



Andrés Mauricio Céspedes Garavito

**Análise Estocástica da Viabilidade Econômica
da Instalação de Painéis Fotovoltaicos em
Grandes Consumidores**

Dissertação de Mestrado

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-graduação em Engenharia Elétrica do Departamento de Engenharia Elétrica da PUC-Rio.

Orientador: Prof. Delberis Araujo Lima

Rio de Janeiro
Dezembro de 2017



Andrés Mauricio Céspedes Garavito

**Análise Estocástica da Viabilidade Econômica
da Instalação de Painéis Fotovoltaicos em
Grandes Consumidores**

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-Graduação em Engenharia Elétrica do Departamento de Engenharia Elétrica do Centro Técnico Científico da PUC-Rio. Aprovada pela Comissão Examinadora abaixo assinada.

Prof. Delberis Araujo Lima

Orientador

Departamento de Engenharia Elétrica – PUC-Rio

Prof. Marley Maria Bernardes Rebuzzi Vellasco

Departamento de Engenharia Elétrica – PUC-Rio

Prof. José Roberto Sanches Mantovani

Departamento de Engenharia Elétrica – UNESP

Prof. Marcio da Silveira Carvalho

Coordenador Setorial do Centro

Técnico Científico – PUC-Rio

Rio de Janeiro, 5 de Dezembro de 2017

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

Andrés Mauricio Céspedes Garavito

Graduou-se em Engenharia Eletrônica em 2013 e em Engenharia Elétrica em 2014 na Universidade Nacional da Colômbia. Sua área de pesquisa envolve mercados de energia elétrica, geração distribuída, otimização e contratação eficiente de energia elétrica para grandes consumidores.

Ficha Catalográfica

Céspedes Garavito, Andrés Mauricio

Análise Estocástica da Viabilidade Econômica da Instalação de Painéis Fotovoltaicos em Grandes Consumidores/Andrés Mauricio Céspedes Garavito; orientador: Delberis Araujo Lima. – 2017.

132 f. : il. color. ; 29,7 cm

Dissertação (mestrado)–Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Elétrica, 2017.

Inclui bibliografia

1. Engenharia elétrica – Teses. 2. Grandes consumidores 3. Contratação de energia elétrica. 4. Painel Fotovoltaico. 5. Otimização estocástica. I. Lima, Delberis Araujo. II. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Elétrica. III. Título.

CDD: 621.3

Para meus pais Nubia e Abelardo, minha irmã Andrea e minha
namorada Alejandra. Obrigado pelo apoio e por acreditar.

Agradecimentos

Em primeiro lugar a Deus, pela vida, pelas bênçãos concedidas e pelas oportunidades oferecidas.

Aos meus pais, Nubia e Abelardo por todo o amor, pelo apoio que sempre me deram ao longo da minha vida e por acreditar em mim. Mesmo na distância sempre estiveram presentes.

À minha irmã, Andrea por todo o amor e por sempre torcer por mim.

À Alejandra, pela paciência e amor, que me deram forças para continuar na realização deste sonho.

Ao meu orientador Delberis, pela oportunidade conferida, pela paciência, pela dedicação ao trabalho e por toda a ajuda que recebi, obrigado de coração.

Aos meus amigos Estiven Orozco e Sergio Álvarez por terem sido meus parceiros nesta grande aventura.

Aos meus amigos na Colômbia, especialmente Heber Cardona, Jacobo Castro, Carlos Castaño e Juan Jose Castellanos que sempre estiveram presentes.

Aos meus amigos do LSE, pelo conhecimento compartilhado e companheirismo.

Aos professores e funcionários do Departamento de Engenharia Elétrica da PUC-Rio, pela qualidade do ensino e excelente infraestrutura, essenciais para a execução do curso de mestrado.

Ao CNPq e à PUC-Rio, pelos auxílios concedidos, sem os quais este trabalho não teria sido realizado.

Resumo

Céspedes Garavito, Andrés Mauricio; Lima, Delberis Araújo. **Análise Estocástica da Viabilidade Econômica da Instalação de Painéis Fotovoltaicos em Grandes Consumidores**. Rio de Janeiro, 2017. 132p. Dissertação de Mestrado – Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

A geração distribuída (GD) vem crescendo nos últimos anos no Brasil, particularmente a geração fotovoltaica, permitindo a pequenos e grandes consumidores ter um papel ativo no sistema elétrico, podendo investir em um sistema próprio de geração. Para os consumidores cativos, além da redução do custo de energia, o consumidor também pode ter uma redução no custo de demanda, que é calculado a partir de um contrato com a distribuidora que o atende. Assim, considerando a possibilidade de instalação de painéis fotovoltaicos, o desafio dos consumidores é estimar com maior acurácia possível sua energia, a energia gerada pelos painéis e as demandas máximas futuras de forma a determinar a quantidade ótima de painéis, bem como o contrato de demanda com a distribuidora. Nesta dissertação, propõe-se resolver este problema a partir da simulação de cenários futuros de consumo de energia, demanda máxima e correlacionando-os com cenários futuros de geração de energia. Em seguida, a partir de um modelo de otimização linear inteiro misto, calcula-se a quantidade ótima de painéis fotovoltaicos e a demanda a ser contratada. Na primeira parte da dissertação, a modelagem Box & Jenkins é utilizada para estimar os parâmetros do modelo estatístico de energia consumida e demanda combinados com a geração de energia dos painéis. Na segunda parte, é utilizado um modelo de otimização estocástica que utiliza uma combinação convexa de Valor Esperado (VE) e *Conditional Value-at-Risk* (CVaR) como métricas de risco para avaliar o número ótimo de painéis e a melhor contratação de demanda. Para ilustrar a abordagem proposta, é apresentado um caso de estudo real para um grande consumidor considerado na modalidade Verde A4 no Ambiente de Contratação Regulado. Os resultados obtidos mostraram que a utilização de

painéis fotovoltaicos em um grande consumidor reduzem o custo anual de energia em até 20%, comparado com o valor real faturado.

Palavras-chave

Grandes Consumidores; Contratação de Energia Elétrica; Pannel Fotovoltaico; Ambiente de Contratação Regulada; Modelos Estatísticos; Otimização Estocástica; *Conditional Value-at-Risk* (CVaR).

Abstract

Céspedes Garavito, Andrés Mauricio; Lima, Delberis Araujo (Advisor). **Stochastic Analysis of Economic Viability of Photovoltaic Panels Installation in Large Consumers.** Rio de Janeiro, 2017. 132p. Dissertação de Mestrado – Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

Distributed Generation (GD) is growing up in the last years in Brazil, particularly photovoltaic generation, allowing small and large consumers play an important role in the electric system, investing in a own generation system. For the regulated consumers, besides the reduction of energy cost, they also may have a reduction in demand cost, which is computed from peak demand contract with the supply utility company. Therefore, taking into account the possibility of photovoltaic panels installation, the challenge of consumers is estimate with highest accuracy as possible its energy, the energy generation by the panels, and the future peak demand in order to estimate the optimum quantity of panels, as well as the peak demand contract with the utility. A way to solve this problem is to simulate future scenarios of energy consumption, peak demand, and correlate them with future scenarios of energy generation. After that, from a mixed integer linear stochastic optimization model, the optimum quantity of panels and peak demand to be contracted are computed. In the first part, the Box & Jenkins modelling is used to estimate the parameters of the energy consumption and peak demand by statistical model, combined with the energy generation of the panels. In the second part, a stochastic optimization model is applied using a convex combination of the Expected Value (VE) and Conditional Value-at-Risk (CVaR), which were used as risk metrics to rate the optimum number of panels and the best peak demand contract. To illustrate the proposed approach, a real case study of a large consumer presented considering the Green Tariff group A4 in the Regulated Environment. The results show that to use photovoltaic panels can reduce the annual cost by up to 20%, compared with the billed real value.

Keywords

Large Consumers; Energy Contracting; Photovoltaic Panel; Regulated Environment Contract; Statistical Models; Stochastic Optimization; Conditional Value-at-Risk (CVaR).

Sumário

1	Introdução	22
1.1	Revisão Bibliográfica	24
1.2	Estrutura da Dissertação	26
2	Ambientes de Contratação	28
2.1	Ambiente de Contratação Regulada (ACR)	28
2.2	Modalidade Verde	29
3	Modelos de Previsão e Simulação de Séries Temporais	32
3.1	Série Temporal	32
3.1.1	Análise no Domínio do Tempo	33
3.2	Processo Estocástico	35
3.2.1	Estacionaridade	35
3.2.2	Ergodicidade	36
3.2.3	Ruído Branco	36
3.3	Previsão de Séries Temporais	37
3.3.1	Modelos Box & Jenkins	38
3.4	Avaliação dos Modelos	41
3.4.1	Crítério de Informação de Akaike (AIC)	42
3.4.2	Crítério de Informação Bayesiano (BIC)	42
3.4.3	Sobrefixação	42
3.4.4	Teste de Portmanteau	43
3.4.5	Teste Jarque-Bera	43
3.4.6	Gráfico Quantil-Quantil	44
3.4.7	Erro Médio Absoluto Percentual (MAPE)	44
3.4.8	Coeficiente de Determinação (R^2)	45
4	Tratamento das Séries Temporais	46
4.1	Série Temporal de Energia e Demanda Máxima	46

4.2	Modelagem das Séries Temporais por B&J SARIMA	48
4.3	Previsão das Séries Temporais por B&J SARIMA	55
4.4	Geração dos Cenários	58
5	Simulação da Geração Distribuída	60
5.1	Geração Fotovoltaica	61
5.2	Considerações para o Sistema Fotovoltaico Aplicado ao Trabalho	62
5.3	Geração dos Cenários	64
6	Modelo de Otimização	66
6.1	Métricas de Risco	66
6.1.1	Value at Risk (VaR)	67
6.1.2	Conditional Value at Risk (CVaR)	67
6.2	Otimização para o ACR - Verde A4 Considerando Geração Fotovoltaica	69
7	Resultados e Discussões	78
7.1	Resultados de Otimização ACR - Verde A4 sem Geração Fotovoltaica, para 2016	78
7.2	Resultados de Otimização ACR - Verde A4 com Geração Fotovoltaica, para 2016	80
7.2.1	Resultados de Otimização sem redução nos cenários de Geração	81
7.2.2	Resultados de Otimização com redução de 10% nos cenários de Geração	83
7.2.3	Resultados de Otimização com redução de 20% nos cenários de Geração	88
7.3	Análise de Viabilidade Econômica	92
7.3.1	Vantagem do Pannel em Relação ao não Uso do Pannel	92
7.3.2	Variação da Tarifa de Energia	95
7.3.3	Análise de Retorno Financeiro (<i>Pay-Back</i>)	98
8	Conclusão e Perspectivas	101

9	Referências bibliográficas	103
	Anexo Artigo	109

Lista de Figuras

Figura 2.1 – Variação do custo da demanda máxima	30
Figura 4.1 – Série de consumo de energia de 2002 até 2015.	47
Figura 4.2 – Série de demanda máxima de 2002 até 2015.	47
Figura 4.3 – ACF e PACF: Resíduos da série de energia.	50
Figura 4.4 – Avaliação normalidade dos resíduos da série de energia.	51
Figura 4.5 – Análises <i>In-Sample</i> e <i>Pseudo Out-of-Sample</i> da série de energia.	52
Figura 4.6 – ACF e PACF: Resíduos da série de demanda máxima.	54
Figura 4.7 – Avaliação normalidade dos resíduos da série de demanda máxima.	54
Figura 4.8 – Análises <i>In-Sample</i> e <i>Pseudo Out-of-Sample</i> da série de demanda máxima.	55
Figura 4.9 – Previsão por B&J para a série de energia.	56
Figura 4.10 – Previsão por B&J para a série de demanda máxima.	57
Figura 4.11 – Simulação de cenários de energia.	58
Figura 4.12 – Simulação de cenários de demanda máxima.	58
Figura 4.13 – Histórico e simulação de cenários de energia.	59
Figura 4.14 – Histórico e simulação de cenários de demanda máxima.	59
Figura 5.1 – Perfil de geração média horária de um painel fotovoltaico 330Wp.	63
Figura 5.2 – Geração de energia mensal de um painel fotovoltaico 330Wp.	63
Figura 5.3 – Cenários de geração de energia de um painel fotovoltaico 330Wp.	64
Figura 6.1 – VaR, CVaR e Perda Esperada.	68
Figura 6.2 – Demanda máxima vs quantidade de painéis fotovoltaicos.	75

