al.*, 2014; OLIVEIRA; COSTA, 2011), sobretudo, ao ser considerado um horizonte anual.

O trabalho de ARCHER e JACOBSON (2013) calcula o potencial teórico global de geração eólica com auxílio de modelo numérico dinâmico e aponta características sazonais da geração eólica e a sua relação com a dinâmica atmosférica e oceânica. Apesar de não ser explorada a relação entre o potencial eólico e os fenômenos climáticos, é possível esperar algum impacto, dada a influência destes sobre as dinâmicas atmosférica e oceânica. Ademais, estudos como os de AMARAL (2011) e FÂNZERES *et al.* (2012) buscam inferir a relação entre geração eólica e vazões de rio, que, em última instância, relacionam-se às condições meteorológicas, particularmente, à velocidade dos ventos e à precipitação, que podem sofrer maior ou menor influência de fenômenos climáticos.

Alguns estudos tentam revelar o impacto das condições climáticas no regime de ventos e precipitação no nordeste do Brasil (OLIVEIRA; COSTA, 2011; CERQUEIRA, 2010; ARAUJO JUNIOR *et al.*, 2014; ARAGÃO, 1998). Por estes estudos, também fica clara a relação entre vento e precipitação, que pode ser resumida em: quanto mais precipitação, menos vento e vice-versa. Portanto, a depender da localidade do rio e do parque eólico, de fato, espera-se observar correlação entre geração eólica e vazão.

OLIVEIRA e COSTA (2011) estudam a influência da variabilidade climática e da circulação geral no comportamento do vento no Nordeste do Brasil, particularmente, no Ceará. A motivação vem do incentivo para a introdução do potencial eólico na matriz energética brasileira e a reconhecida susceptibilidade do clima do Nordeste brasileiro à pressão atmosférica e às anomalias de TSM dos oceanos Atlântico e Pacífico, como apontado em ENFIELD (1996).

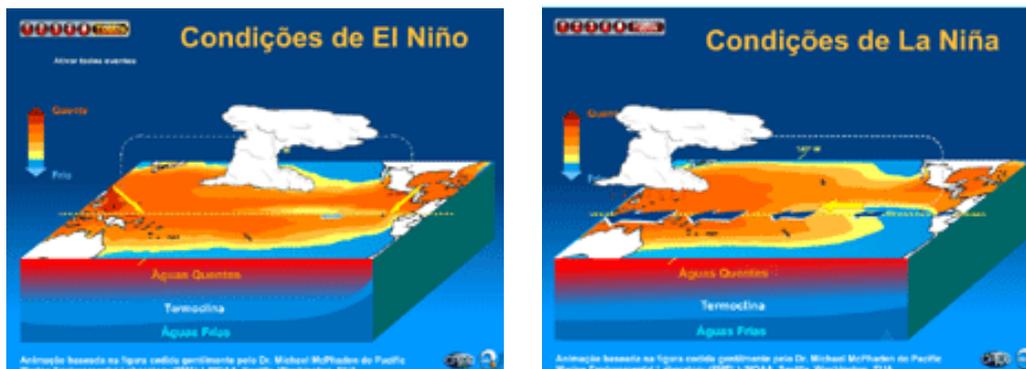
A anomalia de TSM na região do *Niño* 3.4 do oceano Pacífico (Figura 8) é determinante para caracterizar a condição oceânica-atmosférica do ENSO – *El Niño Southern Oscillation*, que pode ser: neutra, *La Niña* ou fase fria (negativa) e *El Niño* ou fase quente (positiva). A condição de *La Niña* está associada ao resfriamento anômalo da TSM e a intensificação dos ventos alísios no Oceano Pacífico Equatorial, enquanto a condição de *El Niño* está associada ao aquecimento anômalo

da TSM e enfraquecimento dos ventos alísios no Oceano Pacífico Equatorial (Figura 9). Há de se ressaltar, que sob condição de neutralidade, o Oceano Pacífico Equatorial já apresenta águas mais frias, portanto, a *La Niña* representa um resfriamento exacerbado desse oceano, ao passo que o *El Niño* altera o sinal de temperatura de sua condição de neutralidade. O ENSO é o fenômeno que mais contribui para a variabilidade climática em uma escala global (ZEBIAK, 1993).



**Figura 8 – Oceano Pacífico e as regiões do Niño**

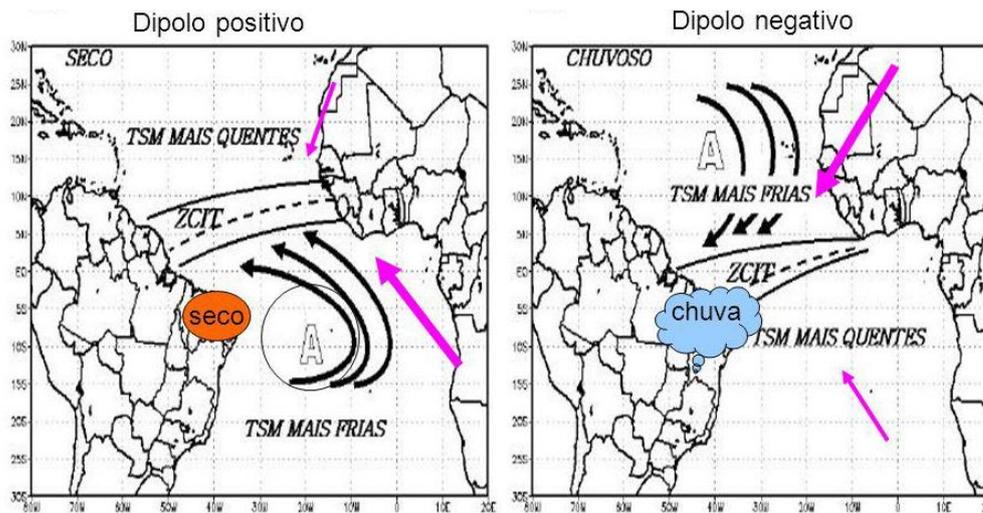
Fonte: HONG KONG OBSERVATORY (2016).



**Figura 9 – Circulação dos ventos alísios e *El Niño* (a esquerda) e *La Niña* (a direita)**

Fonte: CPTEC (2016).

De modo semelhante, a anomalia de TSM do Atlântico Norte e Sul é determinante para computar o Dipolo do Atlântico, que tem relação direta com o posicionamento da ZCIT – Zona de Convergência Inter Tropical e a ocorrência de precipitação no Nordeste brasileiro (CERQUEIRA, 2010; ENFIELD, 1996). Na Figura 10 podem ser melhor visualizadas as regiões do Atlântico Norte e Sul, com a configuração de Dipolo Negativo e Positivo do Atlântico.



**Figura 10 – Dipolo Negativo do Atlântico (à direita) e Dipolo Positivo do Atlântico (à esquerda) e o posicionamento da ZCIT**

Fonte: ALGARVE (2016).

OLIVEIRA e COSTA (2011) concluem que a ocorrência de *El Niño* e Dipolo Positivo do Atlântico favorecem a geração eólica, enquanto a ocorrência de *La Niña* e Dipolo Negativo do Atlântico, resultam em aumento da precipitação, desfavorecendo, assim, a geração eólica. Os efeitos das anomalias de TSM do Atlântico e do Pacífico não foram analisados separadamente, no entanto, observou-se que: (i) anomalias de TSM nas regiões *Niño 3* e *Niño 3.4* do Pacífico precedem em dois meses mudanças na velocidade dos ventos; (ii) a velocidade dos ventos responde mais rapidamente a anomalias na TSM do Atlântico Tropical, conforme observado em relação à precipitação por ENFIELD (1996). Os autores destacam também a maior influência do Dipolo do Atlântico na estação chuvosa, geralmente, de fevereiro a maio.

ARAÚJO JUNIOR *et al.* (2014), analisam o impacto do ENSO na produção de energia de eólica no Ceará e obtém o mesmo resultado sobre a influência do ENSO, ou seja, melhor condição para produção de energia eólica na fase quente e pior na fase fria, principalmente no litoral.

ARAGÃO (1998) explica que o Dipolo do Atlântico inibe ou aumenta a formação de nuvens sobre o Nordeste brasileiro e alguns países de África. Quando a TSM do Atlântico Norte tem anomalia positiva e a TSM do Atlântico Equatorial ou Sul tem anomalia negativa (Dipolo Positivo do Atlântico), a formação de nuvens é inibida e a ZCIT posiciona-se mais ao norte, restando a precipitação reduzida. Por outro lado, quando a TSM do Atlântico Norte tem anomalia negativa e a TSM do

Atlântico Equatorial ou Sul tem anomalia positiva (Dipolo Negativo do Atlântico), a formação de nuvens é reforçada e a ZCIT posiciona-se mais ao sul, restando a precipitação aumentada. A relação entre ENSO e precipitação (OLIVEIRA; COSTA, 2011; CERQUEIRA, 2010; ARAUJO JUNIOR *et al.*, 2014), também, é ratificada. Outro resultado obtido é que as informações de TSM do Atlântico, até seis meses antes do início da estação chuvosa, são mais relevantes do que as do Pacífico para prever anomalias de precipitação no Nordeste brasileiro.

CERQUEIRA (2010) traz alguns estudos que confirmam o sinal da influência do ENSO e do Dipolo do Atlântico sobre a precipitação no Nordeste brasileiro. Ele também conclui que a influência do Dipolo do Atlântico parece ser maior do que a influência do ENSO (*La Niña* e *El Niño*). No entanto, ele observa que a relação entre a TSM do Atlântico e precipitação torna-se maior na ocorrência de *La Niña* ou *El Niño* fortes.

Nos trabalhos apresentados fica clara a existência teórica e, mesmo empírica da influência dos fenômenos *El Niño*, *La Niña* e Dipolo Positivo e Negativo do Atlântico sobre a precipitação e velocidade dos ventos no Nordeste brasileiro, particularmente, no Ceará. Assim, ao realizar a previsão de geração eólica nessa região para horizontes anuais, espera-se que a incorporação desses fenômenos na modelagem, resulte em um modelo mais robusto e com melhor acurácia de previsão.

### **3.2.**

#### **Funções de preferência e medidas de desempenho**

Nesta seção é apresentada a revisão de literatura sobre funções de preferência e medidas de desempenho, destacando-se os conceitos necessários para o desenvolvimento da nova função de preferência no capítulo 5. Inicialmente é revista a Teoria da Utilidade Esperada e algumas medidas de desempenho dela derivadas. Em seguida, é explorado o conceito de medidas coerentes de risco, seguido dos conceitos de Equivalente Certo e Prêmio de Risco. Por fim, aborda-se sucintamente a parametrização de medidas de desempenho.

### 3.2.1. Teoria da Utilidade Esperada

A Teoria da Utilidade Esperada de VON NEUMANN e MORGENSTERN (1944) foi durante muito tempo a base principal da moderna teoria financeira. Uma função utilidade de Von Neumann-Morgenstern é definida, com base na riqueza do investidor, conforme eq. (8).

$$U(W) \tag{8}$$

Onde:

$U(.)$  = alguma função específica;

$W$  = nível de riqueza do investidor.

A função utilidade permite comparar e representar preferências entre variáveis aleatórias (v.a.'s) de modo analítico, estabelecendo a preferência entre as decisões associadas às distribuições de probabilidade dos resultados. Quando uma v.a. A é preferível a outra v.a. B, então, o valor esperado da utilidade de A é maior que o valor esperado da utilidade de B, podendo-se visualizar a utilidade como uma medida de felicidade ou satisfação do investidor. Utilidade é, portanto, um índice de ganho ou perda psíquica, constituindo-se como um atributo individual de cada pessoa. A função utilidade leva em consideração toda a gama de cenários, transformando cada possível resultado financeiro em unidades de utilidade. Assim, o objetivo do investidor é maximizar a sua utilidade esperada, a qual descreve sua atitude frente ao risco de forma objetiva (BESSADA, 1982), que pode ser de aversão, neutralidade ou propensão ao risco.

A segunda derivada da função utilidade caracteriza o perfil de risco do investidor do seguinte modo:

- ✓ se  $U(.)$  é côncava, o investidor é avesso a risco;
- ✓ se  $U(.)$  é linear, o investidor é neutro ao risco;
- ✓ se  $U(.)$  é convexa, o investidor é propenso ao risco.

Um investidor avesso ao risco é mais sensível a perdas do que a ganhos, portanto, para uma mesma variação de  $+d$  em torno do ponto  $W_0$  (aumento da

riqueza), o incremento da utilidade do indivíduo é menor, em módulo, que o decréscimo de utilidade resultante da mesma variação negativa ( $-d$ ) em torno do mesmo ponto  $W_0$ , ou seja,  $|U(W_0 + d) - U(W_0)| \leq |U(W_0) - U(W_0 - d)|$ . Matematicamente, tem-se uma função côncava, cuja segunda derivada é negativa, ou seja, à medida que se avance no sentido positivo do domínio da função, o benefício marginal da utilidade (primeira derivada) é decrescido de forma monótona. Para o investidor neutro a risco, como a utilidade apresenta primeira derivada constante ao longo de todo o domínio, variações positivas e negativas de mesmo módulo, em torno de um mesmo ponto, proporcionam variações idênticas (em módulo) de utilidade, ou seja,  $|U(W_0 + d) - U(W_0)| = |U(W_0) - U(W_0 - d)|$ . Já com um investidor propenso ao risco ocorre o oposto do caso da aversão, ele dá mais valor a variações positivas do que às negativas de mesma magnitude, em torno de um mesmo ponto, resultando, matematicamente, em uma função convexa, com a primeira derivada aumentando à medida que a riqueza cresce.

A conhecida teoria moderna de carteiras de Markowitz e a utilização da função de utilidade de média-variância pode ser justificada pela aproximação de uma função de utilidade de Von Neumann-Morgenstern a esta (SAMUELSON, 1970; TSIANG, 1972; LEVY; MARKOWITZ, 1979), quando os retornos são normais ou a função utilidade do investidor é quadrática. Entretanto, a função utilidade quadrática possui propriedades consideradas anômalas, particularmente, o aumento da aversão ao risco à medida que o nível de riqueza cresce (KOEKEBAKKER; ZAKAMOULINE, 2007b). A função de média-variância é definida conforme eq. (9).

$$E[U(W)] = E[W] - \frac{1}{2}\gamma \times \sigma^2[W] \quad (9)$$

Onde:

$E[U(W)]$  = utilidade esperada da riqueza;

$E[W]$  = riqueza esperada;

$\sigma^2[W]$  = variância da riqueza;

$\gamma$  = coeficiente de aversão ao risco do investidor, computado como sendo menos a divisão da segunda derivada da função utilidade pela primeira ( $\gamma = -U''/U'$ ), que é conhecido como medida de Arrow-Pratt de aversão absoluta ao risco.

ZAKAMOULINE e KOEKEBAKKER (2009) demonstraram, também, que a função de utilidade de média-variância leva à clássica medida de performance índice de Sharpe (IS), definido na eq. (10).

$$IS = \frac{\mu - r}{\sigma} \quad (10)$$

Onde:

$\mu$  = retorno esperado do ativo selecionado;

$\sigma$  = desvio padrão dos retornos;

$r$  = taxa livre de risco.

As vantagens do IS são sua fácil implementação e a anulação das preferências do investidor em seu cálculo, fazendo com que independentemente do nível de aversão ao risco, todos os investidores com função utilidade quadrática ou de média-variância classifiquem do mesmo modo diferentes investimentos (PÉZIER, 2011). Entretanto, estudos posteriores demonstraram que na presença de assimetria na curva normal de retornos (o que pode ocorrer pelo uso de derivativos), fundos com risco indesejado (*left-tailrisk*) podem acabar sendo preferidos, caso haja um momento de tranquilidade no mercado (GOETZMANN *et al.*, 2002; INGERSOLL *et al.*, 2007).

Outra crítica ao IS vem de KOEKEBAKKER e ZAKAMOULINE (2007b) ao demonstrarem que a função utilidade do investidor não deve ser ignorada. Eles defendem que, primeiramente, deve-se especificar a função utilidade do investidor para posterior escolha do ativo de risco ou da carteira que maximiza a utilidade esperada do investidor. Em sua análise, eles sugerem que a classificação de diferentes alternativas de investimento pode variar bastante para diferentes tipos de função utilidade. Em função dessas críticas, foram desenvolvidas medidas a partir do IS, como o Índice de Sharpe ajustado à Assimetria (ISA) de KOEKEBAKKER e ZAKAMOULINE (2007b). O ISA é obtido a partir da aproximação de uma função utilidade geral pelos primeiros três momentos das distribuições dos retornos (média, variância e assimetria), conforme eq. (11).

$$ISA = IS \sqrt{1 + \frac{bA}{3} IS}; \quad b = \frac{U'''/U'}{(U''/U')^2} \quad (11)$$

Onde:

IS = Índice de Sharpe definido na eq. (10);

A = assimetria da distribuição dos retornos;

b = parâmetro de preferências do investidor pela assimetria da distribuição dos retornos, definido pelas três primeiras derivadas da função utilidade (U).

Ao contrário do IS, o ISA não é único, pois depende da preferência do investidor pela assimetria, obtida pelas derivadas da função utilidade específica. Assim, o uso do ISA implica certa ambiguidade na hora de ordenar os diferentes ativos de risco, já que o ranqueamento depende substancialmente do valor do parâmetro  $b$ , especialmente no caso de grande assimetria na distribuição dos retornos ou  $b$  elevado (KOEKEBAKKER; ZAKAMOULINE, 2007a).

Após a Teoria da Utilidade Esperada ter sido formulada por VON NEUMANN e MORGENSTERN (1944), questionou-se seu valor enquanto modelo para descrever escolhas sob incerteza. Dentre as críticas, ALLAIS (1953) e ELLSBERG (1961) demonstraram que algumas de suas premissas não encontravam amparo em estudos empíricos.

Por outro lado, a análise de média-variância de Markowitz foi muito criticada em função de investidores associarem risco, habitualmente, à possibilidade de perdas e, não, ao desvio-padrão dos retornos, conforme reconhecido pelo próprio MARKOWITZ (1959), ao propor a semivariância como medida alternativa de risco. Apesar da semivariância não ter sido agregada a seleção de carteiras, ela serviu de base para proposição de uma medida generalizada de semivariância ajustada para baixo como medida de risco (FISHBURN, 1977; BAWA, 1978), o Momento Parcial Inferior (MPI).

$$MPI_n(x, tg) = \int_{-\infty}^{tg} (tg - x)^n dF(x) \quad (12)$$

Onde:

$MPI_n(x, tg)$  = momento parcial inferior de ordem  $n$  no nível  $tg$  da v.a.  $x$ ;

$F(x)$  = função de probabilidade acumulada de  $x$ ;

$tg$  = nível pré-definido, que pode ser visto como retorno mínimo aceitável pelo investidor ou ponto de referência no qual o investidor baseia seus ganhos e perdas (ZAKAMOULINE, 2010).

De modo similar, pode-se definir o Momento Parcial Superior (MPS) (SCHIPPER; THOMPSON, 1983) de ordem  $n$  a um nível  $tg$ , presente na eq. (13).

$$MPS_n(x, tg) = \int_{tg}^{\infty} (x - tg)^n dF(x) \quad (13)$$

FISHBURN (1977) e BAWA (1978) propuseram o modelo de MPI médio para a seleção de carteiras e provaram que a escolha de ativos pelo modelo corresponde a uma função utilidade específica do investidor, conforme eq. (14).

$$U(x) = \begin{cases} x; & x \geq tg \\ x - \gamma(tg - x)^n; & x < tg \end{cases} \quad (14)$$

Onde:

$\gamma$  = medida de aversão ao risco do investidor;

$n$  = ordem do momento parcial inferior.

É possível observar que para o caso  $n = 1$ , o MPI passa a ser  $(1 - \alpha)(VaR_\alpha - CVaR_\alpha)$ , onde  $\alpha = 1 - F(tg)$ . A formalização da definição de  $VaR_\alpha$  – *Value at Risk* e  $CVaR_\alpha$  – *Conditional Value at Risk* encontra-se na seção 3.2.2. Tem-se, portanto, que o MPI de ordem 1 é o valor da diferença entre o *Value at Risk* ao nível de significância de um menos a probabilidade acumulada do ponto  $tg$  e a perda esperada além do ponto  $tg$ , ponderado pela probabilidade acumulada do ponto  $tg$ . De modo recíproco, o  $CVaR_\alpha$  é o  $VaR_\alpha - MPI_1(x, VaR_\alpha)/(1 - \alpha)$ . STREET (2010) mostra que uma função utilidade linear por partes e bastante similar a eq. (14), resulta na medida de otimização de ponderação entre o valor esperado da distribuição e o  $CVaR_\alpha$  da distribuição a um determinado nível de significância  $\alpha$ ,

denominado ECP – *Extended CVaR Preference functional*, presente na eq. (15) para um período. O ECP é justamente a função objetivo que passou a ser empregada na otimização do despacho hidrotérmico do SIN em agosto de 2013 e é, também, empregado em variados problemas de otimização do setor elétrico. Uma de suas vantagens é a facilidade de implementação em problemas de programação estocástica dual.

$$ECP_{\alpha,\lambda} = (1 - \lambda)E[X] + \lambda CVaR_{\alpha}(X); \lambda \in [0,1] \quad (15)$$

Onde:

$\lambda$  = medida de aversão ao risco do investidor.

Contudo, o uso mais comum do MPI é a definição da taxa livre de risco ( $r$ ) como ponto de referência ( $tg = r$ ) (ZAKAMOULINE, 2010) e  $n = 2$ , obtendo-se a medida de desempenho conhecida como o conhecido Índice de Sortino (ISO) (SORTINO; PRICE, 1994). Outras medidas de desempenho baseadas em momentos parciais da distribuição são: medida Ômega (SHADWICK; KEATING, 2002), medida de Kappa (KAPLAN; KNOWLES, 2004), relação do potencial de *upside* (SORTINO *et al.*, 1999) e razão Farinelli-Tibiletti (FARINELLI *et al.*, 2008). A Tabela 1 apresenta essas medidas e seus diferenciais.

**Tabela 1 – Medidas de desempenho baseadas em momentos parciais da distribuição**

Fonte: elaboração própria.

Medida e Formulação	Diferencial
<p><b>Índice de Sortino</b></p> $ISO = \frac{E[X] - r}{\sqrt{MPI_2(x, r)}}$	Penalização apenas dos desvios negativos em relação à rentabilidade mínima exigida pelos investidores.
<p><b>Ômega</b></p> $\Omega(x, tg) = \frac{MPS_1(x, tg)}{MPI_1(x, tg)}$ $= K_2(x, tg)$ $+ 1 = RFT_{1,1}$	Pondera o benefício dos ganhos com o impacto das perdas (CHEN <i>et al.</i> , 2011), sendo capaz de percorrer toda a distribuição.

<p><b>Kappa</b></p> $K_n(x, tg)$ $= \frac{E[X] - tg}{\sqrt[n]{MPI_n(x, tg)}}; n > 0$	<p>Generalização das medidas baseadas no MPI ao permitir variação do parâmetro <math>n</math>.</p>
<p><b>Relação do potencial de upside</b></p> $RPU = \frac{MPS_1(x, tg)}{\sqrt{MPI_2(x, tg)}}$ $= RFT_{1,2}$	<p>SORTINO <i>et. al.</i> (2003) apontam que essa medida é adequada para investidores que procuram o melhor desempenho acima do seu ponto de referência.</p>
<p><b>Razão Fairnelli-Tibiletti</b></p> $RFT_{m,n}$ $= \frac{\sqrt[m]{MPI_n(x, tg)}}{\sqrt[n]{MPI_n(x, tg)}}; m, n$ $> 0$	<p>Generalização da medida Ômega, onde <math>m</math> e <math>n</math> capturam a atitude do investidor em relação a ganhos e perdas, respectivamente. Quanto maior o parâmetro, maior a preferência do investidor (ganhos) ou aversão (perdas) (ELING <i>et al.</i>, 2011).</p>

A noção de aversão à perda, contemplada nas medidas baseadas no MPI foi, também, amplamente discutida no contexto da Teoria do Prospecto (KAHNEMAN; TVERSKY, 1979, TVERSKY; KAHNEMAN, 1992), que surge de questionamentos às premissas da Teoria da Utilidade Esperada. KAHNEMAN e TVERSKY (1979) a propuseram como um modelo alternativo descritivo de escolha sob incerteza, capaz de prever corretamente escolhas individuais mesmo sob violação de premissas da Teoria da Utilidade Esperada (CAMERER, 2000). Duas diferenças principais dessa teoria são:

- ✓ uso da função valor no lugar da função utilidade, a qual é definida sobre perdas e ganhos em relação a uma referência e exibe aversão ao risco na área de perdas e, propensão na de ganhos;
- ✓ uso de pesos de decisão ao invés de probabilidades simples, representando uma estimativa das probabilidades dos eventos.

Medidas de desempenho, também, foram desenvolvidas a partir da Teoria do Prospecto (alguns exemplos podem ser vistos em KLOTZLE *et al.* (2012)), bem

como modelos de decisão multicritério, como o TODIM (Tomada de Decisão Interativa Multicritério) (GOMES; LIMA, 1992), mas fogem ao escopo deste estudo. Entretanto, é interessante observar a função de utilidade comportamental, presente na eq. (16), obtida por ZAKAMOULINE e KOEKEBAKKER (2009) e KOEKEBAKKER e ZAKAMOULINE (2008), como aproximação da função valor da Teoria do Prospecto para o problema de alocação ótima do capital de um investidor avesso a perdas.

$$E[U(W)] = MPS_{\alpha}(W, W_0) - \lambda MPI_{\beta}(W, W_0) \quad (16)$$

Onde:

$W_0$  = ponto de referência;

$\lambda$  = coeficiente de aversão à perda.

Nota-se certa similaridade da função de utilidade comportamental com o ECP se  $\alpha = \beta = 1$  e  $W_0 = VaR_{\alpha}$ , contudo, enquanto este assume como perda o  $CVaR_{\alpha}$  e, como ganho, o valor esperado ( $E[W]$ ), aquela assume como ganho o  $MPS_1(W, VaR_{\alpha})$  e, como perda, o  $MPI_1(W, VaR_{\alpha})$ . Ademais, na função de utilidade comportamental, não se impõe que os pesos de ganhos e perdas somem um, uma vez que não é atribuído peso ao  $MPS_{\alpha}(W, W_0)$ . Outra diferença na equação é que no ECP a perda é somada e na função de utilidade comportamental, deduzida, isto ocorre porque na formulação daquela a perda pode ser positiva ou, como esperado, negativa. Nesta, porém, a perda é sempre um valor positivo.

Tanto as medidas de desempenho baseadas em momentos parciais, quanto as derivadas da Teoria do Prospecto buscam definir perdas e/ou ganhos em relação a um único ponto de referência  $W_0$ . Apesar de coerente, em alguns casos, é possível que o tomador de decisão ou a empresa tenham mais pontos de referência que determinam mudanças de comportamento ou utilidade, conforme será explorado no capítulo 5.

De fato, Rabin (2000) critica a habilidade da Teoria da Utilidade Esperada em modelar aversão ao risco quando o risco é modesto, sobretudo, quando a mesma função utilidade é mantida para qualquer nível de riqueza. Ele apresenta exemplos dos erros de representação passíveis de serem incorridos, bem como cita modelagens capazes de fazer essa correção.

### 3.2.2. Medidas coerentes de risco

As medidas de desempenho apresentadas na seção 3.2.1 constituem medidas de risco-retorno, contudo, cada uma apresenta diferentes definições para retorno, como valor esperado e MPS e, para risco, como desvio-padrão, MPI e CVaR.

RIGUI e CERETTA (2014) apresentam uma revisão de diversas medidas de risco presentes na literatura, agrupando-as em cinco classes: (i) medidas de risco coerentes; (ii) medidas de risco convexas; (iii) medidas de risco espectrais e de distorção; (iv) medidas de desvio generalizado; (v) outras classes de medidas de risco.

As medidas de risco coerentes destacam-se por atenderem a axiomas definidos como desejáveis para medidas de risco. De fato, essas condições exigidas para ser dita coerente foram definidas a partir da observação do comportamento de investidores, levando-se em conta a teoria das preferências, conforme demonstrado em OLIVEIRA (2009). Extensões dos axiomas básicos de medidas de risco também têm sido objeto de estudos (RIGUI; CERETTA, 2014).

Assim, seja  $\Omega$  um conjunto de cenários fixados. Uma posição financeira é descrita por um mapeamento  $X: \Omega \rightarrow \mathbb{R}$ , onde  $X(\omega)$  é o caixa descontado da posição no final do período de transação se o cenário  $\omega \in \Omega$  for realizado. Para quantificar o risco de  $X$ , pertencente a uma dada classe  $\chi$  de posições financeiras, por algum número  $\rho(X)$ , toma-se o mapeamento  $\rho: \chi \rightarrow \mathbb{R}$ . No caso,  $\chi$  será um espaço linear de funções limitadas contendo as funções constantes e não é suposta qualquer medida de probabilidade em  $\Omega$ .

Um mapeamento  $\rho: \chi \rightarrow \mathbb{R}$  é uma MMR – Medida Monetária de Risco se satisfaz as condições i. e ii. a seguir. Se a condição iii. também for satisfeita, a medida é chamada MRC – Medida Convexa de Risco.

- i. Monotonicidade: Se  $X \leq Y$ , então  $\rho(X) \geq \rho(Y)$
- ii. Invariância de translação: Se  $m \in \mathbb{R}$ , então  $\rho(X + m) = \rho(X) - m$
- iii. Convexidade:  $\rho(\lambda X + (1 - \lambda) Y) \leq \lambda \rho(X) + (1 - \lambda) \rho(Y)$ ,  $0 \leq \lambda \leq 1$

A condição i. garante que se uma posição financeira tem sempre resultados piores que outra, seu risco é maior. Já a condição ii. diz que se for acrescido um ganho certo  $m$  à posição financeira, o risco deve decrescer na mesma quantidade  $m$ ,

o que é importante em termos regulatórios para definição de chamadas de margem (ARTZNER *et al.*, 1999). A condição iii. é importante para garantir que se um investidor realizar a diversificação de seu portfólio, seu risco não aumentará, o que é esperado na teoria financeira.

Finalmente, uma MRC – Medida Convexa de Risco é chamada de MCR – Medida Coerente de Risco se é positivamente homogênea (satisfaz iv.), ou seja, se posições financeiras maiores aumentam o risco na mesma proporção.

iv. Homogeneidade Positiva: Se  $\lambda \geq 0$ , então  $\rho(\lambda X) = \lambda \rho(X)$

Tem-se, ainda, que satisfazer as condições iii. e iv. é equivalente a satisfazer a condição v. de subaditividade.

v. Subaditividade:  $\rho(X + Y) \leq \rho(X) + \rho(Y)$

São exemplos de medidas coerentes de risco o  $ES_\alpha$  – *Expected Shortfall* ou  $CVaR_\alpha$  e as medidas espectrais de risco ou *weighted-VaR<sub>α</sub>*, conforme demonstrado em OLIVEIRA (2009), dentre outros. O  $CVaR_\alpha$  é definido como sendo a perda esperada além do  $VaR_\alpha$ , que foi proposto como o risco máximo a um nível  $\alpha$  de confiança (JORION, 1996). Apesar de sua popularidade, o  $VaR_\alpha$  é criticado por infringir a subaditividade sob certas condições da distribuição da posição financeira X (OLIVEIRA, 2009).

As definições do  $VaR_\alpha$  e  $CVaR_\alpha$  são apresentadas formalmente, respectivamente, nas eq. (17) e eq. (18), considerando seus valores absolutos. Vale destacar que em algumas definições são apresentados seus valores em módulo, uma vez que já é assumido desde o início que eles são valores negativos por representarem perdas.

$$\begin{aligned} VaR_\alpha(X) &= \inf\{m \mid P[X - m > 0] \leq \alpha\} \\ &= \inf\{m \mid P[X - m < 0] \leq 1 - \alpha\}; m \in \mathbb{R}; \alpha \in [0,1[ \end{aligned} \tag{17}$$

$$\begin{aligned} CVaR_\alpha(X) &= E[X \mid X \leq VaR_\alpha] \\ &= \frac{1}{1 - \alpha} \int_{-\infty}^{VaR_\alpha} xf(x)dx = \frac{1}{1 - \alpha} \int_0^{1-\alpha} VaR_u(X)du \end{aligned} \tag{18}$$

Outro ponto a ser destacado é que uma medida de risco coerente não é necessariamente melhor do que outra não coerente, como corrobora o estudo de MORAES (2012). Nesse estudo, foi avaliado o desempenho de carteiras de investimentos no mercado brasileiro em períodos de crise, comparando-se as perdas reais com o risco estimado pelo  $VaR_\alpha$  e  $CVaR_\alpha$ , mensurados sob diferentes técnicas. Aparentemente, o  $CVaR_\alpha$  não demonstrou ganho de eficiência sobre o  $VaR_\alpha$ , acrescentando apenas uma margem maior ao intervalo adotado pelo  $VaR_\alpha$ . O estudo aponta que o grande desafio de um bom modelo de risco de mercado está na distribuição dos retornos dos ativos e nas hipóteses adotadas pelo modelo e, não, nas propriedades de coerência. Salienta, ainda, que para efetiva vantagem do  $CVaR_\alpha$  é imprescindível a modelagem realista da distribuição dos retornos.

CHEN e YANG (2011) apresentam uma outra abordagem de medidas de risco, que satisfazem apenas monotonicidade e convexidade, sendo apresentadas como perda esperada ponderada (WES – *Weighted Expected Short-fall*) na eq. (19). Em linha com as críticas de RABIN (2000) à capacidade da Teoria da Utilidade Esperada em modelar adequadamente aversão ao risco quando a mesma função utilidade é utilizada para diferentes níveis de riqueza, a WES, através de uma função de pesos não linear ( $w$ ), trata perdas grandes e pequenas além do  $VaR_\alpha$  de modo assimétrico, de acordo com o perfil de aversão ao risco do investidor. O estudo empírico mostrou que a WES reflete melhor as restrições do mercado, superando portfólios construídos com base no  $CVaR_\alpha$ .

$$\begin{aligned} WES_\alpha(X) &= -\frac{1}{\alpha} \int_0^\alpha w(F_X^{-1}(u)) F_X^{-1}(u) du \\ &= -\frac{1}{\alpha} \int_0^\alpha w(VaR_{1-u}(X)) VaR_{1-u}(X) du \end{aligned} \tag{19}$$

Onde:

$w: \mathbb{R} \rightarrow \mathbb{R}$  é uma função monótona não crescente, positiva e convexa para valores negativos ou iguais a zero e, não negativa e côncava para valores positivos.

Ainda no âmbito das medidas de risco, mas fazendo o paralelo com as medidas de desempenho, CHERNY e MADEN (2009) mostram teoricamente que medidas de desempenho que satisfazem condições inspiradas na teoria de medidas

de risco coerentes sobressaem-se em relação às demais. Um exemplo de medida que atende essa condição é o ECP (STREET, 2010), dada sua inspiração no  $CVaR_\alpha$ . Observa-se, ainda, uma certa relação das ideias por trás do ECP e da WES, uma vez que em ambas é atribuído um peso ao  $CVaR_\alpha$ . Contudo, ao passo que aquela pondera ganho e risco esperados, esta distorce o peso da perda esperada, de acordo com o perfil de risco do investidor. Outra diferença importante é que, dado um nível  $\alpha$  de risco, para obtenção do grau de aversão ao risco no ECP, é preciso definir o parâmetro  $\lambda$ , que vale para qualquer nível de riqueza, enquanto na WES, o grau de aversão risco é uma função do  $VaR_\alpha$ .

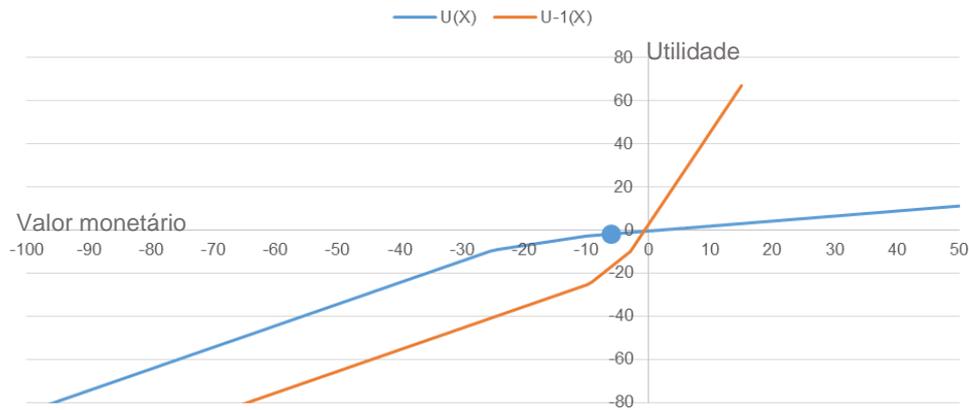
### 3.2.3.

#### O Equivalente Certo e o cálculo de prêmio de risco

Na seção 3.2.1 foram apresentadas diversas medidas de desempenho, bem como a Teoria da Utilidade Esperada, na qual o objetivo do investidor é justamente a maximização do valor esperado da utilidade (BESSADA, 1982). Nesse contexto, insere-se a definição de Equivalente Certo ( $Eq$ ) de uma posição financeira aleatória como sendo o menor montante determinístico que torna o investidor indiferente ao fluxo estocástico. Pensando essa definição em termos de preferência, deve-se comparar a utilidade esperada de ambos os fluxos, determinístico (à esquerda na eq. (20)) e estocástico (à direita na eq. (20)), de modo a igualar o valor esperado de suas utilidades. Temos, assim, a seguinte igualdade:

$$\overbrace{E[U(Eq)]}^{\text{Determinístico}} = \overbrace{E[U(X)]}^{\text{Estocástico}} \Rightarrow U(Eq) = E[U(X)] \Rightarrow Eq = U^{-1}(E[U(X)]) \quad (20)$$

Vale observar que para obtenção do  $Eq$  é necessário que a função utilidade seja invertível na vizinhança de  $E[U(X)]$ , o que é garantido para funções bijetoras ou, de modo mais abrangente, para funções com primeira derivada não nula no ponto  $E[U(X)]$  (Teorema da Função Inversa). A Figura 11 mostra uma função utilidade linear por partes côncava e sua inversa, a semelhança da função utilidade abordada no capítulo 5.



**Figura 11 – Função utilidade e sua inversa**

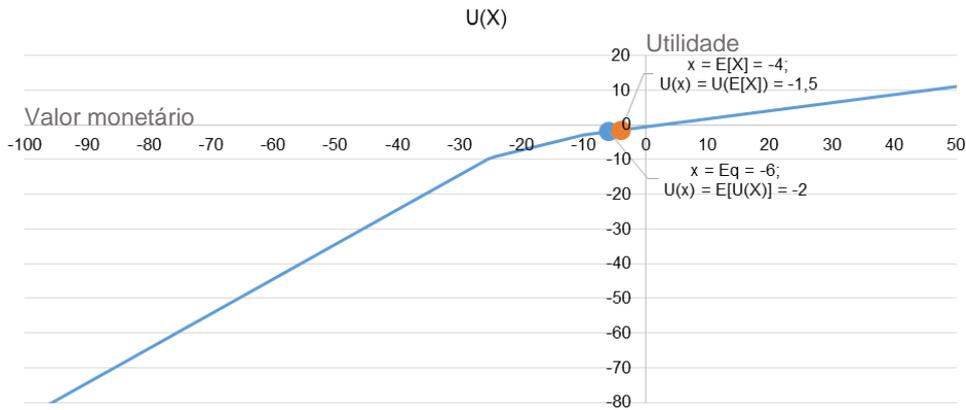
Fonte: elaboração própria.

A importância do equivalente certo é explorada em STREET (2008) e pode ser resumida em permitir a tradução da utilidade de um fluxo estocástico em um único montante determinístico, abrindo caminho para a noção de prêmio de risco. O prêmio de risco pode ser visto como a menor quantia necessária para igualar o valor atribuído a uma variável aleatória por um investidor avesso ao risco ao valor atribuído a esta por um investidor neutro a risco, conforme ilustrado nas Figuras 12 e 13, que tratam da mesma função utilidade presente na Figura 9.

Na Figura 11, observa-se o que o investidor é capaz de trocar um fluxo estocástico com valor esperado de  $-4$  ( $E[X] = -4$ ), por um fluxo certo de  $-6$  ( $Eq = -6$ ). Ora, um investidor neutro ao risco, por definição, tem função utilidade linear e não trocaria um fluxo estocástico de valor esperado  $-4$  por um fluxo determinístico de menor valor. Assim, essa diferença entre as percepções corresponde ao prêmio de risco ( $Pr$ ) que o investidor avesso ao risco dispõe-se a pagar, conforme formulado na eq. (21) e ilustrado na Figura 13, que amplia a região dos pontos  $(Eq; E[U(X)])$  e  $(E[X]; U(E[X]))$  da Figura 12.

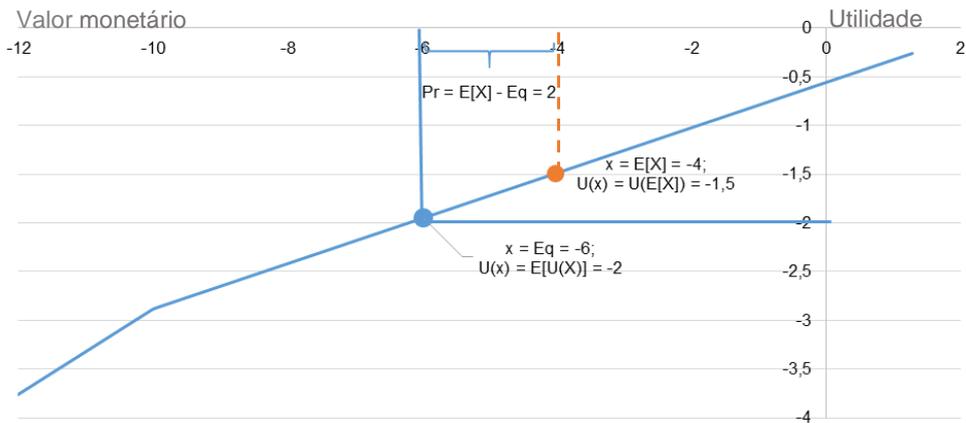
$$Pr = E[X] - Eq$$

(21)



**Figura 12 – Função utilidade de investidor avesso ao risco, ( $E_q$ ;  $E[U(X)]$ ) e ( $E[X]$ ;  $U(E[X])$ )**

Fonte: elaboração própria.



**Figura 13 – Prêmio de risco e sua relação com  $E_q$  e  $E[X]$**

Fonte: elaboração própria.

Na seção 3.2.1 foram apresentadas as condições da função utilidade que caracterizam o perfil do investidor como neutro, avesso ou propenso ao risco. A partir dessas condições é possível obter a relação entre  $U(E_q)$  e  $U(E[X])$ , bem como,  $E_q$  e  $E[X]$  para cada perfil de investidor, de modo que (STREET, 2008):

- ✓ se  $U(.)$  é côncava,  $U(E[X]) > U(E_q) \Rightarrow E(X) > E_q$ , e o investidor é avesso a risco;
- ✓ se  $U(.)$  é linear,  $U(E[X]) = U(E_q) \Rightarrow E(X) = E_q$ , e o investidor é neutro ao risco;
- ✓ se  $U(.)$  é convexa,  $U(E[X]) < U(E_q) \Rightarrow E(X) < E_q$ , e o investidor é propenso ao risco.

Ainda sobre o *Eq*, outra aplicação é sua utilização diretamente como funcional para comparação de fluxos financeiros, sendo um exemplo a proposta de STREET (2008) para comparação de fluxos financeiros intertemporais através de funcional do equivalente certo, delegando à função utilidade somente o papel de valorar a distribuição do resultado financeiro de cada período.

#### 3.2.4.

#### Parametrização de medidas e método AHP de decisão

Diversas foram as medidas de risco e retorno apresentadas, requerendo algumas a especificação de parâmetros e/ou limites para adequada representação de aversão ou propensão ao risco do investidor, bem como delimitação da fronteira entre perdas e ganhos.

No âmbito da Teoria da Utilidade Esperada, a ideia base para parametrização de funções utilidade é a classificação das preferências do investidor em relação a diferentes loterias e seu valor esperado ou equivalente certo, conforme abordado em KEENEY e RAIFFA (1993). Abordagem similar é adotada no trabalho seminal de TVERSKY e KAHNEMAN (1992), ao tratarem da estimação de parâmetros de medidas de desempenho no contexto da Teoria do Prospecto.

É importante destacar que a parametrização dessas medidas é específica de cada tomador de decisão, sobretudo, em função do grau de aversão ao risco individual. Contudo, quando as decisões ocorrem em grupos, pode-se adotar as medianas dos parâmetros individuais obtidos (TVERSKY; KAHNEMAN, 1992, ABDELLAOUI *et al.*, 2008) ou as medianas dos resultados individuais das loterias que serviram para estimá-los (ABDELLAOUI *et al.*, 2008).

No caso da parametrização do ECP, proposto por STREET (2010), é sugerida uma abordagem conceitual para definição dos parâmetros, sem ocorrer, contudo, um maior aprofundamento da questão. O mesmo ocorre na utilização prática dessa medida para cálculo do PLD, apresentado na seção 2.3, tendo a escolha dos parâmetros  $\alpha$  e  $\lambda$  dado-se através de um processo de tentativa e erro com comparação de cenários (Audiência Pública ANEEL nº 86/2013). Em outras aplicações do ECP ou função similar, como ocorre em POURSINHO *et al.* (2011), FÂNZERES *et al.* (2012) e LAZO *et al.* (2012), os parâmetros são determinados sem que haja um processo de estimação. Nestes trabalhos o parâmetro  $\alpha$  é fixado

em 95% e o parâmetro  $\lambda$  é fixado, respectivamente, em 1,0 (máxima aversão ao risco) e 0,95, em FÂNZERES *et al.* (2012) e LAZO *et al.* (2012), e varia de 0,0 a 1,0, com espaçamento de 0,1, em POURSINHO *et al.* (2011).

Observa-se, que a determinação dos parâmetros do ECP divide-se em dois focos: (i) definição do nível  $\alpha$  do CVaR, que está associado ao risco do qual o investidor quer se proteger e, (ii) definição do parâmetro  $\lambda$ , que está associado ao nível de proteção (aversão ao risco) requerido pelo investidor. A determinação do parâmetro  $\lambda$  pode ser vista como uma comparação paritária entre o peso dado ao valor esperado dos resultados e o risco esperado. No caso de expansão do ECP, com inclusão de níveis de risco intermediários, haveria necessidade de ponderação entre os múltiplos níveis de risco e o valor esperado. Para lidar com essas ponderações, uma possibilidade seria o uso de métodos de comparação paritária para determinação dos parâmetros  $\lambda$  de aversão. Um dos métodos mais conhecidos neste âmbito é o AHP – *Analytic Hierarchy Process*.

O AHP é um método de análise hierárquica de desempenho baseado na decomposição e síntese das relações par-a-par entre os critérios, de modo que se obtenha uma medida única de desempenho, capaz de estabelecer uma priorização global das alternativas (SAATY, 1991). Ele é um método de decisão multicritério advindo da escola americana, que defende que os tomadores de decisão conhecem a utilidade das alternativas disponíveis e, com isso, os pesos de cada critério. Ele foi desenvolvido por Thomas Saaty, em 1980, na busca de refletir o processo de tomada de decisão da mente humana, que, segundo SAATY (1991), se dá na agregação e análise de critérios em pequenos grupos, pela incapacidade humana de julgamento diante de um grande número de critérios.

Os principais aspectos positivos do AHP são (RAMANATHAN, 2001; MACHARIS *et al.*, 2004; ZAHIR, 1999; ISHIZAKA; LABIB, 2011): flexibilidade; simplicidade; fácil intuição para o tomador de decisão; capacidade de verificar possíveis inconsistências; clareza na importância de cada critério, dada a decomposição do problema em suas partes constituintes; hierarquização dos critérios de acordo com suas importâncias atribuídas; capacidade de capturar medidas de avaliação subjetivas e objetivas, ou seja, critérios qualitativos e quantitativos; contribuição para redução de possíveis vieses na tomada de decisão ao ser utilizado como ferramenta para tomada de decisão consensual de grupos.

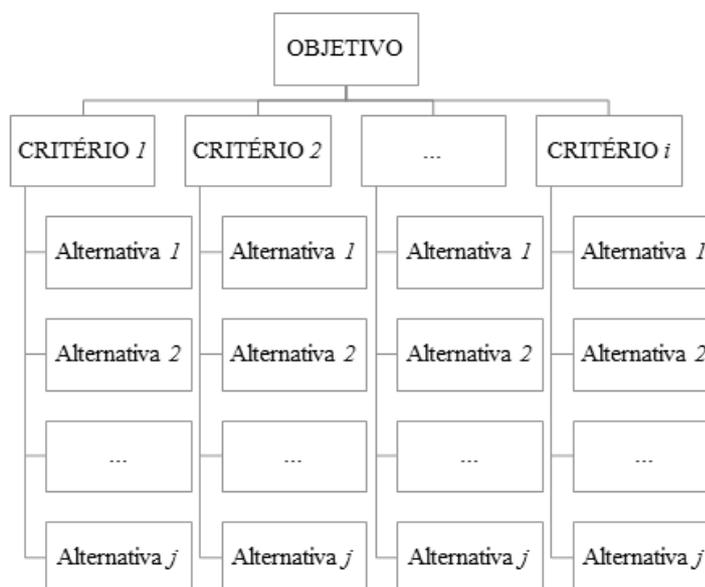
Em contraponto aos aspectos listados, as principais críticas ao AHP são (BELTON, 2002; BELTON; GEAR, 1983; 1997; MURPHY, 1993; MACHARIS *et al.*, 2004): possível reversão do *ranking* de critérios ao incluir ou excluir uma alternativa similar às existentes do modelo, em função do processo de normalização dos critérios; custo computacional expressivo em caso de grande número de critérios, dado o número de comparações a serem feitas e processadas ( $N \times (N - 1) / 2$ ); falsa limitação criada pela utilização da escala de nove pontos, pois o tomador de decisão pode ter dificuldade em determinar a real importância de cada critério. ISHIZAKA e LABIB (2011) ao reverem os aspectos metodológicos do AHP, mostram alternativas para superar algumas das críticas apontadas e GRANDZOL (2005) corrobora com a desconsideração das principais críticas ao AHP quando de sua utilização em ambientes ou problemas adequados.

Dentre as aplicações do AHP encontram-se (ISHIZAKA; LABIB, 2011): seleção de corpo docente, priorização de pesquisa de agricultura internacional, medição da eficiência do gerenciamento de atividades de pesquisa e desenvolvimento em universidades, decisão de estratégias de TI, escolha de operador logístico, planejamento de projeto de produto, avaliação de riscos em projetos de ERP – *Enterprise Resource Planning*, determinação de prioridades em sistema de gestão de segurança e, particularmente, proposição de um indicador geral (FRANCISCHINI; CABEL, 2003; RAFAELI; MÜLLER, 2007).

A metodologia para aplicação do modelo AHP sugere a identificação do problema, elegendo seus objetivos, as alternativas existentes, a identificação dos critérios de tomada de decisão e a seleção do(s) tomador(es) de decisão, conforme esquema na Figura 14.

Uma vez mapeado o cenário (objetivo, critério e alternativas possíveis), os tomadores de decisão devem ponderar a importância de cada um dos critérios em relação a outro, determinando a matriz de julgamentos. Uma vez elaborada a matriz de julgamentos, é realizada a normalização dos julgamentos, obtendo-se uma matriz de pesos atribuídos às comparações paritárias (matriz de preferências) e à cada um dos critérios (vetor de pesos).

As comparações são feitas da coluna da esquerda em relação à linha superior e os julgamentos são atribuídos com base na escala de importância 1-9 proposta por SAATY (1991) e apresentada na Tabela 2.



**Figura 14 – Estrutura Geral do Modelo AHP**

Fonte: elaboração própria.

**Tabela 2 – Escala de importância 1-9 de Saaty**

Fonte: Adaptado de SAATY (1991).

<b>Intensidade da importância</b>	<b>Definição</b>	<b>Explicação</b>	<b>Intensidade da recíproca</b>
1	Importância igual	Atividades contribuem igualmente para o objetivo.	1
3	Importância fraca de um sobre o outro	Experiência e julgamento favorecem levemente uma atividade sobre a outra.	1/3
5	Importância essencial ou forte	Experiência e julgamento favorecem fortemente uma atividade sobre a outra.	1/5
7	Importância demonstrada	Uma atividade é fortemente favorecida e sua dominância é demonstrada na prática.	1/7
9	Importância absoluta	As evidências favorecem uma atividade sobre outra com o mais elevado grau de certeza.	1/9
2, 4, 6 e 8	Valores intermediários entre os julgamentos adjacentes	Quando se procura uma condição intermediária entre duas explicações.	1/2, 1/4, 1/6 e 1/8

SAATY e MARIANO (1979) estabeleceram também um índice médio de consistência e a razão de consistência para avaliar o resultado das matrizes de pesos, com base em 500 (quinhentos) resultados aleatórios das ponderações. Eles obtiveram que uma razão de consistência (CR) igual ou inferior a 10% é muito boa,

ou seja, se  $CR < 0,10$ , a matriz de comparação paritária tem consistência aceitável e os pesos são válidos e podem ser utilizados. O índice de consistência (CI) e a razão de consistência (CR) são calculados conforme eq. (22) e eq. (23).

$$CI = \frac{\lambda_{max} - n}{n - 1} \quad (22)$$

Onde:

$\lambda_{max}$  = principal autovalor da matriz de julgamento;

n = ordem da matriz de julgamento.

$$CR = \frac{CI}{RI(n)} \quad (23)$$

Onde:

RI(n) = índice de consistência aleatória para matrizes de ordem n, que pode variar de acordo com o número de matrizes simuladas, mas aproximam-se aos resultados de SAATY (1997), apresentados na Tabela 3.

**Tabela 3 – Índices de consistência aleatória (RI)**

Fonte: SAATY (1997).

N	3	4	5	6	7	8	9	10
RI(n)	0,58	0,90	1,12	1,24	1,32	1,41	1,45	1,49

Outros índices de consistência foram propostos na literatura para não descarte de matrizes razoáveis e podem ser encontrados em ISHIZAKA e LABIB (2011), mas o índice apresentado permanece como mais adotado nos estudos. Caso seja detectado problema de consistência na matriz de julgamentos, faz-se necessário aprofundar as informações para nova rodada de decisões e/ou redefinição do problema.

Apesar da tomada de decisão via método AHP ser individual, o método pode ser utilizado para decisão em grupo. Nesses casos, há quatro formas principais para agregação da decisão: consenso sobre os julgamentos ou prioridades, utilização da média geométrica dos julgamentos ou utilização da média aritmética ponderada das prioridades (ISHIZAKA; LABIB, 2011). Nota-se que essas soluções possuem

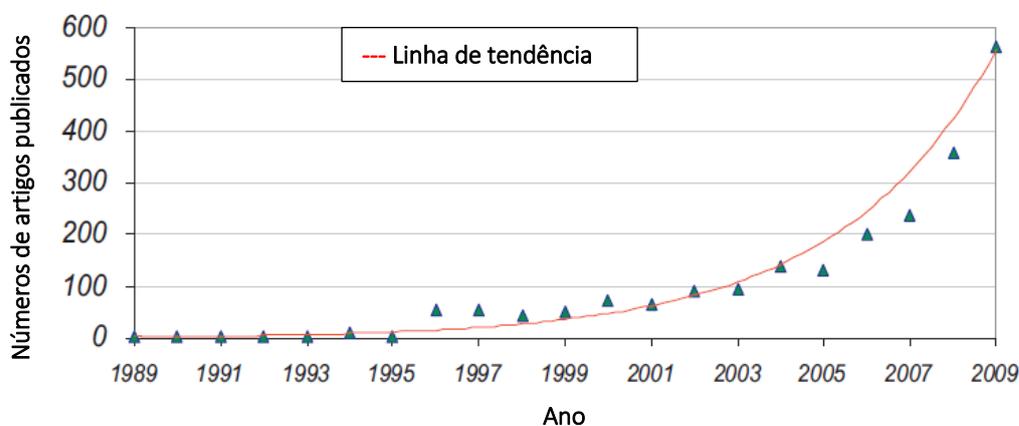
similaridade às propostas na estimação de parâmetros de medidas de desempenho, funções utilidade e funções valor (TVERSKY; KAHNEMAN, 1992, ABDELLAOUI *et al.*, 2008).

### 3.3.

#### Otimização em comercialização de energia eólica

A energia eólica não é despachável, nem de fácil previsão, como abordado na seção 3.1. Mesmo assim, é crescente o número de geradores eólicos, tornando-se imprescindível definir estratégias de comercialização adequadas para lidar com os incentivos e limitações desta fonte. Entre as estratégias frequentemente adotadas, encontram-se os modelos de otimização com base em simulações de geração eólica.

BAÑOS *et al.* (2011) revisam diversos métodos de otimização utilizados no gerenciamento e avaliação de projetos de energias renováveis. Apesar dos autores não abordarem diretamente a energia eólica, eles mostram a importância crescente do uso de métodos de otimização nesse contexto, conforme Figura 15, na qual não estão contabilizados estudos de revisão de literatura.



**Figura 15 – Número de artigos utilizando algoritmos de otimização aplicados a energias renováveis de 1989 a 2009**

Fonte: Traduzido de BAÑOS *et al.* (2011).

POURSINHO *et al.* (2011; 2012) propõem modelos de otimização estocástica para solução de problemas de comercialização de energia eólica em ambientes de incerteza. Eles apontam como principais causas de incerteza a volatilidade e intermitência da geração eólica e, a volatilidade dos preços de mercado, que, conjuntamente, resultam na volatilidade dos lucros dos geradores. Em ambos os

estudos, a função objetivo é a maximização do lucro do gerador eólico no mercado do dia seguinte. As incertezas de preços e geração eólica são modeladas através de cenários de realizações prováveis com probabilidades associadas a cada realização. Em ambos os estudos a otimização é processada com o pacote CPLEX do programa MatLab®, em computador com processador de 2GHz e 2GH de memória RAM.

Em POURSINHO *et al.* (2011), a função objetivo é similar ao ECP (eq. (15)), apresentado na seção 3.2.1 contudo, não existe o fator  $(I - \lambda)$  para ponderar o valor esperado do lucro, além de serem acrescidos os custos operacionais. O CVaR, assim como no ECP, é visto como medida de risco e o  $\lambda$  como parâmetro vinculado à aversão ao risco do tomador de decisão. O lucro esperado é maior se o gerador é neutro ao risco ( $\lambda = 0$ ), mas a volatilidade do lucro também é maior do que sob outros graus de aversão ao risco, sendo mínima para  $\lambda = 1$ . Portanto, um gerador avesso ao risco deve observar menor volatilidade de seus lucros. O horizonte do estudo é o dia seguinte dividido em 24 (vinte e quatro) horas, sendo gerados 10 (dez) cenários de preços e 10 (dez) de geração, totalizando 1.000 (um mil) cenários de realizações, cada um com 0,1% de probabilidade de ocorrência.

Em POURSINHO *et al.* (2012), a função objetivo é simplesmente a maximização do lucro esperado, mas com restrição de CVaR a fim de considerar a aversão ao risco. Nesse estudo, também, observa-se o horizonte do dia seguinte dividido em 24 (vinte e quatro) horas, contudo, são analisados dois casos. No primeiro caso, há incerteza de geração e preços de mercado, utilizando-se 100 (cem) cenários, enquanto no segundo caso é acrescida a incerteza de preços de ajuste, com utilização de 1.000 (um mil) cenários. A mesma função objetivo é utilizada em MORENO *et al.* (2012) para otimização da comercialização de energia eólica no dia seguinte, buscando redução dos riscos de negociação no mercado intradiário, considerando incertezas de geração eólica e preços nesse mercado. Os resultados do estudo de caso, processado em MatLab®, são avaliados para o período de março a dezembro de 2007, com horizontes de otimização de até 38 (trinta e oito) horas, sendo informados os volumes ótimos de negociação no mercado diário e intradiário. Contrariando o esperado, a inclusão de restrição de CVaR na função objetivo não foi capaz de reduzir as maiores perdas observadas quando da decisão ótima, pois a redução dos custos de diferenças no mercado intradiário não acarretou um aumento de receita.

Ainda assim, para MORENO *et al.* (2012), a incorporação de aversão ao risco no modelo é fundamental, pois os preços de venda no mercado de ajustes intradiários são limitados e os de compra, não, gerando assimetria nos resultados de ganhos e perdas para um mesmo volume de sobra ou déficit de energia. No Mercado de Curto Prazo no Brasil, conforme apresentado na seção 2.3, os preços também são limitados, porém há limitação de mínimo e máximo, além dos preços valerem igualmente para sobras ou déficits de energia. O único ponto de atenção é que os limites têm validade anual.

Em mercados diários de energia, apesar da estratégia comum de geradores eólicos de adotarem como volumes para negociação do dia seguinte aqueles resultantes de modelos de previsões de geração ou de modelos de maximização da utilidade esperada (otimização estocástica), ZUGNO *et al.* (2013) propõem a incorporação de restrições na otimização dos volumes a serem negociados. A argumentação é de que a prática mostra desvios significativos entre os valores previstos de geração eólica e os realizados, o que não é bem tolerado pelos operadores de sistemas elétricos. O modelo apresentado é um modelo geral de mercado, que considera a atitude perante os preços e a maximização dos lucros do mercado. O resultado das simulações mostrou ganhos da estratégia proposta, contudo, restrições na maximização da utilidade esperada também contribuem para redução do impacto dos erros de previsão sobre os lucros, no longo prazo.

No Brasil, AMARAL (2011) e FÂNZERES *et al.* (2012) modelaram a otimização conjunta da comercialização de energia de um parque eólico e de uma PCH, considerando a simulação integrada de cenários de geração eólica, vazão (*proxy* para geração hídrica) e PLD. Eles concluíram pela possibilidade de mitigação de riscos através da comercialização conjunta desse portfólio de geração eólica e hídrica. Em FÂNZERES *et al.* (2012), a função objetivo do problema baseia-se no ECP e em AMARAL (2011), no  $CVaR_{\alpha}$ . Em FÂNZERES *et al.* (2012) a simulação das incertezas de geração eólica e vazão é feita de modo a manter consistência com os cenários de PLD gerados pelo Newave®, para o período de um ano a frente, enquanto a otimização é processada por programação linear. AMARAL (2011) realiza a simulação de 2.000 (duas mil) séries para o horizonte de 5 (cinco) anos, também, em consistência com a simulação de PLD do Newave® e otimização por programação linear.

### 3.3.1. Simulação de Monte Carlo

Alguns trabalhos de otimização da comercialização de energia eólica foram apresentados, porém é vasto o número de estudos que tratam do assunto com predomínio do problema de otimização dos volumes de geração eólica declarados para o dia e gestão das diferenças no mercado intradiário.

Dentre esses trabalhos, é frequente a utilização de SMC – Simulação de Monte Carlo para modelagem da incerteza de geração eólica e preços, através de cenários. Posteriormente, a função objetivo do problema é otimizada, buscando-se a distribuição de probabilidades do resultado em cada um dos cenários simulados que melhor atenda ao objetivo.

A SMC é classificada como um método de simulação estatística, que gera simulações a partir de sequências de números aleatórios ou, dito de outro modo, um método numérico de solução de problemas por meio de aproximação, através de amostragem aleatória (ZABARAS; SANKARAN, 2007; SHONKWILER; MENDIVIL, 2009).

A formalização deste método foi realizada por METROPOLIS e ULAM (1949), a partir das reflexões de Ulam sobre as probabilidades de sucesso de determinada jogada. O nome do método é inspirado no cassino de Monte Carlo, cujo aspecto aleatório de jogos está intimamente relacionado ao mesmo.

Resumidamente, a SMC é uma técnica matemática computadorizada que possibilita levar em conta o risco em análises quantitativas e tomadas de decisão, sendo utilizada em diversas áreas, como: finanças; gerenciamento de projetos; energia; indústrias; engenharia; pesquisa e desenvolvimento; seguros; petróleo e gás; transportes; meio ambiente. Ela funciona do seguinte modo: (i) é feita a análise de risco por meio da construção de modelos de possíveis resultados, atribuindo-se distribuições de probabilidades a todos as variáveis de incerteza; (ii) são calculados os resultados repetidamente, cada vez com diferentes conjuntos de valores aleatórios gerados pelas funções de probabilidades; (iii) são produzidas distribuições de valores dos resultados possíveis.

As distribuições de probabilidade representam uma forma simples e realista de descrever incerteza em variáveis de análise de risco, podendo-se adotar distribuições conhecidas como Normal, LogNormal, Uniforme, Triangular ou

distribuições discretas, obtidas a partir da frequência de dados históricos ou semelhantes.

No caso de modelos autorregressivos, mencionados na seção 3.1, a distribuição de probabilidade dos erros (incerteza), geralmente, é a distribuição Normal, que é simétrica e representa muitos fenômenos naturais.

## 4

### **Modelagem estocástica da geração eólica: previsão e simulação**

No capítulo 1 mostrou-se o crescimento da geração eólica em nível global e sua participação na matriz energética brasileira, demonstrando-se a importância crescente dessa fonte e dos estudos sobre ela para o país. No capítulo 1 e na seção 3.1 discutiu-se a importância de previsibilidade da geração eólica futura, seja para fins de operação do sistema elétrico e dos parques, seja para fins comerciais, contudo, ressaltou-se a carência de estudos que contribuam para a comercialização de energia eólica no Brasil, dado o horizonte mensal da comercialização de energia no país.

De fato, há carência de estudos sobre a previsão e simulação de médias mensais de geração eólica, necessários para melhor gestão da comercialização de energia eólica no Brasil, bem como para o planejamento da operação energética do SIN. Ainda, sobre a previsão e simulação de médias mensais de geração eólica para horizontes anuais, na seção 3.1.3, revelou-se a possibilidade de influência de variáveis climáticas nessas previsões e simulações, com necessidade de estudos que corroborem ou não o incremento de capacidade preditiva de modelos que considerem essas variáveis.

Dentro desse contexto, tomando por base os dados de um parque eólico localizado no Ceará, que entrou em operação comercial em novembro de 2014, e tem toda a sua energia destinada ao ACL, este capítulo trata do primeiro objetivo intermediário desta tese, qual seja:

- ✓ especificar modelos adequados para previsão e simulação de Monte Carlo de médias mensais de geração eólica para o horizonte anual, verificando-se, também, a influência de fenômenos climáticos.

Portanto, busca-se, através de um estudo empírico, responder as seguintes questões:

- ✓ Como modelar a média mensal de geração eólica para horizonte anual e considerar a influência de fenômenos climáticos?
- ✓ Qual a relevância desses fenômenos na previsão e simulação da média mensal de geração eólica? Há outros fatores relevantes a serem considerados?

No capítulo 6, as simulações geradas são utilizadas em exemplos de otimização comercial do parque eólico abordado.

A partir do referencial teórico, restringiu-se a seleção de modelos aos modelos autorregressivos adequados para modelagem da média mensal de geração eólica, testando-se a incorporação de variáveis climáticas exógenas aos dados. O ajuste de modelos autorregressivos seguiu a metodologia de Box-Jenkins (BOX *et al.*, 2015). Os modelos elencados para ajuste a partir do referencial teórico, considerando a presença de sazonalidade na série, foram: SARMA, AR com 11 *dummies* sazonais e PAR. Todos os ajustes e cálculos dos modelos foram processados em R (R CORE TEAM, 2015).

Para avaliação e comparação dos modelos utilizaram-se as medidas de erro e critérios de informação presentes nas eq. (3) a eq. (7), bem como os testes de comparação de acurácia ou médias, apresentados na seção 3.1.1: teste de Diebold-Mariano (DIEBOLD; MARIANO, 1995; FRANCES; VAN DIJK, 2005); teste de Giacomini-White (GIACOMINI; WHITE, 2006); teste ANOVA, conforme GUO *et al.* (2011); teste de Turkey (TURKEY, 1953).

#### **4.1. Base de dados**

Os dados de velocidade dos ventos e geração eólica utilizados são referentes a um parque eólico localizado no Ceará, com 75,6 MW de capacidade instalada e 28 aerogeradores. O acesso aos dados do parque eólico em estudo deu-se no âmbito do Projeto de P&D da Aneel nº PD-0622-0213/2013.

Os dados de velocidade dos ventos são originários de duas fontes: (i) dados brutos, a cada 10 minutos, de uma torre anemométrica do parque, a 90 m, a partir de fevereiro de 2009; (ii) dados horários de reanálise do MERRA – *Modern Era-Retrospective Analysis for Research and Applications*, a 50 m, a partir de janeiro

de 1982. O período e forma de utilização de cada uma das séries de dados são explicitados na seção 4.1.1.

Os dados de reanálise do MERRA são concebidos e disponibilizados pela *NASA's Global Modeling and Assimilation Office* para atender a dois objetivos principais: colocar as observações dos satélites *NASA's Earth Observing System* no contexto climático; aperfeiçoar a representação do ciclo hidrológico em reanálises (RIENECKER *et al.*, 2011). De acordo com RIENECKER *et al.* (2011) e considerando o período de 1979 até o presente, o MERRA atingiu os seus objetivos com melhorias significativas na climatologia de precipitação e de vapor de água. SONDEREGGER (2011) não verificou diferenças ao se considerar dados de reanálise do MERRA ou de outras duas fontes para estimação de geração eólica na avaliação de projetos, contudo, há de se ressaltar que enquanto o MERRA fornece dados horários, as duas outras fontes abordadas pelo autor fornecem médias para cada seis horas.

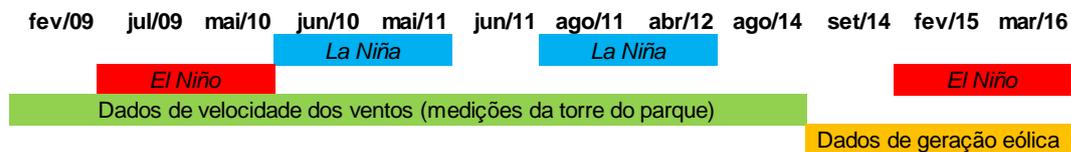
Os dados referentes a variáveis climáticas foram obtidos junto ao NCEP – *National Centers for Environmental Prediction*, lembrando-se que a localização do parque eólico afeta diretamente a seleção das variáveis climáticas e o referencial teórico voltou-se para as variáveis climáticas que afetam a velocidade dos ventos e, conseqüentemente, a geração eólica no Ceará.

#### 4.1.1.

##### **Série histórica de geração de energia eólica**

O parque eólico em estudo entrou em geração de teste em setembro de 2014 e, em geração comercial, em novembro de 2014, a partir de quando se tornaram disponíveis os dados reais de geração, tendo se iniciado neste período um *El Niño* (trimestre fevereiro-março-abril/2015) ainda em curso até o último mês de dados disponíveis (março/2016). O parque possui, também, dados de medição a cada 10 (dez) minutos da velocidade dos ventos para o período de fevereiro/2009 a agosto/2014, período durante o qual ocorreram um *El Niño* (trimestre junho-julho-agosto/2009 a março-abril-maio/2010) e duas *La Niña* (trimestre junho-julho-agosto/2010 a março-abril-maio/2011; trimestre agosto-setembro-outubro/2011 a fevereiro-março-abril/2012). Na Figura 16, observa-se melhor o período abrangido

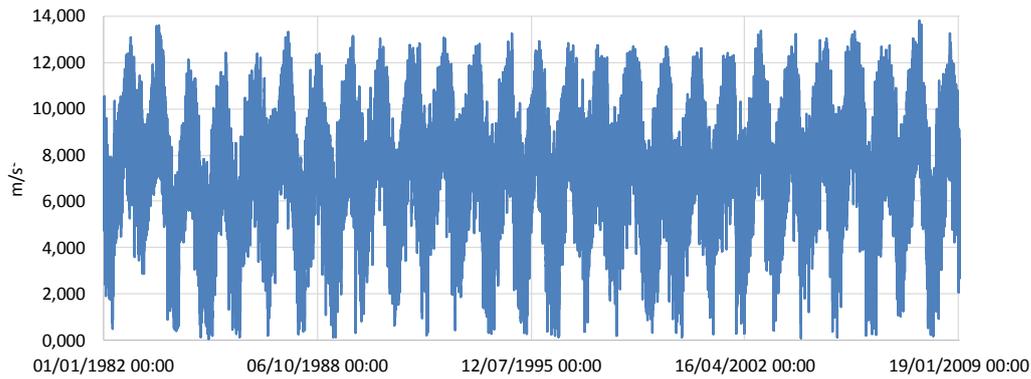
pelos dados de velocidade dos ventos e de geração eólica do parque em estudo, bem como a ocorrência de *El Niño* e *La Niña*, durante esses períodos.



**Figura 16 – Tipo de dados do parque eólico em estudo e ocorrência de *El Niño/La Niña* (fev/2009 a mar/2016)**

Como o objetivo do estudo é a previsão de médias mensais de geração para horizonte anual, mais especificamente, para o próximo ano, bem como testar a influência de variáveis climáticas, o histórico de dados reais do parque, que totaliza 7 (sete) anos, sendo um ano e meio de dados de geração (setembro/2014 a março/2016) e cinco anos e meio de dados de velocidade dos ventos (fevereiro/2009 a agosto/2014), pode ser considerado insuficiente para estimação de parâmetros. De fato, faz-se necessária a obtenção de um histórico estendido para ter-se um mínimo de dados com a ocorrência das diferentes configurações das variáveis climáticas apontadas no referencial teórico como capazes de influenciar a velocidade dos ventos na região e, conseqüentemente, a geração eólica. Essas variáveis são ENSO e Dipolo do Atlântico, cujas possíveis configurações são: *El Niño*, *La Niña* ou neutralidade para o ENSO; positivo, negativo ou neutro para o Dipolo do Atlântico.

Portanto, para ajuste e estimação de modelos autorregressivos, optou-se por estender a série medida de velocidade dos ventos com dados de reanálise. Após a análise de quatro séries de reanálise do MERRA, com medições horárias da velocidade dos ventos a 50 m de altura, em diferentes coordenadas geográficas mais próximas às do parque, a série escolhida foi a base de dados horária do MERRA, a 50 m de altura, com longitude -39,999 e latitude -3,500, ajustada para 90 m de altura (eq. (24)). O ajuste para 90 m de altura faz-se necessário em função da altura do rotor do gerador eólico, que é de 89m, e para manutenção da consistência com a série de dados de medição do parque eólico. As séries do MERRA foram extraídas para o período de janeiro/1982 a abril/2014, mas a série escolhida foi utilizada apenas para o período de janeiro/1982 a janeiro/2009 (Figura 17), como extensão à série de dados de velocidade dos ventos reais do parque eólico. A partir de fevereiro/2009, utilizou-se os dados do próprio parque eólico, conforme Figura 16.



**Figura 17 – Série do MERRA de velocidade horária do vento ajustada para 90 m (01/01/1982 a 31/01/2009)**

O período de fevereiro/2009 a abril/2014 foi considerado para escolha da série do MERRA, através de comparação dessa com a série de dados de medição de velocidade dos ventos do parque. Assim, a escolha da série do MERRA deu-se por apresentar melhor ajuste à média horária dos dados de medição do parque a 90 m de altura, no período de fevereiro/2009 a abril/2014, apresentando um  $R^2$  de 0,56 e correlação de 0,75 para base horária e,  $R^2$  de 0,96 e correlação de 0,98 para base mensal, sendo, também, a mesma série de referência do estudo de avaliação e certificação do parque. Na Figura 18 observa-se as médias mensais da velocidade dos ventos para série de dados de medição do parque a 90 m de altura e do MERRA, tanto a 50 m de altura, como após o ajuste para 90 m de altura. O ajuste da velocidade média do vento de 50 m para 90 m de altura, para cada horário, foi calculado pela equação do perfil vertical do vento (eq. (24)), conforme DONGMEI (2011) e LIRA *et al.* (2011), utilizando-se o expoente de perfil vertical do vento de 0,27 ( $\alpha = 0,27$ ), obtido no estudo de avaliação do parque e verificado como expoente médio entre as séries de vento medidas no parque para as alturas: 90 m, 57,2 m e 37,6 m.

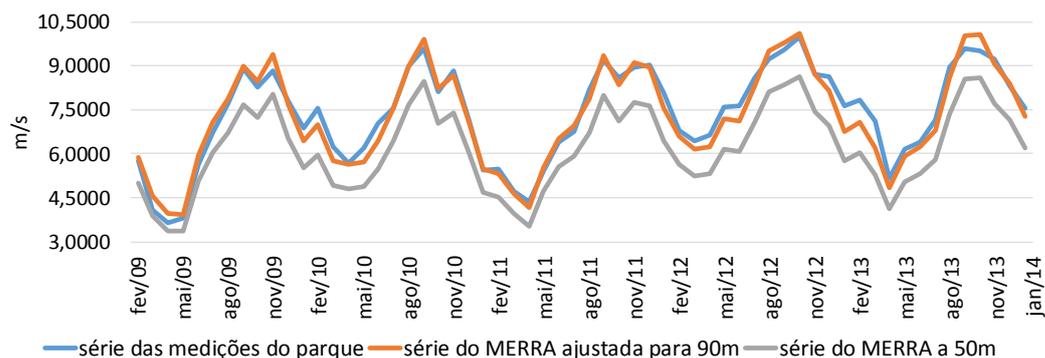
$$U_{h_1} = \left(\frac{h_1}{h_2}\right)^\alpha \times U_{h_2} \quad (24)$$

Onde:

$U_h$  = velocidade média do vento na altura  $h$  (m/s);

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

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



**Figura 18 – Média mensal da velocidade do vento: série das medições do parque a 90 m e do MERRA a 50 m e ajustada para 90 m (fevereiro/2009 a janeiro/2014)**

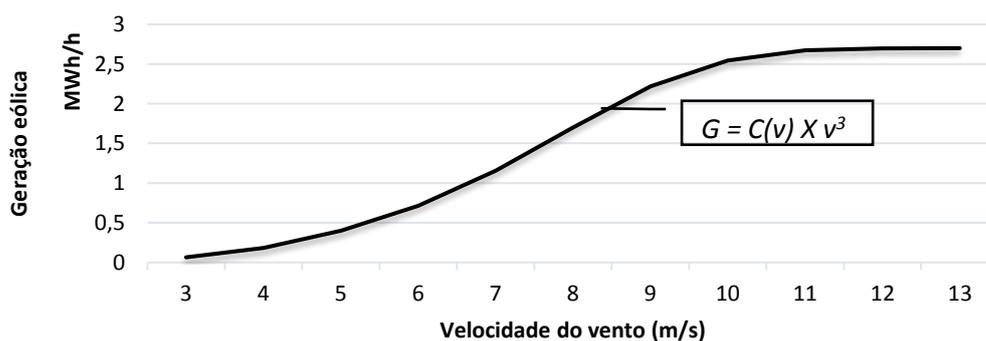
Inicialmente, os dados brutos medidos de velocidade dos ventos do parque, a cada dez minutos, para as alturas: 90 m, 57,2 m e 37,6 m, foram também analisados com o programa SPSS® e procedeu-se a complementação de dados faltosos de modo similar a LIRA *et al.* (2011). A função utilizada pelo programa SPSS® foi a *Automatic Multiple Imputation*, que utiliza regressão linear ou método de interação de simulação de Monte Carlo em Cadeias de Markov (MCMC) para complementação de dados, conforme as características de monotonicidade (IBM, 2016). A Tabela 4 apresenta o resumo dessa complementação.