Figura 7.1 – Demanda contratada mensal para diferentes valores de λ .	80
Figura 7.2 – Energia média consumida e energia média gerada sem redução nos cenários de geração.	82
Figura 7.3 – Redução de energia pelo uso do sistema fotovoltaico para diferentes valores de λ sem redução nos cenários de geração.	82
Figura 7.4 – Redução de 10% dos dados de geração.	84
Figura 7.5 – Energia média consumida e energia média gerada com redução de 10% dos dados de geração.	85
Figura 7.6– Redução de energia pelo uso do sistema fotovoltaico para diferentes valores de λ com redução de 10% dos dados de geração.	86
Figura 7.7 – Demanda contratada mensal para diferentes valores de λ com redução de 10% dos dados de geração.	87
Figura 7.8 – Redução de 20% dos dados de geração.	88
Figura 7.9– Energia média consumida e energia média gerada com redução de 20% dos dados de geração.	90
Figura 7.10 – Redução de energia consumida pelo uso do sistema fotovoltaico para diferentes valores de λ com redução de 20% dos dados de geração.	90
Figura 7.11– Demanda contratada mensal para diferentes valores de λ com redução de 20% dos dados de geração.	91
Figura 7.12 – Comparação de custo anualizado para $\lambda = 0$.	93
Figura 7.13 – Comparação de custo anualizado para $\lambda = 0.5$.	94
Figura 7.14 – Comparação de custo anualizado para $\lambda = 1$.	95
Figura 7.15 – Comparação custos anuais com variação da tarifa de energia e $\lambda = 0$.	96
Figura 7.16 – Comparação custos anuais com variação da tarifa de energia e $\lambda = 1$.	97
Figura 7.17 – Comparação custos anuais com variação da tarifa de energia e $\lambda = 0$.	97
Figura 7.18 – Comparação custos anuais com variação da tarifa de energia e $\lambda = 1$.	98

Lista de Tabelas

Tabela 4.1– Resultados dos melhores modelos, segundo o critério <i>I</i> . Energia.	49
Tabela 4.2 – Parâmetros estimados do modelo <i>SARIMA</i> 1,1,23 × 0,1,112.	50
Tabela 4.3 – Testes estatísticos para análise <i>In-Sample</i> e <i>Pseudo</i> <i>Out-of-Sample</i> .	51
Tabela 4.4 – Resultados dos melhores modelos, segundo o critério <i>I</i> . Demanda Máxima.	52
Tabela 4.5 – Parâmetros estimados do modelo <i>SARIMA</i> 0,1,21 × 1,1,212.	53
Tabela 4.6 – Testes estatísticos para análise <i>In-Sample</i> e <i>Pseudo</i> <i>Out-of-Sample</i> .	55
Tabela 4.7 – Comparação de valores reais e previstos para o ano 2016, Energia.	56
Tabela 4.8 – Comparação de valores reais e previstos para o ano 2016, Demanda Máx.	57
Tabela 6.1 – Demanda máxima e geração de um painel fotovoltaico, intervalo de tempo 14h-15h.	73
Tabela 6.2 – Maiores 50 demandas máximas considerando um painel fotovoltaico, para o intervalo de tempo 14h-15h.	74
Tabela 7.1 – Perfis ótimos de demanda contratada e custo para diferentes valores de λ	79
Tabela 7.2 – Perfis ótimos de demanda contratada e custo para diferentes valores de λ . Sem redução nos cenários de geração.	83
Tabela 7.3 – Perfis ótimos de demanda contratada e custo para diferentes valores de λ com redução de 10% dos dados de geração.	87
Tabela 7.4 – Perfis ótimos de demanda contratada e custo para diferentes valores de λ com redução de 20% dos dados de geração.	91

Tabela 7.5 – Comparação de custo anualizado e quantidade de painéis fotovoltaicos para $\lambda = 0$.	93
Tabela 7.6 – Comparação de custo anualizado e quantidade de painéis fotovoltaicos para $\lambda = 0.5$.	94
Tabela 7.7 – Comparação de custo anualizado e quantidade de painéis fotovoltaicos para $\lambda = 1$.	95
Tabela 7.8 – Retorno do investimento considerando 100% da geração para $\lambda = 0.5$.	98
Tabela 7.9 – Retorno do investimento considerando 96% da geração para $\lambda = 0.5$.	99

Nomenclatura

Caracteres Romanos Maiúsculos

AIC_i	Valor do AIC do modelo testado na iteração i
BIC_i	Valor do BIC do modelo testado na iteração i
C_{AM}	Custo de amortização do painel fotovoltaico
$C_{D,s,t}$	Custo da demanda contratada para o cenário s e mês t
$C_{E,s,t}$	Custo da energia para o cenário s e mês t
$C_{inv,s,t}$	Custo de investimento do painel fotovoltaico para o cenário s e mês t
$C_{s,t}$	Função que calcula o custo associado à demanda/energia contratada para o cenário s e mês t
C_{pv}	Custo do painel fotovoltaico
C_t^{cat}	Custo do consumidor cativo no mês t
$Custo_{Anual}$	Custo ótimo anual
D_{MAX}	Demanda máxima
$D_{pv,s,t}^{max}$	Demanda máxima com painel fotovoltaico no cenário s e mês t
D_t	Série demanda máxima
D_t^c	Demanda contratada no mês t
D_t^{max}	Demanda máxima registrada no mês t
$D_{s,t}^{max}$	Demanda máxima simulada no cenário s e mês t
D_t^*	Maior valor entre a demanda contratada e a demanda máxima registrada no mês t
E_t	Série de energia consumida
$E_{pv,s,t}^{fp}$	Energia com painel fotovoltaico fora da ponta no cenário s e mês t
$E_{pv,s,t}^p$	Energia com painel fotovoltaico na ponta no cenário s e mês t
E_t^{fp}	Energia consumida fora da ponta no mês t
E_t^p	Energia consumida na ponta no mês t
$E_{s,t}^{fp}$	Energia fora da ponta simulada no cenário s e mês t

$E_{s,t}^p$	Energia na ponta simulada no cenário s e mês t
$G_{s,t}^{fp}$	Energia gerada fora da ponta pelo painel fotovoltaico no cenário s e mês t
$G_{s,t}^p$	Energia gerada na ponta pelo painel fotovoltaico no cenário s e mês t
M	Número grande (<i>Big M</i>) utilizado como parâmetro auxiliar
R_i^2	Valor do R^2 do modelo testado na iteração i
S	Cenários totais
T	Período de análise
T_D	Tarifa de demanda (resolução ANEEL)
T_D^u	Tarifa de ultrapassagem de demanda (resolução ANEEL)
T_E^{fp}	Tarifa de consumo de energia fora da ponta (resolução ANEEL)
T_E^p	Tarifa de consumo de energia na ponta (resolução ANEEL)
Z_t	Série Temporal

Caracteres Romanos Minúsculos

a_t	Ruído branco
d_0	Demanda contratada no primeiro mês
$d_{s,t}^u$	Ultrapassagem de demanda do cenário s e mês t
j	Taxa de juros associada ao custo oportunidade do painel fotovoltaico
n	Vida útil do painel fotovoltaico
n_{pv}	Número total de painéis fotovoltaicos
tol	Percentual de tolerância de contratação de energia
u	Percentual de tolerância de ultrapassagem de demanda
w_t	Variável auxiliar que atinge o valor em risco (VaR) da distribuição de custos no mês t para o período de análise
x_t	Variável binária indicativa de ultrapassagem de demanda no mês t
y_t	Variável binária indicativa de redução da demanda no mês t
$z_{1s,t}$	Variável auxiliar que trata o produto de variável quando há ultrapassagem de demanda no cenário s e mês t

z_{2t}	Variável auxiliar que trata o produto de variável quando há ultrapassagem de demanda no mês t
z_t	Variável auxiliar que trata o produto de variável quando há ultrapassagem de demanda no mês t

Caracteres Gregos Maiúsculos

$\Delta_{s,t}$	Tolerância de demanda do cenário s e mês t
Θ_Q	Parâmetro do componente sazonal de médias móveis de ordem Q
Φ_P	Parâmetro do componente sazonal autorregressivo de ordem P

Caracteres Gregos Minúsculos

α	Parâmetro de aversão ao risco que define o nível de confiança da medida de risco CVaR
$\beta_{s,t}$	Variável binária indicativa de ausência de geração no cenário s e mês t
γ	Parâmetro associado à variável explicativa
$\delta_{s,t}$	Variável auxiliar que representa o lado esquerdo de custos a partir do valor de custo w_t no mês t para o período de análise
θ_q	Parâmetro do componente de médias móveis de ordem q
λ	Constante que faz a ponderação entre Valor Esperado (VE) e CVaR
$\mu_{s,t,h}$	Demanda máxima com painel fotovoltaico no cenário s , mês t e hora h
ϕ_p	Parâmetro do componente autorregressivo de ordem p

Sobrescritos

c	Valor contratado
cat	Valor para consumidor cativo
fp	Valor fora da ponta

max	Valor máximo
p	Valor na ponta
u	Valor de ultrapassagem

Subscritos

0	Valor inicial
AM	Amortização
D	Demanda
E	Energia
h	Hora
inv	Investimento
pv	Painel fotovoltaico
s	Cenário
S	Total cenários
t	Tempo
T	Total ou referente ao período de análise

Abreviaturas, Siglas e Símbolos

ACF	Função de Autocorrelação
ACL	Ambiente de Contratação Livre
ACR	Ambiente de Contratação Regulada
AIC	Critério de Informação de Akaike
$ANEEL$	Agência Nacional de Energia Elétrica
AR	Autorregressivo
$ARIMA$	Modelo Autorregressivo-Integrado de Médias Móveis
$ARMA$	Modelo Autorregressivo de Médias Móveis
B	Operador de atraso
BIC	Critério de Informação Bayesiano
$B\&J$	Box e Jenkins

<i>CCEE</i>	Câmara de Comercialização de Energia Elétrica
<i>CMSE</i>	Comitê de Monitoramento do Setor Elétrico
<i>CVaR</i>	<i>Conditional Value at Risk</i>
<i>EPE</i>	<i>Empresa de Pesquisa Energética</i>
<i>GD</i>	<i>Geração Distribuída</i>
<i>ILP</i>	<i>Programação Linear Inteira</i>
<i>INEE</i>	<i>Instituto Nacional de Eficiência Energética</i>
<i>kV</i>	Quilovolt
<i>kW</i>	Quilowatt
<i>kWh</i>	Quilowatt-hora
<i>MA</i>	Média Móvel
<i>MAE</i>	Mercado Atacadista de Energia
<i>MAPE</i>	Erro Médio Absoluto Percentual
<i>MILP</i>	Programação Linear Inteira Mista
<i>MW</i>	Megawatt
<i>PACF</i>	Função de Autocorrelação Parcial
<i>PLD</i>	Preço de Liquidação das Diferenças
<i>PV</i>	Painel Fotovoltaico
<i>R\$</i>	Reais
<i>R\$/kWh</i>	Reais por quilowatt-hora
<i>R\$/kW</i>	Reais por quilowatt
<i>R²</i>	Coeficiente de Determinação
<i>SARIMA</i>	Modelo Autorregressivo-Integrado de Médias Móveis Sazonal
<i>SIN</i>	Sistema Interligado Nacional
<i>STC</i>	Condições Padrão de Avaliação
<i>VaR</i>	<i>Value at Risk</i>
<i>VE</i>	Valor Esperado
<i>Wp</i>	Watt-pico

1

Introdução

Devido à crise energética ocorrida em 2001, reestruturou-se o setor de energia, tanto no aspecto institucional quanto regulamentar, com o objetivo de incluir os segmentos de geração e comercialização de energia elétrica em um cenário competitivo. Assim, foi adotado o modelo institucional baseado nas leis Nº 10.847/2004 [1], Nº 10.848/2004 [2] e no decreto Nº 5.163/2004 [3], onde tentava-se destacar a segurança energética, modicidade tarifária e universalização do atendimento. O modelo definiu três entidades para estruturar o setor elétrico: A Empresa de Pesquisa Energética (EPE) responsável pelo planejamento de longo prazo, o Comitê de Monitoramento do Setor Elétrico (CMSE) com a função de avaliar permanentemente a segurança do suprimento de energia e, finalmente, a Câmara de Comercialização de Energia Elétrica (CCEE) com a missão de dar continuidade às atividades do Mercado Atacadista de Energia (MAE) relativas à comercialização de energia elétrica no Sistema Interligado Nacional (SIN) [4].

A partir desse momento, criam-se dois sistemas diferentes: (i) o Ambiente de Contratação Regulado (ACR), que corresponde ao atendimento dos consumidores cativos por distribuidoras locais de forma exclusiva e por intermédio de contratos regulados onde as distribuidoras são remuneradas por tarifas que incluem todos os custos necessários ao fornecimento de energia aos consumidores; (ii) o Ambiente de Contratação Livre (ACL) que compreende o atendimento dos consumidores livres através de contratos livremente negociados entre as partes (consumidores e comercializadoras) e remunerados por preço. Usualmente, as comercializadoras e as distribuidoras dispõem de métodos sofisticados de contratação para definir os contratos de energia e demanda com os consumidores. No entanto, o consumidor não possui muita informação nem tecnologia para tomar decisões de contratação de energia e demanda. Adicionalmente, com a expansão da geração distribuída (GD) o consumidor deve ter em conta em suas análises a viabilidade da utilização deste elemento para otimizar seu contrato de energia e/ou demanda. Segundo o Instituto Nacional de Eficiência Energética (INEE), entende-se por GD qualquer

fonte geradora com produção destinada, em sua maior parte, a cargas próximas, alimentadas sem necessidade de transporte de energia da rede de transmissão [5].