**Tabela 4 – Série de velocidade dos ventos medida a 90 m com discretização de 10 minutos: complementação de dados**

Dados	Nº de dados	Média	Desvio-padrão	Mínimo	Máximo
Originais	255525	7,392570	2,5468241	0,380000	17,490000
Faltosos entrados	12501	6,284642	2,2469474	0,000064	15,024847
Completos	268026	7,340896	2,5443717	0,000064	17,490000

Após complementação da série de velocidade dos ventos medida do parque a 90 m e a cada 10 minutos, tomaram-se as médias horárias dessa série, a fim de manter coerência com a série de dados do MERRA, passando-se a ter uma série de velocidade de vento horária de 01/janeiro/1982 00:00 a 31/agosto/2014 23:00. Essa série horária foi composta, portanto: (i) pela série de velocidade dos ventos horária do MERRA, ajustada para 90 m, de 01/janeiro/1982 00:00 a 31/janeiro/2009 23:00; (ii) pela série da média horária da velocidade medida do parque a 90 m, de 01/fevereiro/2009 00:00 a 31/agosto/2014 23:00.

Uma vez obtida a série horária de velocidade dos ventos de 01/janeiro/1982 00:00 a 31/agosto/2014 23:00, aplicou-se a curva de potência do equipamento instalado no parque (Figura 19), para conversão do vento em geração eólica, seguindo a ideia de DONGMEI (2011), BROWN *et al.* (1984), KARKI *et al.* (2006) e CAPORIN e PRÉS (2012), obtendo-se a geração teórica de um aerogerador. O equipamento instalado no parque é um aerogerador Alstom ECO122 de 2,7 MW com 89 m de altura de rotor, constando em suas especificações técnicas a tabela de valores de velocidade do vento ( $v$ ) e geração eólica ( $G$ ) apresentados na Figura 19. A partir dos dados do equipamento, obteve-se a função multiplicadora ( $C(v)$ ), para completar a especificação da relação cúbica entre a velocidade do vento (m/s) e a geração eólica teórica do equipamento (MWh/h). Há de se mencionar que a aplicação direta da curva de potência à velocidade dos ventos para obtenção da geração eólica requer cautela, pois desconsidera a direção do vento, como bem menciona JUNG e BROADWATER (2014). No caso do parque sob estudo, contudo, observa-se constância da direção do vento, o que torna sua influência reduzida, especialmente, ao ter-se como interesse do estudo as médias mensais de geração. Por outro lado, o alerta de JUNG e BROADWATER (2014) corrobora com a necessidade da prévia conversão da velocidade dos ventos em média mensal de geração, a fim de transpassar problemas de não linearidade entre velocidade dos ventos e geração eólica.



**Figura 19 – Curva de potência do aerogerador**

Fonte: elaboração própria, a partir dos dados técnicos do aerogerador Alstom ECO122 de 2,7 MW com 89 m de altura de rotor.

Definições:  $G$  = geração eólica;  $v$  = velocidade do vento;  $C(v)$  = função multiplicadora das características locais e do equipamento.

Assim, uma vez obtida a geração teórica de um aerogerador, calculou-se a média mensal e multiplicou-se pelo número total de aerogeradores (28) e pelo fator de efeito esteira do parque calculado no estudo de certificação (0,89), obtendo-se a média mensal de geração teórica do parque de janeiro/1982 a agosto/2014. O efeito esteira busca reproduzir o fato da velocidade dos ventos não chegar igualmente a cada aerogerador, culminando em diferenças de geração individuais por aerogerador.

Por fim, no período de setembro/2014 a março/2016, tomou-se como média mensal de geração teórica do parque, a geração bruta observada (em MWh), dividida pela disponibilidade observada e pelo número de horas do mês. Em setembro/2014 e outubro/2014, em função da operação de teste do parque, foi realizado ajuste da geração considerando a velocidade dos ventos.

Na Figura 20 tem-se o resumo da construção da série final utilizada.

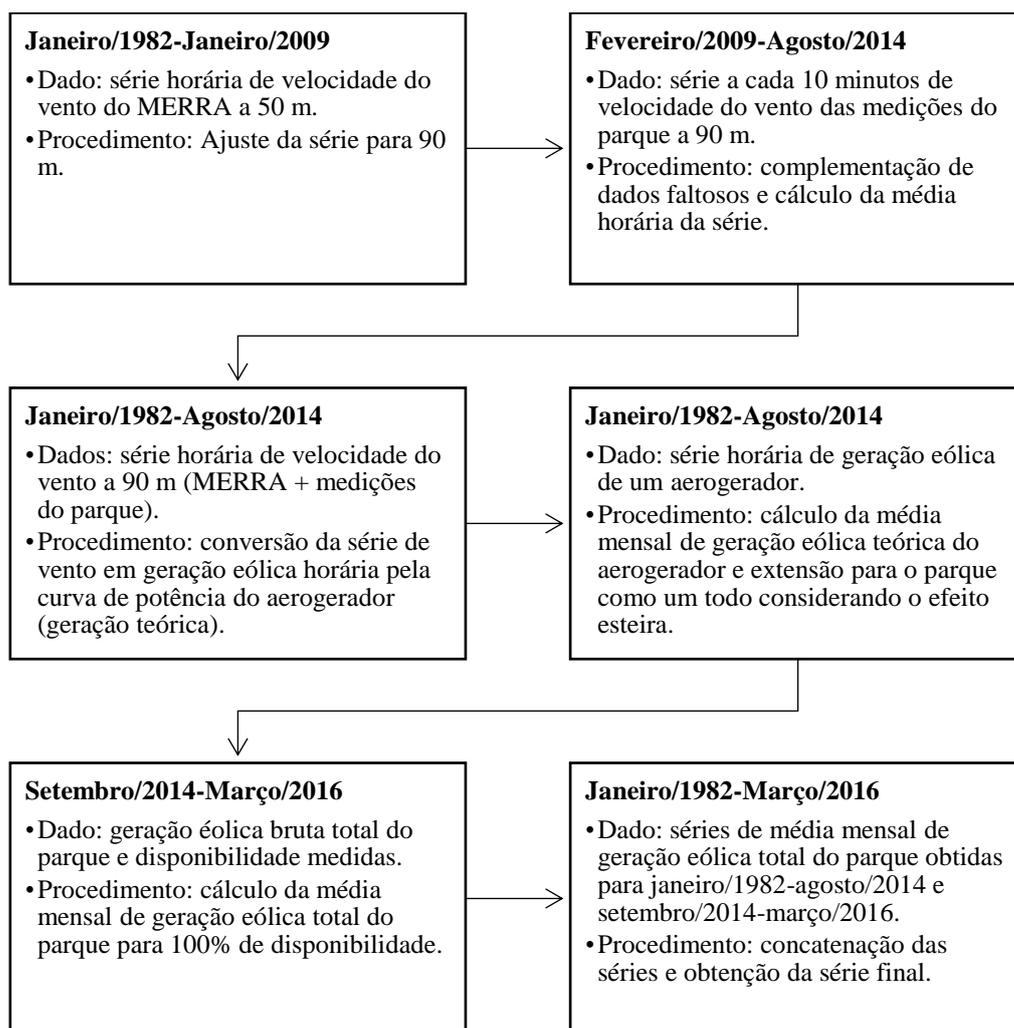
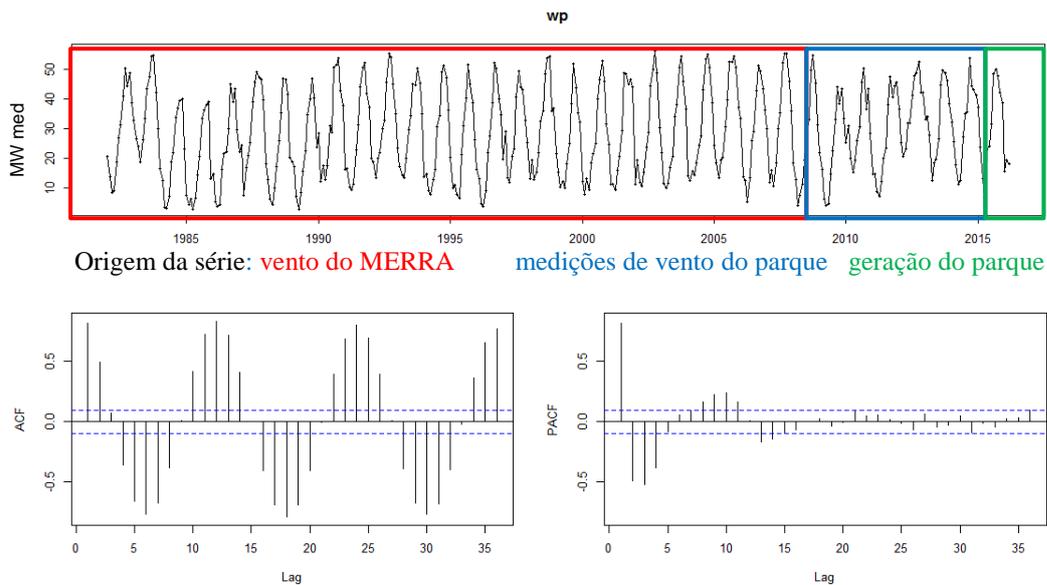


Figura 20 – Construção da série temporal final de média mensal de geração teórica do parque

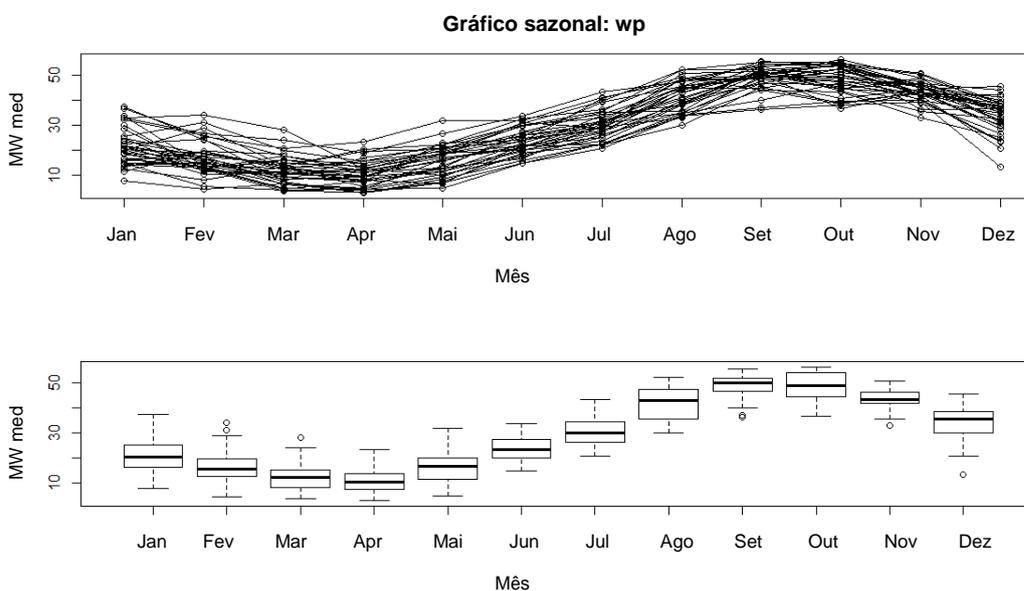
Na Figura resumiu-se a construção da série temporal final de média mensal de geração teórica do parque utilizada (denominada **wp** nos gráficos e equações). Essa série contém 411 observações e os valores estão MWmed, ou seja, média da geração de MWh por hora (MWh/h), e suas propriedades podem ser melhor observadas nas Figuras 21 a 23.



**Figura 21 – Série temporal de média mensal de geração eólica (jan/1982 a mar/2016) (acima) e funções de autocorrelação - ACF (à esquerda) e autocorrelação parcial - PACF (à direita)**

Na parte superior da Figura 21, observa-se a série temporal da média mensal de geração eólica e é notória a sua sazonalidade, bem como sua aparente estacionariedade. No canto esquerdo inferior da mesma figura, visualiza-se a função de autocorrelação (ACF), que reforça a sazonalidade a cada 12 períodos e, no canto direito inferior, observa-se a função de autocorrelação parcial (PACF) e a existência de autocorrelação até quatro períodos de defasagem. A estacionariedade da série foi confirmada pelo teste Dickey-Füller, que rejeitou a hipótese nula de existência de raiz unitária (série não estacionária) a 1% (p-valor inferior a 1%). Testou-se, também, a hipótese de não-linearidade da série e falhou-se em rejeitar as seguintes hipóteses nulas: (i) linearidade da média (teste de rede neural de Teraesvirta, p-valor de 0,51, e teste de rede neural de White, p-valor de 0,37); (ii) a série segue um processo autorregressivo AR (teste de um passo de não-linearidade de Keenan, p-valor de 0,96, e teste de não-linearidade de Tsay, p-valor de 0,39). Por estes quatro primeiros testes a linearidade da série mostra-se confirmada,

contudo, no teste da razão de verossimilhança para o limite de não-linearidade, a hipótese nula de que a série segue um processo autorregressivo AR foi rejeitada a 1% (p-valor inferior a 1%), diante da seguinte hipótese alternativa: a série segue um processo autorregressivo TAR. As Figuras 22 e 23 ajudam a visualizar a pretensa não linearidade da série e indicação de modelagem através de um modelo TAR, uma vez que é observada diferença da série ao separá-la por períodos (meses). Essas diferenças próprias da periodicidade (ou sazonalidade) da série podem relacionar-se indiretamente a valores limites (*thresholds*).

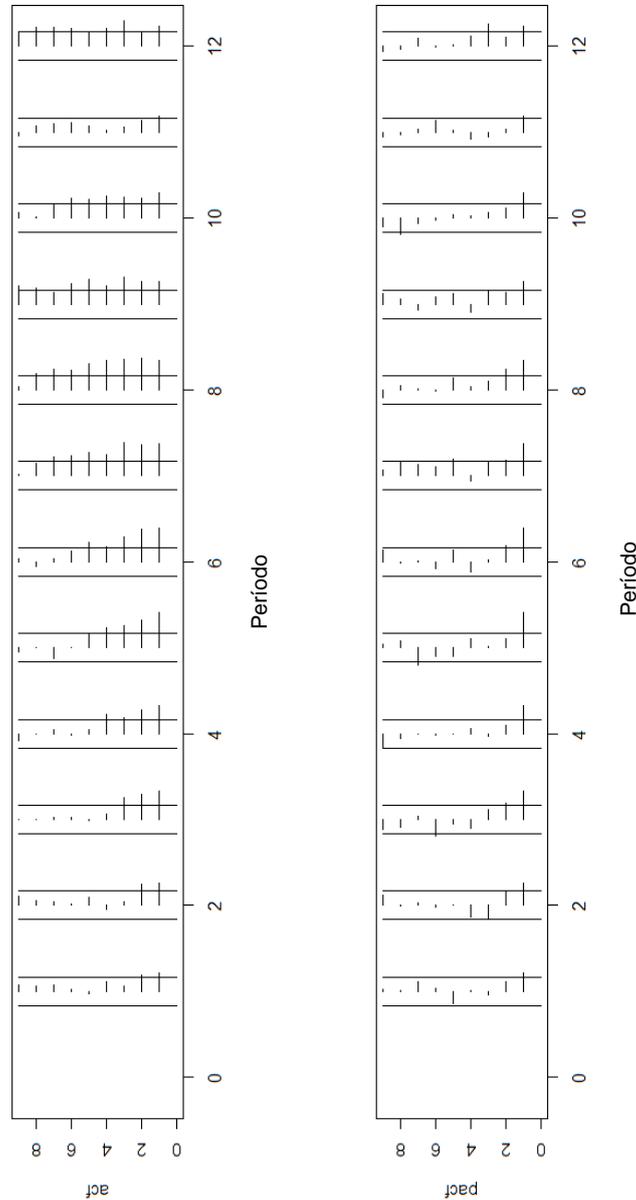


**Figura 22 – Série temporal periódica de média mensal de geração eólica (jan/1982 a mar/2016) (acima) e box-plot da série periódica (abaixo)**

Na parte superior da Figura 22, é apresentada a série temporal da média mensal de geração eólica por períodos (no caso, meses) para cada ano, entre 1982 e 2016, e, na parte inferior, é apresentado o gráfico *box-plot* para cada mês, considerando esses 34,25 anos de série. Em ambos os gráficos é evidente a sazonalidade da média mensal de geração eólica, com menor geração no primeiro semestre e maior no segundo. Nota-se, ainda, diferença de dispersão da geração em função dos meses, como pode ser visto com maior clareza nas Figuras 24 a 26.

Na Figura 23 tem-se, para cada período (mês), a função de autocorrelação (ACF) na parte superior e, na parte inferior, a função de autocorrelação parcial (PACF). Pela autocorrelação deixa-se de observar qualquer sazonalidade e pela autocorrelação parcial nota-se a existência de autocorrelação de um período de

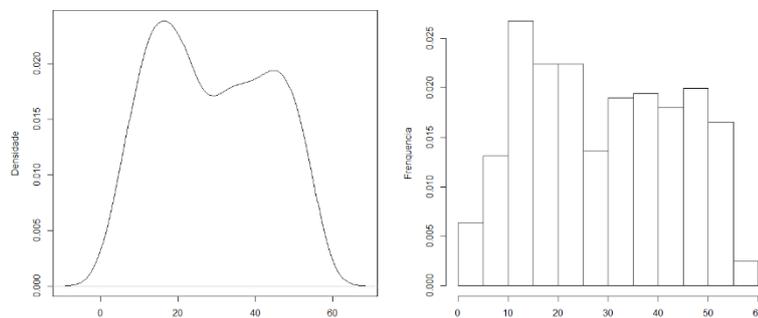
defasagem para os meses de janeiro a novembro e de três períodos de defasagem para dezembro.



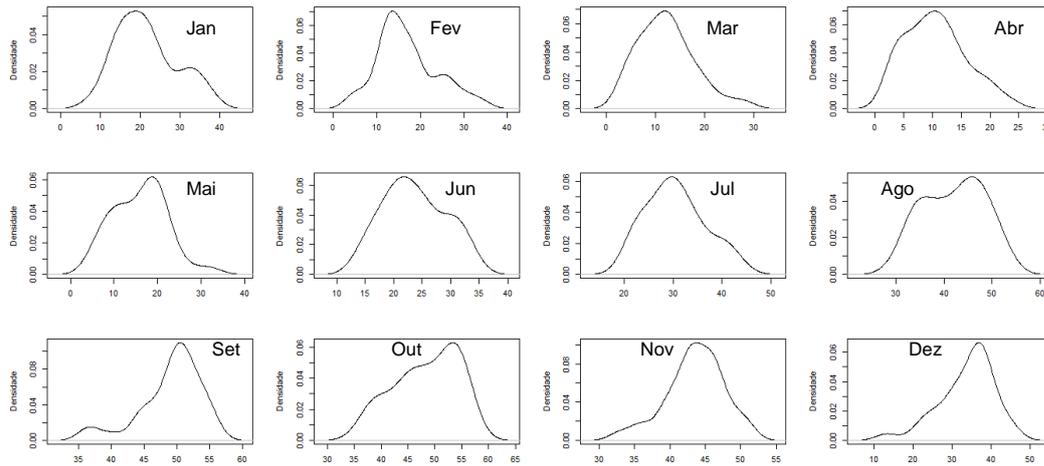
**Figura 23 – ACF (à esquerda) e PACF (à direita) periódicas da média mensal de geração eólica (jan/1982 a mar/2016)**

Com o intuito de melhor visualizar a aparente diferença de dispersão da geração a cada mês, as Figuras 24 a 26 apresentam, respectivamente, a densidade de probabilidade e histograma da série completa, as densidades de probabilidade da série para cada mês e os histogramas da série para cada mês. Nota-se que a função de densidade geral tem caudas grossas e dois picos, já que incorporam tanto o pico

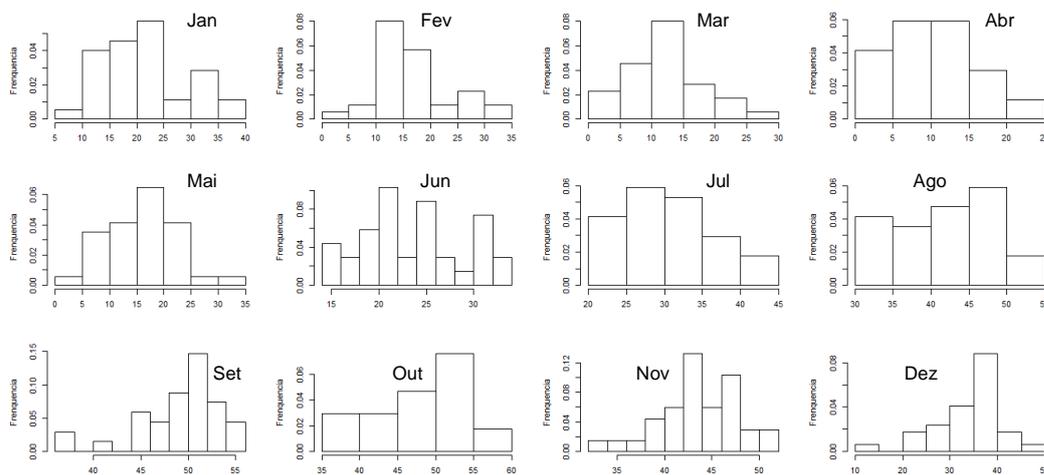
dos meses de maior geração quando o dos de menor geração, além de estender-se aproximadamente por um intervalo de 55 MW<sub>med</sub>. Olhando para os meses individualmente, o primeiro ponto que chama atenção é que enquanto a dispersão dos meses de dezembro a maio, exceto abril, estende-se por intervalo de aproximadamente 30 MW<sub>med</sub>, a dos meses de junho a novembro estende-se por um intervalo aproximado de apenas 20 MW<sub>med</sub>. Nota-se, também, diferenças nas características das caudas das distribuições, que são: mais grossas em abril, junho a agosto e outubro; mais finas à direita, de janeiro a março e em maio; mais finas à esquerda em setembro, novembro e dezembro. Essas diferenças sugerem que possa haver necessidade de especificação de diferentes modelos e/ou parametrizações para cada um dos meses ou conjunto de meses. De fato, a sazonalidade verificada nas Figuras 21 e 22 garante a necessidade de modelagem capaz de capturar as diferenças de médias mensais, contudo, as Figuras 23 a 26 sugerem que, além da sazonalidade da média mensal, possa haver variação da dispersão (volatilidade) dessas médias em função dos meses ou conjunto de meses.



**Figura 24 – Densidade de probabilidade ajustada (à esquerda) e histograma (à direita) da média mensal de geração eólica (jan/1982 a mar/2016)**



**Figura 25 – Densidade de probabilidade ajustada à média mensal de geração eólica (jan/1982 a mar/2016) por período (meses)**



**Figura 26 – Histograma da média mensal de geração eólica (jan/1982 a mar/2016) por período (meses)**

Nesta seção, foi apresentada a construção e características da série temporal de geração eólica tomada como base para ajuste e comparação de modelos de previsão e simulação de geração mensal de energia eólica na seção 4.2. De modo resumido, observou-se que a série é estacionária, possui sazonalidade mensal marcante e autocorrelação de um a quatro períodos de defasagem (*lag*). Além disso, sua linearidade é questionável e possui aparente diferença de volatilidade mensal em função da dispersão por períodos (meses).

#### 4.1.2. Séries históricas de variáveis climáticas

Uma vez visualizadas as características da série temporal a ser modelada, é interessante visualizar, também, os candidatos a variáveis exógenas a serem incorporados. A partir do referencial teórico, obteve-se que as ocorrências de *El Niño* e/ou Dipolo Positivo Atlântico estão associadas a condições favoráveis à velocidade dos ventos e desfavoráveis à precipitação no Ceará, enquanto as ocorrências de *La Niña* e/ou Dipolo Negativo do Atlântico estão associadas à condição inversa. Os estudos referenciam, ainda, que a influência do Dipolo é mais relevante no período chuvoso, isto é, de fevereiro a maio. Assim, as variáveis exógenas selecionadas e testadas foram:

- ✓ anomalia mensal de TSM na região do Niño 3.4, sob ocorrência de *El Niño* ou *La Niña* (denominada **ninoA** nesta tese);
- ✓ diferença da anomalia mensal de TSM entre o Atlântico Norte e o Atlântico Sul, sob ocorrência de Dipolo Positivo ou Negativo (denominada **dipA** nesta tese);
- ✓ *dummy* para ocorrência de *El Niño* a cada mês (denominada **nino** nesta tese);
- ✓ *dummy* para ocorrência de *La Niña* a cada mês (denominada **nina** nesta tese);
- ✓ *dummy* para ocorrência de Dipolo Positivo do Atlântico a cada mês (denominada **dipP** nesta tese);
- ✓ *dummy* para ocorrência de Dipolo Negativo do Atlântico a cada mês (denominada **dipN** nesta tese).

A **ninoA** é obtida quase diretamente do NCEP, tomando-se o valor da anomalia de TSM na região do Niño 3.4, utilizada para cálculo do ONI – *Oceanic Niño Index*, para os meses com ocorrência de *El Niño* ou *La Niña* e zero para os demais. Já a **nina** e **nino** foram definidas como 1 para o mês central de um trimestre com ocorrência de *La Niña* e *El Niño*, respectivamente, e 0 para os demais meses. Ao observar as anomalias trimestrais de TSM no Niño 3.4 a partir dos dados do NCEP, a ocorrência de *La Niña* é verificada nos trimestres azuis, enquanto a ocorrência de *El Niño* é identificada pelos trimestres vermelhos.

Para o Dipolo do Atlântico não há uma disponibilização direta do índice, portanto, o cálculo do **dipA** seguiu a ideia de ARAUJO JUNIOR (2014) e consta na eq. (25). A partir da eq. (25), definiu-se as *dummies* para Dipolo Positivo e Negativo do Atlântico nas eq. (26) e (27), respectivamente.

$$dipA = \begin{cases} Anom\ TSM\ AtlN - Anom\ TSM\ AtlS, & \text{se sinal}(Anom\ TSM\ AtlN) \\ & \neq \text{sinal}(Anom\ TSM\ AtlN) \\ 0, & \text{caso contrário} \end{cases} \quad (25)$$

$$dipP = \begin{cases} 1, & \text{se } Anom\ TSM\ AtlN > 0 \text{ e } Anom\ TSM\ AtlS < 0 \\ 0, & \text{caso contrário} \end{cases} \quad (26)$$

$$dipN = \begin{cases} 1, & \text{se } Anom\ TSM\ AtlN < 0 \text{ e } Anom\ TSM\ AtlS > 0 \\ 0, & \text{caso contrário} \end{cases} \quad (27)$$

Onde:

Anom TSM AtlN = anomalia de TSM no Atlântico Norte;

Anom TSM AtlS = anomalia de TSM no Atlântico Sul.

As séries de **dipA** e **ninoA** estão presentes na Figura 27, enquanto **nino**, **nina**, **dipP** e **dipN**, na Figura 28. Pela inspeção visual é possível notar redução da geração eólica, sobretudo, das gerações mínimas na presença de *La Niña* (**ninoA** < 0 ou **nina** = 1) e Dipolo Negativo do Atlântico (**dipA** < 0 ou **dipN** = 1), conforme destacado nas Figuras 27 e 28. De modo inverso, observa-se aumento das gerações mínimas na presença de *El Niño* (**ninoA** > 0 ou **nino** = 1) e Dipolo Positivo do Atlântico (**dipA** > 0 ou **dipP** = 1). Contudo, pela simples inspeção visual, há períodos em que não é tão evidente a influência desses fenômenos climáticos sobre a geração eólica, fazendo-se necessário a realização de testes para confirmar ou negar essa influência.

A vantagem de testar-se variáveis *dummies* climáticas reside no fato de ser mais usual e robusta a previsão de especialistas sobre a ocorrência ou não dos fenômenos climáticos (*El Niño*, *La Niña*, Dipolo Positivo e Dipolo Negativo do Atlântico) para horizontes futuros do que a previsão numérica das anomalias de

TSM. De qualquer modo, é possível obter previsões de TSM do Atlântico e Pacífico junto ao NOAA *Research* ([http://www.esrl.noaa.gov/psd/forecasts/sst\\_lim/](http://www.esrl.noaa.gov/psd/forecasts/sst_lim/)).

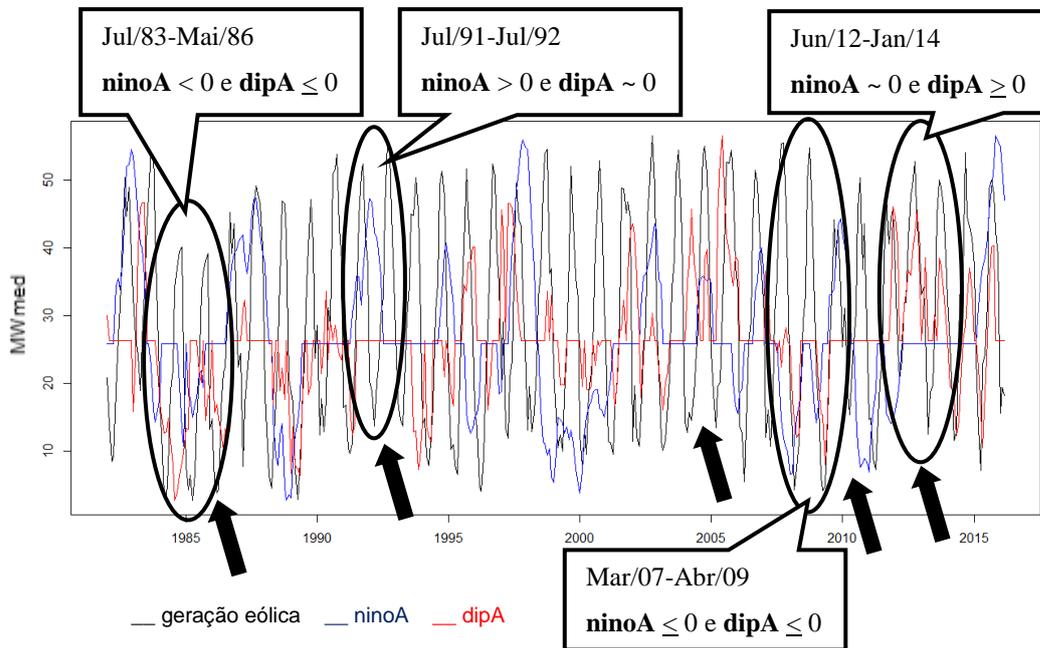


Figura 27 – Histórico de geração eólica (preto), ninoA (azul) e dipA (vermelho); valores do eixo-y referentes a geração eólica (MWmed)

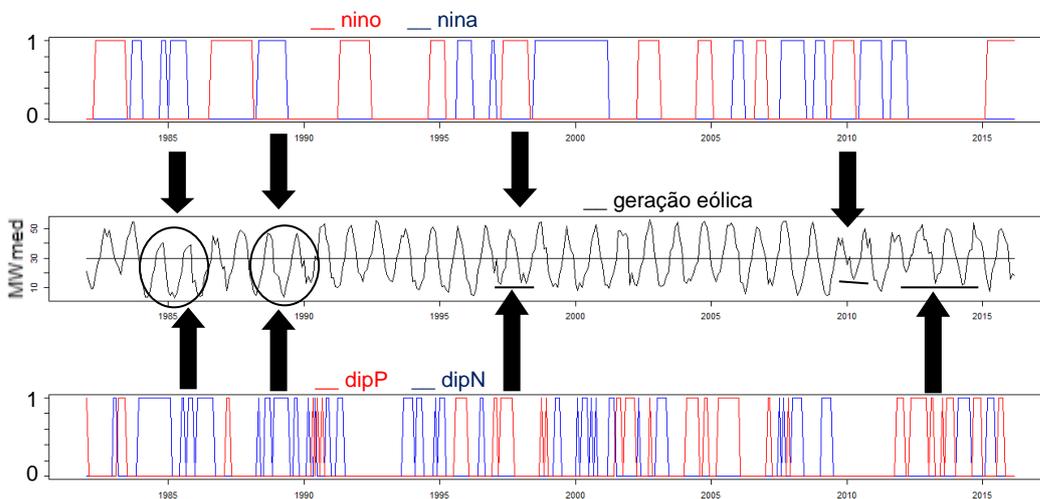


Figura 28 – Histórico de geração eólica (centro) e *dummies* climáticas: nino (vermelho, acima), nina (azul, acima), dipP (vermelho, abaixo) e dipN (azul, abaixo)

## 4.2. Comparação de modelos

Conforme mencionado, considerando a sazonalidade marcante da série, buscou-se, primeiramente, o ajuste de modelos SARMA, ARMA com 11 variáveis *dummies* para definição da sazonalidade (ARX-11) e PAR à série de geração eólica. A seleção da ordem do melhor modelo para cada tipo foi baseada nos critérios de informação, seguindo-se a metodologia de Box-Jenkins (BOX *et al.*, 2015) para ajuste e validação dos modelos, constando os resultados na seção 4.3, mais especificamente na Tabela 5.

Escolheu-se, então, o melhor modelo entre o SARMA e ARX-11 com base nos critérios de informação e medidas de erro presentes nas eq. (3) à eq. (7), para inclusão das variáveis climáticas como exógenas. Primeiramente, incluiu-se **ninoA** e **dipA** conjuntamente e, posteriormente, as quatro *dummies* conjuntamente. Observou-se, além dos critérios já mencionados e adequação do modelo, a significância dos parâmetros associados às variáveis climáticas. Testou-se, ainda, a consideração das variáveis exógenas apenas para determinados meses, conforme sugerido em OLIVEIRA e COSTA (2011). No caso, foram testados os períodos de fevereiro a maio e de dezembro a maio, correspondentes ao período chuvoso na região, logo, de menor geração, contudo, serão reportados, na seção 4.3, especificamente na Tabela 6, apenas os resultados referentes ao período de dezembro a maio, por terem sido mais significativos.

Não obstante os resultados dos 9 (nove) modelos apresentados na seção 4.3, vale mencionar que foram rodados cerca de 22 (vinte e dois) modelos, sendo 8 (oito) sem variáveis climáticas e 14 (quatorze) com, optando-se por apresentar nesta tese apenas os resultados mais significativos.

Testou-se, também, a existência de diferença estatística entre a acurácia dos melhores modelos, seguindo DIEBOLD e MARIANO (1995) e GIACOMINI e WHITE (2006).

Finalmente, foram simuladas 500 séries de média mensal de geração eólica para o horizonte de 21 meses, ou seja, até dezembro do próximo ano, utilizando-se os modelos sem e com variáveis climáticas, selecionados como modelos de referência. As séries foram simuladas a partir das equações obtidas para cada modelo (eq. (28) a eq. (30)), tomando-se erros aleatórios conforme a distribuição

Normal dos erros obtida para cada modelo, com auxílio da função *rnorm* do programa R (R CORE TEAM, 2015). A fim de manter coerência com a realidade, os valores simulados foram delimitados pelos mínimos e máximos históricos de geração.

### **4.3. Resultados e discussão**

Nesta seção, são apresentadas diversas tabelas e figuras referentes à comparação dos modelos ajustados. A Tabela 5 compara os resultados para os modelos SAR, ARMA (apenas como referência), ARX-11 sem variáveis climáticas e PAR. A primeira parte da tabela apresenta o p-valor dos testes de autocorrelação Ljung-Box para os resíduos e o quadrado dos resíduos (Ljung-Box<sup>2</sup>), bem como o teste de normalidade de Shapiro-Wilk. A hipótese nula do teste de Ljung-Box é a não existência de autocorrelação entre os resíduos, portanto, para um modelo bem ajustado, espera-se falhar em rejeitar a hipótese nula (p-valores elevados). No caso do Ljung-Box<sup>2</sup>, a hipótese nula é a não existência de autocorrelação entre o quadrado dos resíduos, cuja existência sugeriria a presença de heteroscedasticidade e necessidade de modelagem da volatilidade com modelos ARCH/GARCH. Mais uma vez, para um modelo bem ajustado, espera-se falhar em rejeitá-la (p-valores elevados). Já a hipótese nula do teste de Shapiro-Wilk é que os dados possuem distribuição Normal, portanto, para um modelo bem ajustado, deve-se falhar em rejeitá-la (p-valores elevados). A segunda parte da tabela apresenta os valores dos critérios de informação e as duas últimas partes apresentam, respectivamente, as medidas de erro calculadas para amostra completa (dentro da amostra) e para os últimos 24 (vinte e quatro) meses da série (fora da amostra). Tanto para os critérios de informação, quanto para os erros, quanto menores os valores, melhor o modelo.

Tabela 5 – Comparação de modelos autorregressivos sem variáveis climáticas

Modelo	Auto.Arima: SAR(3)(2)[12]	ARMA(8,2)	ARX(2)- 11	PAR(3)
<b>p-valor dos Testes</b>				
Ljung-Box (autocorrelação)	0,4713	0,3575	0,5295	0,9360
Ljung-Box <sup>2</sup> (autocorrelação <sup>2</sup> )	0,5169	0,6483	0,1469	0,5138
Shapiro-Wilk (normalidade)	0,5432	0,1526	0,4115	0,1191
<b>Crítérios de Informação</b>				
AIC	2601,73	2499,94	2448,07	<b><u>1238,53</u></b>
BIC	2629,86	2548,16	2508,35	<b><u>1254,57</u></b>
<b>Medidas de erro (dentro da amostra)</b>				
RMSE	5,50467	4,77683	4,59268	<b><u>4,28695</u></b>
MAE	4,38968	3,76571	3,59891	<b><u>3,28179</u></b>
MAPE	23,921%	19,430%	18,866%	<b><u>17,251%</u></b>
<b>Medidas de erro (fora da amostra)</b>				
RMSE	6,10446	<b><u>5,32720</u></b>	5,53329	5,42947
MAE	5,01025	4,25981	4,34023	<b><u>4,21314</u></b>
MAPE	25,657%	19,982%	18,698%	<b><u>17,823%</u></b>

A Tabela 6 é muito semelhante à Tabela 5, porém, como compara os modelos com variáveis climáticas, é acrescentada uma quinta parte sobre a significância dessas variáveis, assim, consta o p-valor do teste t para hipótese nula de que o coeficiente associado a cada uma das variáveis acrescentadas no modelo é nulo. Portanto, espera-se p-valores baixos, de modo a rejeitar a hipótese nula e confirmar a significância de cada variável exógena. Para sinalizar o uso das variáveis apenas no período de dezembro a maio foi utilizada a menção “(dez-mai)” após a sigla da variável. Apesar do modelo PAR(3) ter apresentado menores medidas de erros e de critérios de informação do que o modelo ARX(2)-11, optou-se por realizar a inclusão das variáveis climáticas neste, prezando-se pela parcimônia do modelo. Enquanto o modelo ARX(2)-11 possui 15 parâmetros e seriam incluídos mais 4 (quatro) em função das variáveis climáticas, o modelo PAR(3) já possui 60 parâmetros e, idealmente, seriam incluídos mais 48 (quarenta e oito) em função das variáveis climáticas, reduzindo-se extremamente os graus de liberdade do modelo.

Tabela 6 – Comparação de modelos autorregressivos com variáveis climáticas

Modelo	ARX(2)-13	ARX(2)-15	ARX(2)-15 (dez-mai)	ARX(2)-14 (dez-mai)	ARX(2)-13 (dez-mai)
<b>p-valor dos Testes</b>					
Ljung-Box (autocorrelação)	0,2767	0,3787	0,3519	0,3207	0,4077
Ljung-Box <sup>2</sup> (autocorrelação <sup>2</sup> )	0,2551	0,2977	0,3593	0,3267	0,2385
Shapiro-Wilk (normalidade)	0,3525	0,4797	0,7027	0,7152	0,4065
<b>Críticos de Informação</b>					
AIC	<b>2437,56</b>	2444,37	2439,75	2438,17	2438,82
BIC	<b>2505,87</b>	2520,72	2516,11	2510,51	2507,14
<b>Medidas de erro (dentro da amostra)</b>					
RMSE	4,51331	4,52848	<b>4,50292</b>	4,50515	4,54346
MAE	3,57881	3,57361	3,56702	<b>3,56568</b>	3,59552
MAPE	18,639%	18,761%	18,655%	<b>18,612%</b>	18,898%
<b>Medidas de erro (fora da amostra)</b>					
RMSE	5,55748	5,45300	<b>5,35669</b>	5,38251	5,47703
MAE	4,51019	4,31290	<b>4,11508</b>	4,12581	4,26440
MAPE	17,888%	18,347%	<b>17,789%</b>	17,855%	18,048%
<b>p-valor Relevância Variáveis</b>					
ninoA	0,08948	-	-	-	-
dipA	0,00028	-	-	-	-
nino	-	0,16748	0,12224	0,10041	-
nina	-	0,44913	0,51690	-	-
dipP	-	0,00857	-	-	-
dipN	-	0,13850	-	-	-
dipP (dez-mai)	-	-	0,00854	0,00876	0,01693
dipN (dez-mai)	-	-	0,02458	0,02348	0,03276

O primeiro modelo da Tabela 5, o SAR(3)(2)[12], foi obtido pelo ajuste automático da função Auto.Arima, do pacote *forecast*, do programa R (R CORE TEAM, 2015), contudo, mostrou-se inferior aos demais quanto aos critérios de informação e medidas de erros. O segundo modelo ARMA(8,2) foi o modelo sem sazonalidade explícita que obteve melhor ajuste, mas, também, mostrou-se inferior ao modelo ARX(2)-11, que obteve o melhor desempenho entre aqueles não-periódicos e sem variáveis climáticas, o que levou à sua seleção para inclusão das variáveis climáticas exógenas.

O modelo periódico PAR(3) foi ajustado como contraponto aos demais, na busca de uma melhor representação da diferença de volatilidade entre os meses, contudo, restou para um momento futuro a inclusão das variáveis climáticas nele. A ordem do modelo PAR foi escolhida com base: na seleção automática da ordem  $p$  para cada mês pelo programa R (R CORE TEAM, 2015); nos valores de AIC e

BIC gerais; na significância dos parâmetros para a maioria dos meses (Tabela 7). Na Tabela 7, um “x” assinalado no mês para cada linha  $p = n$ , com  $n$  de 1 a 3, significa que o coeficiente associado aquela defasagem  $n$  (*lag*) foi significativo a 5%. O PAR(1) foi rejeitado no teste de Ljung-Box. Conforme observado na Tabela 5, o modelo PAR(3) obteve melhor desempenho que o ARX(2)-11 em relação aos critérios de informação e medidas de erros. Para confirmar a adequabilidade da modelagem da série com o modelo PAR, executou-se o teste de periodicidade dos parâmetros do pacote *partsm* do programa R (R CORE TEAM, 2015). A hipótese nula é de que a série segue um processo  $AR(n)$  com sazonalidade, enquanto a hipótese alternativa é de que a série segue um processo  $PAR(n)$ . Para  $n = 2$ , a hipótese nula não foi rejeitada, contudo, para  $n = 3$ , foi rejeitada a 3%, o que sugere adequação tanto da modelagem da série com o ARX(2)-11 quanto com o PAR(3). Testou-se, ainda a presença de heteroscedasticidade na modelagem com PAR(3) e a mesma foi fortemente rejeitada ( $p$ -valor  $< 0,001$ ).

**Tabela 7 – Critérios de seleção da ordem p do modelo PAR**

Mês	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
Ordem <b>AIC</b>	2	4	6	1	1	2	8	5	1	1	12	3
Ordem <b>BIC</b>	1	2	2	1	1	1	2	2	1	1	1	3
<b>Sig. 5%</b>												
p=1	x	x	x	x	x	x	x	x	x	x	x	x
p=2		x	x			x	x	x				
p=3							x		x			x

A partir dos dados da Tabela 6, observou-se que a anomalia de TSM no *Niño* 3.4 (**ninoA**) foi significativa apenas a 10% e que a ocorrência de *La Niña* (**nina**) ou *El Niño* (**nino**) não foram significativas nem a 10%. A diferença de anomalia de TSM no Atlântico (**dipA**) foi extremamente significativa (a 1%), mas ao considerar a ocorrência dos Dipolos do Atlântico Positivo (**dipP**) e Negativo (**dipN**), apenas o dipP permaneceu significativo a 1% e o dipN deixou de ser significativo. Seguindo a literatura, restringiu-se a influência das variáveis exógenas representativas do Dipolo do Atlântico ao período entre dezembro e maio, o que tornou a variável **dipN** significativa a 5%, mantendo-se a significância do **dipP**, além de observar-se melhora das medidas de erro e dos critérios de informação. Independente da

significância dos parâmetros associados às variáveis climáticas, constatou-se que o sinal deles seguiu o esperado pela literatura, ou seja, positivo para **ninoA**, **dipA**, **nino** e **dipP** e, negativo para **nina** e **dipN**. Dentre os modelos com variáveis climáticas, os que apresentaram melhores medidas de desempenho foram:

- ✓ ARX(2)-13, ou seja, o modelo ARX(2)-11 apresentado anteriormente com inclusão das variáveis de anomalia de TSM na região do Niño 3.4 quando da ocorrência de *El Niño* ou *La Niña* e de diferença de anomalia de TSM no Atlântico;
- ✓ ARX(2)-15 (dez-mai), ou seja, o modelo ARX(2)-11 com inclusão de *dummy* de *El Niño*, *dummy* de *La Niña* e, *dummy* de Dipolo Positivo e *dummy* de Dipolo Negativo apenas nos meses de dezembro a maio;
- ✓ ARX(2)-14 (dez-mai), ou seja, o modelo ARX(2)-11 com inclusão de *dummy* de *El Niño* e, *dummy* de Dipolo Positivo e *dummy* de Dipolo Negativo apenas nos meses de dezembro a maio.

Para checar até que ponto as diferenças dos indicadores de desempenho dos modelos possuem significância estatística, realizou-se alguns testes de comparação paritária entre eles. Primeiramente, os modelos foram comparados dois a dois pelo teste de Diebold-Mariano (DIEBOLD; MARIANO, 1995) e Giacomini-White (GIACOMINI; WHITE, 2006) para o horizonte de 12 meses de previsão dentro da amostra e, excluído o modelo periódico PAR(3), observou-se maior acurácia dos modelos da classe ARX(2). Pelo teste de Diebold-Mariano, observou-se, ainda maior acurácia em relação ao modelo ARX(2)-11 dos seguintes modelos com variáveis climáticas: ARX(2)-13, ARX(2)-14 (dez-mai) e ARX(2)-15 (dez-mai), ao nível de significância de 5%.

Nas matrizes das Tabelas 8 e 9 estão os p-valores, respectivamente, do teste de Diebold-Mariano e de Giacomini-White, para previsão dentro da amostra dos modelos não-periódicos. A hipótese nula (H0) testada em ambos é: “O modelo da linha i possui igual acurácia ao modelo da coluna j.” e a hipótese alternativa (H1) é: “O modelo da linha i possui maior acurácia que o da coluna j.”. Portanto, para garantir que o modelo da linha i seja melhor que o da coluna j deve-se rejeitar a hipótese nula, ou seja, obter p-valores pequenos.

Tabela 8 – p-valores do teste Diebold-Mariano (H1: Acurácia do modelo da linha i é maior que a do modelo da coluna j)

p-valor Diebold-Mariano	SAR (3)(2) [12]	ARMA (8,2)	ARX (2)-11	ARX (2)-13	ARX (2)-15	ARX (2)-15 (dez-mai)	ARX (2)-14 (dez-mai)	ARX (2)-13 (dez-mai)
SAR(3)(2)[12]		0,9999	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000
ARMA(8,2)	<0,001		0,9984	0,9994	0,9993	0,9999	0,9999	0,9992
ARX(2)-11	<0,001	0,0016		0,9808	0,9347	0,9747	0,9723	0,8867
ARX(2)-13	<0,001	<0,001	0,0192		0,3222	0,5780	0,5610	0,1704
ARX(2)-15	<0,001	<0,001	0,0653	0,6778		0,7177	0,6971	0,0950
ARX(2)-15 (dez-mai)	<0,001	<0,001	0,0253	0,4220	0,2823		0,3317	0,1590
ARX(2)-14 (dez-mai)	<0,001	<0,001	0,0277	0,4390	0,3029	0,6683		0,1793
ARX(2)-13 (dez-mai)	<0,001	<0,001	0,1133	0,8296	0,9050	0,8207	0,8410	

Tabela 9 – p-valores do teste Giacomini-White (H1: Acurácia do modelo da linha i é maior que a do modelo da coluna j)

p-valor Giacomini-White	SAR (3)(2) [12]	ARMA (8,2)	ARX (2)-11	ARX (2)-13	ARX (2)-15	ARX (2)-15 (dez-mai)	ARX (2)-14 (dez-mai)	ARX (2)-13 (dez-mai)
SAR(3)(2)[12]		0,9999	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000
ARMA(8,2)	<0,001		0,9983	0,9986	0,9990	0,9990	0,9990	0,9981
ARX(2)-11	<0,001	0,0017		0,6759	0,7458	0,7602	0,7754	0,5432
ARX(2)-13	<0,001	0,0014	0,3241		0,5759	0,6297	0,6390	0,3000
ARX(2)-15	<0,001	0,0010	0,2542	0,4241		0,5801	0,5932	0,1199
ARX(2)-15 (dez-mai)	<0,001	0,0010	0,2398	0,3703	0,4199		0,5786	0,2187
ARX(2)-14 (dez-mai)	<0,001	<0,001	0,2245	0,3610	0,4069	0,4213		0,2036
ARX(2)-13 (dez-mai)	<0,001	0,0020	0,4567	0,6700	0,8801	0,7812	0,7963	

Na Tabela 10 estão os p-valores dos testes de Diebold-Mariano e Giacomini-White para acurácia do modelo PAR(3), em relação aos demais, considerando previsão dentro da amostra. Nota-se que a hipótese nula é rejeitada ao nível de significância de 1% para todos os modelos, confirmando a melhor acurácia do modelo PAR(3).

**Tabela 10 – p-valores dos testes de Diebold-Mariano e Giacomini-White para acurácia do modelo PAR(3) em relação aos demais (H1: Acurácia do modelo PAR(3) é maior que a do modelo da coluna j)**

p-valor Modelo PAR(3)	SAR (3)(2) [12]	AR MA (8,2)	ARX (2)-11	ARX (2)-13	ARX (2)-15	ARX (2)-15 (dez- mai)	ARX (2)-14 (dez- mai)	ARX (2)-13 (dez- mai)
<b>Diebol- Mariano</b>	<0,001	<0,001	<0,001	0,0144	0,0078	0,0105	0,0093	0,0022
<b>Giacomini- White</b>	<0,001	<0,001	<0,001	<0,001	<0,001	<0,001	<0,001	<0,001

Ao repetir esses mesmos testes para previsão fora da amostra, considerando o horizonte dos últimos 24 (vinte e quatro) meses da série, não foi possível confirmar, estatisticamente e com clareza, a superioridade entre os modelos. Contudo, pelo teste de Diebold-Mariano e esse horizonte de previsão fora da amostra, os modelos com a presença da variável climática **nino** (ARX(2)-15, ARX(2)-14 (dez-mai) e ARX(2)-15 (dez-mai)) apresentaram maior acurácia que o modelo ARX(2)-11, com p-valores < 0,001. Este resultado é importante, uma vez que nos últimos 13 (treze) desses 24 (vinte e quatro) meses, o fenômeno *El Niño* esteve presente.

Testou-se, ainda, a comparação das médias de geração eólica obtidas pelos modelos e a da série real por meio do teste ANOVA (GUO *et al.*, 2011). Para todos os modelos a hipótese de médias iguais não foi rejeitada. Em complementação, foi realizado o teste *post hoc* de Turkey (TURKEY, 1953), pelo qual não foi possível distinguir um modelo de outro, quando da comparação dois a dois, obtendo-se p-valores superiores a 0,9999 em todos os casos. No teste de Turkey a hipótese nula é de igualdade das médias.

A partir do exposto, foram tomados os seguintes três, entre os melhores modelos como referência para simulação de séries de médias mensais de geração eólica: ARX(2)-11, PAR(3), ARX(2)-15 (dez-mai). O ARX(2)-11 foi escolhido por ser o não-periódico e sem variáveis climáticas com melhor desempenho, o PAR(3) foi escolhido pelo melhor desempenho entre todos e o ARX(2)-15 (dez-mai) foi escolhido entre os com variáveis climáticas e melhor desempenho por considerar todos os fenômenos e, apenas, a ocorrência dos mesmos, cuja previsibilidade é mais confiável. Os parâmetros obtidos com ajuste dos modelos de referência à série da média mensal de geração eólica de janeiro/1982 a março/2016 estão presentes nas

eq. (28) à eq. (30). Os parâmetros informados para distribuição Normal dos erros são média e desvio-padrão.

## ARX(2)-11

$$\begin{aligned}
 wp_j = & 9,9593 + 0,4196 \times (wp_{j-1} - \alpha_{m-1}) + 0,2855 \times (wp_{j-2} - \alpha_{m-2}) \\
 & - 12,1803Jan - 16,7184Fev - 21,5503Mar - 23,1121Abr \\
 & - 17,8009Mai - 10,0542Jun - 3,2231Jul + 8,2970Ago \\
 & + 15,3556Set + 14,6030Out + 9,7477Nov \\
 & + \varepsilon_j; \varepsilon_j \sim N(0; 4,5924)
 \end{aligned}
 \tag{28}$$

Onde:

$wp_j$  = média mensal de geração eólica do parque no mês  $j$ ;

Jan ... Nov = 1, para o mês correspondente a  $j$  e 0, para os demais (o mês igual a 1 é considerado o mês  $m$ );

$\alpha_n$  = coeficiente associado ao mês  $n$  (Jan ... Nov);

$\varepsilon_j$  = erro do modelo no mês  $j$ .

## PAR(3)

$$\begin{aligned}
 wp_j^m = & \mu_m + \sigma_m \left[ \varphi_1^m \left( \frac{wp_{j-1} - \mu_{m-1}}{\sigma_{m-1}} \right) + \varphi_2^m \left( \frac{wp_{j-2} - \mu_{m-2}}{\sigma_{m-2}} \right) \right. \\
 & \left. + \varphi_3^m \left( \frac{wp_{j-3} - \mu_{m-3}}{\sigma_{m-3}} \right) \right] + \varepsilon_j^m; \varepsilon_j^m \sim N(0; \sigma_m)
 \end{aligned}
 \tag{29}$$

Onde:

$wp_j^m$  = média mensal de geração eólica do parque no mês  $j$ , com  $j$  no período  $m$ ;

$wp_j$  = média mensal de geração eólica do parque no mês  $j$ ;

$\mu_m$  = média mensal de geração eólica para o período  $m$ ;

$\sigma_m$  = desvio-padrão da distribuição Normal dos erros para o período  $m$ ;

$\varphi_i^m$  = parâmetro do modelo PAR(3) para o período  $m$ , associado a defasem (*lag*)  $i$ ;

$\varepsilon_j^m$  = erro do modelo no mês  $j$ , com  $j$  no período  $m$ .

Tabela 11 – Parâmetros do modelo PAR(3) para cada período m

Período (m)	$\mu_m$	$\sigma_m$	$\phi_1$	$\phi_2$	$\phi_3$
Jan	21,5813	6,5562	0,3889	0,4664	-0,1164
Fev	17,0461	5,2151	0,4091	0,4307	-0,4681
Mar	12,2174	3,8163	0,3395	0,2215	0,1573
Abr	10,5637	3,8192	0,5130	0,1558	-0,0433
Mai	15,8817	3,4139	0,8010	0,1624	0,0255
Jun	23,6566	3,0803	0,3855	0,3804	0,0412
Jul	30,5024	3,3889	0,3659	0,1748	0,4204
Ago	42,0382	3,7793	0,2121	0,4911	0,2348
Set	49,1087	3,5458	0,0642	0,1015	0,3941
Out	48,3610	4,4078	0,5683	0,1301	0,1421
Nov	43,5216	3,6566	0,2437	0,1079	-0,0759
Dez	33,7936	5,0050	0,6036	-0,1646	0,8683

ARX(2)-15 (dez-mai)

$$\begin{aligned}
wp_j = & 11,0925 + 0,3932 \times (wp_{j-1} - \alpha_{m-1} - \alpha c_{m-1}) + 0,2735 \\
& \times (wp_{j-2} - \alpha_{m-2} - \alpha c_{m-2}) - 11,9206Jan - 16,2334Fev \\
& - 21,0238Mar - 22,4411Abr - 17,1687Mai - 9,8457Jun \\
& - 2,9951Jul + 8,5018Ago + 15,5267Set + 14,7740Out \\
& + 9,9448Nov + 1,4297nino - 0,5758nina + 2,3197dipP \\
& - 1,8602dipN + \varepsilon_j; \varepsilon_j \sim N(0; 4,5033)
\end{aligned}
\tag{30}$$

Onde:

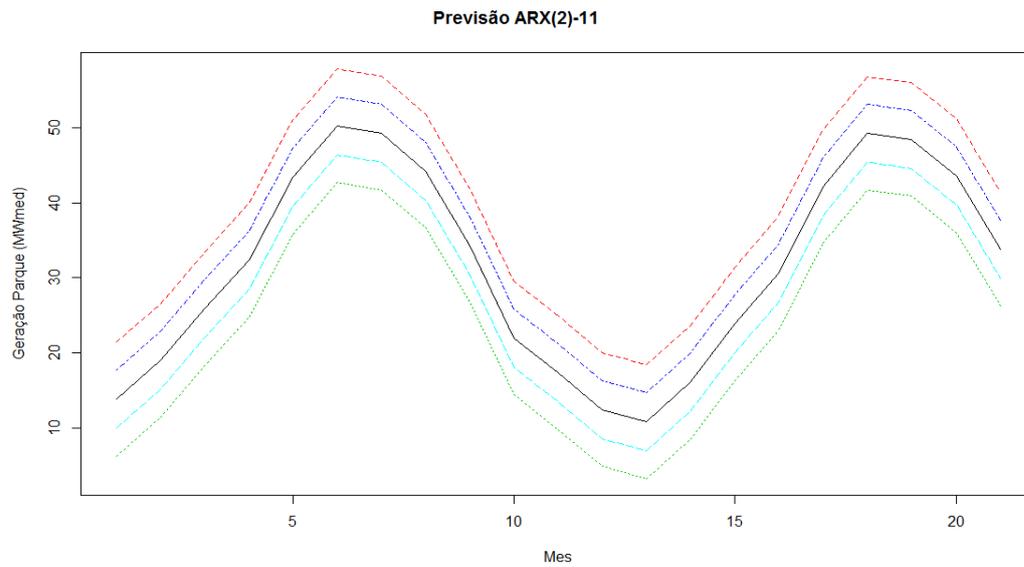
 $wp_j$  = média mensal de geração eólica do parque no mês j;

Jan ... Nov = 1, para o mês correspondente a j e 0, para os demais (o mês igual a 1 é considerado o mês m);

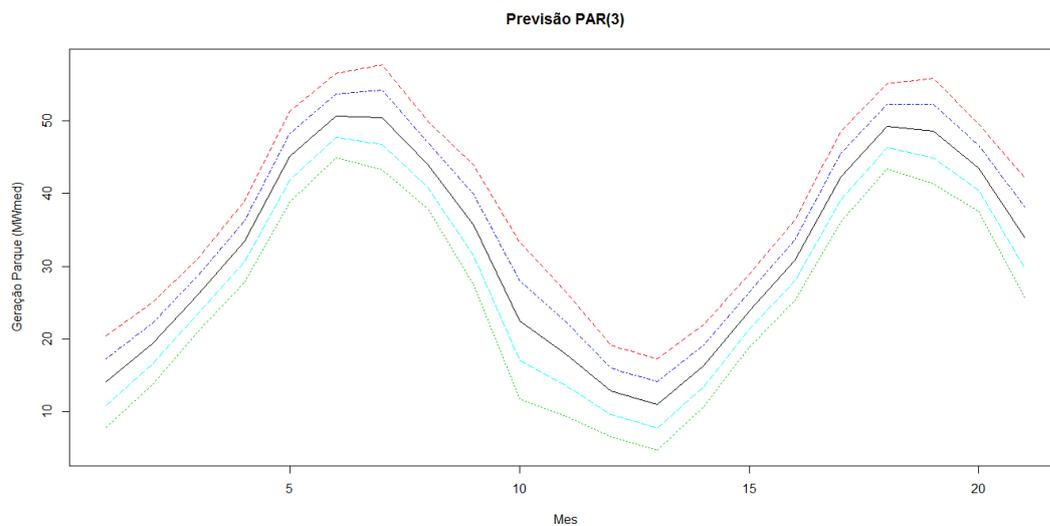
 $\alpha_n$  = coeficiente associado ao mês n (Jan ... Nov); $\alpha c_n$  = coeficiente(s) associado(s) à(s) variáveis climáticas ocorridas no mês n (Jan ... Nov); $\varepsilon_j$  = erro do modelo no mês j.

Para ilustrar as diferenças de comportamento entre os três modelos de referência, as Figuras 29 a 31 mostram a previsão de cada um para os próximos 21 (vinte e um meses), ou seja, abril/2016 a dezembro/2017, bem como os intervalos de confiança de 80% e 95% para as previsões. No caso do modelo ARX(2)-15 (dez-

mai), é necessário informar a expectativa de ocorrência dos fenômenos climáticos, então, seguindo as informações dos centros de pesquisa meteorológicas, foram considerados os valores da Tabela 12 para as *dummies* de fenômenos climáticos. Posteriormente, as Figuras 32 a 34 mostram o resultado de 500 (quinhentas) simulações com cada um dos modelos para o mesmo horizonte. As simulações foram realizadas de modo encadeado, mês a mês, com sorteio aleatório dos erros para cada mês do horizonte.



**Figura 29 – Previsão da média mensal de geração eólica de abril/2016 a dezembro/2017 e intervalos de confiança de 95% e 80%, com modelo ARX(2)-11**



**Figura 30 – Previsão da média mensal de geração eólica de abril/2016 a dezembro/2017 e intervalos de confiança de 95% e 80%, com modelo PAR(3)**

Tabela 12 – Valores das variáveis climáticas para previsão e simulação

Mês/Variável	nino	nina	dipP	dipN
Abr/16	1	0	0	0
Mai/16	1	0	1	0
Jun/16	0	0	1	0
Jul/16	0	0	1	0
Ago/16	0	0	1	0
Set/16	0	0	1	0
Out/16	0	0	1	0
Nov/16	0	0	0	0
Dez/16	0	1	0	0
Jan/17	0	1	0	0
Fev/17	0	1	0	1
Mar/17	0	1	0	1
Abr/17	0	1	0	1
Mai/17	0	1	0	1
Jun/17	0	1	0	0
Jul/17	0	1	0	0
Ago/17	0	1	0	0
Set/17	0	1	0	0
Out1/17	0	1	0	0
Nov/17	0	1	0	0
Dez/17	0	1	0	0

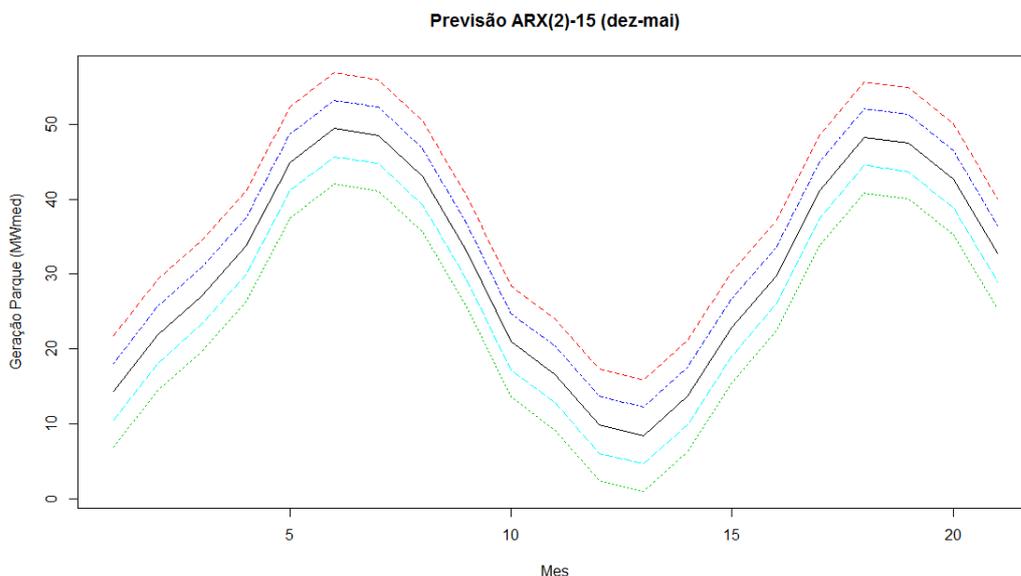
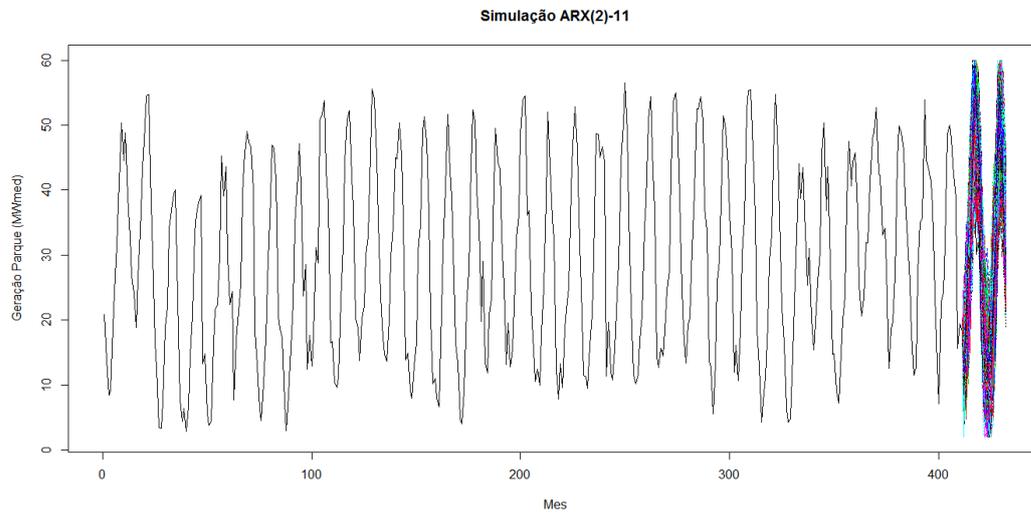


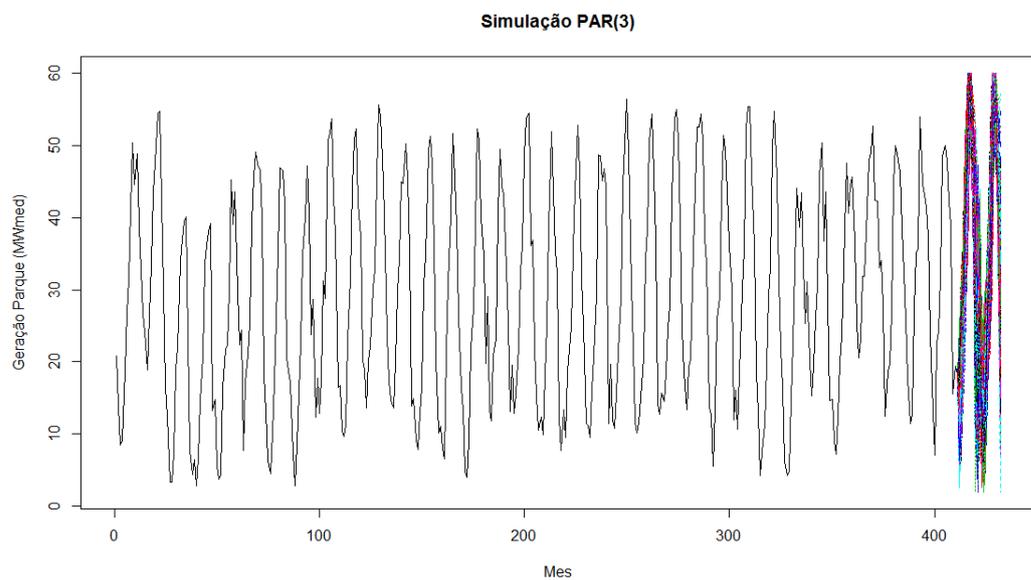
Figura 31 – Previsão da média mensal de geração eólica de abril/2016 a dezembro/2017 e intervalos de confiança de 95% e 80%, com modelo ARX(2)-15 (dez-mai), considerando *El Niño* (abr/16-mai/16), *La Niña* (dez/16-dez/17), Dipolo Positivo (mai/16-out/16) e Dipolo Negativo (fev/17-mai/17)

Nas simulações, para correção de viés dos modelos e manutenção de coerência com a realidade, fez-se necessária a inclusão de limites de máxima e mínima média mensal de geração possível, a fim de evitar a ocorrência de valores de médias mensais de geração fora dos limites de realizações reais viáveis. Foram

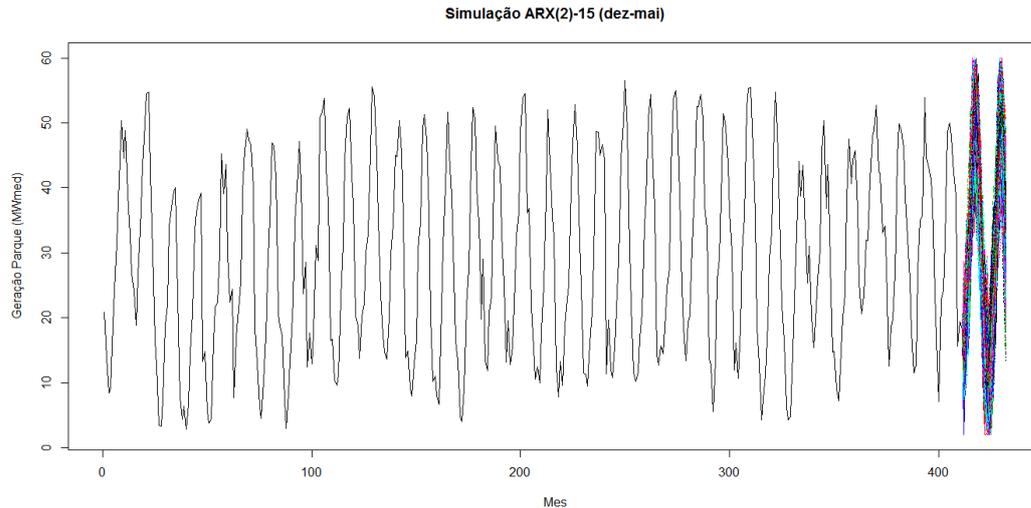
considerados como limite mínimo 2 (dois) MWmed e máximo, 60 (sessenta) MWmed, com base no histórico observado e na capacidade de geração do parque. Ao observar os gráficos de simulação nas Figuras 32 a 34, nota-se o efeito da diferença de volatilidade no modelo PAR(3).



**Figura 32 – Simulação de 500 séries da média mensal de geração eólica de abril/2016 a dezembro/2017, com modelo ARX(2)-11**



**Figura 33 – Simulação de 500 séries da média mensal de geração eólica de abril/2016 a dezembro/2017, com modelo PAR(3)**



**Figura 34 – Simulação de 500 séries da média mensal de geração eólica de abril/2016 a dezembro/2017, com modelo ARX(2)-15 (dez-mai), considerando *El Niño* (abr/16-mai/16), *La Niña* (dez/16-dez/17), Dipolo Positivo (mai/16-out/16) e Dipolo Negativo (fev/17-mai/17)**

Na Figura 35 são apresentadas estatísticas básicas das simulações por mês e observa-se pouca divergência entre os modelos ARX(2), o que já era esperado, dado que a diferença básica dos modelos é o acréscimo ou dedução de geração em função das variáveis climáticas. Outro ponto que chama atenção, na Figura 35, é uma aparente tendência a valores mais altos de geração pelo modelo PAR(3) e mais baixos pelos modelos ARX(2), à exceção dos meses de janeiro e dezembro, para quais também se observa valores de desvio-padrão (*proxy* de volatilidade) mais elevados pelo modelo PAR(3).

Uma última comparação entre os modelos de referência é apresentada nas Figuras 36 a 38, que trazem a previsão fora da amostra de cada um dos três, para os últimos 24 (vinte e quatro) meses do histórico. Não é possível notar grande diferença entre os modelos, contudo, os desvios do PAR(3) parecem levemente menores. Para os três modelos, os maiores erros concentram-se no entorno do mês 10 (dezembro/2015), ou seja, no período chuvoso de 2015-2016.

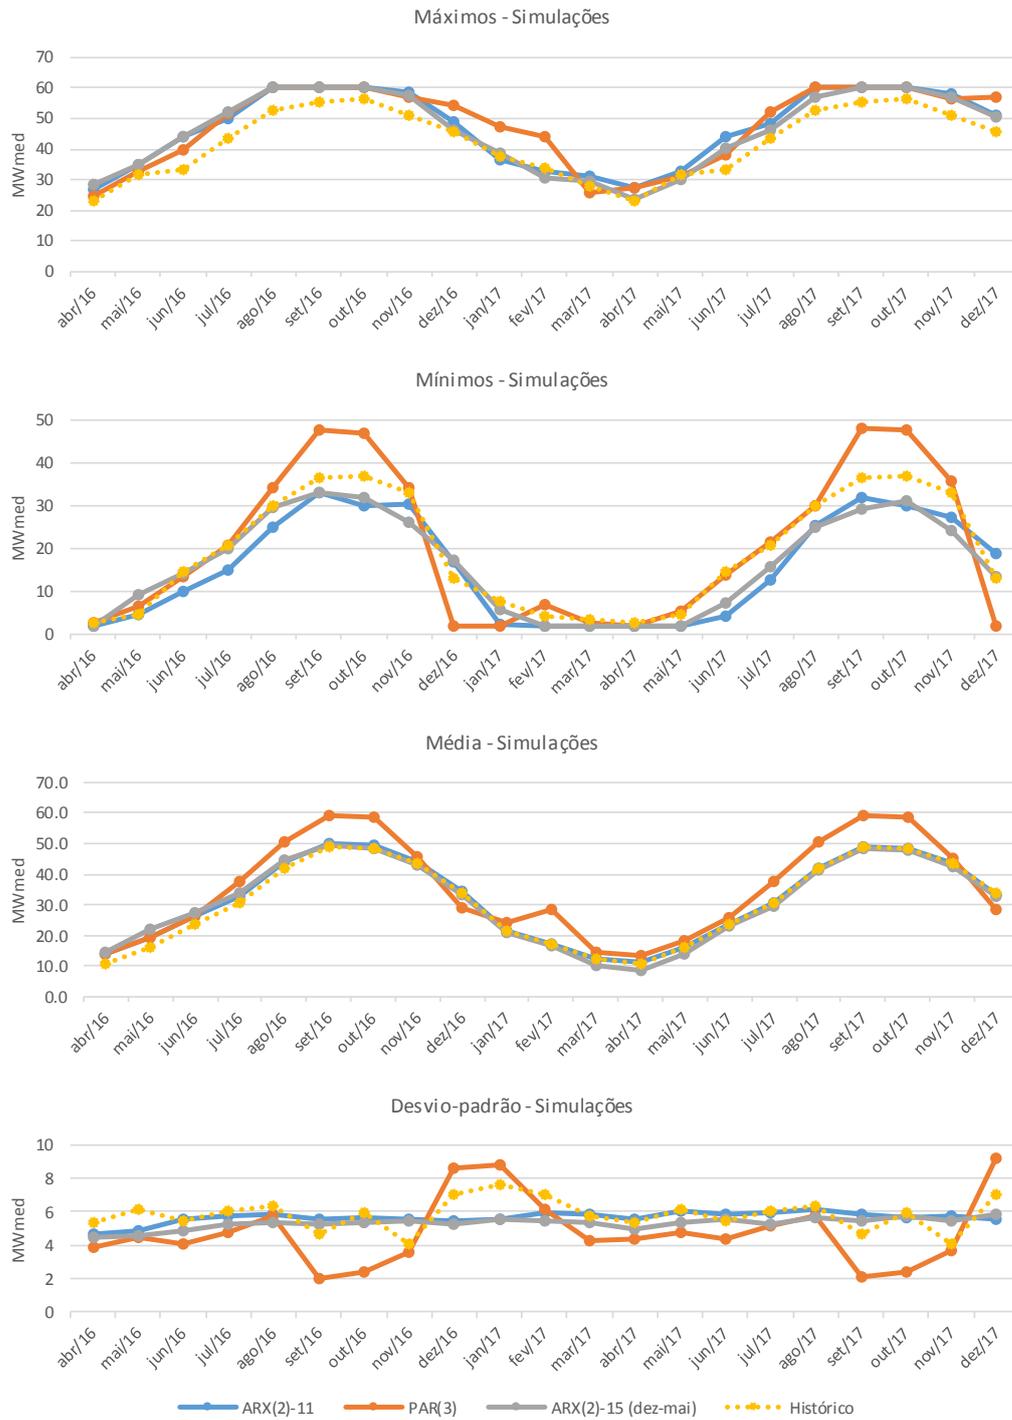
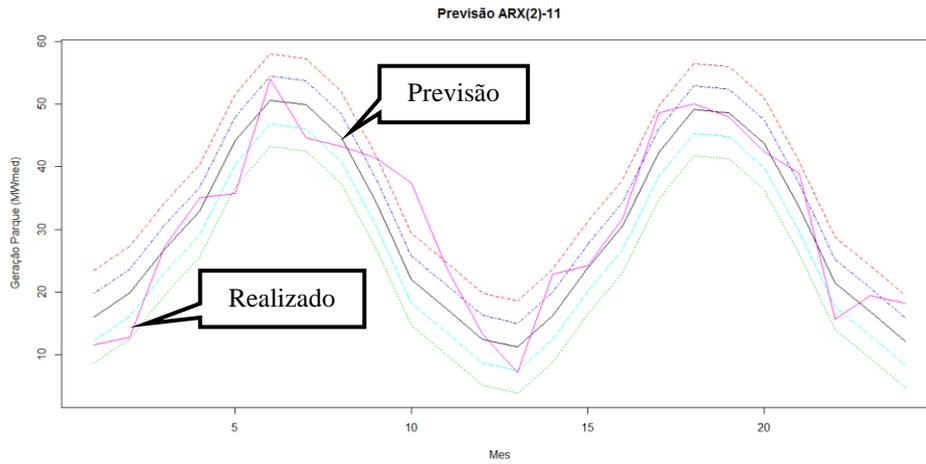
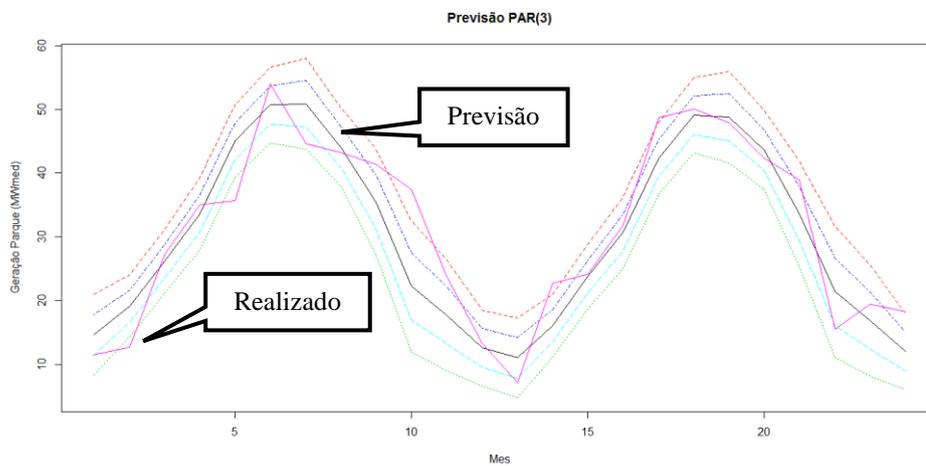


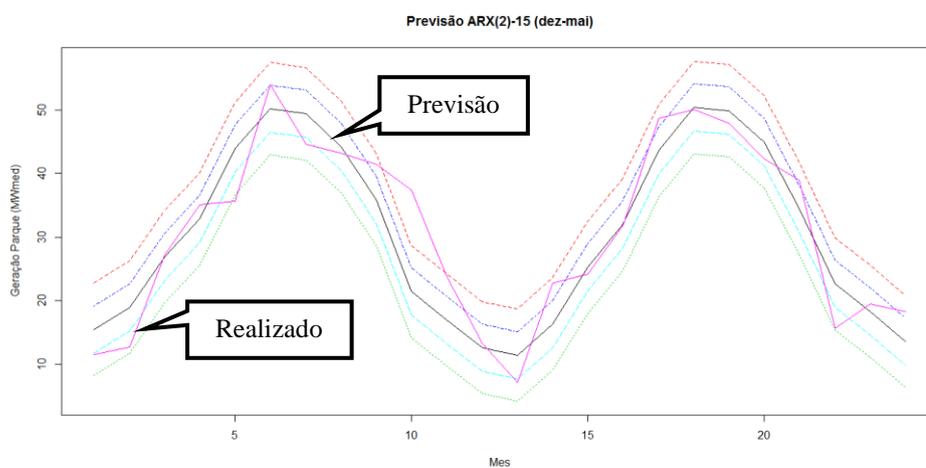
Figura 35 – Estatísticas básicas das simulações por mês e modelo



**Figura 36 – Média mensal de geração eólica de abril/2014 a março/2016: realizado e previsão com intervalos de confiança de 95% e 80%, pelo modelo ARX(2)-11**



**Figura 37 – Média mensal de geração eólica de abril/2014 a março/2016: realizado e previsão com intervalos de confiança de 95% e 80%, pelo modelo PAR(3)**



**Figura 38 – Média mensal de geração eólica de abril/2014 a março/2016: realizado e previsão com intervalos de confiança de 95% e 80%, pelo modelo ARX(2)-15 (dez-mai)**

#### 4.4. Conclusão

O objetivo deste capítulo foi especificar modelos adequados para previsão e simulação de Monte Carlo de médias mensais de geração eólica para o horizonte anual, verificando-se, também, a influência de fenômenos climáticos.