É importante destacar o avanço da GD no Brasil, que foi promovido pela Agência Nacional de Energia Elétrica (ANEEL) em 2012, a partir da Resolução Normativa N° 482/2012 (posteriormente alterada pela Resolução Normativa N° 517/2012 e N°687/15) [6], que estabeleceu as condições gerais para microgeração e minigeração no Brasil, que são um tipo específico de GD. Essa resolução teve início com o propósito de possibilitar que consumidores gerassem sua própria energia elétrica, especialmente através de módulos fotovoltaicos, oferecendo diversas vantagens para eles, os quais conseguem atender a demanda, aumentar a confiabilidade, aumentar a eficiência energética e reduzir os impactos ambientais.

Em geral, os módulos são usualmente instalados no próprio telhado do consumidor e, posteriormente, a eletricidade gerada em corrente contínua passa por um inversor que alimenta o consumidor. O excesso de geração pode ser usado para alimentar o sistema de distribuição.

No entanto, o processo da GD fotovoltaica ainda é recente. De acordo com a EPE, em 2015 o montante do consumo atendido pela geração solar fotovoltaica, que é a única fonte considerada no cálculo da participação da GD de pequeno porte, foi de apenas 22 GWh, que representa apenas 0.004% do consumo total no Brasil [7]. Apesar disso, projeções indicam que nos próximos anos esta forma de geração se tornará cada vez mais relevante, isto devido aos baixos custos de investimento em relação às grandes centrais elétricas, à necessidade de suprir a demanda de energia elétrica próximo à carga e à grande preocupação com a questão ambiental. Adicionalmente, dados revelam que no Brasil a geração solar fotovoltaica é a mais expressiva em termos de aplicação de sistemas de pequeno porte, respondendo por cerca de 98% dos sistemas de microgeração e minigeração [8]. Além disso, destaca-se o excelente potencial da GD fotovoltaica no Brasil para alcance de importantes soluções energéticas; para exemplificar, a EPE [9] indica que a capacidade da geração supera a necessidade de consumo em todos os Estados do país, sendo o índice de cobertura em nível nacional igual a 230%, isto é, a capacidade potencial supera o consumo em mais de duas vezes.

Assim, a GD fotovoltaica vem mudando o mercado energético para os consumidores que têm considerado a possibilidade de inserção desta geração. Neste contexto, a contratação de energia elétrica de um grande consumidor é um

problema atual e complexo, dado que envolve estimar a demanda máxima, o consumo de energia elétrica e a geração produzida por ele. Devido a que os custos com energia elétrica são cada vez mais importantes no fluxo de caixa dos grandes consumidores, definir e estimar as variáveis envolvidas na contratação é fundamental para minimizar os custos que envolvem energia elétrica.

Atualmente a contratação de energia para grandes consumidores tem sido estudada em alguns trabalhos como em [10], [11], [12] e [13]. No entanto, esta contratação influenciada pela GD é pouco aprofundada para este tipo de consumidor, destacando-se os trabalhos [14] e [15] os quais apresentam análises em grandes consumidores com inserção de geração fotovoltaica.

Por esse motivo, este trabalho pretende não só ajudar na tomada de decisão da utilização de painéis fotovoltaicos para um grande consumidor mas também abordar o impacto que produz a GD no Ambiente de Contratação Regulado (ACR), especificamente no impacto na demanda, tendo em conta a incerteza associada à energia e demanda. Para alcançar este objetivo, propõe-se desenvolver um modelo estatístico que permita estimar a demanda e a energia futura a partir do histórico de dados do grande consumidor. Entretanto, em função das cláusulas contratuais do ACR e além da influência causada pela geração dos painéis fotovoltaicos no consumo, é necessário desenvolver um modelo de otimização estocástica, com o emprego de programação linear mista inteira (MILP), cuja função objetivo é minimizar o custo da energia elétrica do grande consumidor através de (i) a construção de um perfil ótimo de demanda a ser contratado e (ii) a quantidade ótima de painéis a serem instalados (potência instalada de GD).

1.1

Revisão Bibliográfica

Nesta seção serão apresentados trabalhos presentes na literatura atual que abordam as questões relacionadas com a proposta da dissertação.

Em [16], propõe-se um método de previsão de demanda para a abordagem deste problema. Em [17] e [18], além da estimação e previsão da demanda máxima, consideram-se variáveis explicativas como temperatura, velocidade do vento e luminosidade. Em [19] e [20] os autores apresentam diferentes estudos que envolvem a redução de demanda máxima em pequenos consumidores.

Em [10] apresenta-se um modelo de otimização estatístico inteiro multiestágio como ferramenta computacional para solucionar o problema de contratação de um grande consumidor. Considera-se a perspectiva de um grande consumidor que precisa estabelecer seu portfólio ótimo de aquisição de energia elétrica entre geração própria, contratos bilaterais e participação no *pool*¹. No caso estudado, o consumidor pode decidir entre: (i) geração própria (decide-se no dia anterior), (ii) aquisição no *pool* (decide-se no dia anterior), (iii) contratos bilaterais semanais (decidem-se no início de cada semana) e (iv) contratos bilaterais mensais (decidem-se no início do mês). Os cenários de preço do *pool* são gerados a partir de sua previsão por um modelo ARIMA. Adicionalmente, é considerada uma análise de aversão ao risco por meio do CVaR, devido à volatilidade dos preços.

Em [21], os autores utilizaram previsão de demanda para avaliar a integração ótima de produção de energia renovável considerando cenários futuros de demanda, a fim de melhorar a eficiência energética e reduzir a dependência da rede de distribuição. Em [22], os autores propõem um modelo estocástico de contratação de energia com diferentes modelos de fontes de energia como geração fotovoltaica, geração eólica, contratos bilaterais, mercados de energia e auto produção, onde formulam uma função de custo de energia considerando a demanda.

Em [23], o autor propõe uma abordagem alternativa para o uso de funções utilidades em problemas de comercialização de energia elétrica, na qual é modelada matematicamente e formulada através de um problema de programação linear inteira mista utilizando como métricas de risco o *Conditional Value at Risk* (CVaR).

Em [11] é formulado um modelo estatístico e um modelo de otimização para contratação de demanda e energia. Os autores apresentam um modelo de previsão baseado num modelo estatístico autorregressivo (AR) que busca auxiliar grandes consumidores a estabelecer sua contratação de energia elétrica a partir de um modelo de previsão de cenários futuros de energia. Em seguida, é considerada a implementação de aversão ao risco utilizando CVaR como métrica de risco. Em [12], é apresentado um modelo de otimização que visa estabelecer a contratação ótima de energia para um grande consumidor. Os autores utilizam um modelo de

¹ *Pool* consiste em leilões de curto e curtíssimo prazo tais como: leilões de dia seguinte, de controle e de reserva [10].

previsão de cenários de consumo, baseado num modelo Autorregressivo Integrado de Médias Móveis (SARIMA). Posteriormente, formula-se um modelo de otimização considerando CVaR como métrica de risco.

Em [13], desenvolveu-se uma metodologia para auxílio na tomada de decisão de contratação de energia elétrica tanto no ACR quanto no ACL para um grande consumidor. Utilizaram-se cenários futuros de demanda e energia do consumidor a partir de um modelo estatístico. A autora propõe um modelo de otimização para minimizar o custo e faz uma comparativo entre as duas modalidades de contratação construindo um modelo de otimização estocástica utilizando programação linear, onde minimiza-se o custo anual de energia do consumidor.

O trabalho [24] consiste no artigo desenvolvido na etapa inicial do desenvolvimento do projeto referente a esta dissertação. Neste trabalho está apresentada uma nova abordagem desde o ponto de vista do consumidor na contratação de demanda. Utilizou-se modelagem Box & Jenkins para estimar os parâmetros do modelo estatístico e, a partir desta modelagem, foram simulados cenários de demanda futura. O modelo de otimização foi desenvolvido com as regras aplicadas no Brasil para contratos realizados entre distribuidoras e consumidores. Finalmente foi utilizada uma combinação convexa de Valor Esperado (VE) e CVaR para avaliar o risco e otimizar o custo da demanda contratada.

1.2 Estrutura da Dissertação

A organização desta dissertação está composta por nove capítulos:

Além do Capítulo 1, no Capítulo 2 descreve-se de forma sucinta como é realizada a comercialização de energia no Brasil. Em seguida, apresenta-se a formulação do custo de energia associado ao Ambiente de Contratação Regulada na modalidade Verde A4 .

No Capítulo 3 estão apresentados alguns conceitos de séries temporais, modelos de previsão, destacando-se o modelo Box & Jenkins utilizado neste trabalho e algumas métricas de avaliação para esses modelos.

No Capítulo 4, o modelo estatístico escolhido é aplicado ao problema proposto, que é a estimação dos cenários de energia consumida e demanda máxima.

No Capítulo 5, apresenta-se o conceito de geração distribuída, descrevem-se algumas tecnologias disponíveis, sendo dada ênfase à geração fotovoltaica e às considerações assumidas para o sistema fotovoltaico empregado no desenvolvimento desta dissertação.

No Capítulo 6, são apresentadas as medidas de risco VaR e CVaR, sendo esta última utilizada na dissertação. Adicionalmente é apresentado o modelo de otimização no Ambiente de Contratação Regulada na modalidade Verde A4 (ACR-Verde A4) considerando geração fotovoltaica.

No Capítulo 7, são apresentados os resultados, primeiramente considerando um grande consumidor com contrato ACR-A4 e, posteriormente com um sistema fotovoltaico para este consumidor.

No Capítulo 8 são apresentadas as considerações finais e a conclusão do trabalho. No Capítulo 9, encontram-se todas as referências bibliográficas utilizadas para o desenvolvimento desta dissertação.

No Anexo é apresentado um artigo resultante do projeto desenvolvido nesta dissertação.

2

Ambientes de Contratação

No contexto do seguinte capítulo, descreve-se de forma sucinta a comercialização de energia elétrica no Brasil e o ambiente de contratação utilizado nesta dissertação.

A partir da Lei Nº10.848/04 [2], o governo instituiu a comercialização de energia elétrica dividida em duas esferas de mercado: o Ambiente de Contratação Regulada (ACR) e o Ambiente de Contratação Livre (ACL) [25], com o objetivo de garantir a expansão da oferta e o atendimento ao consumo de energia. Por um lado o ACR abriga as distribuidoras e seus consumidores cativos, por outro o ACL é destinado aos contratos bilaterais livremente negociados entre produtores independentes, importadores, comercializadoras, autoprodutores e consumidores livres.

Os Agentes de Geração², assim como os Comercializadores, podem vender energia elétrica nos dois ambientes e todos os contratos, sejam ACR ou do ACL, têm de ser registrados na Câmara de Comercialização de Energia Elétrica (CCEE), onde inclui apenas as partes envolvidas, os montantes de energia e o período de vigência. Mais informações podem ser vistas em [25] e [26]. No desenvolvimento desta dissertação, foi considerada a contratação no ACR.

2.1 Ambiente de Contratação Regulada (ACR)

No ACR, mais conhecido como Ambiente Cativo, a energia elétrica adquirida por parte das distribuidoras nos leilões de energia é repassada aos consumidores regulados via tarifa de energia elétrica [27]. Adicionalmente, o custo da distribuição deve ser repassado aos consumidores via tarifa de demanda. Em termos comerciais, o ACR pode ser visualizado como uma “cooperativa” que agrega as demandas de vários distribuidores e têm contratos com um conjunto de geradores.

² Concessionários de serviço público de Geração, Produtores Independentes de energia ou Autoprodutores.

De acordo com [28], neste ambiente as tarifas de energia elétrica estão estruturadas em dois grandes grupos de consumidores, estabelecidos de acordo com seu nível de tensão. Os consumidores do Grupo A são de alta tensão (acima de 2.3 kV) e os consumidores do Grupo B de baixa tensão (abaixo de 2.3 kV).

Além disso, define-se estrutura tarifária como o conjunto de tarifas aplicáveis aos componentes de consumo de energia elétrica e/ou demanda de potência ativa, de acordo com a modalidade de fornecimento. Neste ambiente, as tarifas do Grupo A são constituídas em três modalidades de fornecimento (Convencional, Horo-Sazonal Azul e Horo-Sazonal Verde) que definem o tipo de contratação do consumidor.

A estrutura tarifária adotada para o desenvolvimento deste trabalho foi Horo-Sazonal Verde para um consumidor do tipo A4³, devido às características do grande consumidor para o caso de estudo. Mais informações das estruturas tarifárias existentes podem ser encontradas em [29].

2.2 Modalidade Verde

A Modalidade Verde exige um contrato específico com a concessionária, no qual se pactua a demanda pretendida pelo consumidor (demanda contratada), independentemente da hora do dia. Também, essa modalidade estabelece tarifas diferenciadas de energia para o grupo de horários chamados de ponta e fora da ponta. Por um lado, o posto tarifário na ponta corresponde ao período de maior consumo de energia elétrica que ocorre entre 17h e 20h dos dias úteis no Brasil. Por outro lado, o posto tarifário fora da ponta compreende as demais horas dos dias úteis e às 24 horas dos Sábados, Domingos e feriados. A equação (2.1) expressa o custo associado ao consumidor no ACR nesta modalidade para um mês t [12].

$$C_t^{cat} = D_t^* T_D + E_t^p T_E^p + E_t^{fp} T_E^{fp} \quad (2.1)$$

Sendo:

C_t^{cat} o custo do consumidor cativo no mês t , (R\$).