Em resposta à primeira questão: "Como modelar a média mensal de geração eólica para horizonte anual e considerar a influência de fenômenos climáticos?", pode-se dizer que os modelos autorregressivos SAR(3)(2)[12], ARMA(8,2), ARX(2)-11 e PAR(3) são adequados para previsão e simulação da média mensal de geração eólica no horizonte anual e que a influência de fenômenos climáticos pode ser modelada com variáveis exógenas numéricas ou *dummies*. Deve-se considerar, também, que dada a característica sazonal/periódica da série, o modelo ARMA(8,2) é conceitualmente menos adequado, enquanto o modelo SAR(3)(2)[12], apesar de conceitualmente adequado, apresentou os piores indicadores de desempenho. Já o modelo PAR(3) apresentou os melhores indicadores de desempenho e é o único que considera a variabilidade de volatilidade mensal, contudo, dado seu maior número de parâmetros, ele pode não ser o mais adequado à inclusão das variáveis climáticas exógenas, optando-se por incluí-las no modelo ARX(2)-11. Quanto aos efeitos da consideração de influência de fenômenos climáticos, a incorporação de variáveis exógenas *dummies* ou não para representar os fenômenos climáticos é capaz de capturar certo efeito, tendo, inclusive, agregado capacidade preditiva ao modelo ARX(2)-11 em alguns casos.

Quanto à segunda questão: "Qual a relevância desses fenômenos [climáticos] na previsão e simulação da média mensal de geração eólica?", pode-se respondê-la sobre diferentes perspectivas. Primeiramente, a incorporação de algumas variáveis climáticas agregou capacidade preditiva ao modelo ARX(2)-11, contudo, não foi observada diferença significativa entre as simulações com e sem elas. A inclusão das variáveis climáticas, também, proporcionou pequena redução da volatilidade do modelo, certamente capturada pelos fenômenos modelados. Dentre as variáveis testadas, a anomalia de TSM no Niño 3.4 (condição e intensidade do ENSO) foi significativa apenas a 10% e a ocorrência de *La Niña* ou *El Niño* foi não significativa, apesar do sinal do parâmetro ser, respectivamente, negativo e positivo, conforme esperado. Contudo, a exclusão das variáveis *dummies* de *El*

*Niño* (**nino**) e de *La Niña* (**nina**) pioraram o desempenho do modelo. Dentre as variáveis significativas, a diferença de anomalia de TSM no Atlântico (Dipolo do Atlântico, considerando condição e intensidade) foi a mais significativa, seguida pela ocorrência de Dipolo Positivo. A ocorrência de Dipolo Negativo foi significativa apenas ao ser considerada de dezembro a maio. De fato, era esperada maior significância da ocorrência de Dipolo Positivo ou Negativo do Atlântico ao restringir-se o período de influência das variáveis aos meses de dezembro a maio, quando esses fenômenos estão realmente associados ao posicionamento da ZCIT e à ocorrência de precipitação. Outra conclusão relevante sobre as variáveis climáticas é o fato da simples consideração de *dummies* para identificação da ocorrência dos fenômenos bastar para agregar acurácia ao modelo.

Em relação à terceira questão: “Há outros fatores relevantes a serem considerados?”, observou-se que variabilidade da volatilidade mensal, considerada na modelagem da série pelo modelo PAR(3), apresenta relevância tanto na previsão de médias mensais de geração eólica, dado o melhor desempenho do modelo em relação aos demais, quanto nas simulações, ao permitir a modelagem de maior ou menor incerteza em função dos meses, mais aderente as diferenças de distribuições observadas nas Figuras 25 e 26. Contudo, ao realizar-se as simulações observou-se uma tendência à superestimação de valores com o modelo PAR(3). Consequências da variabilidade de volatilidade mensal serão avaliadas, também, na otimização comercial do parque eólico, no capítulo 6.

Por fim, com base no exposto, os modelos adequados selecionados para previsão e simulação de Monte Carlo de médias mensais de geração eólica para horizonte anual foram ARX(2)-11, ARX(2)-15 (dez-mai) para verificar a influência de fenômenos climáticos e PAR(3) para verificar a variabilidade mensal da volatilidade, cujas equações ajustadas aos dados constam nas eq. (28) a eq. (30).

## 5

### Desenvolvimento de uma nova função de preferência

Inúmeros são os ativos de risco à disposição de investidores no mercado financeiro, cada um com diferentes distribuições de retornos, o que motivou o desenvolvimento de medidas de desempenho capazes de classificar esses ativos e suas combinações, a fim de que se possa escolher o melhor investimento. No mercado de energia, apesar do ativo básico possuir características particulares quanto à impossibilidade de estocagem e haver menor liquidez, há necessidade da definição de medidas de desempenho que auxiliem a tomada de decisão sobre negociações. Mais ainda, há necessidade de extrair dessas medidas funções para o cálculo de prêmios de risco que sirvam de norteadores para precificação de operações de *hedge*.

Na teoria financeira, a metodologia básica para escolha do melhor investimento é o uso de alguma medida de desempenho de carteiras para ordenar os diferentes investimentos de risco e otimizar carteiras. Cada medida de desempenho calcula um escore para cada ativo ou carteira, usando sua distribuição de probabilidade dos retornos, e o melhor ativo para investimento é aquele com o maior escore (ZAKAMOULINE, 2014). Para otimização de carteiras, em geral, a maximização do escore é definida como função objetivo do problema, com restrições de valor disponível para investimento e risco admitido.

A literatura em medidas de desempenho é vasta e teve seu início com o trabalho seminal de SHARPE (1966), que propôs uma medida de retorno-risco conhecida como o índice de Sharpe. Contudo, ele é válido apenas para retornos com distribuição Normal ou existência de preferências quadráticas, podendo levar a conclusões equivocadas e paradoxos na hora da tomada de decisão de alocação sem observância dessas premissas (BERNARDO; LEDOIT, 2000). Assim, diversas medidas alternativas foram propostas, visando considerar a não normalidade dos retornos, conforme exposto na seção 3.2.1.

Uma questão complementar à consideração de não normalidade dos retornos é a consideração das preferências do investidor, que tem ganhado espaço nos

estudos de finanças comportamentais e é particularmente importante em mercados com baixa liquidez e assimetria de informação, como ocorre na comercialização de energia no Brasil (LUZ *et al.*, 2012). No caso da comercialização de energia eólica no Brasil, o trabalho de DALBEM *et al.* (2014a) revela diferenças de perspectivas dos investidores na tomada de decisão de entrar no mercado. O princípio da literatura sobre preferências do investidor reside no modelo de utilidade esperada desenvolvido por VON NEUMANN e MORGENSTERN (1944), que é base do modelo de média-variância de MARKOWITZ (1952). A Teoria do Prospecto (KAHNEMAN; TVERSKY, 1979) e a Teoria do Prospecto Cumulativa (TVERSKY & KAHNEMAN, 1992) também tratam do assunto.

Outra abordagem recorrente e complementar na otimização de carteiras é a minimização do risco, através de sua representação por uma medida de risco, sendo as mais comuns o  $VaR_\alpha$  e o  $CVaR_\alpha$  ou  $ES_\alpha$  (RIGUI; CERETTA, 2014). Diferentemente das medidas de desempenho, que resultam em escores, por vezes, de difícil interpretação, essas medidas de risco fornecem o valor monetário do risco máximo ou perda esperada a um determinado nível de significância. O maior questionamento sobre as medidas de risco reside nas propriedades desejáveis a serem atendidas, sendo as medidas de risco coerentes a principal classe de referência, cujas propriedades estão presentes na seção 3.2.2. Um paralelo entre medidas de desempenho e de risco é feito por CHENY e MADEN (2009) ao observarem que medidas de desempenho inspiradas em medidas de risco coerentes sobressaem-se às demais.

Uma medida que tem sido amplamente empregada em problemas de otimização, particularmente, na comercialização de energia e, mesmo, no despacho hidrotérmico no Brasil, é a ponderação entre o valor esperado da distribuição e o  $CVaR_\alpha$  da distribuição a um determinado nível de significância, apresentada em STREET (2010) como ECP. Exemplos de aplicação direta ou com pequenas variações dessa medida são encontrados em POURSINHO *et al.* (2012), RUDLOFF *et al.* (2014), FÂNZERES *et al.* (2012) e LAZO *et al.* (2012). No caso do despacho hidrotérmico no Brasil, COSTA *et al.* (2013) e PHILPOTT e MATOS (2012) introduzem a formalização do problema. As principais justificativas para utilização dessa medida são: possibilidade de representação da aversão ao risco do investidor; ser inspirada em uma medida coerente de risco; possuir uma interpretação acessível; ser de fácil de implementação em problemas estocásticos

de programação linear. Apesar do amplo uso e das demonstrações das propriedades de coerência, ainda não foram totalmente aprofundadas: (i) a possibilidade de definição de diferentes níveis de risco e de aversão a eles; (ii) a inferência da função utilidade subjacente a ela; (iii) a parametrização dessa medida.

Nesse contexto, tomando por base o ECP (eq. (15)), o objetivo deste capítulo é desenvolver uma nova função de preferência, capaz de capturar diferentes níveis de aversão ao risco do gestor, visando cobrir as lacunas (i) e (ii).

Portanto, busca-se responder as seguintes questões:

- ✓ Como modelar diferentes níveis de aversão ao risco do gestor em uma função de preferência?
- ✓ Quais as propriedades e derivações dessa função?

Propõe-se, ainda, em caráter preliminar, uma forma prática para parametrização da medida a partir de sua interpretação.

### 5.1.

#### **Definição, interpretação e propriedades do ECP\_G**

STREET (2010) apresentou a função utilidade subjacente ao problema de maximização da utilidade esperada com restrição de  $CVaR_\alpha$  e definiu o funcional de preferência estendida do  $CVaR_\alpha$  (ECP, conforme eq. (15)), inspirado nessa função utilidade. Em Aguiar (2008), a ideia dessa função utilidade já é introduzida a partir de uma função utilidade linear por partes.

Como funções utilidades lineares por partes podem ser construídas a partir de  $N$  retas e STREET (2008) sugere cinco ou mais pontos de corte para definição das preferências da empresa por funções desse tipo, parece razoável a generalização do ECP para  $N$  níveis ou pontos de referência, tendo-se uma função utilidade linear por partes subjacente a esta generalização.

Assim, a função utilidade na eq. (31) é uma generalização da proposta de STREET (2010), para um período, que resulta diretamente na generalização do ECP para  $N$  níveis ou pontos de referência. Essa generalização não foi observada na literatura, constituindo-se uma inovação e denominada nesta tese, ECP\_G (eq. (32)). O ECP\_G é calculado diretamente como valor esperado da função utilidade apresentada na eq. (31). A ideia por trás dessa função é que um investidor pode

apresentar diferentes níveis de aversão ao risco (RABIN, 2000) para diferentes faixas de risco, como risco mediano e extremo, por exemplo, onde aquele poderia ser a necessidade de tomada de um empréstimo adicional e, este, acarretar a quebra da empresa. A definição de risco mediano e extremo, também, pode partir da probabilidade de ocorrência de cenários, assim, o risco extremo poderia referir-se aos 5% piores cenários e o risco mediano aos 20% piores. No contexto da otimização do despacho hidrotérmico no Brasil, os diferentes níveis de aversão ao risco poderiam estar associados a diferentes probabilidades de ocorrência de algum corte de carga ou, mesmo, de diferentes percentuais de corte de carga.

A seguir, apresenta-se a função utilidade subjacente ao ECP\_G e, na sequência, a obtenção do ECP\_G e demonstração de algumas propriedades.

Função utilidade  $U: \mathbb{R} \rightarrow \mathbb{R}$

$$\lambda_i \geq 0 \text{ e } \sum_i \lambda_i = 1, i \in [0, N]; \alpha_i \in ]0, 1[, i \in [1, N]; \alpha_{N+1} = 1 \text{ e } \alpha_0 = 0$$

$$\alpha_i = 1 - F(VaR_{\alpha_i}) \left| \begin{array}{l} F: \mathbb{R} \rightarrow [0, 1] \\ F(x) = \int_{VaR_{\alpha_{N+1}}}^{VaR_{\alpha_i}} f(x) dx \text{ e } \int_{VaR_{\alpha_{N+1}}}^{VaR_{\alpha_0}} f(x) dx = 1 \end{array} \right.$$

$$U(x) = \begin{cases} \lambda_0 x + \sum_{i=1}^N \lambda_i VaR_{\alpha_i} + \sum_{i=1}^n \frac{\lambda_i}{(1-\alpha_i)} (x - VaR_{\alpha_i}); & x \in ]VaR_{\alpha_{n+1}}, VaR_{\alpha_n}], \\ & n \in [1, N] \subset \mathbb{N}^*, \\ & VaR_{\alpha_{N+1}} \rightarrow -\infty \\ \lambda_0 x + \sum_{i=1}^N \lambda_i VaR_{\alpha_i}; & x \in ]VaR_{\alpha_1}, VaR_{\alpha_0}[ \\ & VaR_{\alpha_0} \rightarrow +\infty \end{cases}$$

(31)

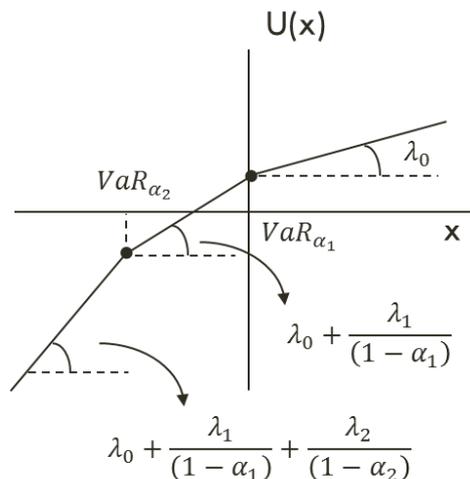


Figura 39 – Função utilidade subjacente ao ECP\_G com  $N = 2$

Fonte: elaboração própria.

A Figura 39 ilustra a função utilidade da eq. (31) quando há dois pontos de referência ( $N = 2$ ). Nota-se que a alteração de retas ocorre quando  $x = VaR_{\alpha_i}$  (ponto de referência), enquanto a inclinação de cada uma das  $N + 1$  retas que formam a função é dada por:  $\lambda_0 + \sum_{i=1..n} \lambda_i / (1 - \alpha_i)$ .

Uma vez definida a função utilidade, pode-se: (i) verificar que  $U$  é contínua, definida sobre todo o espaço dos reais, o que garante sua integração no espaço de probabilidades da função de probabilidade acumulada  $F(x)$ , e, então, (ii) permiti o cálculo da utilidade esperada, conforme eq. (32), que é a generalização do funcional de preferência estendida do CVaR (ECP\_G).

A ECP\_G é a nova função de preferência desenvolvida, capaz de capturar diferentes níveis de aversão ao risco do gestor. Na seção 5.1.1 é calculado o equivalente certo da função utilidade subjacente e, na seção 5.1.2, o prêmio de risco. Com efeito, a presença de prêmio de risco é confirmada na seção 5.1.3, ao mostrar-se que a função é globalmente avessa ao risco e neutra para cada segmento de reta.

i.  $U$  é contínua

Demonstração:

✓ Para  $x = VaR_{\alpha_1}$

Para provar a continuidade de  $U(x)$  no ponto  $x = VaR_{\alpha_1}$ , substitui-se  $x$  por  $VaR_{\alpha_1}$  nas linhas inferior e superior da definição de  $U(x)$ , conforme lados direito e esquerdo, respectivamente, da igualdade a seguir.

$$\begin{aligned} \lambda_0 VaR_{\alpha_1} + \sum_{i=1}^N \lambda_i VaR_{\alpha_i} \\ = \lambda_0 VaR_{\alpha_1} + \sum_{i=1}^N \lambda_i VaR_{\alpha_i} + \sum_{i=1}^1 \frac{\lambda_i}{(1 - \alpha_i)} (VaR_{\alpha_1} - VaR_{\alpha_i}) \end{aligned}$$

Reorganizando os termos e substituindo  $i$  por 1 no somatório de  $i$  de 1 a 1 (à direita da igualdade a seguir), obtém-se a anulação de todos os termos, demonstrando-se a igualdade, logo, a continuidade no ponto  $x = VaR_{\alpha_1}$ .

$$\begin{aligned} & \overbrace{\lambda_0 VaR_{\alpha_1} - \lambda_0 VaR_{\alpha_1}}^0 + \overbrace{\sum_{i=1}^N \lambda_i VaR_{\alpha_i} - \sum_{i=1}^N \lambda_i VaR_{\alpha_i}}^0 \\ &= \frac{\lambda_1}{(1 - \alpha_1)} \overbrace{(VaR_{\alpha_1} - VaR_{\alpha_1})}^0 \end{aligned}$$

$$0 = 0$$

✓ Para  $x = VaR_{\alpha_{n+1}}$ ,  $n \in [1, N] \subset \mathbb{N}^*$

Para provar a continuidade de  $U(x)$  no ponto  $x = VaR_{\alpha_{n+1}}$ , substitui-se  $x$  por  $VaR_{\alpha_{n+1}}$  na linha superior da definição de  $U(x)$ , considerando  $VaR_{\alpha_{n+1}}$  como limite inferior do segmento  $n$  e superior do segmento  $n + 1$ , conforme lados direito e esquerdo, respectivamente, da igualdade a seguir.

$$\begin{aligned} & \lambda_0 VaR_{\alpha_{n+1}} + \sum_{i=1}^N \lambda_i VaR_{\alpha_i} + \sum_{i=1}^n \frac{\lambda_i}{(1 - \alpha_i)} (VaR_{\alpha_{n+1}} - VaR_{\alpha_i}) \\ &= \lambda_0 VaR_{\alpha_{n+1}} + \sum_{i=1}^N \lambda_i VaR_{\alpha_i} \\ &+ \sum_{i=1}^{n+1} \frac{\lambda_i}{(1 - \alpha_i)} (VaR_{\alpha_{n+1}} - VaR_{\alpha_i}) \end{aligned}$$

Reorganizando os termos e separando do somatório de  $i$  de 1 a  $n + 1$  a parcela quando  $i = n + 1$  (à direita da igualdade a seguir), obtém-se a anulação de todos os termos, demonstrando-se a igualdade, logo, a continuidade nos pontos  $x = VaR_{\alpha_{n+1}}$ .

$$\begin{aligned} & \overbrace{\lambda_0 VaR_{\alpha_{n+1}} - \lambda_0 VaR_{\alpha_{n+1}}}^0 + \overbrace{\sum_{i=1}^N \lambda_i VaR_{\alpha_i} - \sum_{i=1}^N \lambda_i VaR_{\alpha_i}}^0 \\ &+ \overbrace{\sum_{i=1}^n \frac{\lambda_i}{(1 - \alpha_i)} (VaR_{\alpha_{n+1}} - VaR_{\alpha_i}) - \sum_{i=1}^n \frac{\lambda_i}{(1 - \alpha_i)} (VaR_{\alpha_{n+1}} - VaR_{\alpha_i})}^0 \\ &= \frac{\lambda_{n+1}}{(1 - \alpha_{n+1})} \overbrace{(VaR_{\alpha_{n+1}} - VaR_{\alpha_{n+1}})}^0 \end{aligned}$$

$$0 = 0$$

ii. Cálculo da utilidade esperada ( $E[U(X)]$ )

$$ECP\_G = E[U(X)] = \lambda_0 E[X] + \sum_{n=1}^N \lambda_n CVaR_{\alpha_n}; \quad \lambda_i \geq 0 \text{ e } \sum_i \lambda_i = 1, i \in [0, N] \quad (32)$$

Demonstração:

Por definição, como  $VaR_{\alpha_{N+1}} \rightarrow -\infty$  e  $VaR_{\alpha_0} \rightarrow +\infty$ , tem-se que:

$$E[U(X)] = \int_{VaR_{\alpha_{N+1}}}^{VaR_{\alpha_0}} U(X) f(x) dx$$

Substituindo  $U(X)$  pela definição na eq. (31), obtém-se:

$$\begin{aligned} E[U(X)] &= \int_{VaR_{\alpha_1}}^{VaR_{\alpha_0}} \left( \lambda_0 x + \sum_{i=1}^N \lambda_i VaR_{\alpha_i} \right) f(x) dx \\ &\quad + \sum_{n=1}^N \left[ \int_{VaR_{\alpha_{n+1}}}^{VaR_{\alpha_n}} \left( \lambda_0 x + \sum_{i=1}^N \lambda_i VaR_{\alpha_i} \right. \right. \\ &\quad \left. \left. + \sum_{i=1}^n \frac{\lambda_i}{(1-\alpha_i)} (x - VaR_{\alpha_i}) \right) f(x) dx \right] \end{aligned}$$

Separando as parcelas do somatório de  $n$  de 1 a  $N$ , tem-se a igualdade a seguir, sendo possível eliminar termos de somatório pelo agrupamento de somatórios ou integrais, conforme indicado nos colchetes:

$E[U(X)]$

$$\begin{aligned} &\int_{VaR_{\alpha_{N+1}}}^{VaR_{\alpha_0}} (\lambda_0 x + \sum_{i=1}^N \lambda_i VaR_{\alpha_i}) f(x) dx \\ &= \overbrace{\int_{VaR_{\alpha_1}}^{VaR_{\alpha_0}} (\lambda_0 x + \sum_{i=1}^N \lambda_i VaR_{\alpha_i}) f(x) dx} + \sum_{n=1}^N \left[ \int_{VaR_{\alpha_{n+1}}}^{VaR_{\alpha_n}} (\lambda_0 x + \sum_{i=1}^N \lambda_i VaR_{\alpha_i}) f(x) dx \right] \\ &\quad \underbrace{\sum_{n=1}^N \left( \int_{VaR_{\alpha_{n+1}}}^{VaR_{\alpha_n}} \frac{\lambda_n}{(1-\alpha_n)} x f(x) dx \right)} \\ &+ \sum_{n=1}^N \left[ \int_{VaR_{\alpha_{n+1}}}^{VaR_{\alpha_n}} \left( \sum_{i=1}^n \frac{\lambda_i}{(1-\alpha_i)} \right) x f(x) dx \right] \\ &\quad \underbrace{\sum_{n=1}^N \left( \int_{VaR_{\alpha_{n+1}}}^{VaR_{\alpha_n}} \frac{\lambda_n}{(1-\alpha_n)} VaR_{\alpha_n} f(x) dx \right)} \\ &- \sum_{n=1}^N \left[ \int_{VaR_{\alpha_{n+1}}}^{VaR_{\alpha_n}} \left( \sum_{i=1}^n \frac{\lambda_i}{(1-\alpha_i)} VaR_{\alpha_i} \right) f(x) dx \right] \end{aligned}$$

Substituindo os termos pelos agrupamentos indicados nos colchetes, ainda é possível resumir alguns termos da igualdade, conforme indicado nos colchetes a seguir. Quatro termos com indicação de substituição decorrem diretamente das definições de: valor esperado ( $E[X]$ ), função de densidade de probabilidade ( $f(x)$ ), conforme apresentado na eq. (31)) e *conditional value at risk* ( $CVaR_{\alpha_n}(X)$ ), conforme eq. (18)).

$$\begin{aligned}
 E[U(X)] &= \lambda_0 \overbrace{\int_{VaR_{\alpha_{N+1}}}^{VaR_{\alpha_0}} xf(x)dx}^{E[X]} + \left( \sum_{i=1}^N \lambda_i VaR_{\alpha_i} \right) \overbrace{\int_{VaR_{\alpha_{N+1}}}^{VaR_{\alpha_0}} f(x)dx}^1 \\
 &+ \sum_{n=1}^N \lambda_n \overbrace{\left( \int_{VaR_{\alpha_{N+1}}}^{VaR_{\alpha_n}} \frac{1}{(1-\alpha_n)} xf(x)dx \right)}^{CVaR_{\alpha_n}(X)} \\
 &- \sum_{n=1}^N \lambda_n VaR_{\alpha_n} \overbrace{\frac{1}{(1-\alpha_n)} \int_{VaR_{\alpha_{N+1}}}^{VaR_{\alpha_n}} f(x)dx}^1
 \end{aligned}$$

Fazendo a substituição de termos pelos destacados nos colchetes, resume-se a igualdade à apresentada na sequência e, observando-se que é possível substituir  $i$  por  $n$ , tem-se a equivalência dos somatórios de  $i$  de 1 a  $N$  e de  $n$  de 1 a  $N$ , chegando-se a demonstração pretendida.

$$\begin{aligned}
 E[U(X)] &= \lambda_0 E[X] + \sum_{n=1}^N \lambda_n CVaR_{\alpha_n} + \overbrace{\sum_{i=1}^N \lambda_i VaR_{\alpha_i} - \sum_{n=1}^N \lambda_n VaR_{\alpha_n}}^0 \\
 &= \lambda_0 E[X] + \sum_{n=1}^N \lambda_n CVaR_{\alpha_n}
 \end{aligned}$$

Observa-se que se  $N = 1$ , então, tem-se a representação do ECP:

$$N = 1 \Rightarrow E[U(X)] = \lambda_0 E[X] + \lambda_1 CVaR_{\alpha_1} = (1 - \lambda_1)E[X] + \lambda_1 CVaR_{\alpha_1} \quad (33)$$

Importante notar que, conforme apontado em STREET (2010), a função utilidade subjacente à ECP\_G (eq. (31)) não é uma função utilidade clássica de Von Neumann-Morgenstern, pois sua utilidade esperada (ECP\_G) depende da distribuição dos resultados, em função dos parâmetros  $\alpha_n$  para cálculo dos valores de  $CVaR_{\alpha_n}$ .

Na seção 3.2.2 foram apresentadas as características de medidas coerentes de risco, dentre as quais o  $CVaR_{\alpha}$ . OLIVEIRA (2009) demonstrou, também, que qualquer combinação convexa de medidas coerentes de risco, é uma medida coerente de risco. Ora, como  $E[X]$  é o  $CVaR_{\alpha}$  para  $\alpha = 0$ , a função de preferência estendida do CVaR generalizada, a ECP\_G, nada mais é do que uma combinação convexa, garantida por  $\sum_i \lambda_i = 1$ , de  $CVaR_{\alpha}$  para diferentes  $\alpha$ 's (eq. (34)), sendo, portanto, uma medida coerente de risco.

$$ECP\_G = \lambda_0 E[X] + \sum_{n=1}^N \lambda_n CVaR_{\alpha_n} = \lambda_0 CVaR_{0\%} + \sum_{n=1}^N \lambda_n CVaR_{\alpha_n};$$

$$\lambda_i \geq 0 \text{ e } \sum_i \lambda_i = 1, i \in [0, N]$$

(34)

Outro ponto de destaque é a possibilidade de definição da ECP\_G tendo os valores de  $VaR_{\alpha_n}$  como parâmetros, ao invés dos valores de  $\alpha_n$ . Nesse caso, o cálculo da ECP\_G ainda depende da distribuição dos resultados, pois os valores de  $CVaR_{\alpha_n}$  dependem do cálculo implícito dos valores de  $\alpha_n$ , contudo, a ECP\_G passa a não atender a todas as propriedades de uma medida coerente de risco. Apesar da observação de CHERNY e MADEN (2009) de que medidas de desempenhos inspiradas em medidas coerentes de risco sobressaem-se às demais, MORAES (2012) aponta que uma medida de risco coerente não é necessariamente melhor do que outra não coerente, sendo o principal ponto de atenção a distribuição dos retornos dos ativos e as hipóteses adotadas pelo modelo. Portanto, a parametrização da ECP\_G por valores de  $VaR_{\alpha_n}$ , ao invés de por valores de  $\alpha_n$ , não deve ser descartada.

Tem-se ainda que, assim como o ECP (eq. (15)), a ECP\_G (eq. (32)) possui relação com a WES (CHEN; YANG, 2011), ao atribuir pesos ao  $CVaR_{\alpha}$ , contudo, os pesos não são definidos diretamente por uma função, como ocorre na WES (eq.

(19)). Ademais, enquanto a função de pesos da WES permite, para um mesmo grau de confiança  $\alpha$ , a distinção do nível de aversão ao risco em função do nível de riqueza  $\text{VaR}_\alpha$ , a ECP\_G permite a distinção do nível de aversão ao risco em função dos graus de confiança  $\alpha_n$ 's ou dos valores de  $\text{VaR}_{\alpha_n}$ 's de interesse.

Sobre a interpretação da ECP\_G, além da definição direta de ponderação entre valor esperado e os valores de  $\text{CVaR}_{\alpha_n}$  para diferentes  $\alpha_n$ 's, observa-se, no seu cálculo, que: (i) o valor esperado abaixo do percentil  $(1 - \alpha_N)$  é considerado integralmente; (ii) o valor esperado entre os percentis  $(1 - \alpha_n)$  e  $(1 - \alpha_{n+1})$ , com  $1 < n < N$ , é considerado na proporção  $(1 - \sum_{i>n+1} \lambda_i)$ ; (iii) o valor esperado acima do percentil  $(1 - \alpha_1)$  é considerado na proporção  $(\lambda_0 = 1 - \sum_{i>1} \lambda_i)$ . Assim, vê-se claramente que, no cálculo da ECP\_G, os piores valores da distribuição de resultados recebem peso 1 e este peso decresce a cada segmento da função utilidade linear por partes, à medida em que os valores da distribuição de resultados aumentam.

Na seção 3.2.3 introduziu-se o conceito do  $Eq$  – Equivalente Certo e seu uso para cálculo de prêmio de risco. É fácil notar que a função utilidade subjacente à ECP\_G é bijetora e, portanto, invertível. Com efeito, por ser contínua e linear por partes, definida sobre todos os números reais, ela é uma regra que associa cada número real (domínio) a um único e diferente número real (imagem). Como a ECP\_G admite inversa, é possível calcular seu  $Eq$  e, conseqüentemente, o prêmio de risco. Assim como a função utilidade subjacente à ECP\_G, o  $Eq$  é definido por uma função linear por partes, contínua, porém, convexa. Na Figura 11, presente na seção 3.2.3, observa-se um exemplo de função utilidade subjacente ao ECP\_G com 3 (três) segmentos de reta e sua inversa.

### 5.1.1. Cálculo do Equivalente Certo (Eq)

Na eq. (35) é apresentado o cálculo do  $Eq$  – Equivalente Certo da função utilidade apresentada na eq. (31), seguindo a definição da seção 3.2.3.

Interessante observar que, apesar do cálculo explícito, o  $Eq$  depende tanto dos níveis de corte quanto da utilidade esperada (ECP\_G).

$$Eq = U^{-1}(E[U(X)]) = U^{-1}\left(\lambda_0 E[X] + \sum_{n=1}^N \lambda_n \text{CVaR}_{\alpha_n}\right)$$

$$\begin{aligned}
 & Eq \\
 & = \left\{ \begin{array}{l} E[X] + \frac{1}{\lambda_0} \sum_{i=1}^N \lambda_i (CVaR_{\alpha_i} - VaR_{\alpha_i}); \\ E[U(X)] \in ]\lambda_0 VaR_{\alpha_1} + \sum_{i=1}^N \lambda_i VaR_{\alpha_i}, \lambda_0 VaR_{\alpha_0} + \sum_{i=1}^N \lambda_i VaR_{\alpha_i}[ \\ \frac{1}{\left(\lambda_0 + \sum_{i=1}^n \frac{\lambda_i}{(1-\alpha_i)}\right)} \left[ \begin{array}{l} \lambda_0 E[X] + \sum_{i=1}^N \lambda_i (CVaR_{\alpha_i} - VaR_{\alpha_i}) + \\ \sum_{i=1}^n \frac{\lambda_i}{(1-\alpha_i)} VaR_{\alpha_i} \end{array} \right]; \\ E[U(X)] \in ]\lambda_0 VaR_{\alpha_{n+1}} + \sum_{i=1}^N \lambda_i VaR_{\alpha_i}, \lambda_0 VaR_{\alpha_n} + \sum_{i=1}^N \lambda_i VaR_{\alpha_i}[ \\ n \in [1, N] \subset \mathbb{N}^* \end{array} \right. \quad (35)
 \end{aligned}$$

Onde:

$$E[U(X)] = \lambda_0 E[X] + \sum_{n=1}^N \lambda_n CVaR_{\alpha_n}$$

Demonstração:

$$\checkmark \text{ Para } E[U(X)] \in ]\lambda_0 VaR_{\alpha_1} + \sum_{i=1}^N \lambda_i VaR_{\alpha_i}, \lambda_0 VaR_{\alpha_0} + \sum_{i=1}^N \lambda_i VaR_{\alpha_i}[$$

$$U(Eq) = E[U(X)]$$

Substituindo-se  $x$  por  $Eq$  na linha inferior da definição de  $U(x)$  (eq. (31)) e  $E[U(X)]$  pelo ECP\_G, conforme eq. (32), obtém-se a primeira igualdade a seguir. Com a reordenação dos termos obtém-se a demonstração pretendida.

$$\lambda_0 Eq + \sum_{i=1}^N \lambda_i VaR_{\alpha_i} = \lambda_0 E(X) + \sum_{n=1}^N \lambda_n CVaR_{\alpha_n}$$

$$Eq = \frac{\overset{1}{\widetilde{\lambda_0}}}{\lambda_0} E[X] + \frac{1}{\lambda_0} \sum_{i=1}^N \lambda_i (CVaR_{\alpha_i} - VaR_{\alpha_i})$$

$$Eq = E[X] + \frac{1}{\lambda_0} \sum_{i=1}^N \lambda_i (CVaR_{\alpha_i} - VaR_{\alpha_i})$$

$$\checkmark \text{ Para } E[U(X)] \in ]\lambda_0 VaR_{\alpha_{n+1}} + \sum_{i=1}^N \lambda_i VaR_{\alpha_i}, \lambda_0 VaR_{\alpha_n} + \sum_{i=1}^N \lambda_i VaR_{\alpha_i}[,$$

$$n \in [1, N] \subset \mathbb{N}^*$$

$$U[Eq] = E[U(X)]$$

Substituindo-se  $x$  por  $Eq$  na linha superior da definição de  $U(x)$  (eq. (31)) e  $E[U(X)]$  pelo ECP\_G, conforme eq. (32), obtém-se a primeira igualdade a seguir. Novamente, com a reordenação dos termos obtém-se a demonstração pretendida.

$$\begin{aligned} \lambda_0 Eq + \sum_{i=1}^N \lambda_i VaR_{\alpha_i} + \sum_{i=1}^n \frac{\lambda_i}{(1-\alpha_i)} (Eq - VaR_{\alpha_i}) \\ = \lambda_0 E[X] + \sum_{n=1}^N \lambda_n CVaR_{\alpha_n} \end{aligned}$$

$$\begin{aligned} \left( \lambda_0 + \sum_{i=1}^n \frac{\lambda_i}{(1-\alpha_i)} \right) Eq - \sum_{i=1}^n \frac{\lambda_i}{(1-\alpha_i)} VaR_{\alpha_i} \\ = \lambda_0 E[X] + \sum_{i=1}^N \lambda_i (CVaR_{\alpha_i} - VaR_{\alpha_i}) \end{aligned}$$

$$\begin{aligned} Eq = \frac{1}{\left( \lambda_0 + \sum_{i=1}^n \frac{\lambda_i}{(1-\alpha_i)} \right)} \left[ \lambda_0 E[X] + \sum_{i=1}^N \lambda_i (CVaR_{\alpha_i} - VaR_{\alpha_i}) \right. \\ \left. + \sum_{i=1}^n \frac{\lambda_i}{(1-\alpha_i)} VaR_{\alpha_i} \right] \end{aligned}$$

### 5.1.2. Cálculo do Prêmio de Risco (Pr)

Uma vez calculado o  $Eq$ , é direto o cálculo do  $Pr$  – Prêmio de Risco da função utilidade presente na eq. (31), seguindo a definição da seção 3.2.3, conforme eq. (36).

Assim como o  $Eq$ , o  $Pr$  depende tanto dos níveis de corte quanto da utilidade esperada (ECP\_G).

$$Pr = E[X] - Eq$$

$$Pr = \begin{cases} -\frac{1}{\lambda_0} \sum_{i=1}^N \lambda_i (CVaR_{\alpha_i} - VaR_{\alpha_i}); \\ E[U(X)] \in ]\lambda_0 VaR_{\alpha_1} + \sum_{i=1}^N \lambda_i VaR_{\alpha_i}, \lambda_0 VaR_{\alpha_0} + \sum_{i=1}^N \lambda_i VaR_{\alpha_i}[ \\ \frac{1}{\left(\lambda_0 + \sum_{i=1}^n \frac{\lambda_i}{(1-\alpha_i)}\right)} \left[ \sum_{i=1}^n \frac{\lambda_i}{(1-\alpha_i)} (E[X] - VaR_{\alpha_i}) - \sum_{i=1}^N \lambda_i (CVaR_{\alpha_i} - VaR_{\alpha_i}) \right]; \\ E[U(X)] \in ]\lambda_0 VaR_{\alpha_{n+1}} + \sum_{i=1}^N \lambda_i VaR_{\alpha_i}, \lambda_0 VaR_{\alpha_n} + \sum_{i=1}^N \lambda_i VaR_{\alpha_i}[ \\ n \in [1, N] \subset \mathbb{N}^* \end{cases} \quad (36)$$

Onde:

$$E[U(X)] = \lambda_0 E[X] + \sum_{n=1}^N \lambda_n CVaR_{\alpha_n}$$

Demonstração:

$$\checkmark \text{ Para } E[U(X)] \in ]\lambda_0 VaR_{\alpha_1} + \sum_{i=1}^N \lambda_i VaR_{\alpha_i}, \lambda_0 VaR_{\alpha_0} + \sum_{i=1}^N \lambda_i VaR_{\alpha_i}[$$

$$Pr = E[X] - Eq$$

$$Pr = E[X] - \left( E[X] + \frac{1}{\lambda_0} \sum_{i=1}^N \lambda_i (CVaR_{\alpha_i} - VaR_{\alpha_i}) \right)$$

$$Pr = -\frac{1}{\lambda_0} \sum_{i=1}^N \lambda_i (CVaR_{\alpha_i} - VaR_{\alpha_i})$$

$$\checkmark \text{ Para } E[U(X)] \in ]\lambda_0 VaR_{\alpha_{n+1}} + \sum_{i=1}^N \lambda_i VaR_{\alpha_i}, \lambda_0 VaR_{\alpha_n} + \sum_{i=1}^N \lambda_i VaR_{\alpha_i}[ \\ n \in [1, N] \subset \mathbb{N}^*$$

$$Pr = E[X] - Eq$$

$$Pr = E[X] - \frac{1}{\left(\lambda_0 + \sum_{i=1}^n \frac{\lambda_i}{(1-\alpha_i)}\right)} \left[ \lambda_0 E[X] + \sum_{i=1}^N \lambda_i (CVaR_{\alpha_i} - VaR_{\alpha_i}) + \sum_{i=1}^n \frac{\lambda_i}{(1-\alpha_i)} VaR_{\alpha_i} \right]$$

$$Pr = \left[ 1 - \frac{\lambda_0}{\left( \lambda_0 + \sum_{i=1}^n \frac{\lambda_i}{(1-\alpha_i)} \right)} \right] E[X] - \frac{1}{\left( \lambda_0 + \sum_{i=1}^n \frac{\lambda_i}{(1-\alpha_i)} \right)} \left[ \sum_{i=1}^N \lambda_i (CVaR_{\alpha_i} - VaR_{\alpha_i}) + \sum_{i=1}^n \frac{\lambda_i}{(1-\alpha_i)} VaR_{\alpha_i} \right]$$

$$Pr = \left[ \frac{\overbrace{\lambda_0 - \lambda_0}^0 + \sum_{i=1}^n \frac{\lambda_i}{(1-\alpha_i)}}{\left( \lambda_0 + \sum_{i=1}^n \frac{\lambda_i}{(1-\alpha_i)} \right)} \right] E[X] - \frac{1}{\left( \lambda_0 + \sum_{i=1}^n \frac{\lambda_i}{(1-\alpha_i)} \right)} \left[ \sum_{i=1}^N \lambda_i (CVaR_{\alpha_i} - VaR_{\alpha_i}) + \sum_{i=1}^n \frac{\lambda_i}{(1-\alpha_i)} VaR_{\alpha_i} \right]$$

$$Pr = \frac{1}{\left( \lambda_0 + \sum_{i=1}^n \frac{\lambda_i}{(1-\alpha_i)} \right)} \left[ \sum_{i=1}^n \frac{\lambda_i}{(1-\alpha_i)} (E[X] - VaR_{\alpha_i}) - \sum_{i=1}^N \lambda_i (CVaR_{\alpha_i} - VaR_{\alpha_i}) \right]$$

### 5.1.3. Aversão ao risco global e local

Apesar de já ter sido apresentado o cálculo do  $Pr$ , indicando a presença de aversão ao risco na função utilidade da eq. (31), que é subjacente à ECP\_G, a demonstração formal é feita a seguir. A função é capaz de capturar a diferença de aversão ao risco para os diferentes segmentos do domínio da função utilidade linear por partes, ou seja, ela tem a propriedade de ser localmente (em cada segmento) neutra ao risco, porém, globalmente avessa ao risco. Conforme explicitado na seção 3.2.3, uma função utilidade é avessa ao risco se é côncava, ou seja,  $U(E[X]) > U(Eq) \Rightarrow E[X] > Eq$ , dito de outro modo, se  $Pr > 0$ .

Primeiramente, confirma-se que a função utilidade é globalmente avessa ao risco.

Demonstração:

✓ Para  $E[U(X)] \in ]\lambda_0 VaR_{\alpha_1} + \sum_{i=1}^N \lambda_i VaR_{\alpha_i}, \lambda_0 VaR_{\alpha_0} + \sum_{i=1}^N \lambda_i VaR_{\alpha_i}[$

$$Pr = -\frac{1}{\lambda_0} \sum_{i=1}^N \lambda_i \overbrace{(CVaR_{\alpha_i} - VaR_{\alpha_i})}^{\leq 0} \Rightarrow Pr \geq 0$$

Como  $CVaR_{\alpha_i} < VaR_{\alpha_i}; \alpha_i \in ]0, 1[$  e  $\lambda_i > 0; \forall i$ , então,  $\sum (CVaR_{\alpha_i} - VaR_{\alpha_i}) < 0$  e  $Pr > 0$ .

Vale notar que  $Pr = 0$  se e somente se  $CVaR_{\alpha_i} = VaR_{\alpha_i}; \forall \alpha_i$ , o que significaria, no caso contínuo, ter  $\alpha_i = 1; \forall i$ , estando fora da definição da função utilidade.

✓ Para  $E[U(X)] \in ]\lambda_0 VaR_{\alpha_{n+1}} + \sum_{i=1}^N \lambda_i VaR_{\alpha_i}, \lambda_0 VaR_{\alpha_n} + \sum_{i=1}^N \lambda_i VaR_{\alpha_i}[$ ,  
 $n \in [1, N] \subset \mathbb{N}^*$

$$Pr = \frac{1}{\left( \underbrace{\lambda_0 + \sum_{i=1}^n \frac{\lambda_i}{(1 - \alpha_i)}}_{\geq 0} \right)} \left[ \frac{\sum_{i=1}^n \frac{\lambda_i}{(1 - \alpha_i)} \overbrace{\left( E(X) - VaR_{\alpha_i} \right)}^{\geq 0}}{\underbrace{- \sum_{i=1}^N \lambda_i \overbrace{(CVaR_{\alpha_i} - VaR_{\alpha_i})}^{\leq 0}}_{\geq 0}} \right] \Rightarrow Pr \geq 0$$

Como  $CVaR_{\alpha_i} < VaR_{\alpha_i}; \alpha_i \in ]0, 1[$  e  $\lambda_i > 0; \forall i$ , então,  $\sum (CVaR_{\alpha_i} - VaR_{\alpha_i}) < 0$  e  $-\lambda_i \sum (CVaR_{\alpha_i} - VaR_{\alpha_i}) > 0$ .

Também, como  $E[X] > VaR_{\alpha_i}; \alpha_i \in ]0, 1[$  e  $\lambda_i > 0; \forall i$ , então,  $\sum [\lambda_i / (1 - \alpha_i)] (E[X] - VaR_{\alpha_i}) > 0$ , logo,  $Pr > 0$ .

Para cada segmento, contudo, como a função utilidade da eq. (31) é linear, ela é também neutra ao risco para todo  $x$  e  $y$  pertencentes a um mesmo segmento do domínio da função utilidade  $U$ , ou seja,  $U(tx + (1 - t)y) = tU(x) + (1 - t)U(y)$ , para  $x$  e  $y$  pertencentes ao mesmo segmento  $[a, b]$ .

Em termos de valor esperado, equivalente certo e prêmio de risco, temos que o equivalente certo de cada segmento  $[a, b]$  ( $Eq_{ab}$ ) é igual ao valor esperado desse segmento ( $E[X]_{ab}$ ), logo, o prêmio de risco dentro do segmento é nulo ( $Pr_{ab} = 0$ ). A seguir demonstra-se essas afirmações.

Demonstração:

$$U(x) = \alpha x + \beta; x \in [a, b]$$

$$U(Eq_{ab}) = E[U(X)]$$

$$\alpha Eq_{ab} + \beta = E[\alpha X + \beta] = \alpha E[X]_{ab} + \beta \Rightarrow \alpha Eq_{ab} = \alpha E[X]_{ab} + \overbrace{\beta - \beta}^0$$

$$\Rightarrow Eq_{ab} = \frac{1}{\alpha} E[X]_{ab}$$

$$\Rightarrow Eq_{ab} = E[X]_{ab}$$

$$Pr_{ab} = E[X]_{ab} - Eq_{ab} = E[X]_{ab} - E[X]_{ab} \Rightarrow Pr_{ab} = 0$$

Portanto, a função utilidade apresentada na eq. (31) é uma alternativa para transpassar o problema apontado por RABIN (2000) de manutenção da aversão ao risco para qualquer nível de riqueza, uma vez que por construção ela é globalmente avessa ao risco, porém, localmente neutra ao risco para cada segmento (reta). Assim, o perfil de risco em relação ao todo depende do segmento em que se encontra o resultado, devendo a definição dos segmentos partir do tomador de decisão de acordo com os valores que alteram suas perspectivas de decisão. Exemplos desses valores são: risco máximo e intermediário admitidos pela empresa, retorno mínimo ou desejável exigidos, capital de giro disponível, entre outros.

#### 5.1.4. Medida de aversão ao risco

Apesar da comprovada aversão ao risco, é importante notar que a função utilidade subjacente à ECP\_G não é diferenciável nos pontos de mudança de reta e, portanto, não admite a definição clássica da medida de aversão ao risco de Arrow-Pratt ( $\gamma = -U''/U'$ ). Contudo, nota-se que a aversão ao risco ocorre nas mudanças de reta, sendo uma aversão relativa em relação ao segmento anterior.

Assim, seguindo a ideia da medida de aversão ao risco de Arrow-Pratt (ARROW, 1965; PRATT, 1964), pode ser definida uma medida de aversão ao risco

relativa ( $\gamma_n$ ), conforme eq. (37). Haverá tantos  $\gamma_n$  quantos pontos de alteração de reta e eles representam a aversão ao risco dos valores maiores que o ponto de alteração em relação aos menores que o ponto. Por definição,  $0 < \gamma_n < 1$ , com  $\gamma_n = 1$  representando aversão absoluta do risco de um segmento em relação ao outro, ao passo que  $\gamma_n = 0$  implica a não existência de aversão ao risco nem alteração de reta.

$$\gamma_n = -\frac{(a_n - a_{n+1})}{a_{n+1}}; a_0 = \lambda_0 \text{ e } a_n = \lambda_0 + \sum_{i=1}^n \frac{\lambda_i}{(1 - \alpha_i)}$$

$$\therefore \gamma_n = \frac{\lambda_{n+1}}{(1 - \alpha_{n+1})} \times \left( \lambda_0 + \sum_{i=1}^{n+1} \frac{\lambda_i}{(1 - \alpha_i)} \right)^{-1}$$
(37)

Onde:

$a_n$  é o coeficiente angular do segmento de reta  $n$  da função utilidade.

## 5.2. Estimação de parâmetros do ECP\_G

Um exemplo importante mencionado da utilização do ECP\_G com  $N = 1$ , para o caso multi-estágio, é o cálculo do PLD no mercado brasileiro de comercialização de energia. O PLD é calculado a partir da otimização do despacho hidrotérmico no sistema elétrico brasileiro, considerando um horizonte de até 5 (cinco) anos, conforme apresentado na seção 2.3. Até agosto de 2013, a função objetivo da otimização era o valor esperado do custo total da operação do sistema elétrico no horizonte de até 5 (cinco) anos (investidor neutro ao risco), tendo passado, em setembro de 2013, a ser a soma de 75% desse valor esperado e 25% do CVaR<sub>50%</sub> de cada estágio, ou seja,  $\lambda_0 = 0,75$ ,  $\lambda_1 = 0,25$  e  $\alpha_1 = 50\%$ . Na época, a escolha dos parâmetros  $\alpha$  e  $\lambda$  deu-se através da comparação dos resultados da otimização em diferentes cenários, para diferentes combinações de  $\alpha$  e  $\lambda$ , sendo um processo de tentativa e erro, com validação dos valores após a Audiência Pública ANEEL nº 86/2013.

Ressalta-se, contudo, que por ser esse um problema multi-estágio, o nível  $\alpha$  não corresponde à interpretação usual de serem os  $(1 - \alpha)$  % cenários mais críticos utilizados em simulações com o modelo, do primeiro ao último ano do horizonte de

planejamento. Na verdade, a cada estágio, o parâmetro  $\alpha$  corresponde aos  $(1 - \alpha)$  % cenários mais críticos do próprio estágio (CPAMP, 2013).

Nas seções 5.1 a 5.1.4, demonstram-se as propriedades satisfatórias da ECP\_G para ser adotado como medida de desempenho e risco, com possibilidade, inclusive, de cálculo de prêmios de risco. Contudo, para sua aplicabilidade, é necessária a existência de um modo objetivo e prático para determinação do número de níveis a ser considerado, bem como estimação dos  $\lambda$ 's.

A estimação dos parâmetros da ECP\_G pode ser dividida em três etapas:

- ✓ Determinação do número de níveis;
- ✓ Determinação de  $\alpha$ 's;
- ✓ Determinação de  $\lambda$ 's.

Para cada uma das etapas, a resposta às respectivas perguntas orienta a parametrização:

- ✓ Existem níveis meta de retorno ou risco para operação/projeto sob avaliação? Quantos e quais são esses níveis?
- ✓ Há uma relação entre os níveis pré-estabelecidos e a probabilidade de ocorrência de valores inferiores a eles ou, ainda, relação com medidas de risco como  $\text{VaR}_\alpha$  para um dado  $\alpha$ ? Caso haja, qual a probabilidade aceitável para cada nível ou o valor de  $\alpha$ ?
- ✓ Dados os níveis meta e o objetivo geral de maximizar o desempenho da operação/projeto, em uma escala de 1 a 9, qual a importância do resultado esperado abaixo de cada um dos níveis (ou do resultado esperado dos  $(1 - \alpha)$  % piores cenários) em relação aos demais e ao valor esperado da distribuição de resultados? Nessa escala, 9 é importância absoluta de um sobre o outro e 1 é de igual importância. Como a maximização de desempenho, em geral, está associada à minimização do risco e à maximização do resultado, pode-se, alternativamente, classificar a importância em relação a esses objetivos intermediários e, então, ponderar a importância deles em relação ao objetivo geral.

Um exemplo da parametrização proposta poderia ser a existência de 2 (dois) níveis meta, com um representando o risco moderado ou aceitável e o outro, o risco extremo ou inadmissível. O risco moderado poderia ser visto como o resultado

esperado dos 20% (vinte por cento) piores cenários e o risco extremo, dos 5% (cinco por cento) piores. Alternativamente, o risco moderado poderia ser o valor esperado dos resultados negativos e o risco extremo, o valor esperado dos resultados menores que a máxima perda suportável ( $P_{max}$ ). Assim, ter-se-ia  $N = 3$ ,  $\alpha_1 = 80\%$  ou  $F(0)$  e  $\alpha_2 = 95\%$  ou  $F(P_{max})$ .

Uma vez definidos os riscos moderado e extremo, estes e o valor esperado dos resultados podem ser vistos como critérios a serem comparadas e priorizados na definição da melhor estratégia para avaliação do desempenho da operação/projeto. Sugere-se, então, a utilização do método AHP com escala de 9 (nove) pontos de Saaty, apresentado na seção 3.2.4, como técnica de priorização, tendo-se como alternativas as opções disponíveis para determinadas decisões a serem tomadas sobre a operação/projeto. O exemplo da estrutura do problema é apresentado na Figura 32 e, a matriz de julgamentos, o cálculo do vetor de pesos e dos valores de consistência CI e CR, na Figura 33. Destaca-se que uma vez definida a priorização de importância dos critérios, obtém-se o vetor de pesos ( $P_1, P_2, P_3$ ) =  $(\lambda_0, \lambda_1, \lambda_2)$  associado ao vetor de critérios (valor esperado, risco moderado, risco extremo) e, conseqüentemente, o perfil de risco do investidor, sua utilidade e a ECP\_G parametrizada.

Caso haja mais de um investidor, poderá ser adotada a média geométrica dos julgamentos (priorizações) da matriz de decisão ou, alternativamente, a média aritmética ponderada dos pesos (ISHIZAKA; LABIB, 2011), obtendo-se, em ambos os casos, pesos únicos e, conseqüentemente, uma medida única para avaliação do desempenho da operação/projeto.

Cabe esclarecer que para parametrização da ECP\_G não há limitação do número de critérios, sendo  $N = n^\circ$  de critérios. Outro ponto importante é que não há necessidade de comparação de cada alternativa por critério, uma vez que o valor de cada critério para cada alternativa é calculável e diretamente comparável.



Figura 40 – Exemplo de estrutura do problema no método AHP com 3 critérios (N = 3)

Fonte: elaboração própria.

Matriz de Julgamentos (MJ)	Retorno esperado	Risco moderado esperado	Risco extremo esperado
Retorno esperado	1	J1	J2
Risco moderado esperado	1 / J1	1	J3
Risco extremo esperado	1 / J2	1 / J3	1

Soma	$S1 = 1 + 1 / J1 + 1 / J2$	$S2 = J1 + 1 + 1 / J3$	$S3 = J2 + J3 + 1$
------	----------------------------	------------------------	--------------------

Matriz de Pesos (MP)	Retorno esperado	Risco moderado esperado	Risco extremo esperado	Peso Critério (P)
Retorno esperado	$1 / S1$	$J1 / S2$	$J2 / S3$	$P1 = (1 / S1 + J1 / S2 + J2 / S3) / 3$
Risco moderado esperado	$(1 / J1) / S1$	$1 / S2$	$J3 / S3$	$P2 = ((1 / J1) / S1 + 1 / S2 + J3 / S3) / 3$
Risco extremo esperado	$(1 / J2) / S1$	$(1 / J3) / S2$	$1 / S3$	$P3 = ((1 / J2) / S1 + (1 / J3) / S2 + 1 / S3) / 3$

$$CI = \frac{\left[ \left( \frac{(MP[1,1:3] \times P)}{P1} + \frac{(MP[2,1:3] \times P)}{P2} + \frac{(MP[3,1:3] \times P)}{P3} \right) / 3 \right] - 3}{(3 - 1)}$$

$$CR = \frac{CI}{0,58}$$

Figura 41 – Exemplo de Matrizes de Julgamentos e Pesos do método AHP com 3 critérios (N = 3) e cálculo dos valores de consistência CI e CR

Fonte: elaboração própria.

Na Figura 41, observa-se o passo a passo de cálculo dos pesos e valores de consistência do modelo. As únicas avaliações do tomador de decisão são as entradas  $J1$  a  $J3$ , avaliando a importância do critério em cada linha em relação ao critério de cada coluna, segundo a escala de Saaty de 1-9, apresentada na seção 3.2.4, na Tabela 2. Uma vez fornecidas as entradas  $J1$  a  $J3$ , obtém-se a matriz de julgamentos (MJ) e é processado o cálculo da matriz de pesos (MP) e do vetor de pesos dos critérios (P), observando-se que o somatório dos elementos do vetor de pesos é 1 (um). Com a MP e o P, pode-se calcular o índice de consistência CI e a razão de consistência CR. Conforme colocado na seção 3.2.4, caso  $CR > 10\%$ , deve-se buscar o reprocessamento dos julgamentos ou redefinição do problema.

Finalmente, a ECP\_G do exemplo proposto seria dado pela eq. (38) e, alternativamente, pela eq. (39).

$$ECP\_G = P1 \times E[X] + P2 \times CVaR_{80\%} + P3 \times CVaR_{95\%} \quad (38)$$

$$ECP\_G = P1 \times E[X] + P2 \times E[X|X \leq 0] + P3 \times E[X|X \leq P_{max}] \quad (39)$$

Na formulação alternativa (eq. (39)), as propriedades de medida coerente de risco da ECP\_G não são garantidas, contudo, sua interpretação é mais clara.

Na otimização da ECP\_G, busca-se a seleção de valores a otimizar que garantam menor comprimento da cauda negativa da distribuição de resultados e/ou a redução da espessura (área abaixo da curva de distribuição) da cauda negativa, com incremento da espessura na direção da média da distribuição de resultados.

### 5.3. Conclusão

Este capítulo teve como objetivo desenvolver uma nova função de preferência, capaz de incorporar diferentes níveis de aversão ao risco do tomador de decisão (gestor), variáveis de acordo com suas faixas de preferência. A função de preferência desenvolvida, denominada ECP\_G, é inovadora e representa uma extensão, para o caso de um período, do ECP, apresentado formalmente por STREET (2010). Dentre as suas vantagens, tem-se o fato dela lidar com conceitos

usuais do mercado (valor esperado, VaR e CVaR) e de representar uma extensão de uma função que já vem sendo usada em problemas de otimização do setor elétrico. Seu diferencial é, justamente, modelar a variação do nível de aversão ao risco de um mesmo gestor, para diferentes faixas de preferência.

A primeira questão formulada para o capítulo é: “Como modelar diferentes níveis de aversão ao risco do gestor em uma função de preferência?”. Não obstante outras possíveis modelagens, como a WES (CHEN; YANG, 2011), a modelagem apresentada é uma função de preferência que pondera o valor esperado e diferentes níveis de CVaR dos resultados, com a soma dos pesos igual a 1 (um). Cada nível de CVaR é calculado em função dos pontos de alteração das preferências do gestor, que devem ser definidos pelos percentis  $\alpha$ 's ou valores de VaRs, conforme demonstrado na função de utilidade subjacente à função de preferência obtida. Vale lembrar que a ECP\_G, seguindo a Teoria da Utilidade Esperada, é obtida como o valor esperado da função utilidade subjacente a ela, que é uma função utilidade linear por partes. Essa função utilidade é apresentada no início na seção 5.1 e possui tantas partes, quantos forem as faixas de preferências do gestor. Assim, para 1 (um) ponto de alteração das preferências, a função utilidade possui 2 (duas) partes; para 2 (dois) pontos de alteração, possui 3 (três) partes, e assim por diante. Ela não é uma função utilidade clássica de Von Neumann-Morgenstern, pois a distribuição dos resultados está presente em sua formulação. De certo modo, ao ponderar o valor esperado e os CVaRs, ela altera as probabilidades dos resultados, de acordo as preferências do gestor, similar ao efeito dos pesos de decisão na Teoria do Prospecto.

Em relação à segunda questão formulada para este capítulo: “Quais as propriedades e derivações dessa função?”, uma vez tendo a ECP\_G sido obtida a partir de sua função utilidade subjacente, foi possível mostrar: (i) a presença de aversão global ao risco e neutralidade, em cada segmento; (ii) o cálculo do equivalente certo e, conseqüentemente, do prêmio de risco, que são, também, funções lineares por partes, cujo resultado depende de em qual parte da imagem da função utilidade recai a ECP\_G; (iii) o coeficiente de aversão relativa ao risco entre cada parte da função utilidade; (iv) as propriedades de uma medida coerente de risco na ECP\_G, caso definida pelos parâmetros  $\alpha$ 's.

Mostrou-se, também, que o método AHP pode ser utilizado para auxiliar a parametrização da ECP\_G, contudo, este tema merece maior aprofundamento.

## 6

### Aplicação da função de preferência estendida do CVaR a um problema de otimização da comercialização de energia eólica no ACL

A comercialização de energia no ACL é dinâmica e pode envolver diversos problemas de otimização, tais como: volume a ser vendido no ano ou semestre seguinte; sazonalização do volume anual; *swap* de submercado de um mesmo volume, entre outros.

Neste capítulo, apresenta-se a formulação e solução de um problema de otimização geral de venda da expectativa de geração do parque eólico, no horizonte do mês corrente até dezembro do ano seguinte. A solução do problema é gerada para as diferentes simulações de média mensal de geração eólica, obtidas no capítulo 4, e diferentes parametrizações da função objetivo, ou seja, diferentes perfis de aversão ao risco. O principal objetivo do capítulo é fornecer evidências que permitam esclarecer e responder a questão principal desta tese:

- ✓ Como o perfil de risco do gestor e diferentes modelos de simulação da geração eólica interferem na otimização da comercialização de energia, no mercado livre, de um parque eólico no Brasil?

O problema selecionado para representar a comercialização de energia no ACL do parque eólico resume-se na seguinte questão:

- ✓ Qual o volume de energia, já sazonalizado, a ser vendido no submercado SE/CO, a um preço fixo, maximiza a utilidade do gestor da comercialização de energia eólica no NE?

Neste problema, as variáveis de incerteza consideradas são: média mensal de geração eólica e PLD médio mensal dos submercados SE/CO e NE, que são, respectivamente, os submercados de venda e geração da energia. O submercado SE/CO é adotado como o de venda por ser o submercado com maior demanda e liquidez no SIN. As incertezas são tratadas por SMC, estando modeladas através de

cenários. Os cenários de média mensal de geração são os obtidos no capítulo 4, enquanto os cenários de PLDs médio mensais são aqueles gerados na rodada oficial do modelo Newave® para o mês de abril/2016.

Como o objetivo do problema é a alocação da geração eólica, o volume médio vendido no horizonte de otimização deve estar limitado à expectativa de máximo volume médio de geração para o horizonte. Essa restrição, normalmente, considera o horizonte anual. É necessário, também, considerar a restrição de máxima e mínima média mensal de geração para o volume mensal de venda. Assim, as restrições do problema são: (i) venda mínima mensal = 0 MWmed; (ii) venda máxima mensal = 60 MWmed; (iii) máximo volume médio de venda anual = 37 MWmed. O máximo volume médio anual de venda foi obtido a partir da série histórica de geração, apresentada na seção 4.1.1.

No caso de horizontes de otimização diferentes do anual, é necessário obter a restrição de máximo volume médio de venda para o horizonte específico ou para partições dele. No problema considerado, o horizonte é de abril/2016 a dezembro/2017 (21 meses), portanto, optou-se por definir duas restrições, baseadas nas médias máximas de geração de: (i) abril a dezembro e (ii) anual. A média máxima de geração de abril a dezembro, na série histórica, é de 40 MWmed. Assim, a restrição de máximo volume médio de geração ficou definida como: (i) 40 MWmed para o volume médio de venda de abril/2016 a dezembro/2016 (MWmed); (ii) 37 MWmed para o volume médio de venda do ano de 2017 (MWmed).

O problema adotado considera, ainda, que todo volume excedente ou deficitário para atender a venda é negociado ao PLD médio mensal do SE/CO, acrescido do ágio para negociação de energia especial incentivada com 50% de desconto na TUSD/TUST. Considera-se, ainda, que a disponibilidade média do parque é de 95% (noventa e cinco por cento) e as perdas de transmissão são estimadas em 2,5% (dois e meio por cento). Portanto, a geração líquida disponível para comercialização no centro de gravidade é a geração bruta simulada multiplicada por 92,625% (noventa e dois, seiscentos e vinte e cinco centésimos por cento), que é a multiplicação da disponibilidade por um menos as perdas de transmissão ( $92,625\% = 95\% \times (1 - 2,5\%)$ ).

Por fim, a função objetivo do problema é a minimização de menos a função de preferência estendida do CVaR generalizada ( $-ECP\_G$ ), tendo-se adotado diferentes parametrizações para avaliar a otimização do problema. Os valores dos

parâmetros para cada função objetivo, a razão de consistência do método AHP e os coeficientes de aversão relativa ao risco constam na Tabela 13.

A função objetivo 1 (Obj1) é menos o próprio valor esperado (gestor neutro ao risco). A função objetivo 2 (Obj2) considera  $N = 1$ ,  $\lambda_1 = 25\%$ , como adotado no cálculo do PLD, e  $\alpha_1 = 95\%$ , conforme POURSINHO *et al.* (2011), FÂNZERES *et al.* (2012) e LAZO *et al.* (2012). Na função objetivo 3 (Obj3) acrescenta-se uma *proxy* de risco intermediário, com  $\alpha = 80\%$  e  $N = 2$ , sendo os valores de  $\lambda$ 's obtidos a partir da aplicação do método AHP para 3 (três) critérios, conforme exemplo da seção 5.2, buscando-se manter o peso de 0,25 para o risco extremo. Na função objetivo 4 (Obj4), acrescenta-se mais um nível ( $N = 3$ ), a mediana ( $\alpha = 50\%$ ) e, novamente, os valores de  $\lambda$ 's são obtidos a partir da aplicação do método AHP, porém, para 4 (quatro) critérios, buscando-se manter o peso de 0,25 do risco extremo.

Tabela 13 – Parametrizações da função objetivo

Parâmetro	Obj1 (-E[X])	Obj2	Obj3	Obj4	Obj5	Obj6
$\lambda_1$	0	0,25	0,10	0,18	-	0,10
$\lambda_2$	-	-	0,25	0,09	0,25	0,25
$\lambda_3$	-	-	-	0,25	-	-
Modo	Percentil	Percentil	Percentil	Percentil	Valor	Valor
$\alpha_1$ ou $VaR_{\alpha_1}$	0	0,95	0,80	0,50	-	53.587.744
$\alpha_2$ ou $VaR_{\alpha_2}$	-	-	0,95	0,80	40.190.808	40.190.808
$\alpha_3$ ou $VaR_{\alpha_3}$	-	-	-	0,95	-	-
CR (AHP)	n.a.	n.a.	1,7%	4,0%	n.a.	1,7%
<b>Aversão relativa ao risco entre os segmentos i ( <math>(VaR_{i+1}, VaR_i)</math> ) e j (<math>\gamma_{i-j}</math>)</b>						
$\gamma_{0-1}$	n.a.	<b>0,87</b>	0,43	0,43	Variável	Variável
$\gamma_{1-2}$	n.a.	n.a.	<u>0,81</u>	0,35	n.a.	Variável
$\gamma_{2-3}$	n.a.	n.a.	n.a.	<u>0,79</u>	n.a.	n.a.
$\gamma_{0-2}$	n.a.	n.a.	<b>0,89</b>	0,63	n.a.	Variável
$\gamma_{0-3}$	n.a.	n.a.	n.a.	<b>0,92</b>	n.a.	n.a.
$\gamma_{1-3}$	n.a.	n.a.	n.a.	0,87	n.a.	n.a.

n.a. = não aplicável

As funções objetivo 5 e 6 (Obj5 e Obj6) são consideradas com intuito de observar o comportamento do ECP\_G quando especificado os valores de VaR, ao invés dos percentis

$\alpha$ 's. Assim, a Obj5 considera um valor de VaR extremo e  $\lambda_l = 25\%$ , como na Obj2, enquanto a Obj6 considera o mesmo VaR extremo e um VaR intermediário, com os valores de  $\lambda$ 's iguais ao da Obj3. O VaR extremo e intermediário são definidos, respectivamente, como 60% (sessenta por cento) e 80% (oitenta por cento) do valor da venda *flat* do máximo volume médio do horizonte, ou seja, 40 MWmed para os meses de abril/2016 a dezembro/2016 e 37 MWmed para os meses do ano de 2017.

Nas funções objetivo 2 a 4 (Obj2 a Obj4), observa-se a variação máxima de 0,05 dos coeficientes de aversão ao risco relativa entre o primeiro e o último segmento da função utilidade, bem como entre o penúltimo e o último segmento, mostrando certa coerência entre os perfis de risco das 3 (três) funções, no que diz respeito aos valores de interesse ( $\alpha$ 's) comuns. Outro ponto relevante é que, apesar da variabilidade dos coeficientes de aversão ao risco relativa, eles mantêm-se na ampla faixa de valores observados para o Brasil no estudo de GANDELMAN e HERNÁNDEZ-MURILLO (2014).

## 6.1.

### Modelagem matemática do problema de otimização

Uma vez descrito o problema, passa-se a sua formulação matemática. As parcelas que compõem o fluxo de caixa de cada mês “ $j$ ” para cada cenário de preços “ $s$ ” e de geração “ $w$ ” estão descritos na Tabela 14, divididos entre liquidações bilaterais e a liquidação do MCP na CCEE. O mês atual é representado por  $j = 0$ .

**Tabela 14 – Composição do fluxo de caixa de cada mês “ $j$ ” para cada cenário de preços “ $s$ ” e de geração “ $w$ ”**

Liquidação	MCP (CCEE)	Bilateral
Receita	$G_{w,j} \times h_j \times PLDNE_{s,j}$	$v_j \times h_j \times p_j$
Despesa	$-v_j \times h_j \times PLDSE_{s,j}$	
Receita/ Despesa	$-(G_{w,j} - v_j) \times h_j$ $\times PLDSE_{s,j}$	$(G_{w,j} - v_j) \times h_j$ $\times (s_j + PLDSE_{s,j})$

Onde:

$G_{w,j}$  = média mensal de geração líquida (média mensal de geração bruta X 0,9215) no mês  $j$  para o cenário de geração  $w$  (MWmed);

$v_j$  = volume de venda no mês  $j$  (MWmed);

$h_j$  = número de horas do mês  $j$ ;

$p_j$  = preço fixo de venda no mês  $j$  (R\$/MWh);

$s_j$  = spread de energia incentivada com 50% de desconto no mês  $j$  (R\$/MWh);

$PLDNE_{s,j}$  = PLD médio do NE no mês  $j$  para o cenário de preços  $s$  (R\$/MWh);

$PLDSE_{s,j}$  = PLD médio do SE no mês  $j$  para o cenário de preços  $s$  (R\$/MWh).

Na eq. (40) tem-se o resultado descontado de cada mês “ $j$ ” para cada cenário de preços “ $s$ ” e de geração “ $w$ ”, agrupado por volume de geração e venda.

$$FC_{w,s,j} = v_j \times h_j \times (p_j - PLDSE_{s,j} - s_j) \times \frac{1}{(1 + tx)^j} + G_{w,j} \times h_j \times (PLDNE_{s,j} + s_j) \times \frac{1}{(1 + tx)^j} \quad (40)$$

Onde:

$FC_{w,s,j}$  = fluxo de caixa mensal descontado para o mês  $j$ , cenário de preços  $s$  e de geração  $w$  (R\$);

$tx$  = taxa de desconto mensal (custo de capital do gestor).

Para otimização do volume de venda de cada mês, define-se, primeiramente, a função de cálculo do valor presente (VP) do fluxo de caixa descontado (FC) para os  $Nn$  cenários, onde  $Nn = Ns \times Nw$ ,  $Ns$  = total de cenários de preços e  $Nw$  = total de cenários de geração, conforme eq. (41). Posteriormente, os cenários de VP são os dados de entrada para cálculo e maximização da ECP\_G. Para maximização da ECP\_G, a função objetivo adotada é  $-ECP\_G$ , devido à rotina de otimização buscar minimizar a função objetivo (eq. (42)). Todos os cálculos de otimização foram processados em R (R CORE TEAM, 2015).

$$VP_{w,s} = \sum_{j=1}^{21} FC_{w,s,j} \quad (41)$$

Onde:

$VP_{w,s}$  = valor presente do fluxo de caixa do cenário de preços  $s$  e de geração  $w$ .

Na eq. (42) tem-se a formalização do problema de otimização.

$$\begin{aligned}
 obj &= \max_{v_j, j \in [1,21]} ECP\_G(VP) = \min_{v_j, j \in [1,21]} - ECP\_G(VP) \\
 \therefore obj &= \min_{v_j, j \in [1,21]} \left( -\lambda_0 E[VP] - \sum_{i=1}^N \lambda_i CVaR_{\alpha_i}[VP] \right) \\
 \text{sujeito a } &\begin{cases} 0 \leq v_j \leq 60, j \in [1,21] \\ 0 \leq \frac{\sum_{j=1}^9 v_j \times h_j}{\sum_{j=1}^9 h_j} \leq 40 \\ 0 \leq \frac{\sum_{j=10}^{21} v_j \times h_j}{\sum_{j=10}^{21} h_j} \leq 37 \end{cases}
 \end{aligned} \tag{42}$$

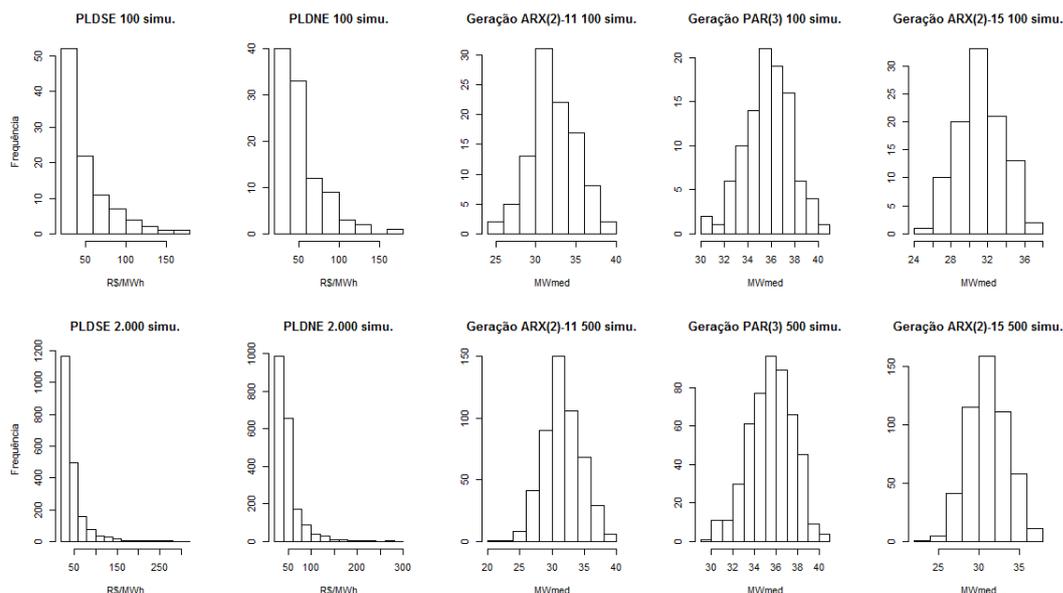
Os valores das variáveis fixas do problema estão presentes na Tabela 15. Os preços foram definidos a partir de referências: (i) de negociações do mercado para os períodos considerados; (ii) da curva de preços para energia convencional divulgada pela plataforma de negociações Brix (BRIX, 2016); (iii) do Boletim Semanal da Curva Forward, produzido a partir de um *pool* de preços gerenciado pela Dcide (DCIDE, 2016). As referências de preços foram obtidas no período de 30/03/2016 a 01/04/2016. A taxa de desconto adotada tomou como referência a taxa de desconto interna ao programa de otimização Newave®, fixada em 12,0% a.a. (doze por cento ao ano).

**Tabela 15 – Valores das variáveis fixas do problema de otimização**

Parâmetro	Valor	Unidade
<b>h</b>	(720, 744, 720, 744, 744, 720, 743, 720, 744, 744, 673, 744, 720, 744, 720, 744, 744, 720, 743, 720, 744)	Horas
<b>p</b>	(88, 88, 88, 88, 88, 88, 88, 88, 88, 88, 135, 135, 135, 135, 135, 135, 135, 135, 135, 135, 135)	RMWh
<b>s</b>	(14, 15, 15, 15, 15, 15, 15, 15, 15, 20, 25, 25, 25, 18, 18, 18, 18, 18, 18, 18, 18, 25)	R\$/MWh
<b>tx</b>	1,0	% a.m.

O número total de cenários de VP obtidos foi de 10.000 (dez mil) ( $Nn = 10.000$ ), tendo-se 100 (cem) cenários de geração ( $Nw = 100$ ) e 100 (cem) cenários de preços ( $Ns = 100$ ). Apesar de terem sido gerados 500 cenários de geração e 2.000

de preços, limitou-se o número de cenários utilizados na otimização, mantendo-se a distribuição original, para evitar uma demanda computacional exagerada, além de observar-se equivalência dos resultados com a redução do número de cenários. Na Figura 42, apresenta-se o histograma do valor médio no horizonte de otimização de cada uma das variáveis de incerteza, para os 100 (cem) cenários utilizados na otimização e para o total de cenários gerados (500 ou 2.000)



**Figura 42 – Histograma do valor médio no horizonte de otimização das variáveis de incerteza para os cenários utilizados e o total de cenários gerados**

O total de cenários de VP utilizados supera o de trabalhos semelhantes, encontrando-se: 100 (cem) e 1.000 (mil) cenários, respectivamente, para 2 (duas) e 3 (três) incertezas em POURSINHO *et al.* (2012); 1.000 (mil) cenários em POURSINHO *et al.* (2011); 80 (oitenta) cenários por período, totalizando 5.760 (cinco mil, setecentos e sessenta) cenários, no problema multi-estágio de GONZÁLEZ *et al.* (2014).

## 6.2. Resultados e discussão

Conforme apresentado, o problema de otimização do volume de energia, já sazonalizado, a ser vendido no submercado SE/CO, a um preço fixo, que maximiza a utilidade do gestor da comercialização de energia eólica no NE, foi resolvido para 6 (seis) funções objetivo e, conseqüentemente, funções utilidade diferentes e, para

3 (três) modelos diferentes de simulação da geração, totalizando 18 (dezoito) otimizações.

Nesta seção apresentam-se os principais resultados de cada uma das dezoito otimizações, comparando-se as diferenças e semelhanças para uma mesma função utilidade e diferentes modelos de simulação de geração e, para um mesmo modelo de simulação e diferentes funções utilidade.

O volume médio de venda otimizado para o período abril/2016 a dezembro/2016 foi, para todas as otimizações, de 40 MWmed (quarenta megawatt-médios). Para o ano de 2017, o volume de venda médio otimizado foi de 36,993 MWmed para simulação com ARX(2)-15 (dez-mai) e Obj6 e, de 37 MWmed (trinta e sete megawatt-médios) para todas as demais otimizações. Na Tabela 16, estão listados os resultados das estatísticas média, desvio-padrão, VaR<sub>50%</sub>; 80%; 95% e CVaR<sub>50%</sub>; 80%; 95%, em R\$, bem como prêmio de risco (em R\$/MWh vendido) e ECP\_G das distribuições de cenários de VP resultantes das otimizações com Obj1 a Obj4 e cada um dos modelos de simulação.