D_t^* o maior valor entre a demanda contratada e a demanda máxima registrada no mês t , (kW), ($D_t^* = \max_t \{D_t^c, D_t^{max}\}$).

³ O Grupo A4 corresponde aos consumidores atendidos pela rede com nível de tensão de 2.3 a 25 kV.

T_D a tarifa de demanda dada por resolução ANEEL, (R\$/kW).

E_t^p a energia consumida na ponta no mês t , (kWh).

T_E^p a tarifa de consumo de energia na ponta dada por resolução ANEEL, (R\$/kWh).

E_t^{fp} a energia consumida fora da ponta no mês t , (kWh).

T_E^{fp} a tarifa de consumo de energia fora da ponta dada por resolução ANEEL, (R\$/kWh).

A expressão (2.1) só é considerada quando a demanda máxima não ultrapassa em 5% a demanda contratada, isto é, $D_t^{max} < 1.05D_t^c$.

No caso em que a demanda contratada seja ultrapassada em 5% pela demanda máxima registrada, ou seja, $D_t^{max} > 1.05D_t^c$, o custo para o consumidor cativo é calculado pela equação (2.2).

$$C_t = (D_t^{max} - D_t^c)T_D + E_t^p T_E^p + E_t^{fp} T_E^{fp} + (D_t^{max} - D_t^c) \cdot T_D^u \quad (2.2)$$

Sendo:

T_D^u a tarifa de ultrapassagem de demanda dada por resolução ANEEL, (R\$/kW).




Figura 2.1 – Variação do custo da demanda máxima

Para explicar as expressões (2.1) e (2.2), na Figura 2.1, apresenta-se a variação do custo da demanda contratada no mês t (C_t) com a variação da demanda máxima no mês t (D_t^{max}). Note que o custo está dividido em três partes, de acordo com o valor de D_t^{max} . Na primeira parte, de zero até o valor da D_t^c , o custo é constante independente do valor de D_t^{max} , dado que $D_t^{max} < D_t^c$. A segunda parte desde D_t^c até $1.05D_t^c$, o valor da D_t^{max} é maior que a D_t^c , mas não é suficiente para aplicar penalidade. Portanto, o custo dependerá somente do valor

da D_t^{max} . Finalmente, com a D_t^{max} maior que $1.05D_t^c$, o custo total da Demanda envolve duas partes: (i) do valor da D_t^{max} e (ii) da diferença entre o valor da D_t^{max} e D_t^c . Note que a função custo muda em cada etapa. Assim, o principal objetivo de modelá-lo como um problema de otimização é quando o valor D_t^{max} viola a regra da tolerância de 5%, criando a não convexidade ⁴ do problema.

⁴ Um problema não convexo é um problema onde alguma ou várias das restrições são funções não convexas. Para mais detalhes de convexidade e funções convexas ver [30]

3

Modelos de Previsão e Simulação de Séries Temporais

No contexto do presente capítulo apresentam-se alguns conceitos fundamentais para a análise de séries temporais considerados para a abordagem do trabalho. Na sequência, indicam-se vários dos modelos de previsão de séries temporais disponíveis na literatura, especificamente os modelos estatísticos. Esses modelos consideram diversas metodologias, tais como: Método ingênuo, Método média móvel, Métodos de amortecimento exponencial, Método de amortecimento direto, Regressão dinâmica e Modelos de Box & Jenkins, sendo este último utilizado no presente trabalho. Em seguida, serão apresentados alguns dos critérios de avaliação com o propósito de escolher o melhor modelo e criar os cenários futuros que serão apresentados no capítulo 3.

3.1

Série Temporal

Uma série temporal é definida como um conjunto de observações quantitativas em uma ordem cronológica [31] ou intervalos de tempo de uma ou mais variáveis, mas realmente, é parte de um conjunto dentre de muitos que poderiam ter sido observados. Se Z_t representa o valor da variável aleatória Z no instante t , denota-se a série temporal por Z_1, Z_2, \dots, Z_T sendo T o número de observações seriais da variável [32].

É importante salientar que nem todo evento observado no tempo consiste em uma série temporal (por exemplo a loteria). Portanto, para caracterizar uma série temporal consideram-se as seguintes componentes [33]:

- Nível: Semelhante ao coeficiente linear em uma função matemática polinomial.
- Tendência: Comportamento de longo prazo da série temporal (linear, parabólico, exponencial, etc.).

- Sazonalidade: Repetição de um padrão durante um período conhecido.
- Ruído: Componente estocástica da série temporal associada a uma distribuição de probabilidade.

Podem-se classificar as séries temporais em discretas, contínuas, determinísticas, estocásticas, multivariadas (discretas ou contínuas) e multidimensionais, Para maiores detalhes ver [34].

Existem vários objetivos na análise de séries temporais. Contudo, esses objetivos podem ser classificados em descrição, explicação previsão e o controle [35].

3.1.1 Análise no Domínio do Tempo

Segundo [34], há dois enfoques usados para essa análise das séries temporais. A primeira análise é feita no domínio do tempo onde os modelos propostos são paramétricos, ou seja, com um número finito de parâmetros. A segunda é conduzida no domínio das frequências e os modelos propostos são modelos não-parametrizados.

Neste trabalho considera-se o primeiro enfoque, para maiores detalhes da análise no domínio da frequência ver [36] e [37].

Essa análise considera a evolução temporal do processo, ou seja, mede-se a magnitude do evento que ocorre em determinado intervalo de tempo [38]. Utilizam-se, portanto, as funções de autocovariância e autocorrelação onde observa-se o comportamento gráfico dos coeficientes de autocorrelação (autocorrelograma).

3.1.1.1 Autocovariância

É a covariância entre uma série temporal \mathbf{Z}_t e seu valor em outro período de tempo \mathbf{Z}_{t+k} , definido pela equação (3.1).

$$\gamma_k = Cov[\mathbf{Z}_t, \mathbf{Z}_{t+k}] = E\{[\mathbf{Z}_t - \mu][\mathbf{Z}_{t+k} - \mu]\} \quad (3.1)$$

Sendo:

μ a média do processo.

A coleta dos valores de γ_k para $k = 0, 1, 2, \dots, K$ é chamada função de autocovariância. Note que para $k = 0$ o valor da autocovariância é a variância da série temporal.

Para uma série temporal de comprimento finito Z_1, Z_2, \dots, Z_T , a estimação para a autocovariância é dada pela equação (3.2).

$$c_k = \hat{\gamma}_k = \frac{1}{T} \sum_{t=1}^{T-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z}). \quad k = 0, 1, 2, \dots, K \quad (3.2)$$

3.1.1.2

Autocorrelação

É a autocovariância padronizada que serve para medir o comprimento e a memória do processo e está definida pela equação (3.3).

$$\rho_k = \frac{\gamma_k}{\gamma_0} = \frac{Cov[Z_t, Z_{t+k}]}{Var[Z_t]} = \frac{E\{[Z_t - \mu][Z_{t+k} - \mu]\}}{\sqrt{E\{[(Z_t - \mu)^2][(Z_{t+k} - \mu)^2]\}}} \quad (3.3)$$

A coleta dos valores de ρ_k para $k = 0, 1, 2, \dots, N$ é chamada função de autocorrelação (ACF). Verifica-se que por definição $\rho_0 = 1$ (igual acontece com a autocovariância) e $\rho_k = \rho_{-k}$, ou seja, a ACF é simétrica em torno de zero. Em consequência, só é necessário calcular valores positivos de k . Sua estimação é muito importante nos modelos Box & Jenkins que serão utilizados neste trabalho.

Para uma série temporal de comprimento finito Z_1, Z_2, \dots, Z_N , a estimação para a autocorrelação é dada pela equação (3.4).

$$r_k = \rho_k = \frac{c_k}{c_0}. \quad k = 0, 1, 2, \dots, K \quad (3.4)$$

Uma regra geral, segundo [39], é que são necessárias pelo menos 50 observações para dar uma estimativa confiável do ACF e r_k deve ser calculado até K , onde K é aproximadamente $\frac{T}{4}$.

3.2

Processo Estocástico

Um processo estocástico pode ser definido como um fenômeno estatístico que evolui no tempo de acordo com leis probabilísticas [35]. Esses processos estocásticos são modelos matemáticos que descrevem a estrutura de probabilidade de uma sequência de observações.

Matematicamente o processo estocástico pode ser expresso como $\{Z(t), t \in T\}$, onde T indica o conjunto de pontos temporais em que o processo é definido. Se $-\infty < t < \infty$ o processo é contínuo e denota-se como $Z(t)$, mas se $t = 0, \pm 1, \pm 2, \dots, T$ o processo é discreto e denota-se como Z_t . Em consequência, um processo estocástico é um conjunto de variáveis aleatórias ordenadas no tempo.

Dessa forma, e pela definição de série temporal expressada anteriormente, conclui-se que uma série temporal pode ser interpretada como parte de uma realização parcial ou trajetória do processo estocástico.

Assim, tendo um conjunto de observações (Processo estocástico) retira-se uma amostra finita de observações no tempo (série temporal) e através do estudo dessa amostra (análise de série temporal) é possível identificar um modelo apropriado para inferir o comportamento da realidade [38].

Para fazer deduções estatísticas sobre a estrutura de um processo estocástico baseado em um registro observado do mesmo, assumem-se duas restrições: estacionaridade e ergodicidade.

3.2.1

Estacionaridade

É a restrição mais importante para um processo estocástico. Basicamente, a estacionaridade indica que as leis de probabilidade que atuam no processo não mudam com o tempo, ou seja, o processo mantém o equilíbrio estatístico. Segundo [39], há duas formas de estacionaridade: estrita ou fraca.

3.2.1.1

Estritamente Estacionário

Um processo estocástico diz-se estritamente estacionário se suas propriedades não são afetadas por uma mudança na origem do tempo, isto é, a

função de densidade $P(Z_1, \dots, Z_t; t_1, \dots, t_t)$ deve ser tal que permaneça idêntica quando se varia a origem dos tempos $P(Z_1, \dots, Z_t; t_{1+k}, \dots, t_{t+k})$.

3.2.1.2

Fracamente Estacionário

Um processo estocástico diz-se fracamente estacionário ou estacionário de segunda ordem se cumpre com as condições (3.5)-(3.7).

$$E[Z_t] = \mu \quad \forall t \quad (3.5)$$

$$Var[Z_t] = \sigma^2 \quad \forall t \quad (3.6)$$

$$E\{[Z_t - \mu][Z_{t+k} - \mu]\} = \gamma_k \quad \forall t \quad (3.7)$$

Significa que o processo estacionário deve ter uma média constante, uma variância constante e sua estrutura de dependência linear está sujeita somente da distância entre os períodos de tempo.

Note que, se Z_t for estritamente estacionário, ele não precisará ser fracamente estacionário, pois a restrição (3.6) não pode ser satisfeita. Porém, se o processo é estritamente estacionário de ordem dois, então ele será fracamente estacionário.

3.2.2

Ergodicidade

A restrição de ergodicidade significa que apenas uma realização do processo estocástico é suficiente para obter todas as estatísticas do mesmo (teorema ergódico) [31]. Portanto, algumas das propriedades dos processos estacionários também se aplicam aos processos ergódicos (média e variância constantes, funções de autocovariância e autocorrelação independentes da origem dos tempos).

3.2.3

Ruído Branco

Um processo estocástico é chamado de ruído branco se, além de estacionário de segunda ordem, não apresenta qualquer dependência serial, isto é:

$$\rho_k = \begin{cases} 1, & \text{para } k = 0 \\ 0, & \text{para } k > 0 \end{cases} \quad (3.8)$$

3.3 Previsão de Séries Temporais

Um dos principais objetivos na análise de séries temporais é a previsão. Simplesmente é a arte de indicar os valores futuros da série, ou seja, realiza-se uma estimativa quantitativa ou conjunto de estimativas acerca da probabilidade de eventos futuros com base na informação passada ou atual. Portanto, dado um conjunto de observações passadas (série histórica) $Z_t = (Z_1, Z_2, \dots, Z_T)$ e com base nas propriedades estatísticas desta série histórica (e possivelmente outras), determinam-se quais são os valores prováveis $Z_{t+1}, Z_{t+2}, \dots, Z_{T+k}$, sendo k o horizonte de previsão. É importante destacar o termo “*horizonte de previsão*” que é o comprimento de tempo da série e varia dependendo do propósito final. À medida que aumenta k diminui a precisão da previsão.

Os horizontes de previsão, para dados mensais, são classificados geralmente em: Prazo imediato (menor que um mês), Curto prazo (de um a três meses), Médio prazo (de três a seis meses) e Longo prazo (um ano ou mais) [38].

Adicionalmente, os tipos de modelos de previsão podem-se classificar em:

- Univariados: Onde são usados apenas valores passados da própria série para estimar os valores futuros. Dentre os modelos tradicionais na literatura pode-se citar o modelo de Box & Jenkins, utilizado no estudo deste trabalho.
- Multivariados: Onde são realizadas as previsões de várias séries temporais simultaneamente.
- Causais: Onde são utilizados tanto os valores observados da série que se deseja prever quanto os valores atuais e observados de outras séries que mantêm uma relação explicativa com a série principal através de funções de transferência.