O VP resultante da otimização determinística (em R\$), para cada um dos modelos de simulação foi de: 52.623.036 para simulações com ARX(2)-11, 56.657.204 para simulações com PAR(3) e 52.623.001 para simulações com ARX(2)-15 (dez-mai). Na otimização determinística, considera-se as médias mensais de PLD do SE/CO e NE e, de geração eólica para cada modelo de simulação, tendo-se um único cenário para otimização do volume de venda.

**Tabela 16 – Estatísticas das distribuições de cenários de VP otimizados (Obj1 a Obj4)**

	<b>Obj1</b>	<b>Obj2</b>	<b>Obj3</b>	<b>Obj4</b>
<b>Média</b>				
ARX(2)-11	53.583.314	53.404.077	53.367.570	53.261.701
PAR(3)	56.651.186	56.473.130	56.429.238	56.335.291
ARX(2)-15	52.622.622	52.453.769	52.379.432	52.280.797
<b>Desvio-padrão</b>				
ARX(2)-11	5.459.360	4.718.854	4.611.661	4.437.049
PAR(3)	4.606.656	3.762.947	3.646.031	3.440.171
ARX(2)-15	5.474.346	4.753.924	4.596.466	4.432.925
<b>ECP_G</b>				
ARX(2)-11	53.583.314	50.505.699	49.843.200	49.315.531
PAR(3)	56.651.186	54.503.018	54.018.844	53.613.234
ARX(2)-15	52.622.622	49.449.366	48.756.909	48.247.016

**Prêmio de Risco (R\$/MWh)**

ARX(2)-11	0,00	1,96	3,20	3,88
PAR(3)	0,00	1,19	1,95	2,90
ARX(2)-15	0,00	1,96	3,24	3,85
<b>CVaR<sub>50%</sub></b>				
ARX(2)-11	49.876.026*	50.073.069*	50.095.486*	50.088.566
PAR(3)	53.617.849*	53.868.879*	53.880.474*	53.896.526
ARX(2)-15	48.960.015*	49.134.975*	49.146.280*	49.144.565
<b>CVaR<sub>80%</sub></b>				
ARX(2)-11	45.892.445*	46.701.947*	46.770.907	46.845.798
PAR(3)	50.770.389*	51.630.733*	51.677.990	51.764.332
ARX(2)-15	44.664.615*	45.530.658*	45.613.941	45.702.737
<b>CVaR<sub>95%</sub></b>				
ARX(2)-11	39.518.718*	41.810.566	41.908.757	42.071.405
PAR(3)	46.231.865*	48.592.680	48.688.159	48.848.520
ARX(2)-15	37.908.285*	40.436.156	40.595.538	40.771.862
<b>VaR<sub>50%</sub></b>				
ARX(2)-11	53.983.235*	53.773.582*	53.749.233*	53.671.140
PAR(3)	56.664.718*	56.477.062*	56.453.476*	56.401.297
ARX(2)-15	53.309.878*	53.035.709*	52.979.724*	52.889.638
<b>VaR<sub>80%</sub></b>				
ARX(2)-11	50.538.548*	50.376.873*	50.403.753	50.391.252
PAR(3)	54.004.388*	53.950.844*	53.968.160	53.977.372
ARX(2)-15	49.687.139*	49.406.849*	49.425.377	49.420.535
<b>VaR<sub>95%</sub></b>				
ARX(2)-11	43.861.243*	45.265.936	45.343.637	45.415.332
PAR(3)	49.323.858*	50.687.481	50.760.532	50.907.198
ARX(2)-15	42.165.476*	43.887.569	44.019.564	44.157.046

\*Valores não utilizados no cálculo do ECP\_G ou função utilidade  
ARX(2)-15 nesta tabela refere-se ao modelo ARX(2)-15 (dez-mai).

Na Tabela 17, estão listados os resultados das estatísticas média, desvio-padrão e CVaR<sub>intermediário; extremo</sub>, em R\$, bem como prêmio de risco (em R\$/MWh vendido), ECP\_G,  $\alpha_{intermediário; extremo}$  e coeficientes de aversão relativa ao risco das distribuições de cenários de VP resultantes das otimizações com Obj5 e Obj6 e cada um dos modelos de simulação.

**Tabela 17 – Estatísticas e coeficientes de aversão relativa ao risco das distribuições de cenários de VP otimizados (Obj5 a Obj6)**

	<b>Obj5</b>	<b>Obj6</b>
<b>Média</b>		
ARX(2)-11	53.359.295	53.326.678
PAR(3)	56.223.703	56.216.849
ARX(2)-15	52.362.830	52.240.269
<b>Desvio-padrão</b>		
ARX(2)-11	4.669.783	4.606.872
PAR(3)	3.706.412	3.655.898
ARX(2)-15	4.671.639	4.498.934

<b>ECP_G</b>		
ARX(2)-11	49.382.262	49.008.060
PAR(3)	52.060.559	51.600.130
ARX(2)-15	48.484.711	48.179.397
<b>Prêmio de Risco (R\$/MWh)</b>		
ARX(2)-11	1,55	2,00
PAR(3)	0,35	0,91
ARX(2)-15	1,89	1,99
<b>CVaR<sub>intermediário</sub> (CVaR<sub>1</sub>)</b>		
ARX(2)-11	49.898.037*	49.927.468
PAR(3)	51.027.902*	51.107.307
ARX(2)-15	49.675.469*	49.730.853
<b>CVaR<sub>extremo</sub> (CVaR<sub>2</sub>)</b>		
ARX(2)-11	37.451.164	37.411.890
PAR(3)	39.571.126	39.793.790
ARX(2)-15	36.850.354	37.000.545
<b><math>\alpha</math><sub>intermediário</sub> (<math>\alpha_1</math>)</b>		
ARX(2)-11	52,01%*	51,66%
PAR(3)	81,66%*	81,66%
ARX(2)-15	41,70%*	40,28%
<b><math>\alpha</math><sub>extremo</sub> (<math>\alpha_2</math>)</b>		
ARX(2)-11	98,81%	98,86%
PAR(3)	99,97%	99,97%
ARX(2)-15	98,40%	98,39%
<b>Aversão relativa ao risco: <math>\gamma_{0-1}</math></b>		
ARX(2)-11	0,97	0,24
PAR(3)	1,00	0,46
ARX(2)-15	0,95	0,20
<b>Aversão relativa ao risco: <math>\gamma_{1-2}</math></b>		
ARX(2)-11	n.a.	0,96
PAR(3)	n.a.	1,00
ARX(2)-15	n.a.	0,95
<b>Aversão relativa ao risco: <math>\gamma_{0-2}</math></b>		
ARX(2)-11	n.a.	0,97
PAR(3)	n.a.	1,00
ARX(2)-15	n.a.	0,96

\*Valores não utilizados no cálculo do ECP\_G ou função utilidade  
 ARX(2)-15 nesta tabela refere-se ao modelo ARX(2)-15 (dez-mai).  
 n.a. = não aplicável

Ao observar a Tabela 16, os dois primeiros pontos observados são que da função objetivo 1 à 4 (Obj1 à Obj4), para cada um dos modelos de simulação, a média (valor esperado) e o desvio-padrão da distribuição de VP's decrescem, enquanto o prêmio de risco cresce. O mesmo é observado em relação à Obj5 e Obj6 (Tabela 17). Esse resultado é coerente com o fato do nível de aversão ao risco aumentar da primeira à quarta função objetivo (Obj1 à Obj4), conforme consta na Tabela 13, bem como da Obj5 à Obj6, conforme Tabela 17. A medida que a aversão ao risco aumenta, em função do efeito dos parâmetros  $\lambda$ 's, a otimização busca

reduzir os valores da cauda inferior da distribuição de VP's, em troca de alguma redução do valor esperado. Como consequência deste efeito, além da redução do valor esperado, há redução da volatilidade (desvio-padrão) dos VP's e aumento do prêmio de risco pago pela redução dos valores da cauda inferior, vistos como risco. Em POURSINHO *et al.* (2011) observa-se o mesmo comportamento em relação ao desvio-padrão e média dos resultados, contudo, o incremento da aversão ao risco é modelado pela variação do único parâmetro  $\lambda$ .

Outra observação geral é que as otimizações resultam na venda dos máximos volumes médios para as 2 (duas) partições do horizonte, passando o problema de otimização a ser um problema de sazonalização dos máximos volumes médios para cada uma das partições do horizonte. Esse resultado parece encontrar amparo no fato das simulações de PLDs (vide Figuras 42 e 44) apresentarem, predominantemente, valores inferiores ao preço de venda.

Em relação aos valores de CVaR e VaR, observa-se predomínio do aumento do CVaR (redução do risco) da Obj1 à Obj4 e da Obj5 à Obj6, para cada um dos modelos de simulação, em acordo com o aumento da aversão ao risco. As únicas exceções são o CVaR<sub>50%</sub> na Obj4 para as simulações com ARX(2)-11 e ARX(2)-15 (dez-mai). Contudo, para o VaR, não há uniformidade no comportamento, o que pode ser resultado do VaR não ser uma medida coerente de risco, exceto sob condições particulares das distribuições de resultados (OLIVEIRA, 2009).

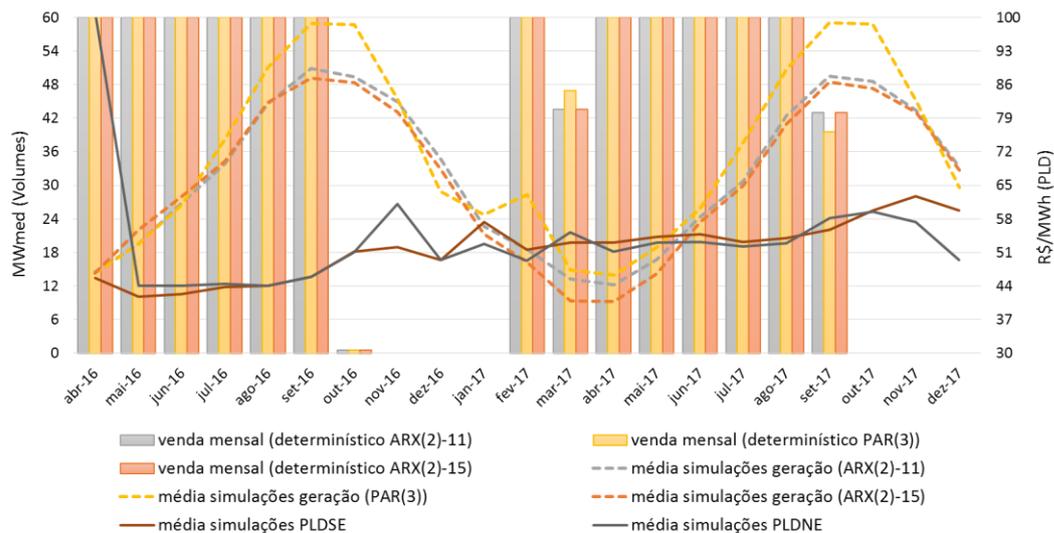
Uma última observação geral é que os valores de médias, VaRs e CVaRs são maiores para as otimizações com simulações de geração pelo modelo PAR(3), enquanto os desvio-padrões são menores. Uma possível explicação para os valores mais elevados reside nas simulações de geração com modelo PAR(3), apresentadas na Seção 4.3, demonstrarem tendência a valores mais altos de geração do que as simulações com os modelos ARX(2). Sobre o desvio-padrão, não é possível ter uma visão clara do efeito, visto que o desvio-padrão do modelo PAR(3) é variável, sendo ora maior, ora menor, que o dos modelos ARX(2).

Em relação aos resultados da otimização com as funções objetivo 5 e 6 (Obj5 e Obj6), foram testados outros valores de VaR intermediário e extremo e observou-se que caso os valores de VaR estejam fora da faixa dos resultados de VP's, o cálculo do ECP\_G retorna vazio, por não ser possível calcular os valores de CVaR. Portanto, na otimização, o modelo busca uma nova alocação de volumes que permita o cálculo dos CVaRs e, conseqüentemente, do ECP\_G, retornando decisões

não ótimas. Este resultado é importante para alertar que o uso do ECP\_G com determinação dos valores de VaRs, ao invés de  $\alpha$ 's, precede de conhecimento da faixa de valores possíveis dos resultados a serem otimizados.

Nos casos da Obj5 e Obj6, uma vez que são determinados valores de corte e, não, percentis, possibilita-se melhor comparação dos resultados para as diferentes simulações e compreensão do posicionamento desses valores nas diferentes distribuições de VP's otimizados. Observa-se que o percentil  $\alpha$  do  $VaR_{\text{extremo}}$  é bem próximo para todas as simulações (aproximadamente 99% (noventa e nove por cento)), enquanto o percentil  $\alpha$  do  $VaR_{\text{intermediário}}$  é bem diferente para cada simulação, estando na faixa de 50% (cinquenta por cento) para simulação com ARX(2)-11, 80% (oitenta por cento) para simulação com PAR(3) e 40% (quarenta por cento) para simulação com ARX(2)-15 (dez-mai). O percentil de 0,99 para uma faixa de risco extremo é alto, mas ainda coerente com o praticado pelo mercado. O percentil de 0,80 para risco intermediário também é coerente, no entanto, os percentis de 0,40 e 0,50 para risco intermediário são baixos. Estas observações reforçam a importância de conhecimento prévio de um esboço da distribuição e valores de resultados possíveis para uso da ECP\_G com determinação dos valores de VaRs, ao invés de  $\alpha$ 's.

Analisados os resultados de características das distribuições de VP's otimizados, falta responder à questão formulada no início deste capítulo: "Qual o volume de energia, já sazonalizado, a ser vendido no submercado SE/CO, a um preço fixo, maximiza a utilidade do gestor da comercialização de energia eólica no NE?". A resposta a esta questão é apresentada nas Figuras 43 e 45 a 48, que contêm o volume de venda (em MWmed) para cada mês do horizonte, ou seja, o volume sazonalizado, resultante da otimização com cada uma das funções objetivo e modelos de simulação da média mensal geração eólica. Na Figura 43, apresenta-se o volume de venda sazonalizado otimizado para o caso determinístico, para cada modelo de simulação, além das médias mensais das simulações de geração eólica, por modelo, e médias mensais de PLD do SE/CO e NE. Nas Figuras 45 a 47, considerando os modelos de simulação de geração eólica: ARX(2)-11, PAR(3) e ARX(2)-15 (dez-mai), respectivamente, apresenta-se o volume de venda sazonalizado otimizado para as funções objetivo 1 a 4 (Obj1 a Obj4). Na Figura 48, apresenta-se o volume de venda sazonalizado otimizado para as funções objetivo 5 e 6 (Obj5 e Obj6).

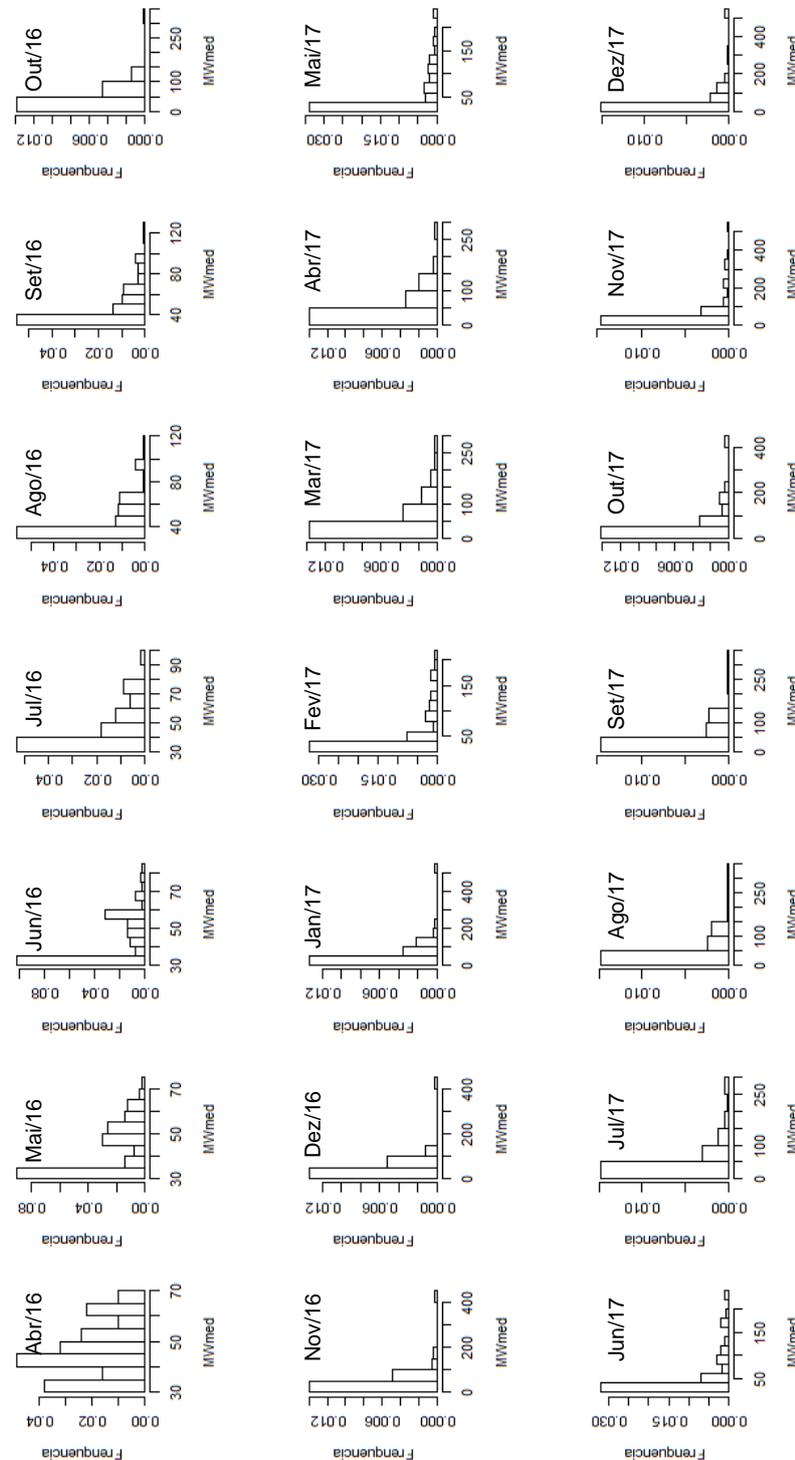


**Figura 43 – Volumes sazonalizados de venda otimizados para o caso determinístico e médias mensais das simulações de: geração eólica, PLD do SE/CO e PLD do NE**

Na Figura 43, observa-se uma tendência à alocação de grandes volumes de venda tanto em meses de alta quanto de baixa geração eólica, bem como a não alocação de volume nos últimos meses de cada ano e em janeiro do segundo ano. Este resultado pode parecer contraintuitivo, contudo, há de se observar que as médias mensais de PLD do SE/CO são substancialmente inferiores aos preços de venda, mesmo quando acrescidos os valores de *spread* de energia incentivada com 50% de desconto na TUSD/TUST. Portanto, o modelo de otimização parece buscar um duplo ganho para o gestor, qual seja: (i) em meses de menor geração, o ganho provém da diferença entre o preço de venda e o preço de mercado (PLD SE/CO + *spread*) para compra do volume de energia remanescente para atender o contrato; (ii) nos meses de maior geração, o ganho provém da venda do volume excedente de geração ao preço de mercado (PLD SE/CO + *spread*). No caso do gestor neutro ao risco (Obj1) os volumes alocados a cada mês são essencialmente iguais aos alocados no caso determinístico.

Um ponto de consenso entre as otimizações é a alocação, no ano de 2016, idêntica à dos casos determinísticos (Figura 43), à exceção dos casos da Obj5 e Obj6, com simulação de geração eólico pelo modelo PAR(3). Enquanto isso, a principal divergência entre os casos determinísticos e neutro ao risco (Obj1) e os casos avessos ao risco (Obj2 a Obj6) é a alocação em janeiro/2017 (Figuras 45 a 48). Enquanto aqueles alocam o mínimo volume mensal de venda (0 MWmed), estes alocam o máximo volume mensal de venda (60 MWmed), à exceção da Obj5

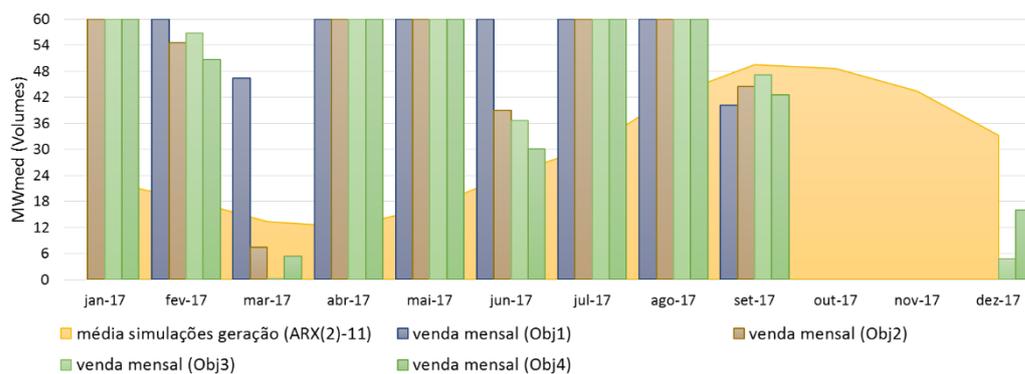
e Obj6, com simulação pelo modelo PAR(3), que alocam, respectivamente, 52 e 47 MWmed.



**Figura 44 – Histogramas mensais das simulações de PLD do SE/CO no horizonte de otimização**

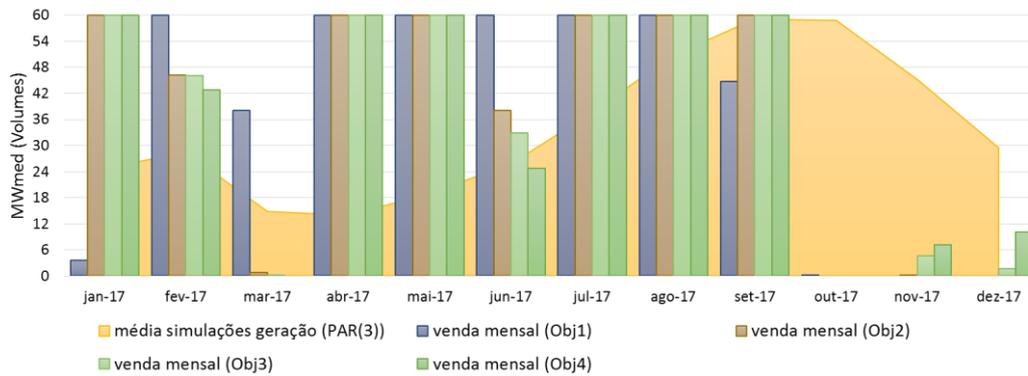
A compensação dessas diferenças nas alocações de janeiro/2017 ocorre predominantemente nos meses de março/2017 e junho/2017, com redução de 20%

(vinte por cento) a 100% (cem por cento) do volume alocado para o gestor neutro ao risco. Os volumes alocados nestes meses, nos casos determinístico e do gestor neutro ao risco (Obj1), situam-se nas faixas de 38 a 46 MWmed (março/2017) e 60 MWmed (junho/2017), enquanto nos casos do gestor avesso ao risco (Obj2 a Obj6) limitam-se às faixas de 0 a 21 MWmed (março/2017) e 30 a 48 MWmed (junho/2017). Um dos pontos que contribui para o aumento do volume alocado em janeiro/2017 nos casos avessos ao risco (Obj2 a Obj6), com redução dos volumes de março/2017 e junho/2017 diz respeito à distribuição dos cenários de PLDs nesses meses. Apesar da média mais elevada do PLDSE em janeiro/2017, a maioria dos cenários concentra-se na faixa de PLDs inferiores a 50,00 R\$/MWh, enquanto em março/2017 e junho/2017 há maior dispersão dos valores de PLDSE (vide histogramas mensais do PLD do SE/CO na Figura 44). Como nas funções objetivos com aversão ao risco (Obj2 a Obj6), os cenários acabam recebendo pesos diferenciados, a dispersão dos cenários ganha relevância em relação à média.



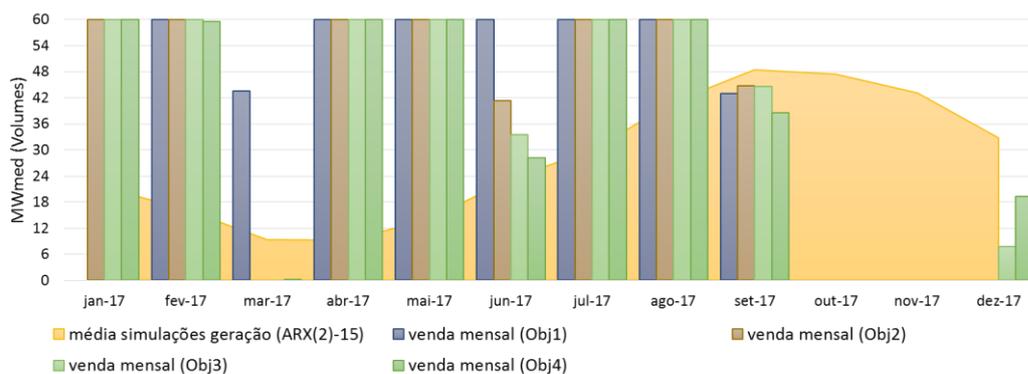
**Figura 45 – Volumes sazonalizados de venda otimizados para o ano de 2017 com simulação de geração pelo modelo ARX(2)-11 e Obj1 a Obj4**

Além dos meses de janeiro/2017, março/2017 e junho/2017, para as otimizações com as simulações de geração eólica pelo modelo ARX(2)-11, os meses de fevereiro/2017, setembro/2017 e dezembro/2017, também, sofrem alteração dos volumes de venda alocados à medida que aumenta a aversão ao risco do gestor. Contudo, em relação ao gestor neutro ao risco (Obj1), essas variações são menores do que as observadas para os meses de janeiro, março e junho de 2017. Nota-se, ainda, que para gestores avessos ao risco, o volume de venda alocado parece seguir melhor o perfil da média mensal de geração (vide Figura 45).



**Figura 46 – Volumes sazonalizados de venda otimizados para o ano de 2017 com simulação de geração pelo modelo PAR(3) e Obj1 a Obj4**

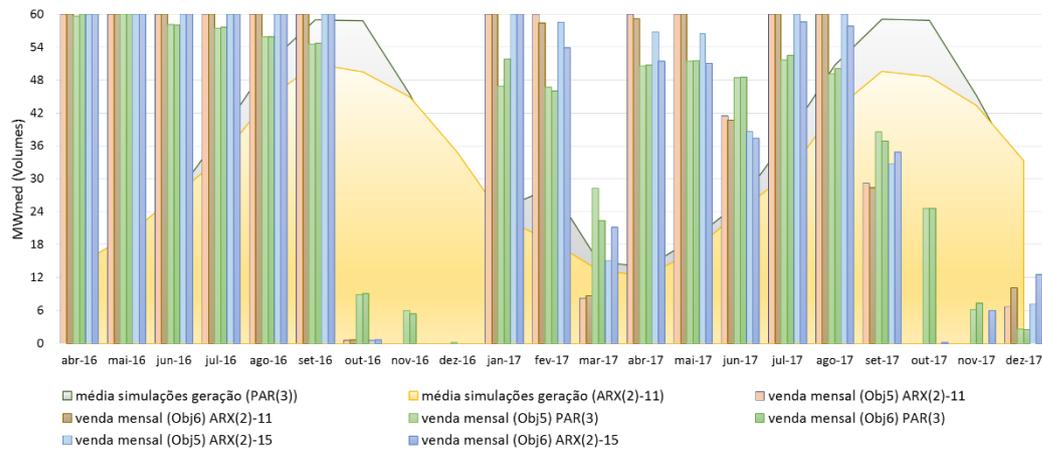
Para as otimizações com as simulações de geração eólica pelo modelo PAR(3) (Figura 46), além dos meses já mencionados nos casos de simulações com o modelo ARX(2)-11, os meses de outubro/2017 e novembro/2017, também, sofrem alteração dos volumes de venda alocados à medida que aumenta a aversão ao risco do gestor. Neste caso, aos meses com maiores variações em relação ao gestor neutro ao risco (Obj1) são os mesmos que no caso de uso do modelo ARX(2)-11 (janeiro, março e junho de 2017), seguidos pelos meses de setembro/2017 e fevereiro/2017.



**Figura 47 – Volumes sazonalizados de venda otimizados para o ano de 2017 com simulação de geração pelo modelo ARX(2)-15 (dez-mai) e Obj1 a Obj4**

Os resultados das alocações do volume de venda nas otimizações com simulação de geração eólica pelo modelo ARX(2)-15 (dez-mai) e Obj1 a Obj4 (Figura 47) são similares aos resultados para os casos do modelo ARX(2)-11. Contudo, não se observa variação do volume alocado em fevereiro/2017 e, em março/2017, o volume alocado nos casos avessos ao risco (Obj2 a Obj4) é nulo.

Uma possível explicação para esta alocação é a presença de *La Niña* e Dipolo Negativo do Atlântico nesse mês, que reduzem a expectativa de geração eólica.

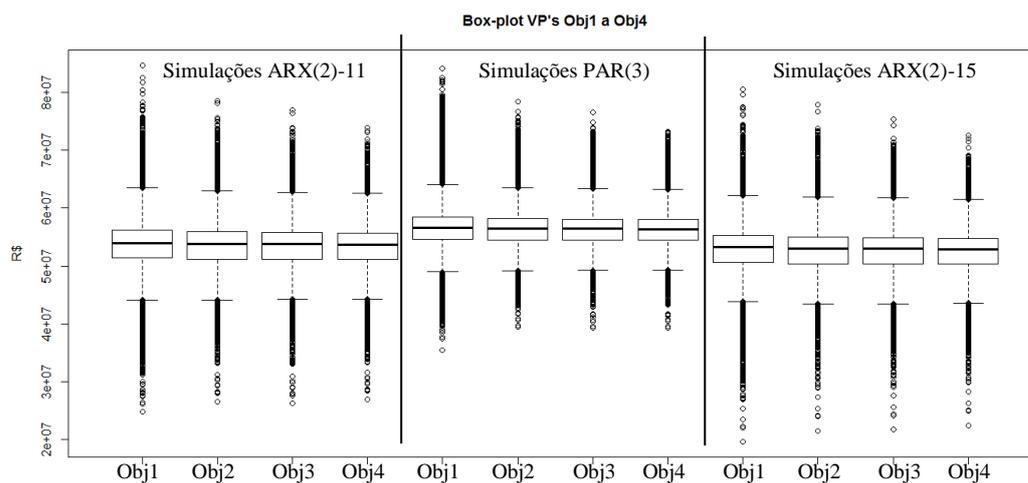


**Figura 48 – Volumes sazonalizados de venda otimizados para Obj5 e Obj6**

Na Figura 48 é apresentado o resultado das alocações para as funções objetivo 5 e 6 (Obj5 e Obj6) e cada um dos modelos de simulação da média mensal de geração eólica. As alocações para simulações com os modelos ARX(2)-11, PAR(3) e ARX(2)-15 (dez-mai) estão, respectivamente, nas cores vermelho, verde e azul, sendo o tom mais claro para Obj5 e mais escuro, para Obj6. A sazonalização para as simulações com PAR(3) difere da observada com os modelos ARX(2), havendo alocações em outubro e novembro. Já a sazonalização para as simulações com ARX(2)-11 tende a valores mais extremos. Para o caso da Obj6, as alocações nos meses de março/2017 a maio/2017, setembro/2017 e novembro/2017 são mais semelhantes para as simulações com PAR(3) e ARX(2)-15 (dez-mai). De modo geral, observa-se, ainda, que os volumes alocados para os casos com simulação pelo modelo ARX(2)-15 (dez-mai), a partir de fevereiro/2017, são menores que os alocados para os casos com simulação pelo modelo ARX(2)-11, exceto nos meses de março/2017, setembro/2017 e dezembro/2017. Uma possível explicação é a existência de um fator redutor da geração eólica fixo, de setembro/2016 a dezembro/2017, em função da presença de *La Niña*, e sua interação com a busca de proteção contra valores estipulados de VaR. Entre fevereiro/2017 e maio/2017 há, ainda, a presença de Dipolo Negativo do Atlântico, representando um fator redutor extra da geração eólica. O maior volume alocado em março/2017 pode decorrer da menor expectativa de geração neste mês, quando das simulações com ARX(2)-15

(dez-mai) e dos baixos valores de PLD. Já os maiores volumes em setembro/2017 e dezembro/2017, podem ter relação, respectivamente, com a maior expectativa de geração eólica e os menores valores de PLDNE. Por fim, as diferenças de sazonalização entre Obj5 e Obj6 para as simulações com ARX(2)-11, PAR(3) e ARX(2)-15 (dez-mai) são, respectivamente: imperceptíveis; pequenas e pontuais; pequenas e presentes na maioria dos meses de 2017.

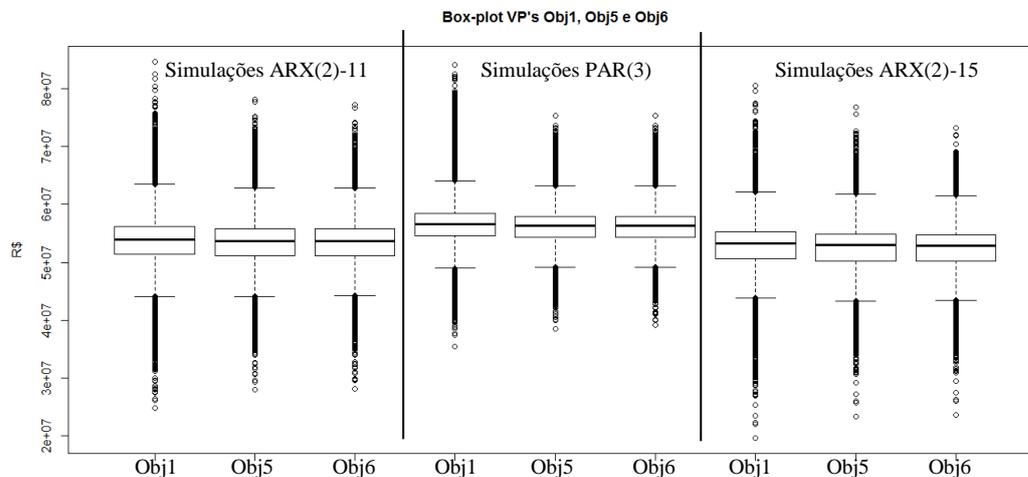
Para finalizar a análise dos resultados, nas Figuras 49 e 50, apresentam-se os gráficos *box-plot* dos cenários de VP's resultantes das otimizações. Uma vez que os cenários de VP's resultantes das otimizações são equiprováveis, observar os gráficos *box-plot* é uma *proxy* do que se observa nos gráficos de distribuição dos resultados. Independentemente do modelo de simulação das médias mensais de geração eólica, observa-se redução tanto dos extremos “positivos” (maiores resultados) quanto dos “negativos” (menores resultados), à medida em que aumenta a aversão ao risco (Obj1 à Obj4 e Obj1 em relação às Obj5 à Obj6). Este resultado é coerente com a redução do desvio-padrão observada nas Tabelas 16 e 17. Contudo, da Obj5 à Obj6, para o caso da simulação de geração eólica com modelo PAR(3), não é possível visualizar, com clareza, uma diferença entre os gráficos.



**Figura 49 – Box-plot dos cenários de VPs para as funções objetivo parametrizadas por valores de  $\alpha$ 's**

A redução dos extremos corresponde, também, à redução da probabilidade associada aos menores resultados e à concentração da probabilidade associada aos

resultados intermediários, à medida em que aumenta a aversão ao risco. Esse comportamento condiz com o esperado na presença de aversão ao risco.



**Figura 50** – *Box-plot* dos cenários de VPs para as funções objetivo parametrizadas por valores de VaRs

### 6.3. Conclusão

Neste capítulo, foram buscadas evidências que permitissem conduzir a resposta da questão principal desta tese: “Como o perfil de risco do gestor e diferentes modelos de simulação da geração eólica interferem na otimização da comercialização de energia, no mercado livre, de um parque eólico no Brasil?”.

Em linhas gerais, observou-se nos casos do problema determinístico de otimização ou do gestor neutro a risco, que as diferentes simulações de geração eólica, provenientes dos diferentes modelos, em nada ou pouco alteraram a quantidade e alocação do volume de venda de energia eólica. As diferenças de resultados observadas limitaram-se a valores maiores ou menores, em função das diferenças de volumes de geração eólica simulados por cada um dos 3 (três) modelos.

Para os casos de diferentes perfis de aversão ao risco do gestor, com a ECP\_G parametrizada pelos  $\alpha$ 's (Obj2 a Obj4), observou-se a manutenção do volume total de venda para todas as simulações de geração eólica, bem como a manutenção do comportamento de incremento ou decremento da energia alocada no mês, em relação ao aumento ou redução do grau de aversão ao risco, para a maioria dos

meses. Os volumes alocados mês a mês, contudo, ora foram os mesmos (máximo ou mínimo volume mensal de venda possível), ora divergiram muito, ora pouco. Observou-se, ainda, particularidades nas alocações quando das simulações com o modelo ARX(2)-15 (dez-mai), que parecem relacionadas à presença de fenômenos climáticos.

As otimizações para esses diferentes perfis de aversão ao risco do gestor, tiveram resultados coerentes com o esperado, com redução da média e desvio-padrão e aumento dos CVaRs e prêmio de risco, à medida que se aumentou o nível de aversão ao risco, com inclusão de mais pontos de corte na função de preferência e reparametrização dos pesos. Apesar do mesmo grau de aversão ao risco ter sido considerado para as 3 (três) simulações, em função das diferenças de volumes de venda alocados mês a mês e de geração eólica simulados, os valores das medidas citadas foram diferentes para cada modelo de simulação.

No caso da definição do perfil de risco do gestor, com a ECP\_G parametrizada por valores de VaR, percebeu-se o risco dessa aplicação, com distorção da otimização, caso os valores de VaR estipulados estejam fora da faixa de resultados otimizados possíveis. Nos casos da Obj5 e Obj6 tomou-se o devido cuidado para que isto não ocorresse e observou-se que houve maior dispersão dos volumes alocados entre os meses.

## 7 Considerações finais

Esta tese buscou avaliar a otimização comercial de um parque eólico no mercado livre de energia brasileiro, considerando diferentes modelos de simulação da incerteza de geração eólica e níveis de aversão ao risco do gestor. O horizonte de otimização considerado foi de 21 (vinte e um) meses, com discretização mensal. Apesar de longo, este horizonte é adequado à realidade da comercialização de energia no mercado livre brasileiro. Além da incerteza de geração eólica, o modelo de otimização considerou a incerteza de preços de energia, através da simulação do modelo oficial de cálculo de preços do setor.

Os diferentes modelos de simulação da média mensal de geração eólica adotados buscaram revelar a influência da consideração de variáveis climáticas e de volatilidade mensal sobre as simulações, previsões e resultados da otimização. Os modelos selecionados foram autorregressivos com variáveis exógenas e periódicos. Tanto a incorporação de variáveis climáticas exógenas, quanto a representação de volatilidade mensal, agregaram capacidade preditiva na previsão de geração eólica. Para o parque eólico estudado, as variáveis climáticas mais relevantes foram *El Niño* e Dipolos Positivo e Negativo do Atlântico (no período de dezembro a maio), contribuindo aquelas para incremento da geração eólica e, esta para redução. O modelo com volatilidade mensal apresentou os melhores índices de acurácia de previsão, contudo, tendeu a simulações com valores mais elevados.

Portanto, sob a ótica de previsão de médias mensais de geração eólica, sugere-se a utilização do modelo com representação da volatilidade mensal (PAR (3)) para o parque estudado, ao passo que para avaliações do risco da geração eólica deste parque, sugere-se a simulação de médias mensais de geração eólica a partir do modelo com *dummies* de variáveis climáticas (ARX(2)-15 (dez-mai)).

Para consideração de diferentes níveis de aversão ao risco do gestor, desenvolveu-se uma nova função de preferência, capaz de modelar a variação do nível de aversão ao risco de um mesmo gestor, para diferentes faixas de preferência,

definidas a partir de percentis  $\alpha$ 's de  $\text{VaR}_\alpha$ . A partir dessa função é possível calcular equivalente certo, prêmios de risco e coeficientes de aversão ao risco relativos, isto é, entre as faixas de preferência. A função de preferência desenvolvida é uma ponderação entre valor esperado e níveis de CVaR dos resultados. Assim, seu cálculo pode ser visto como uma alteração das probabilidades dos resultados, de acordo as preferências e valores de interesse do gestor, similar ao efeito dos pesos de decisão na Teoria do Prospecto.

O gestor avesso ao risco abordado é, em um primeiro momento, o gestor de um projeto ou grupo de projetos afins dentro de um grupo empresarial, portanto é das preferências desse gestor dentro do grupo que a tese trata. Apesar da capacidade de diversificação empresarial, que poderia levar ao questionamento quanto à consideração de aversão ao risco pela teoria clássica de finanças, a depender da organização da empresa, cada gestor é responsável por apresentar resultados de sua área de forma independente das demais. No caso do setor elétrico, apesar da existência de grandes grupos empresariais, é comum a gestão separada e independente das áreas, bem como a existência de pequenas empresas ou especializadas com pouca capacidade de diversificação. Além disso, a consideração de aversão ao risco é recorrente nos estudos de comercialização de energia e de energias renováveis, como trata esta tese, justificando-se sua abordagem.

A principal questão a ser respondida nesta tese é: “Como o perfil de risco do gestor e diferentes modelos de simulação da geração eólica interferem na otimização da comercialização de energia, no mercado livre, de um parque eólico no Brasil?”. No capítulo 6, processou-se 18 (dezoito) otimizações relativas a um problema de comercialização de energia eólica no mercado livre, no Brasil, com diferentes configurações de perfil de risco do gestor e modelos de simulações da geração eólica. Concluiu-se que para um gestor neutro ao risco, ou seja, cuja função de preferência é o próprio valor esperado dos resultados, os diferentes modelos de simulações não alteraram a decisão ótima do gestor. O mesmo não é verdade para um gestor avesso ao risco.

Apesar de decisões ótimas diferentes entre os 3 (três) modelos de simulação de geração eólica para um mesmo nível de aversão ao risco, as decisões seguiram o mesmo padrão de acréscimo ou decréscimo de volumes mensais de venda de energia, em relação ao aumento/decrécimo do nível de aversão ao risco, para a maioria dos meses. Observou-se, também, particularidades nas alocações quando

das simulações com o modelo ARX(2)-15 (dez-mai), que parecem relacionadas à presença de fenômenos climáticos. Portanto, as diferentes simulações de geração eólica alteram a decisão ótima do gestor, particularmente, quando considerada a influência de variáveis climáticas exógenas. Portanto, é importante a definição de um único modelo de simulação a ser considerado pelo gestor avesso ao risco ou, a adoção de alguma técnica multicritério para ponderação dos diferentes resultados dos modelos. As diferentes simulações, também, afetam os valores dos resultados otimizados.

Para definição de qual modelo de simulação adotar é importante considerar: a adequação do modelo, segundo o método de Box-Jenkins no caso de modelos autorregressivos, como os utilizados nesta tese; a acurácia das previsões realizadas pelo modelo, tendo-se cautela para que não ocorra *overfit* dos parâmetros; a correspondência da distribuição dos dados simulados à distribuição dos dados históricos ou verificados; a capacidade do modelo de simular realizações extremas dentro dos limites físicos da variável simulada, sobretudo, quando as simulações visam a avaliação de riscos; os requisitos computacionais e a parcimônia do modelo. No caso do gestor avesso ao risco, torna-se fundamental a capacidade do modelo de simular realizações extremas, pois essas têm peso diferenciado na decisão do gestor. Do mesmo modo, a identificação de variáveis externas que reduzem a incerteza do modelo é grande valor, pois além de garantir um mínimo de assertividade ao modelo (supondo a correta modelagem e precisão dos valores das variáveis externas), possibilita a segregação da avaliação do risco/incerteza associado diretamente a essas variáveis. Tomando-se essas orientações e verificando os resultados dos capítulos 4 e 6, sugere-se a adoção do modelo ARX(2)-15 (dez-mai) para simulação de médias mensais de geração eólica para o parque estudado.

Quanto ao perfil de risco, o aumento da aversão ao risco altera as decisões ótimas do gestor, de modo a reduzir o desvio-padrão e média da distribuição dos resultados, com aumento dos CVaRs e prêmio de risco. Mais uma vez, é importante a definição de uma única função de preferência a ser adotada, que represente adequadamente o perfil de risco do gestor ou da empresa, para otimização da comercialização. Para este ponto, contribui a flexibilidade da função de preferência desenvolvida, que permite a definição de diferentes níveis de aversão ao risco do gestor, para diferentes faixas de preferência. O estudo de DALBEM *et al.* (2014a)

corroborar com a presença de aversão ao risco entre os gestores de energia eólica, ao mostrar discrepâncias na visão de futuro para projetos eólicos participantes de leilões no ACR.

Não obstante não se ter tratado diretamente da parametrização da função de preferência desenvolvida, a análise do prêmio de risco vis a vis à redução de risco pretendida pode ser um caminho para avaliação da adequação de parametrizações. No exemplo de aplicação da função de preferência desenvolvida, no capítulo 6, com o aumento da aversão ao risco observou-se, conforme esperado, o aumento tanto dos valores de CVaR (redução do risco) quanto do prêmio de risco. Contudo, há de se observar que o aumento relativo do prêmio de risco é bem maior do que a redução de risco quando comparadas as parametrizações. Essa observação sugere que se avance em estudos empíricos de parametrizações da ECP\_G, além de suscitar a possibilidade de transformações da ECP\_G que a permitam contemplar, além da aversão ao risco, a propensão a ganhos, em linha com a Teoria do Prospecto.

Conforme apresentado inicialmente, as principais contribuições desta tese são: (i) a modelagem de previsão e simulação de médias mensais de geração eólica, considerando a influência de fenômenos climáticos, que pode auxiliar tanto a gestão da comercialização de energia de parques eólicos no Brasil, quanto o planejamento energético anual, tendo avançado ainda em uma das áreas de estudo propostas por FOLEY *et al.* (2012); (ii) o desenvolvimento de uma nova função de preferência, capaz de representar diferentes níveis de aversão ao risco do gestor em função de faixas de preferência, com demonstração de sua função utilidade subjacente e propriedades. Essa nova função de preferência representa uma contribuição acadêmica, ao generalizar a função de preferência, para o caso de um período, apresentada por STREET (2010) e utilizada como função objetivo nos programas de cálculo do preço de energia no Brasil.

Apesar das contribuições, é necessário reconhecer as limitações desta tese. Primeiramente, devido à escassez de dados históricos de geração eólica para as análises, parte da série histórica de média mensal de geração eólica utilizada foi obtida como uma série teórica de geração eólica, a partir da aplicação da curva de potência do aerogerador a dados, medidos ou de reanálise, da velocidade dos ventos na região do parque. Outra limitação foi a não análise de possíveis correlações entre as variáveis de incerteza simuladas (PLDs médio mensais e médias mensais de geração eólica), contudo, essa correlação foi deixada a parte em função dos valores

de geração eólica considerados nos modelos de cálculo dos PLDs serem sazonais, porém fixos, não interferindo a geração eólica diretamente no cálculo dos PLDs. No sentido contrário, os PLDs não impactam a geração eólica, pois ela depende tão somente do vento e disponibilidade do parque. Portanto, a análise de correlação que teria sentido seria entre vazões de rios, que influenciam diretamente os PLDs e estão correlacionadas com precipitação, e geração eólica. Ainda, assim, para o parque estudado, a precipitação que afeta a geração eólica não contribui para a vazão de nenhuma grande bacia hidrológica do sistema elétrico brasileiro, sugerindo mínima ou nula correlação entre a média mensal de geração eólica do parque e os PLDs do SE/CO e NE.

Por fim, como sugestões para trabalhos futuros, alguns temas que surgem desta tese são listados a seguir:

- ✓ a modelagem de variáveis climáticas exógenas juntamente com a volatilidade mensal para previsão e simulação de média mensal de geração eólica, bem como a extensão deste estudo para outros parques;
- ✓ a incorporação da simulação de médias mensais de geração eólica nos programas de cálculo do PLD, com prévia análise da existência de correlações entre geração eólica e vazões para as diversas localidades;
- ✓ o aprofundamento do estudo sobre a parametrização do ECP\_G, inclusive, com sua aplicação em outras áreas;
- ✓ a extensão da formulação da ECP\_G para aplicação em problemas de otimização multiperíodo;
- ✓ o estudo de possíveis variações da ECP\_G para contemplar além da aversão ao risco, a propensão a ganhos, aproximando-a da Teoria do Prospecto.

ABDELLAOUI, M; BLEICHRODT, H.; L'HARIDON, O. A Tractable Method to Measure Utility and Loss Aversion under Prospect Theory. **Journal of Risk and Uncertainty**, v. 36, p. 245-266, 2008.

ABEEÓLICA – ASSOCIAÇÃO BRASILEIRA DE ENERGIA EÓLICA. Boletim de Dados: Dez. 2015. Disponível em: <<http://abeeolica.org.br/pdf/Boletim-de-Dados-ABEEolica-Dezembro-2015-Publico.pdf>>. Acesso em: 30 abr. 2016.

AJAYI, O. O.; FAGBENLE, R. O.; KATENDE, J. Wind Profile Characteristics and Econometrics Analysis of Wind Power Generation of a Site in Sokoto State, Nigeria. **Energy Science and Technology**, v. 1, n. 2, p. 54-66, 2011.

AKAIKE, H. A new look at the statistical model identification. **IEEE Transactions on Automatic Control**, v. 19 n. 6, p. 716-72, 1974.

ALLAIS, M. Le Comportement de l'Homme Rationnel devant Le Risque: Critique Des Postulats et Axiomes de l'Ecole Americaine. **Econometrica**, v. 21, p. 503-546, 1953.

ALGARVE, V. R. Seminário Oceanografia Física MET-336-3. Disponível em: <<http://slideplayer.com.br/slide/1686037/>>. Acesso em: 18 mar. 2016.

AMARAL, B. M. **Modelos VARX para Geração de Cenários de Vento e Vazão Aplicados à Comercialização de Energia**. Rio de Janeiro, 2011. 155 p. Dissertação (Mestrado em Engenharia Elétrica) - Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

ARAGÃO, J. O. R. O impacto do ENSO e do Dipolo do Atlântico no Nordeste do Brasil. **Bull. Inst. Fr. Études andines**, v. 27, n. 3, p. 839-844, 1998.

ARAÚJO JUNIOR, L. M. *et al.* Avaliação dos recursos eólicos simulado no Estado do Ceará: um estudo de caso para o *El Niño* 97/98 e para *La Niña* 98/99. **Revista Brasileira de Meteorologia**, v. 29, n. 1, p. 139-152, 2014.

ARCHER, C. L.; JACOBSON, M. Z. Geographical and seasonal variability of the global “practical” wind resources. **Applied Geography**, v. 45, p. 119-130, 2013.

ARROW, K. **Aspects of the theory of risk-bearing**. Helsinki: Yrjö Jahnsson Foundation, 1965.

ARTZNER, P.; DELBAEN, F.; EBER, J-M.; HEATH, D. Coherent Measures of Risk. **Mathematical Finance**, v. 9, p. 203-228, 1999.

BAÑOS, R. *et al.* Optimization methods applied to renewable and sustainable energy: A review. **Renewable and Sustainable Energy Reviews**, v. 15, n. 4, p. 1753-1766, 2011.

- BARTHELMIE, R. J.; MURRAY, F.; PRYOR, S. C. The economic benefit of short-term forecasting for wind energy in the UK electricity market. **Energy Policy**, v. 36, n. 5, p. 1687-1696, 2008.
- BAWA, V. S. Safety-First, Stochastic Dominance, and Optimal Portfolio Choice. **Journal of Financial & Quantitative Analysis**, v. 13, p. 255-271, 1978.
- BELTON, V., GEAR, T. On a short-coming of Saaty's method of analytic hierarchies. **Omega**, 1983, v. 11, p. 228-230.
- BELTON, V.; GEAR, T. On the meaning of relative importance (discussion paper). **Journal of MultiCriteria Decision Analysis**, 1997, v. 6, p. 335-337.
- BELTON, V.; STEWART, T. J. **Multiple criteria decision analysis: an integrated approach**. Massachusetts: Kluwer Academic Publishers, 2002.
- BERNARDO, A. E.; LEDOIT, O. Gain, Loss, and Asset Pricing. **Journal of Political Economy**, v. 108, p. 144-172, 2000.
- BESSADA, O. Construção e análise de fronteiras eficientes para a seleção de carteiras de investimentos. **Revista Brasileira de Mercado de Capitais**, v. 8, n. 24, p. 179-190, 1982.
- BOX, G. E. P. *et al.* **Time series analysis: forecasting and control**. New Jersey: John Wiley & Sons, 2015.
- BRIX - BRAZILIAN INTERCONTINENTAL EXCHANGE. BRIX Curva de Preços Futuros em 01/04/2016. Disponível em: <[https://www.brix.com.br/public/docs/brix/data\\_files/FW\\_Curve.xls](https://www.brix.com.br/public/docs/brix/data_files/FW_Curve.xls)>. Acesso em: 30 abr. 2016.
- BROWN, B. G.; KATZ, R. W.; MURPHY, A. H. Time series models to simulate and forecast wind speed and wind power. **Journal of climate and applied meteorology**, v. 23, p. 1184-1195, 1984.
- CAMELO, H. N.; TEIXEIRA, W. F.; LUCIO, P. S.; LEAL JUNIOR, J. B. V. Previsão de Velocidade Média do Vento através da utilização de modelagem Auto-Regressiva de Médias Móveis (ARMA) em Região Serrana no Estado do Ceará – Brasil. **Revista Brasileira de Energias Renováveis**, v. 4, p. 17- 29, 2015.
- CAMERER, C. Prospect Theory in the Wild: Evidence from the Field. In: KAHNEMAN, D.; TVERSKY, A. (Org.). **Choices, Values and Frames**. Cambridge: Cambridge University Press, 2000. p. 288-300.
- CAPORIN, M.; PRÉS, J. Modelling and forecasting wind speed intensity for weather risk management. **Computational Statistics and Data Analysis**, v. 56, p. 3459-3476, 2012.
- CCEE – Câmara de Comercialização de Energia Elétrica. Regras de Comercialização: Balanço Energético. Versão 1.0. São Paulo, 2012, 14p.
- CCEE – Câmara de Comercialização de Energia Elétrica. O que fazemos: Preços. Disponível em: <[http://www.ccee.org.br/portal/faces/oquefazemos\\_menu\\_lateral/procedimentos?\\_adf.ctrl-state=p9uds0fi9\\_49&\\_afLoop=935017252797931](http://www.ccee.org.br/portal/faces/oquefazemos_menu_lateral/procedimentos?_adf.ctrl-state=p9uds0fi9_49&_afLoop=935017252797931)>. Acesso em: 18 jan. 2016.
- CERQUEIRA, H. D. V. **Modulação da temperatura da superfície do mar do Pacífico e Atlântico Tropical na precipitação no Estado da Paraíba**. Campina Grande, 2010. 112p. Dissertação (Mestrado em Meteorologia) - Centro de Tecnologia e Recursos Naturais, Universidade Federal de Campina Grande.

CHEN, L.; HE, S.; ZHANG, S. When All Risk-Adjusted Performance Measures are the Same: In Praise of the Sharpe Ratio. **Quantitative Finance**, v. 11, p. 1439-1447, 2011.

CHEN, Z.; YANG, L. Nonlinearly weighted convex risk measure and its application. **Journal of Banking & Finance**, v. 35, p. 1777-1793, 2011.

CHERNY, A.; MADAN, D. New Measures for Performance Evaluation. **Review of Financial Studies**, v. 22, p. 2571-2606, 2009.

COSTA JR., L. C.; PEREIRA, M. V.; GRANVILLE, S.; CAMPODÓNIO, N.; FAMPA, M. H. C. Planejamento da operação de sistemas hidrotérmicos com aversão ao risco: uma abordagem para controlar o risco de déficit e limitar a energia não suprida. In SEMINÁRIO NACIONAL DE PRODUÇÃO E TRANSMISSÃO DE ENERGIA ELÉTRICA, XXII SNTPEE, Brasília, 2013.

CPAMP – Comissão de Permanente para Análise de Metodologias e Programas Computacionais do Setor Elétrico. Desenvolvimento, implementação e testes de validação das metodologias para internalização de mecanismos de aversão a risco nos programas computacionais para estudos energéticos e formação de preço. Brasília, 2013, 68p. Relatório Técnico.

CPTEC – Centro de Previsão de Tempo e Estudos Climáticos. Apresenta animações sobre *El Niño* e *La Niña*. Disponível em: <<http://enos.cptec.inpe.br/animacao/pt>>. Acesso em: 18 mar. 2016.

DALBEM, M. C.; BRANDÃO, L. E. T.; GOMES, L. L. Investors' asymmetric views and their decision to enter Brazil's wind energy sector. **Pesquisa Operacional**, v. 34, n. 2, p. 319-345, 2014a.

DALBEM, M. C.; BRANDÃO, L. E. T.; GOMES, L. L. Can the regulated market help foster a free market for wind energy in Brazil? **Energy Policy**, v. 66, p. 303-311, 2014b.

DCIDE. Boletim Semanal da Curva Forward: 30-03-16 Semana13. Disponível em: <<http://www.dcide.com.br/>>. Acesso em: 30 mar. 2016.

DIEBOLD, F. X.; MARIANO, R. S. Comparing predictive accuracy. **Journal of Business and Economic Statistics**, v. 13, p. 253-263, 1995.

DONGMEI, Z.; YUCHEN, Z.; XU, Z. Research on wind power forecasting in wind farms. In: Power Engineering and Automation Conference (PEAM), 2011 IEEE. **Proceedings... IEEE**, 8-9 Sept. 2011, v. 1, p. 175-178.

ELING, M.; FARINELLI, S.; ROSSELLO, D.; TIBILETTI, L. One-Size or Tailor-Made Performance Ratios for Ranking Hedge Funds. **Journal of Derivatives and Hedge Funds**, v. 16, p. 267-277, 2011.

ELLSBERG, D. Risk, Ambiguity, and the Savage Axioms. **Quarterly Journal of Economics**, v. 75, p. 643-669, 1961.

ENFIELD, D. B. Relationships of inter-American rainfall to tropical Atlantic and Pacific SST variability. **Geophysical Research Letters**, v. 23, n. 23, p. 3305-3308, 1996.

FÂNZERES, B.; STREET, A.; LIMA, D.; VEIGA, A.; FREIRE, L.; AMARAL, B. Comercialização de Energia Eólica no Ambiente Livre: Desafios e Soluções

Inovadoras. In SIMPÓSIO DE ESPECIALISTAS EM PLANEJAMENTO DA OPERAÇÃO E EXPANSÃO ELÉTRICA, XII SEPOPE, Rio de Janeiro, 2012.

FARINELLI, S.; FERREIRA, M.; ROSSELLO, D.; THOENY, M.; TIBILETTI, L. Beyond Sharpe Ratio: Optimal Asset Allocation Using Different Performance Ratios. **Journal of Banking and Finance**, v. 32, p. 2057-2063, 2008.

FISHBURN, P. C. Mean-Risk Analysis with Risk Associated with Below-Target Returns. **American Economic Review**, v. 67, p. 116-126, 1977.

FOLEY, A. M. *et al.* Current methods and advances in forecasting of wind power generation. **Renewable Energy**, v. 37, n. 1, p. 1-8, 2012.

FRANCISCHINI, P. G.; CABEL, G. M. Proposição de um indicador geral de desempenho utilizando AHP. In ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, XXIII UFOP, Ouro Preto, 2003. **Anais...** Ouro Preto: UFOP, 2003.

FRANSES, P. H.; VAN DIJK, D. The forecasting performance of various models for seasonality and nonlinearity for quarterly industrial production. **International Journal of Forecasting**, v. 21, n. 1, p. 87-102, 2005.

GANDELMAN, N.; HERNÁNDEZ-MURILLO, R. **Risk Aversion at the Country Level**. Federal Reserve Bank of St. Louis, Working Paper 2015-005B, 2014.

GIACOMINI, R.; WHITE, H. Test of Conditional Predictive Ability. **Econometrica**, v. 74, n. 6, p. 1545-1578, 2006.

GOETZMANN, W.; INGERSOLL, J.; SPIEGEL, M.; WELCH, I. **Sharpening Sharpe Ratios**. National Bureau of Economic Research, Working Paper Series No 9116, 2002.

GOMES, L. F. A. M.; LIMA, M. M. P. P. TODIM: Basics and Application to Multicriteria Ranking of Projects with Environmental Impacts. **Foundations of Computing and Decision Sciences**, v. 16, p. 113-127, 1992.

GONZÁLEZ, J. S.; PAYÁN, M. B.; SANTOS, J. M. R., GONZÁLEZ-LONGATT, F. A review and recent developments in the optimal wind-turbine micro-siting problem. **Renewable and Sustainable Energy Reviews**, v. 30, p. 133-144, 2014.

GOOIJER, J. G.; HYNDMAN, R. J. 25 years of time series forecasting. **International Journal of Forecasting**, v. 22, p. 443-473, 2006.

GRAMBSCH, P.; STAHEL, W. A. Forecasting demand for special telephone services: A case study. **International Journal of Forecasting**, v. 6, p. 53-64, 1990.

GRANDZOL, J. R. **Improving the Faculty Selection Process in Higher Education**: A Case for the Analytic Hierarchy Process. Bloomsburg University of Pennsylvania, IR Applications, v. 6, August 24, 2005.

GUO, Z. *et al.* A corrected hybrid approach for wind speed prediction in Hexi Corridor of China. **Energy**, v. 36, p. 1668-1679, 2011.

GWEC – GLOBAL WIND ENERGY COUNCIL. Global Wind Report: Annual Market Update 2015. Disponível em: <[http://www.gwec.net/wp-content/uploads/vip/GWEC-Global-Wind-2015-Report\\_April-2016\\_22\\_04.pdf](http://www.gwec.net/wp-content/uploads/vip/GWEC-Global-Wind-2015-Report_April-2016_22_04.pdf)>. Acesso em: 18 mar. 2016.

HARRIS, J. L.; LIU, L. M. Dynamic structural analysis and forecasting of residential electricity consumption. **International Journal of Forecasting**, v. 9, p. 437-455, 1993.

HONG KONG OBSERVATORY. Apresenta informações climáticas sobre *El Niño* e *La Niña*. Disponível em: <<http://www.hko.gov.hk/lrf/enso/enso-backgnd.htm>>. Acesso em: 18 mar. 2016.

IBM. IBM SPSS Missing Values 20. Disponível em: <[ftp://public.dhe.ibm.com/software/analytics/spss/documentation/statistics/20.0/en/client/Manuals/IBM\\_SPS\\_S\\_Missing\\_Values.pdf](ftp://public.dhe.ibm.com/software/analytics/spss/documentation/statistics/20.0/en/client/Manuals/IBM_SPS_S_Missing_Values.pdf)>. Acesso em: 18 mar. 2016.

IEA – INTERNATIONAL ENERGY AGENCY. Monthly Electricity Statistics: December 2015. Disponível em: <http://www.iea.org/media/statistics/surveys/electricity/MES201512.XLS>>. Acesso em: 18 mar. 2016.

INGERSOLL, J.; SPIEGEL, M.; GOETZMANN, W. Portfolio Performance Manipulation and Manipulation-Proof Performance Measures. **The Review of Financial Studies**, v. 20, p. 1503-1546, 2007.

ISHIZAKA A.; LABIB A. Review of the main developments in the analytic hierarchy process. **Expert Systems with Applications**, 2011, v. 38, n. 11, p. 14336-14345.

JORION, P. Risk2: Measuring the Risk in Value-At-Risk. **Financial Analysts Journal**, v. 52, p. 47-56, 1996.

JUNG, J.; BROADWATER, R. P. Current status and future advances for wind speed and power forecasting. **Renewable and Sustainable Energy Reviews**, v. 31, p. 762-777, 2014.

KAHNEMAN, D.; TVERSKY, A. Prospect Theory: An Analysis of Decision under Risk. **Econometrica**, v. 47, p. 263-291, 1979.

KAPLAN, P. D.; KNOWLES, J. A. A Generalized Downside Risk-Adjusted Performance Measure. **Journal of Performance Measurement**, v. 8, p. 42-54, 2004.

KARKI, R. *et al.* A Simplified Wind Power Generation Model for Reliability Evaluation. **IEEE Transactions on Energy Conversion**, v. 21, n. 2, p. 533-540, 2006.

KEENEY, L. K.; RAIFFA, H. **Decisions with Multiple Objectives: Preferences and Value Tradeoffs**. Cambridge: Cambridge University Press, 1993.

KLOTZLE, M. C.; GOMES, L. L.; BRANDÃO, L. E. T.; PINTO, A. C. F. Desenvolvimento de uma Medida de Desempenho Comportamental. **Revista Brasileira de Finanças**, v. 10, n. 3, p. 395-416, 2012.

KOEKEBAKKER, S.; ZAKAMOULINE, V. Analysis of Financial Decision Making with Loss Aversion. In: EUROPEAN FINANCIAL MANAGEMENT ASSOCIATION ANNUAL MEETING, 2008, Athens.

KOEKEBAKKER, S.; ZAKAMOULINE, V. Generalized Sharpe Ratios and Portfolio Performance Evaluation. In: EUROPEAN FINANCIAL MANAGEMENT ASSOCIATION ANNUAL MEETING, 2007a, Austria.

KOEKEBAKKER, S.; ZAKAMOULINE, V. **Skewness Preferences in Investment Decisions**. Norway, 2007b. Disponível em: <<http://citeseerx.ist.psu>>.

edu/viewdoc/download?doi=10.1.1.192.7552&rep=rep1&type=pdf>. Acesso em: 03 ago. 2015.

LAZO, J. G. L.; FIGUEIREDO, K.; LIMA, D. A. Análise de um modelo inteligente de contratação de energia elétrica no curto prazo para distribuidoras. **Revista Controle e Automação**, v. 23, n. 6, p. 711-725, 2012.

LEI, M. *et al.* A review of wind speed and power generated power. **Renewable and Sustainable Energy Reviews**, v. 13, p. 915-920, 2009.

LEVY, H.; MARKOWITZ, H. Approximating Expected Utility by a Function of Mean and Variance. **The American Economic Review**, v. 69, p. 308-317, 1979.

LIRA, M. A. T.; SILVA, E. M.; ALVES, J. M. B. Estimativa dos recursos eólicos no litoral cearense usando a teoria da regressão linear. **Revista Brasileira de Meteorologia**, v. 26, n. 3, p. 349-366, 2011.

LUZ, C. P. M. S.; GOMES, L. L.; BRANDÃO, L. E. T. Análise da dinâmica do Mercado a termo de energia elétrica no Brasil. **Revista Brasileira de Gestão de Negócios**, v. 14, n. 44, p. 314-334, 2012.

MACHARIS, C., SPRINGAEL J., DE BRUCKER, K., VERBEKE, A. Promethee and AHP: The design of operational synergies in multicriteria analysis. Strengthening Promethee with ideas of AHP. **European Journal of Operational Research**, 2004, v. 153, p. 307-317.

MARKOWITZ, H. Portfolio Selection. **The Journal of Finance**, v. 7, p. 77-91, 1952.

MARKOWITZ, H. **Portfolio Selection: Efficient Diversification of Investments**. New York: JohnWiley, 1959.

MENEZES, M. L.; SOUZA, R. C.; PESSANHA, J. F. M. Combining singular spectrum analysis and PAR(p) structures to model wind speed time series. **Journal of Systems Science and Complexity**, v. 27, n. 1, p. 29-46, 2014.

METROPOLIS, N.; ULAM, S. The Monte Carlo Method. **Journal of the American Statistical Association**, v. 44, n. 247, p. 335-341, 1949.

MILLIGAN, M. R.; MILLER, A. H.; CHAPMAN, F. **Estimating the economic value of wind forecasting to utilities**. Golden, CO: National Renewable Energy Laboratory, 1995.

MORAES, C. C. Value at Risk e Expected Shortfall: **Medidas de risco e suas propriedades**: Um estudo empírico para o mercado brasileiro. São Paulo, 2012. 90 p. Dissertação (Mestrado Profissional em Economia e Finanças) - Escola de Economia de São Paulo, Fundação Getúlio Vargas.

MORENO, M. A.; BUENO, M.; USAOLA, J. Evaluating risk-constrained bidding strategies in adjustment spot markets for wind power producers. **Electrical Power and Energy Systems**, v. 43, p. 703-711, 2012.

MURPHY, C. K. Limits on the analytic hierarchy process from its consistency index. **European Journal of Operation Research**, 1993, v. 65, p. 138-139.

NOAKES, D. J.; MCLEOD, A. I.; HIPEL, K. W. Forecasting monthly riverflow time series. **International Journal of Forecasting**, v. 1, p. 179-190, 1985.

NOVALES, A.; FRUTO, R. F. Forecasting with time periodic models: A comparison with time invariant coefficient models. **International Journal of Forecasting**, v. 13, p. 393-405, 1997.

OLIVEIRA, E. P. **Medidas Coerentes de Risco**. Rio de Janeiro: IMPA, 2009. 74 f. Dissertação (Mestrado em Matemática) - Instituto Nacional de Matemática Pura e Aplicada, Rio de Janeiro, 2009.

OLIVEIRA, F. L. C. **Modelos de Séries Temporais para Construção de Árvores de Cenários Aplicadas à Otimização Estocástica**. Rio de Janeiro, 2013. 180 p. Tese (Doutorado em Engenharia Elétrica) - Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

OLIVEIRA, J. L.; COSTA, A. A. Estudo de variabilidade do vento em escala sazonal sobre o nordeste brasileiro utilizando o RAMS: os casos de 1973-1974 e 1982-1983. **Revista Brasileira de Meteorologia**, v. 26, n. 1, p. 53-66, 2011.

PENNA, D. D. J. *et al.* Modelo Estratégico de Geração Hidrotérmica a Subsistemas Interligados - NEWAVE, Manual do usuário: Versão 19. Rio de Janeiro: CEPEL, 2013.165p.

PENG, L. V.; YUE, L. Short-term wind speed forecasting based on non-stationary time series analysis and ARCH model. In: International Conference on Multimedia Technology (ICMT), 2011. **Proceedings... IEEE**, 2011. p. 2549-2553.

PEREIRA, M. V. F.; PINTO, L. M. V. G. Multistage stochastic optimization applied to energy planning. *Mathematical Programming*, v. 52, n. 1, p. 359-357, 1991.

PÉZIER, J. **Rationalization of Investment Preference Criteria**. ICMA Centre Discussion Papers in Finance DP2011-12. ICMA Centre, University of Reading, 2011.

PHILPOTT, A. B.; MATOS, V. L. Dynamic sampling algorithms for multi-stage stochastic programs with risk aversion. **European Journal of Operational Research**, v. 218, p. 470-483, 2012.

POURSINHO, H. M. I.; MENDES, V. M. F.; CATALÃO, J. P. S. A risk-averse optimization model for trading wind energy in a market environment under uncertainty. **Energy**, v. 36, n. 8 p. 4935-4942, 2011.

POURSINHO, H. M. I.; MENDES, V. M. F.; CATALÃO, J. P. S. A stochastic programming approach for the development of offering strategies for a wind power producer. **Electric Power Systems Research**, v. 89, p. 45-53, 2012.

PRATT, J. W. Risk Aversion in the small and in the large. **Econometrica**, v. 32, p. 122-136, 1964.

PREEZ, J.; WITT, S. F. Univariate versus multivariate time series forecasting: An application to international tourism demand. **International Journal of Forecasting**, v. 19, p. 435-451, 2003. R CORE TEAM. **R: A language and environment for statistical computing**. Vienna: R Foundation for Statistical Computing, 2015. Disponível em: <<https://www.R-project.org/>>. Acesso em: 10 jan. 2015.

RABIN, M. Risk Aversion and Expected-Utility Theory: A Calibration Theorem. **Econometrica**, v. 68, n. 5, p. 1281-1292, 2000.

- RAFAELI, L.; MÜLLER, C. J. Estruturação de um índice consolidado de desempenho utilizando o AHP. **Gestão e Produção**, 2007, v. 14, n. 2, p. 363-377.
- RAMANATHAN, R. A note on the use of the analytic hierarchy process for environmental impact assessment. **Journal of Environmental Management**, 2001, v. 63, p. 27-35.
- RIENECKER, M. M. *et al.* MERRA: NASA's Modern-Era Retrospective Analysis for Research and Applications. **Journal of Climate**, v. 24, p. 3624-3648, 2011.
- RIGUI, M. B.; CERETTA, P. S. Teoria de Medidas de Risco: Uma Revisão Abrangente. **Revista Brasileira Finanças**, v. 12, n.3, p. 411-464, 2014.
- RUDLOFF, B.; STREET, A; VALLADÃO, D. M. Time consistency and risk averse dynamic decision models: Definition, interpretation and practical consequences. **European Journal of Operational Research**, v. 234, n. 3, p. 743-750, 2014.
- SAATY, T. L. **Método de análise hierárquica**. São Paulo: McGrawHill Pub. Co., 1991. 367 p.
- SAATY, T. L.; MARIANO, R. S. **Rationing Energy to Industries: Priorities and Input-Output Dependence**. Energy Systems and Policy, Winter 1979.
- SAMUELSON, P. A. The Fundamental Approximation Theorem of Portfolio Analysis in Terms of Means, Variances and Higher Moments. **The Review of Economic Studies**, v. 37, p. 537-542, 1970.
- SCHIPPER, K.; THOMPSON, R. Evidence on the Capitalized Value of Merger Activity for Acquiring Firms. **Journal of Financial Economics**, v. 11, p. 85-119, 1983.
- SCHWARTZ, G. E. Estimating the dimension of a model. **Annals of Statistics**, v. 6, n. 2, p. 461-464, 1978.
- SHADWICK, W. F.; KEATING, C. A Universal Performance Measure. **Journal of Performance Measurement**, v. 6, p. 59-84, 2002.
- SHARPE, W. F. Mutual Fund Performance. **The Journal of Business**, v. 39, p. 119-138, 1966.
- SHONKWILER, R. W.; MENDIVIL, F. **Explorations in Monte Carlo Methods**. 1.ed. New York: Springer, 2009.
- SONDEREGGER, J. **Performance of long-term correction at wind power development: An analysis of results from different reanalysis data sets**. Göteborg, Sweden, 2011. 38p. Master of Science Thesis (Master Degree Program Industrial Ecology for a Sustainable Society) - Department of Energy and Environment, Chalmers University of Technology.
- SORTINO, F. A.; VAN DE MEER, R.; PLANTINGA, A. The Dutch Triangle. **Journal of Portfolio Management**, v. 26, p. 50-57, 1999.
- SORTINO, F. A.; VAN DE MEER, R.; PLANTINGA, A.; FORSEY, H. The Upside Potential Ratio: What are We Trying to Measure? **Senior Consultant**, v. 6, p. 1-3, 2003.
- SORTINO, F.; PRICE, L. N. PerformanceMeasurement in a Downside Risk Framework. **Journal of Investing**, v. 3, p. 59-65, 1994.

STREET, A. A. **Equivalente certo e medidas de risco em decisões de comercialização de energia elétrica**. Rio de Janeiro, 2008. 174 p. Tese (Doutorado em Engenharia Elétrica) - Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

STREET, A. On the Conditional Value-at-Risk probability-dependent utility function. **Theory Decision**, v. 68, p. 49-68, 2010.

TSAY, R. S. **Analysis of financial time series**. 3. ed. New Jersey: John Wiley & Sons, 2010.

TSIANG, S.-C. The Rationale of the Mean-Standard Deviation Analysis, Skewness Preference, and the Demand for Money. **The American Economic Review**, v. 62, p. 354-371, 1972.

TUKEY, J.W. **The problem of multiple comparisons**. Mimeographs Princeton University, Princeton, New Jersey, 1953.

TVERSKY, A.; KAHNEMAN, D. Advances in Prospect Theory: Cumulative Representation of Uncertainty. **Journal of Risk and Uncertainty**, v. 5, p. 297-323, 1992.

VARGAS, S. A. **Previsão da distribuição da densidade de probabilidade da Geração de Energia Eólica usando técnicas não paramétrica**. Rio de Janeiro, 2015. 191 p. Tese (Doutorado em Engenharia Elétrica) - Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

VON NEUMANN, J.; MORGENSTERN, O. **Theory of Games and Economic Behavior**. New Jersey: Princeton University Press, 1944.

WANG, M. D.; QIU, Q. R.; CUI, B. W. Short-term wind speed forecasting combined time series method and arch model. In: International Conference on Machine Learning and Cybernetics (ICMLC), 2012. **Proceedings...** IEEE, 2012. p. 924-927.

WELLER, B. R. National indicator series as quantitative predictors of small region monthly employment levels. **International Journal of Forecasting**, v. 5, p. 241-247, 1989.

WELLS, J. M. Modelling seasonal patterns and long-run trends in U.S. time series. **International Journal of Forecasting**, v. 13, p. 407-420, 1997.

ZABARAS, N.; SANKARAN, S. An information-theoretic approach to stochastic materials modeling. **Computing in Science and Engineering**, v. 9, n. 2, p. 30-39, 2007.

ZAHIR, S. Clusters in a Group: Decision Making in the Vector Space Formulation of the Analytic Hierarchy Process. **European Journal of Operational Research**, v. 112, n. 3, p. 620-634, 1999.

ZAKAMOULINE, V. Portfolio performance evaluation with loss aversion. **Quantitative Finance**, v. 14, n. 4, p. 669-710, 2014.

ZAKAMOULINE, V. **The Choice of Performance Measure Does Influence the Evaluation of Hedge Funds**. Norway, 2010. Disponível em: <<http://ssrn.com/paper=1403246>>. Acesso em: 01 out. 2015.

ZAKAMOULINE, V.; KOEKEBAKKER, S. A Generalization of the Mean-Variance Analysis. **European Financial Management**, v. 15, p. 934-970, 2009.

ZEBIAK, S. E. Air-sea interaction in the equatorial Atlantic region. **Journal of Climate**, v. 6, p. 1567-1586, 1993.

ZHANG, Y.; WANG, J.; WANG, X. Review on probabilistic forecasting of wind power generation. **Renewable and Sustainable Energy Reviews**, v. 32, p. 255-270, 2014.

ZUGNO, M.; JÓNSSON, T.; PINSON, P. Trading wind energy on the basis of probabilistic forecasts both of wind generation and of market quantities. **Wind Energy**, v. 6, n. 6, p. 909-926, 2013.

## 9

### Anexo A: Pacotes utilizados do R

Ao longo desta tese o programa R (R CORE TEAM, 2015) foi utilizado para análise, previsão e simulação da série de médias mensais de geração eólica, bem como para execução das otimizações apresentadas no capítulo 6. Não obstante a programação explícita de algumas rotinas, foram utilizadas funções já programadas dos pacotes apresentados na Tabela 18.

Tabela 18 – Pacotes utilizados do R

<b>Pacote</b>	<b>Utilização</b>
<i>Afmtools</i>	Teste de Giacomine-White.
<i>Akima</i>	Teste de normalidade.
<i>fBasics</i>	
<i>Forecast</i>	Diagnóstico e previsão de séries temporais.
<i>fUnitRoots</i>	Teste de estacionariedade.
<i>Graphics</i>	Suporte para gráficos.
<i>Lubridate</i>	Suporte para datação.
<i>Nloptr</i>	Otimização.
<i>nonlinearTseries</i>	Teste de linearidade.
<i>Pear</i>	
<i>Partsm</i>	Diagnóstico e previsão de modelos periódicos.
<i>perARMA</i>	