São muitos os modelos de previsão destacados na literatura. Para ressaltar estão os seguintes: Método Média Móvel [39], Método Ingênuo (*Random Walk*) [40], Método de Amortecimento Exponencial [41], Método de Amortecimento Direto [41] Regressão Dinâmica [42]. Nesta dissertação foi considerado o modelo Box & Jenkins devido à natureza dos dados utilizados.

3.3.1 Modelos Box & Jenkins

A metodologia usada por Box & Jenkins (B&J) tem como objetivo principal a realização de previsão. Essa análise permite que valores futuros de uma série sejam previstos tomando por base seus valores presentes e passados. A filosofia do modelo segue o princípio da parcimônia⁵ e a construção de modelos através de um ciclo iterativo⁶. Também, o modelo assume que a série é estacionária; se não for estacionária, esta pode-se tornar estacionária por meio de sucessivas diferenciações.

Esta metodologia está fundamentada em quatro passos:

- Identificação: Identifica-se um modelo apropriado para a série em questão.
- Estimação: Estimam-se os parâmetros do modelo identificado.
- Verificação do modelo: Checagem do modelo através da análise de resíduos.
- Previsão: O modelo final é usado para prever valores futuros da série.

A seguir, serão apresentados os tipos de modelos na metodologia B&J [43].

3.3.1.1 Modelo Auto-Regressivo (AR)

Esses modelos foram criados com a ideia de que a observação atual da série Z_t pode ser explicada como uma função das observações passadas. A estrutura AR geral é expressada pela equação (3.9).

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \cdots + \phi_p Z_{t-p} + a_t \quad (3.9)$$

Sendo:

ϕ_i os parâmetros da estrutura, $i = 1, 2, \dots, p$.

a_t o ruído branco com média zero e variância σ^2 .

p o número de passos entre as observações passadas e a previsão da próxima observação.

⁵ Representação matemática de um modelo com o menor número de parâmetros possível.

⁶ Estratégia de seleção de modelos até obter um modelo satisfatório.

Utilizando o operador de defasagem B , tem-se:

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)Z_t = a_t \quad (3.10)$$

Sendo:

$$BZ_t = Z_{t-1};$$

$$\phi(B)Z_t = a_t;$$

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p;$$

3.3.1.2

Modelo Médias Móveis (MA)

São formados por combinação linear do ruído branco a_t , ocorridos no período atual e nos períodos passados. A estrutura desse modelo pode-se expressar com a equação (3.11).

$$Z_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (3.11)$$

Sendo:

θ_i os parâmetros da estrutura, $i = 1, 2, \dots, q$.

q o número de passos entre as observações passadas e a previsão da próxima observação.

Utilizando o operador de defasagem B , tem-se:

$$Z_t = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)a_t \quad (3.12)$$

Sendo:

$$Z_t = \theta(B)a_t.$$

$$\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q.$$

3.3.1.3

Modelo Auto-Regressivo Médias Móveis (ARMA)

É uma combinação dos dois modelos anteriores onde Z_t é definido por seus valores passados e pelo ruído branco (atual e passados). Esta estrutura é dada pela equação (3.13).

$$Z_t = \phi_1 Z_{t-1} + \dots + \phi_p Z_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (3.13)$$

Utilizando o operador de defasagem B , tem-se:

$$\begin{aligned}(1 - \phi_1 B - \dots - \phi_p B^p)Z_t &= (1 - \theta_1 B - \dots - \theta_q B^q)a_t \\ \varphi(B)Z_t &= \theta(B)a_t\end{aligned}\quad (3.14)$$

3.3.1.4

Modelo Auto-Regressivo Integrado de Médias Móveis (ARIMA)

O modelo ARIMA (p, d, q) é adequado para a previsão de séries temporais cujo processo estocástico não é estacionário. Portanto, a série original será diferenciada a fim de torná-la estacionária. O número necessário de diferença para transformar a série é denominado ordem de integração. A estrutura geral do modelo está expressada na equação (3.15).

$$\phi(B)\nabla^d Z_t = \theta(B)a_t \quad (3.15)$$

Sendo:

d o número de diferenças.

$\nabla = 1 - B$ e representa o operador diferença.

Este operador é definido como:

$$\begin{aligned}Z_t - Z_{t-1} &= Z_t - BZ_t = (1 - B)Z_t = \nabla Z_t \\ \nabla^d &= (1 - B)^d\end{aligned}\quad (3.16)$$

3.3.1.5

Modelo Sazonal Auto-Regressivo Integrado de Médias Móveis (SARIMA)

O modelo SARIMA (p, d, q) \times (P, D, Q)_S é aplicado na maioria de séries sazonais reais, ou seja, realizações de processos que apresentam correlação serial dentro e entre períodos sazonais. Neste caso pode-se expressar o modelo pela equação (3.17).

$$\phi_p(B)\Phi_P(B^S)\nabla^d\nabla_S^D Z_t = \theta_q(B)\Theta_Q(B^S)a_t \quad (3.17)$$

Sendo:

$\phi(B)$ o componente autorregressivo (AR) de ordem p.

$\theta(B)$ o componente de médias móveis (MA) de ordem q.

$\Phi(B^S) = 1 - \Phi_1 B^S - \Phi_2 B^{2S} - \dots - \Phi_P B^{PS}$ o componente sazonal autorregressivo (AR) de ordem P.

$\Theta(B^S) = 1 - \theta_1 B^S - \theta_2 B^{2S} - \dots - \theta_Q B^{QS}$ o componente sazonal de médias móveis (MA) de ordem Q .

$\nabla^d = (1 - B)^d$ a diferença ordinária de ordem d .

$\nabla_S^D = (1 - B^S)^D$ a diferença sazonal de ordem D .

a_t o ruído branco.

O procedimento de obtenção do modelo SARIMA segue os mesmos passos empregados para achar o modelo ARIMA não sazonal. Isto é, no SARIMA, faz-se também a observação do comportamento da ACF e PACF. Entretanto, verifica-se para os intervalos sazonais, por exemplo os intervalos 12, 24, 36, etc.

3.3.1.6

Modelo Sazonal Auto-Regressivo Integrado de Médias Móveis (SARIMA) com Variáveis Explicativas

Este modelo pode ser estendido em um modelo SARIMA com uma ou mais variáveis explicativas. Este modelo assume que o efeito da variável independente sobre a variável dependente ocorre no tempo atual, ou seja, não considera os efeitos que acontecem em diferentes intervalos de tempo. O modelo pode ser representado pela expressão (3.18).

$$\phi_p(B)\Phi_P(B^S)\nabla^d\nabla_S^D Z_t = \gamma X_t + \theta_q(B)\Theta_Q(B^S)a_t \quad (3.18)$$

Sendo:

X_t a variável explicativa.

γ o parâmetro associado a variável explicativa.

3.4

Avaliação dos Modelos

Para comprovar a validade de um modelo selecionado, pode-se aplicar alguns critérios. Assim, se o modelo é o adequado será utilizado na previsão. A seguir, apresentam-se os critérios utilizados nesta dissertação para definir o modelo. Para mais detalhes sobre outros critérios empregados para avaliação de modelos ver [40], [44], [45] e [46].

3.4.1

Critério de Informação de Akaike (AIC)

Proposto originalmente por Akaike [47], é a distância relativa esperada entre dois modelos probabilísticos, isto é, admite a existência de um modelo “real” que descreve os dados e tenta escolher outro dentre um grupo de modelos avaliados o que minimiza a distância. O critério pode ser expressado pela equação (3.19).

$$AIC = -2 \ln(L) + 2k \quad (3.19)$$

Sendo:

L o valor obtido para a máxima verossimilhança do modelo.

k o número de parâmetros do modelo.

3.4.2

Critério de Informação Bayesiano (BIC)

Proposto por Schwarz [48], definido como a estatística que maximiza a probabilidade de se identificar o modelo dentre os avaliados, considerando-se a existência de um modelo “verdadeiro” que descreve a relação entre a variável dependente e as diversas variáveis explicativas. O critério é dado pela equação (3.20).

$$BIC = -2 \ln(L) + k \ln(n) \quad (3.20)$$

Sendo:

n o número de observações da série.

3.4.3

Sobrefixação

Consiste em estimar um modelo com um número de parâmetros superior ao modelo selecionado. Assim, examina-se se esses parâmetros são significativos e se sua inclusão diminui significativamente a variância residual, ou seja, indicará a necessidade ou não de parâmetros adicionais. A aplicação deste teste é particular para cada caso em estudo, devendo-se conhecer a priori em que direção deve-se acrescentar o número de parâmetros.

3.4.4 Teste de Portmanteau

Teste aplicado aos resíduos. É muito importante ter um teste que considere suas magnitudes como um grupo. Por exemplo, pode ser que a maioria das autocorrelações sejam moderadas, algumas delas próximas de seus valores críticos, mas juntas, parecem excessivas. Box & Jenkins [43], propuseram o expressado na equação (3.21) para abordar essa possibilidade.

$$Q = n \sum_{i=1}^k \hat{\rho}_i^2(\hat{a}) \quad (3.21)$$

Sendo:

$n = N - d$, o número de termos da série.

O teste foi modificado por Ljung & Box [49], expressado pela equação (3.22), onde referindo-se ao valor calculado de Q na tabela de distribuição *Qui-quadrado*⁷, com $M = k - (p + q)$ graus de liberdade, pode-se testar a validade do modelo dentro de um determinado nível de significância.

$$Q = n(n + 2) \sum_{i=1}^k \frac{\hat{\rho}_i^2(\hat{a})}{(n - k)} \quad (3.22)$$

A hipótese de ruído branco é rejeitada para valores grandes de Q .

3.4.5 Teste Jarque-Bera

Teste aplicado aos resíduos para verificar a normalidade. As hipóteses a serem testadas são: H_0 : os resíduos possuem distribuição normal, contra H_1 : os resíduos possuem distribuição não normal [50]. O procedimento do teste consiste em calcular os valores da assimetria e da curtose da amostra, portanto, utiliza-se a expressão (3.23).

$$JB = T \left(\frac{b_1^2}{6} + \frac{(b_2 - 3)^2}{24} \right) \quad (3.23)$$

Sendo:

b_1 os coeficientes amostrais de assimetria.

b_2 os coeficientes amostrais de curtose.

⁷ Teste de hipóteses que diz a adequabilidade de um modelo probabilístico a um conjunto de dados observados.

T o tamanho da amostra.

3.4.6 Gráfico Quantil-Quantil

Este teste é um dos métodos gráficos mais utilizados na verificação de normalidade. Consiste na comparação gráfica dos quartis teóricos da distribuição normal com os quartis dos dados amostrais (resíduos). O gráfico quantil-quantil (*QQ-Plot*) consiste em comparar duas distribuições, se elas forem aproximadamente iguais, ou seja, “*uma distribuição sobrepõe a outra*”, considera-se que a série segue uma distribuição normal, caso contrário as duas distribuições diferem ao longo de alguma dimensão “*não normal*”. Sua interpretação é feita pela análise visual no gráfico, em que, se os erros possuírem distribuição normal, todos os pontos do gráfico devem posicionar-se formando uma reta [51].

3.4.7 Erro Médio Absoluto Percentual (MAPE)

O MAPE é calculado pela diferença entre os valores estimados (previsões 1 passo à frente) e os valores reais, sendo usado tanto para a avaliação *in-sample* quanto para *out-of-sample*. Esta é uma das métricas mais utilizadas na literatura de métodos de previsão, pois fornece um resultado em percentual [33].

$$MAPE = \frac{\sum_{t=1}^N \frac{|Y(t) - \hat{Y}(t)|}{Y(t)}}{N} \times 100 \quad (3.24)$$

Sendo:

$Y(t)$ o valor observado da série temporal no período t .

$\hat{Y}(t)$ o valor ajustado da série temporal no período t .

N o total de observações.

3.4.8 Coeficiente de Determinação (R^2)

O coeficiente R^2 indica o quanto a variação total dos dados é explicada pelo modelo. Ele é calculado através da comparação do erro do modelo e a variação dos dados da série dependente (série a ser prevista) em torno de sua média [33].

$$R^2 = \left(1 - \frac{\sum_{i=1}^N (Y(t) - \hat{Y}(t))^2}{\sum_{i=1}^N (Y(t) - \bar{Y})^2} \right) \times 100 \quad (3.25)$$

Sendo:

\bar{Y} a média de Y .

4

Tratamento das Séries Temporais

No contexto do presente capítulo será apresentado o processo de modelagem das séries temporais em estudo (demanda máxima e energia). Adicionalmente, serão mostrados os resultados dos critérios de avaliação utilizados para a escolha de cada modelo, bem como o processo de previsão das séries. Finalmente, será apresentado o processo de geração dos cenários que irão estruturar a base de dados de entrada no estudo de otimização posterior.

Devido a que esta pesquisa está baseada nos dados reais de um grande consumidor de energia elétrica do estado do Rio de Janeiro, foi escolhido para essa dissertação o modelo B&J SARIMA, não só pelas características do problema proposto (séries sazonais), mas também por ser um modelo reconhecido com bons resultados.

Cada um dos processos mencionados será apresentado nas seções seguintes com suas principais premissas.

4.1

Série Temporal de Energia e Demanda Máxima

São duas as séries utilizadas neste trabalho para a análise pelo método Box & Jenkins SARIMA.

Cada série utilizada nesta dissertação para a análise tem valores mensais. Cada valor mensal foi obtido dos dados de consumo diário de um grande consumidor no Rio de Janeiro onde foram feitas medições em intervalos de quinze (15) minutos (desde 2002 até 2015).

O maior valor de consumo dos intervalos de tempo no mês t será a demanda máxima para esse mês t . Além disso, a soma do consumo de todos os intervalos de tempo no mês t será a energia para esse mês t .

A Figura 4.1 mostra a série de energia, que contém um conjunto de 168 observações mensais que vão desde janeiro de 2002 a dezembro de 2015, expresso em kWh.

A Figura 4.2 apresenta a série da demanda máxima, que contém um conjunto de 168 observações mensais que vão desde janeiro de 2002 a dezembro de 2015, expresso em kW.




Figura 4.1 – Série de consumo de energia de 2002 até 2015.




Figura 4.2 – Série de demanda máxima de 2002 até 2015.

4.2

Modelagem das Séries Temporais por B&J SARIMA

Como esta metodologia permite o uso de variáveis explicativas, nesta fase será empregada a série de energia para explicar a série da demanda máxima, isto é, será utilizada como co-variável.

A modelagem visa identificar e analisar o comportamento das séries de energia e demanda máxima para o ano 2016. De acordo com a Figura 4.1 e a Figura 4.2, pode-se observar que tanto a série de energia como a série de demanda máxima não são estacionárias em todo o espaço de tempo e apresentam uma leve tendência de crescimento.

A estratégia usualmente utilizada na construção de um modelo de B&J é através de um ciclo iterativo (estratégia de seleção de modelos até se obter um modelo satisfatório) [38]. Cada ciclo iterativo cria um modelo, e cada modelo possui características diferentes. No entanto se, por exemplo, obtêm-se dois modelos com características similares, qual será o mais apropriado ou adequado para a série? Neste sentido, para fazer a melhor escolha de um modelo para cada uma das séries, propõe-se um critério, representado pela equação (4.1), para classificar os modelos testados em cada iteração. Este critério considera os critérios de informação AIC e BIC, e o coeficiente de determinação R^2 e dá o mesmo peso para cada um deles no índice calculado abaixo. Assim, quanto menor for o valor do critério I melhor será o modelo.

$$I_i = \frac{AIC_i}{\sum_i AIC_i} + \frac{BIC_i}{\sum_i BIC_i} + \frac{(1 - R_i^2)}{\sum_i (1 - R_i^2)} \quad (4.1)$$

Sendo:

AIC_i o valor do AIC do modelo testado na iteração i .

BIC_i o valor do BIC do modelo testado na iteração i .

R_i^2 o valor do R^2 do modelo testado na iteração i .

Também, para garantir a normalidade dos resíduos, realizou-se o teste Jarque-Bera para cada uma das iterações feitas; se o resultado for maior que o nível de 0,05 (5%) aceita-se a hipótese nula confirmando a normalidade dos resíduos. Se o resultado não for maior que o nível de 0,05, o modelo é descartado e continua com a próxima iteração i .

Deste modo, utilizando o *software* RStudio [52], versão 3, foi identificado o modelo apropriado de previsão para cada uma das séries. A seguir são apresentados os resultados obtidos.

Na Tabela 4.1 estão apresentados os resultados do critério I para os dez (10) melhores modelos testados para a série de energia. Consequentemente, considerando a expressão (4.1), o modelo **SARIMA (1, 1, 23) \times (0, 1, 1)₁₂** foi escolhido, sendo o valor de $I = 0.2889$.

Tabela 4.1– Resultados dos melhores modelos, segundo o critério I . Energia.

Modelo	AIC	BIC	R ²	1-R ²	I
(1,1,23) \times (0,1,1) ₁₂	3615,59	3692,63	0,8783	0,1216	0,2889
(1,1,23) \times (0,1,2) ₁₂	3617,48	3697,48	0,8781	0,1219	0,2893
(1,1,23) \times (1,1,1) ₁₂	3616,34	3696,33	0,8742	0,1257	0,2920
(0,1,23) \times (2,1,1) ₁₂	3615,74	3695,73	0,8611	0,1388	0,3016
(0,1,23) \times (2,1,2) ₁₂	3617,69	3700,65	0,8601	0,1398	0,3025
(0,1,23) \times (1,1,1) ₁₂	3620,43	3697,47	0,8592	0,1407	0,3032
(0,1,23) \times (0,1,1) ₁₂	3624,51	3698,58	0,8585	0,1414	0,3039
(0,1,23) \times (0,1,2) ₁₂	3625,55	3702,59	0,8571	0,1428	0,3050
(0,1,21) \times (2,1,2) ₁₂	3619,98	3697,01	0,8556	0,1443	0,3058
(0,1,20) \times (2,1,1) ₁₂	3622,69	3696,76	0,8536	0,1463	0,3074

De acordo com a equação (3.17) o modelo **SARIMA (1,1,23) \times (0,1,1)₁₂** pode ser representado em função de E_t pela expressão (4.2). Adicionalmente, a Tabela 4.2 apresenta cada um dos parâmetros estimados, onde se encontram destacados aqueles que são significantes.

$$\begin{aligned}
E_t = & (1 + \phi_1)E_{t-1} - \phi_1 E_{t-2} + E_{t-12} + (1 - \phi_1)E_{t-13} + \\
& \phi_1 E_{t-14} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \theta_3 a_{t-3} - \theta_4 a_{t-4} - \theta_5 a_{t-5} - \\
& \theta_6 a_{t-6} - \theta_7 a_{t-7} - \theta_8 a_{t-8} - \theta_9 a_{t-9} - \theta_{10} a_{t-10} - \theta_{11} a_{t-11} - \\
& (\theta_{12} + \theta_1) a_{t-12} - (\theta_{13} - \theta_1 \theta_1) a_{t-13} - (\theta_{14} - \theta_1 \theta_2) a_{t-14} - \\
& (\theta_{15} - \theta_1 \theta_3) a_{t-15} - (\theta_{16} - \theta_1 \theta_4) a_{t-16} - (\theta_{17} - \theta_1 \theta_5) a_{t-17} - \\
& (\theta_{18} - \theta_1 \theta_6) a_{t-18} - (\theta_{19} - \theta_1 \theta_7) a_{t-19} - (\theta_{20} - \theta_1 \theta_8) a_{t-20} - \\
& (\theta_{21} - \theta_1 \theta_9) a_{t-21} - (\theta_{22} - \theta_1 \theta_{10}) a_{t-22} - \\
& (\theta_{23} - \theta_1 \theta_{11}) a_{t-23} + \theta_1 \theta_{12} a_{t-24} + \theta_1 \theta_{13} a_{t-25} + \theta_1 \theta_{14} a_{t-26} + \\
& \theta_1 \theta_{15} a_{t-27} + \theta_1 \theta_{16} a_{t-28} + \theta_1 \theta_{17} a_{t-29} + \theta_1 \theta_{18} a_{t-30} + \\
& \theta_1 \theta_{19} a_{t-31} + \theta_1 \theta_{20} a_{t-32} + \theta_1 \theta_{21} a_{t-33} + \theta_1 \theta_{22} a_{t-34} + \\
& \theta_1 \theta_{23} a_{t-35}
\end{aligned} \quad (4.2)$$

Para avaliar a qualidade do modelo selecionado, foram analisadas as funções de autocorrelação (ACF) e autocorrelação parcial (PACF) dos resíduos.

Igualmente, foi utilizado o QQ-Plot e a distribuição normal padrão para verificar a normalidade dos mesmos.

Na Figura 4.3 pode-se verificar que o modelo estimado é adequado, pois não apresenta padrões de correlação entre os resíduos. As linhas azuis representam os limites de confiança superiores e inferiores. Note que os resíduos são pequenos e encontram-se dentro dos limites.

Tabela 4.2 – Parâmetros estimados do modelo *SARIMA* (1, 1, 23) × (0, 1, 1)₁₂.

Coefficiente	Valor	Coefficiente	Valor
ϕ_1	-0,5710	θ_{13}	0,0183
θ_1	-0,0217	θ_{14}	0,0599
θ_2	-0,4664	θ_{15}	0,0919
θ_3	-0,3323	θ_{16}	0,0282
θ_4	0,0838	θ_{17}	-0,0797
θ_5	-0,0585	θ_{18}	-0,2169
θ_6	-0,3001	θ_{19}	0,1323
θ_7	-0,2474	θ_{20}	0,1716
θ_8	0,3061	θ_{21}	-0,0270
θ_9	0,2701	θ_{22}	-0,3958
θ_{10}	-0,2000	θ_{23}	0,5089
θ_{11}	-0,2029	θ_1	-0,9997
θ_{12}	-0,0182		




Figura 4.3 – ACF e PACF: Resíduos da série de energia.

A Figura 4.4 mostra a verificação da normalidade dos resíduos. O QQ-Plot produz uma linha reta aproximada, sugerindo que a série segue uma distribuição normal.

De acordo com os resultados, têm-se evidências para considerar que os resíduos do modelo são normalmente distribuídos e o modelo é adequado para representar a série de energia. Adicionalmente, para quantificar a qualidade do modelo, foram feitos alguns testes para dados *In-Sample* e *Pseudo Out-of-Sample*. Para realizar isto, o modelo foi estimado desde 2002 até 2014, deixando o ano 2015 para a análise *Pseudo Out-of-Sample*. A Tabela 4.3 apresenta os resultados comparando as duas análises com os valores de referência. Os testes indicam uma boa aderência para ambos casos.




Figura 4.4 – Avaliação normalidade dos resíduos da série de energia.

Tabela 4.3 – Testes estatísticos para análise *In-Sample* e *Pseudo Out-of-Sample*.

Testes Estatísticos	In-Sample	Pseudo Out-of-Sample	Valores ideais
R²	87,83%	74,34%	100%
MAPE	3,83%	5,02%	0%
Assimetria	0,139	-0,131	0
Curtoses	2,911	2,483	3
Jarque-Bera	0,758	0,919	> 0.05

Para ilustrar os resultados obtidos, a Figura 4.5 apresenta a série de energia e o modelo estimado aplicado para as análises *In-Sample* e *Pseudo Out-of-Sample*.

Deve-se destacar que foram utilizados todos os dados, desde 2002 até 2015, para simular os cenários futuros para o ano 2016, que serão apresentados na seção 4.4.

Por outro lado, a Tabela 4.4 mostra os resultados do critério I para os dez (10) melhores modelos testados para a série de demanda máxima.




Figura 4.5 – Análises *In-Sample* e *Pseudo Out-of-Sample* da série de energia.

Igualmente, como foi considerado para a série de energia, utilizou-se a expressão (4.1) para obter o modelo B&J de estimação. O modelo escolhido foi aquele com menor valor do critério I . Neste caso é o modelo $SARIMA(0,1,21) \times (1,1,2)_{12}$, onde $I = 0,2957$

Tabela 4.4 – Resultados dos melhores modelos, segundo o critério I . Demanda Máxima.

Modelo	AIC	BIC	R ²	1-R ²	I
$(0,1,21) \times (1,1,2)_{12}$	1965,89	2041,92	0,8758	0,1241	0,2957
$(0,1,20) \times (2,1,2)_{12}$	1969,45	2046,48	0,8748	0,1251	0,2969
$(0,1,21) \times (0,1,2)_{12}$	1965,07	2039,14	0,8731	0,1268	0,2976
$(0,1,20) \times (1,1,2)_{12}$	1964,28	2038,35	0,8713	0,1286	0,2989
$(0,1,23) \times (0,1,1)_{12}$	1968,2	2045,24	0,8709	0,1290	0,2998
$(3,1,4) \times (1,1,1)_{12}$	1942,43	1975,02	0,8642	0,1357	0,3001
$(3,1,4) \times (0,1,2)_{12}$	1943,00	1975,59	0,8640	0,1359	0,3003
$(0,1,20) \times (0,1,2)_{12}$	1963,99	2035,1	0,8676	0,1323	0,3016
$(0,1,20) \times (0,1,1)_{12}$	1962,21	2030,35	0,8671	0,1328	0,3016
$(1,1,10) \times (2,1,2)_{12}$	1959,54	2009,91	0,8588	0,1411	0,3068

Nesta estimação do modelo, destaca-se como variável explicativa a série de energia E_t . De acordo com a equação (3.18), o modelo $SARIMA(0,1,21) \times$

$(1,1,2)_{12}$, pode ser representado pela expressão (4.3). Adicionalmente, a Tabela 4.5 apresenta cada um dos parâmetros estimados, onde estão destacados aqueles significantes.

$$\begin{aligned}
 D_t = & \gamma E_t + D_{t-1} + (1 + \Phi_1)D_{t-12} - (1 + \Phi_1)D_{t-13} - \Phi_1 D_{t-24} + \\
 & \Phi_1 D_{t-25} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \theta_3 a_{t-3} - \theta_4 a_{t-4} - \theta_5 a_{t-5} - \\
 & \theta_6 a_{t-6} - \theta_7 a_{t-7} - \theta_8 a_{t-8} - \theta_9 a_{t-9} - \theta_{10} a_{t-10} - \theta_{11} a_{t-11} - \\
 & (\theta_{12} + \theta_1) a_{t-12} - (\theta_{13} - \theta_1 \theta_1) a_{t-13} - (\theta_{14} - \theta_1 \theta_2) a_{t-14} - \\
 & (\theta_{15} - \theta_1 \theta_3) a_{t-15} - (\theta_{16} - \theta_1 \theta_4) a_{t-16} - (\theta_{17} - \theta_1 \theta_5) a_{t-17} - \\
 & (\theta_{18} - \theta_1 \theta_6) a_{t-18} - (\theta_{19} - \theta_1 \theta_7) a_{t-19} - (\theta_{20} - \theta_1 \theta_8) a_{t-20} - \\
 & (\theta_{21} - \theta_1 \theta_9) a_{t-21} + \theta_1 \theta_{10} a_{t-22} + \theta_1 \theta_{11} a_{t-23} + (\theta_1 \theta_{12} - \\
 & \theta_2) a_{t-24} + (\theta_1 \theta_{13} - \theta_2 \theta_1) a_{t-25} + (\theta_1 \theta_{14} - \theta_2 \theta_2) a_{t-26} + \\
 & (\theta_1 \theta_{15} - \theta_2 \theta_3) a_{t-27} + (\theta_1 \theta_{16} - \theta_2 \theta_4) a_{t-28} + (\theta_1 \theta_{17} - \\
 & \theta_2 \theta_5) a_{t-29} + (\theta_1 \theta_{18} - \theta_2 \theta_6) a_{t-30} + (\theta_1 \theta_{19} - \theta_2 \theta_7) a_{t-31} + \\
 & (\theta_1 \theta_{20} - \theta_2 \theta_8) a_{t-32} + (\theta_1 \theta_{21} - \theta_2 \theta_9) a_{t-33} + \theta_2 \theta_{10} a_{t-34} + \\
 & \theta_2 \theta_{11} a_{t-35} + \theta_2 \theta_{12} a_{t-36} + \theta_2 \theta_{13} a_{t-37} + \theta_2 \theta_{14} a_{t-38} + \\
 & \theta_2 \theta_{15} a_{t-39} + \theta_2 \theta_{16} a_{t-40} + \theta_2 \theta_{17} a_{t-41} + \theta_2 \theta_{18} a_{t-42} + \\
 & \theta_2 \theta_{19} a_{t-43} + \theta_2 \theta_{20} a_{t-44} + \theta_2 \theta_{21} a_{t-45}
 \end{aligned} \tag{4.3}$$

Tabela 4.5 – Parâmetros estimados do modelo *SARIMA* $(0, 1, 21) \times (1, 1, 2)_{12}$.

Coeficiente	Valor	Coeficiente	Valor
Φ_1	-0,6069	θ_{13}	-0,8263
θ_1	-0,9158	θ_{14}	0,2966
θ_2	0,0245	θ_{15}	0,0023
θ_3	0,1678	θ_{16}	-0,2876
θ_4	-0,1914	θ_{17}	0,2247
θ_5	0,0943	θ_{18}	0,1049
θ_6	-0,0260	θ_{19}	-0,0545
θ_7	-0,0264	θ_{20}	-0,0031
θ_8	-0,0980	θ_{21}	-0,1301
θ_9	-0,1339	θ_1	-0,8582
θ_{10}	0,0432	θ_2	-0,1414
θ_{11}	-0,0404	γ	0,007
θ_{12}	0,7754		

Para avaliar a qualidade do modelo selecionado, como foi feito para a série de energia, foram analisadas as funções de autocorrelação (ACF) e autocorrelação parcial (PACF) dos resíduos. Também, foi utilizado o QQ-Plot e a distribuição normal padrão para verificar a normalidade dos mesmos.

Na Figura 4.6 verifica-se que os resíduos não apresentam padrões de correlação. Note que os resíduos são pequenos e encontram-se dentro dos limites.




Figura 4.6 – ACF e PACF: Resíduos da série de demanda máxima.

A Figura 4.7 apresenta a checagem da normalidade dos resíduos. De acordo com os resultados, os resíduos do modelo são considerados normalmente distribuídos. Por isto, o modelo é adequado para representar a série de Demanda Máxima.

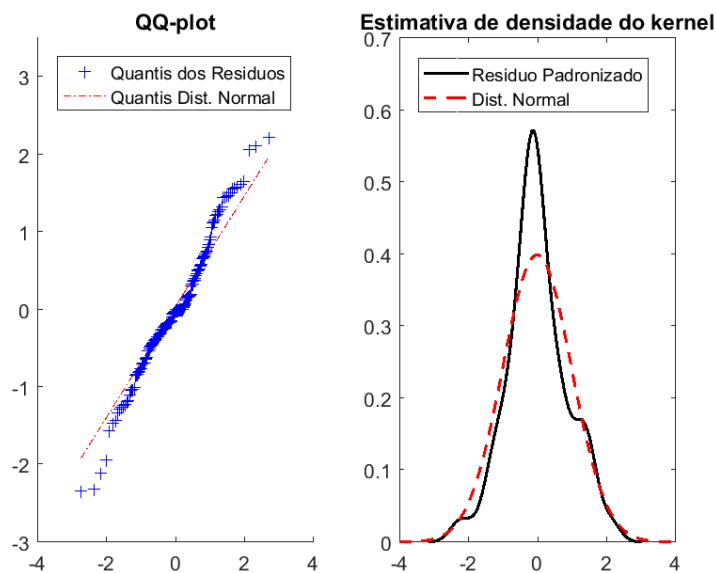



Figura 4.7 – Avaliação normalidade dos resíduos da série de demanda máxima.

Do mesmo modo que foi feito para a série de energia, quantificou-se a qualidade do modelo com os testes *In-Sample* e *Pseudo Out-of-Sample*. A Tabela 4.6 apresenta os resultados comparando as duas análises com os valores de referência. Os testes indicam uma boa aderência para ambos casos.

Tabela 4.6 – Testes estatísticos para análise *In-Sample* e *Pseudo Out-of-Sample*.

Testes Estatísticos	In-Sample	Pseudo Out-of-Sample	Valores ideais
R²	87,59%	78,91%	100%
MAPE	3,94%	5,37%	0%
Assimetria	0,083	-0,182	0
Curtoses	3,257	1,728	3
Jarque-Bera	0,736	0,645	> 0.05

Além disso, a Figura 4.8 mostra a série de energia e o modelo estimado aplicado para as análises *In-Sample* e *Pseudo Out-of-Sample*. Igualmente, para simular os cenários futuros para o ano 2016 foram utilizados todos os dados, desde 2002 até 2015 (ver seção 4.4).

Figura 4.8 – Análises *In-Sample* e *Pseudo Out-of-Sample* da série de demanda máxima.

4.3

Previsão das Séries Temporais por B&J SARIMA

Após encontrar o melhor modelo para cada série temporal foi realizada a previsão para o ano 2016. Na série de energia, os valores previstos dependem dos valores passados da mesma. Assim, a Figura 4.9 apresenta a energia prevista a partir da expressão (4.2).




Figura 4.9 – Previsão por B&J para a série de energia.

Para comparar os dados reais com os valores de previsão para a série de energia, a Tabela 4.7 mostra o erro percentual mensal do ano 2016. É importante destacar que os dados reais do ano 2016 foram obtidos das faturas mensais do grande consumidor, onde as medições não fecharam o mês inteiro, por exemplo, o consumo do mês de Janeiro (na fatura) inclui a leitura desde o dia seis (6) de Janeiro até o dia três (3) de Fevereiro. Nesta dissertação utilizam-se os dados de consumo de energia e demanda para o mês inteiro, isto é, o consumo do mês de Janeiro está compreendido entre os dias 1 até 31. Da mesma forma para todos os meses.

Tabela 4.7 – Comparação de valores reais e previstos para o ano 2016, Energia.

Mês	Real (kWh)	Previsão (kWh)	Erro (%)
Janeiro	927.639,00	937.559,000	1,07%
Fevereiro	1.109.140,00	911.621,900	17,81%
Março	1.427.130,00	1.257.486,600	11,89%
Abril	1.200.691,00	1.160.388,300	3,36%
Maio	1.069.428,00	1.013.860,600	5,20%
Junho	924.828,00	926.725,000	0,21%
Julho	774.967,00	795.132,000	2,60%
Agosto	820.783,00	957.180,600	16,62%
Setembro	989.654,00	1.046.009,600	5,69%
Outubro	1.127.698,00	1.095.117,100	2,89%
Novembro	1.218.527,00	1.135.661,000	6,80%
Dezembro	810.840,00	989.856,500	22,08%

Para a série de demanda máxima, os valores previstos não só dependem dos valores passados da série como também dos valores futuros da variável explicativa, neste caso os valores previstos da série de energia. Assim, a Figura 4.10 apresenta a demanda máxima prevista a partir da expressão (4.3).




Figura 4.10 – Previsão por B&J para a série de demanda máxima.

Da mesma forma, Para comparar os dados reais com os dados previstos Tabela 4.8 mostra o erro percentual mensal da demanda máxima do ano 2016.

Tabela 4.8 – Comparação de valores reais e previstos para o ano 2016, Demanda Máx.

Mês	Real (kWh)	Previsão (kWh)	Erro (%)
Janeiro	3.024,00	2.987,35	1,21%
Fevereiro	3.581,80	3.588,52	0,19%
Março	4.247,00	3.871,77	8,84%
Abril	3.924,50	3.705,37	5,58%
Maio	3.521,30	3.446,65	2,12%
Junho	2.432,60	2.797,83	15,01%
Julho	2.567,00	2.462,63	4,07%
Agosto	2.909,80	3.118,28	7,16%
Setembro	3.790,10	3.202,28	15,51%
Outubro	3.689,30	3.426,91	7,11%
Novembro	3.675,80	3.606,57	1,88%
Dezembro	3.581,80	3.412,17	4,74%

4.4 Geração dos Cenários

Dada a normalidade dos resíduos (ver Figura 4.3 e Figura 4.4), procedeu-se à obtenção de dois mil (2000) cenários, tanto para energia quanto a Demanda Máxima, onde os resíduos são escolhidos por meio de um sorteio randômico e aplicados em torno da estimativa feita para 2016. Destaca-se que foi utilizada uma variância constante para todo ano. Assim, para a energia $var(E) = 2.931.534.737$ e para a demanda $var(D) = 34.254$.




Figura 4.11 – Simulação de cenários de energia.




Figura 4.12 – Simulação de cenários de demanda máxima.

A simulação dos 2000 cenários foi escolhida apenas por razões didáticas, sendo que a simulação poderia ser feita para um número maior ou menor de cenários. Cada cenário contém 12 dados, que correspondem aos meses do ano. Portanto, tem-se no total 24000 dados. Na Figura 4.11 e na Figura 4.12 estão ilustradas as simulações dos cenários realizados.

Para observar os padrões de média e variância das simulações, apresentam-se a Figura 4.13 e a Figura 4.14, onde estão ilustrados os dados empilhados do histórico e dos cenários simulados.

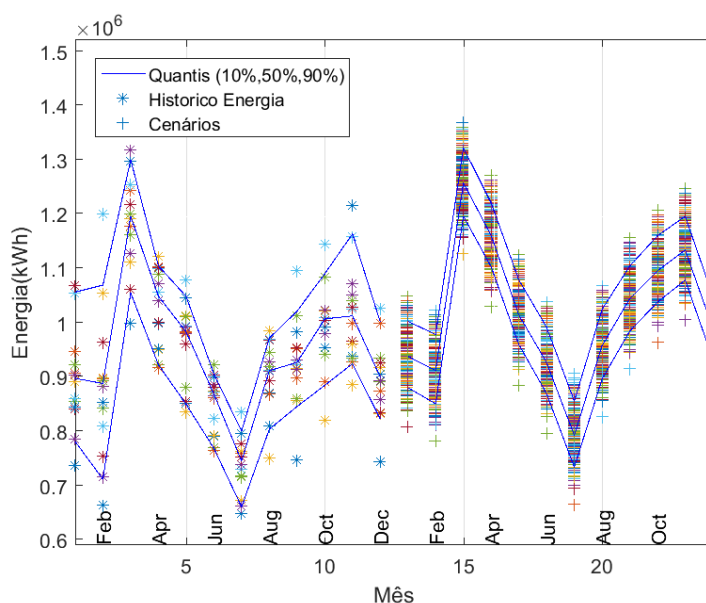


Figura 4.13 – Histórico e simulação de cenários de energia.




Figura 4.14 – Histórico e simulação de cenários de demanda máxima.

5

Simulação da Geração Distribuída

No contexto do presente capítulo, descreve-se o conceito de Geração Distribuída (GD), características, classificação e tipos de tecnologias disponíveis, com foco na Geração Fotovoltaica, utilizada no desenvolvimento desta dissertação. Para a sua aplicação foi escolhido um tipo de painel fotovoltaico e, definindo-se um perfil de produção de energia associado a ele. Finalmente, será apresentado o processo de geração dos cenários que irão estruturar a base de dados de entrada no estudo de otimização posterior, descrito no Capítulo 6.

O termo Geração Distribuída (GD) é definido como a geração de energia, que abrange eletricidade e outros energéticos, localizada próxima ao consumidor final, cuja instalação objetiva seu atendimento prioritário, podendo ou não gerar excedentes energéticos comercializáveis para além das instalações do consumidor [7]. No Brasil, a resolução 482/2012 [6] da ANEEL classifica a GD entre microgeração distribuída (com potência instalada menor ou igual a 100kW), relacionadas principalmente às residências e ao setor comercial; e minigeração distribuída (com potência instalada superior a 100kW e menor ou igual a 1MW), associadas à indústria.

A prática da GD envolve o uso não só de tecnologias comprovadas e comercialmente disponíveis como motores de combustão interna, turbinas a gás e sistemas de cogeração, mas também de tecnologias emergentes como módulos fotovoltaicos, aerogeradores e células a combustível, entre outros. Neste trabalho foi considerada a geração fotovoltaica aplicada a um consumidor comercial. Mais detalhes da utilização desta e outras fontes de GD podem ser obtidos em [53] e [54].

5.1

Geração Fotovoltaica

A energia do sol pode ser utilizada para produzir eletricidade através do efeito fotovoltaico, que consiste no surgimento de uma tensão elétrica em um material semicondutor exposto a uma luz visível [55]. Assim, é possível converter radiação solar em corrente elétrica através de uma célula fotovoltaica, composta por duas camadas de material semicondutor dos tipos P e N⁸, uma grade superior de coletores metálicos e uma base metálica interior, que são os terminais elétricos que no fim fazem a coleta da corrente elétrica produzida pela ação dos fótons⁹, que energizam os elétrons. Atualmente, as placas fotovoltaicas produzidas em larga escala são de silício monocristalino, policristalino ou amorfo.

Os sistemas fotovoltaicos podem empregar um grande número de módulos conectados em série ou em paralelo para produzir a potência na tensão desejada e podem ser instalados em telhados, coberturas de residências, prédios, fábricas ou em qualquer outro tipo de unidade consumidora com ambiente que receba raios do sol diretamente. Um sistema fotovoltaico com ligação à rede, é composto normalmente pelos seguintes componentes:

- PAINEL Fotovoltaico: Composto de vários módulos¹⁰ em série, paralelo ou uma combinação série/paralelo, com estruturas de suporte e montagem.
- Caixa de junção: Equipada com dispositivos de proteção.
- Inversor: Utilizado para a conversão da corrente contínua, gerada pelo arranjo fotovoltaico, em corrente alternada.
- Disjuntor: Aparelho de proteção contra sobrecargas elétricas.
- Medidor: Mede a quantidade de energia consumida e gerada pela instalação fotovoltaica.

Mais detalhes sobre construção, características e especificações podem ser encontrados em [56].

⁸ Nos semicondutores, o nome N provém da negatividade gerada da carga negativa existente (elétron livre); e o nome P da carga positiva existente (ausência de um elétron).

⁹ São as partículas que compõem a luz e podem ser definidos como pequenos “pacotes” que transportam a energia contida nas radiações eletromagnéticas.

¹⁰ A fabricação de módulos fotovoltaicos é feita através do encadeamento de várias células solares.

5.2

Considerações para o Sistema Fotovoltaico Aplicado ao Trabalho

Como não se tem dados históricos de um sistema fotovoltaico instalado próximo ao consumidor considerado neste trabalho, assume-se um painel fotovoltaico composto de um único módulo com 72 células solares de silício com as seguintes características:

- Potência: 330Wp.
- Eficiência: 16%.
- Vida útil: 20 anos (240 meses).

Além disso, assume-se um custo para o painel com um preço base de R\$1250 (mil e dois centos e cinquenta reais), onde o 70% do valor corresponde ao módulo, estruturas de suporte e materiais elétricos e, 30% restante corresponde ao inversor. Em média, um inversor solar tem uma vida útil entre 7 e 10 anos. Assim, assume-se também que o inversor será trocado três vezes ao longo do período de tempo (20 anos). É importante destacar que não foram considerados custos de adequação de terreno e custos de instalação, além de não considerar a troca de outros elementos durante o período de tempo como por exemplo medidor, proteções, etc.

Finalmente, assume-se o custo final do painel fotovoltaico para todo o período de tempo, dado pela expressão (5.1).

$$C_{pv} = (1250 * 0.7) + (1250 * 0.3 * 3) = R\$2000 \quad (5.1)$$

Com as características descritas anteriormente, é possível obter os dados de geração do painel através do site *Renewables.ninja* [57]. Este é um site que trabalha tomando dados meteorológicos e observações por satélite. Deste modo, permite ao usuário gerar de forma gratuita, dados a cada hora de geração eólica ou geração solar em qualquer lugar do planeta. Basicamente, consiste em escolher a localização desejada e selecionar o tipo de geração (vento ou solar) com o valor da capacidade do sistema.

Neste trabalho considera-se um grande consumidor localizado no Rio de Janeiro no bairro da Gávea. Assim, foram simulados os dados a partir de [57] para um painel de 330Wp.

Na Figura 5.1, pode-se observar o perfil de geração de energia no ano 2015. É possível verificar um comportamento típico esperado, com potência gerada

menor no início do dia e um aumento gradativo entre as 6h e 7h, atingindo o valor máximo no período compreendido entre as 12h e 13h aproximadamente. Depois disto, a potência cai chegando a zero a partir das 19h.

Na Figura 5.2, apresenta-se a quantidade de energia gerada pelo painel fotovoltaico de 330Wp ao longo do ano. Note que Junho e Julho são os meses com menos produção de energia (inverno no Brasil). Além disto, outubro é o mês com maior produção de energia com 52.48 kWh. A quantidade média mensal de energia gerada é de 47 kWh.




Figura 5.1 – Perfil de geração média horária de um painel fotovoltaico 330Wp.




Figura 5.2 – Geração de energia mensal de um painel fotovoltaico 330Wp.

5.3 Geração dos Cenários

Com o intuito de avaliar a correlação existente entre a demanda e energia de um grande consumidor com a produção de energia de um sistema fotovoltaico, instalado próximo dele, criaram-se cenários de geração.

Em primeiro lugar, foram replicados os valores de energia gerada (apresentados na Figura 5.2), a fim de obter 2000 cenários, que é a mesma quantidade de cenários considerada para a energia e demanda máxima simulada (cenários apresentados no Capítulo 4). Feito isto, mudou-se cada valor, aumentando ou descontando um montante de energia, ou seja, para cada cenário, escolhe-se aleatoriamente um número, entre uma faixa de 5% para mais e para menos, e faz-se o aumento ou a redução no valor original de geração. Por exemplo, o valor inicial de energia gerada no mês de Janeiro é 51.70 kWh, não obstante, em cada cenário Janeiro terá um valor maior ou menor, dependente do valor obtido na faixa percentual de -5% e +5%. Portanto, todos os cenários nunca terão um valor, para o mês de Janeiro, inferior do que 49.11 kWh nem superior do que 54.28 kWh (95% e 105% respectivamente). Assim, garante-se que cada dado de todo cenário terá valores de energia diferentes, com o objetivo de criar numerosas possibilidades para a geração de energia do sistema fotovoltaico.




Figura 5.3 – Cenários de geração de energia de um painel fotovoltaico 330Wp.

Na Figura 5.3 estão ilustrados os cenários que serão utilizados como dados de entrada no modelo de otimização apresentado no Capítulo 6.

A simulação dos 2000 cenários foi escolhida apenas por razões didáticas, sendo que a simulação poderia ser feita para um número maior ou menor de cenários. Cada cenário contém 12 dados, que correspondem aos meses do ano. Portanto, têm-se no total 24000 dados.

Destaca-se que os cenários simulados de energia, demanda e geração têm a mesma quantidade de elementos, a fim de combiná-los de forma aleatória. Desse modo, serão utilizados como dados de entrada no modelo de otimização apresentado no Capítulo 6.

6 Modelo de Otimização

Neste capítulo, descrevem-se duas métricas de risco necessárias para a análise no desenvolvimento do modelo de otimização. Devido à não-convexidade do problema, descrito no capítulo 2 (ver Figura 2.1), utiliza-se uma formulação MILP¹¹ (*Mixed Integer Linear Programming* ou Programação Linear Inteira Mista).

Finalmente, apresenta-se o modelo de otimização de custo anualizado de um grande consumidor no ACR na modalidade Verde A4 considerando Geração Fotovoltaica.

6.1 Métricas de Risco

O risco pode ser compreendido como a possibilidade de ocorrência de um evento não desejável ou adverso e pode se apresentar de diversas formas, porém todas elas surgem devido às incertezas sobre o futuro [58]. Assim, o risco está relacionado a um acontecimento futuro, portanto informações de eventos passados, experiência e modelos de previsão servem de subsídios para uma avaliação deste evento futuro, melhorando a assertividade na percepção daquilo que está por vir.

No setor elétrico, a utilização de medidas de risco em problemas de contratação de energia ou demanda está associada à incerteza inerente à variabilidade futura destes dados. Isto pode levar a resultados com perdas significativas, no qual o tratamento destas informações considerando as estimativas dos riscos associados pode indicar uma atitude mais ou menos conservadora.

Dessa forma, além de haver várias formas de riscos, existem também inúmeras maneiras de quantificá-lo, dentre das quais existem a metodologia *Value at Risk* (Valor em Risco - VaR) e a metodologia *Conditional Value at Risk* (Valor

¹¹ MILP é uma variante da programação linear inteira (ILP), onde algumas variáveis de decisão estão limitadas para serem valores inteiros e, outras variáveis, valores binários. Para mais detalhes de ILP e MILP ver [59]

em Risco Condicional - CVaR), sendo esta última utilizada no desenvolvimento deste trabalho.

6.1.1

Value at Risk (VaR)

Segundo [60], o VaR é um método de mensuração de risco que utiliza técnicas estatísticas. O VaR mede a pior perda esperada ao longo de determinado intervalo de tempo, sob condições normais e dentro de determinado nível de confiança ($\alpha\%$), ou seja, o VaR corresponderá ao $(100 - \alpha)\%$ da distribuição. Por exemplo, se o nível de confiança for de 98%, teremos um VaR de 2%. Resumindo, o VaR responde a pergunta “até que ponto as coisas podem piorar?”.

Em termos matemáticos, o VaR pode ser definido pela expressão (6.1), onde para uma distribuição de probabilidade de uma variável aleatória R e dado um nível de confiança α entre 0% e 100%, o VaR dessa distribuição será o menor valor r tal que a probabilidade de ocorrência de um cenário R de valor inferior a r seja, no máximo, de $(100 - \alpha)\%$ [61].

$$VaR(R) = \inf\{r \mid P(R \leq r) < (1 - \alpha)\} \quad (6.1)$$

Esta métrica deve ser vista como um procedimento necessário, mas não suficiente, para o controle do risco, isto é, não deve ser utilizada como um gestor de riscos independente, mas sim controlado e limitado. Contudo, esta métrica de risco é criticada por não quantificar a magnitude dos resultados gerados no caso da ocorrência de um cenário muito ruim considerado. Além disso não possui propriedades desejáveis, como por exemplo, convexidade e a diferenciabilidade, o que dificulta a sua implementação em algoritmos de otimização.

6.1.2

Conditional Value at Risk (CVaR)

O CVaR é uma métrica derivada do VaR e é definida como a média das piores perdas esperadas ao longo de determinado intervalo de tempo, sob condições normais de mercado e dentro de um determinado nível de confiança [60], ou seja, indica a perda média que excede o VaR, quantifica “quão” grande é, na média, a perda ou o risco a que se está sujeito [62]. O CVaR é considerado uma

métrica coerente¹² e é mais pessimista que o VaR. Resumindo, o CVaR responde a pergunta “Se as coisas piorarem, quanto se pode esperar perder?”.

Em termos matemáticos, descreve-se o CVaR na expressão (6.2), onde para uma distribuição de probabilidade da variável aleatória R e dado um nível de confiança ($\alpha\%$) entre 0% e 100%, o CVaR é dado pela média dos valores menores do VaR dessa distribuição. Isto é, o CVaR é a média dos $(100 - \alpha)\%$ piores cenários da distribuição de probabilidade de determinada variável aleatória.

$$CVaR(R) = E(R | R \leq VaR(R)) \quad (6.2)$$

A Figura 6.1, extraída de [63], apresenta de maneira gráfica os conceitos de VaR e CVaR.




Figura 6.1 – VaR, CVaR e Perda Esperada.

A grande vantagem do CVaR é a sua capacidade de capturar a presença e a magnitude de cenários mais adversos. Assim, a análise do risco, no que poderia estar exposto, é mais acertada.

A questão da volatilidade dos cenários de consumo de energia e demanda requerida será tratada pelo CVaR no desenvolvimento deste trabalho, não só pelas vantagens que esta métrica apresenta, mas também, por se tratar de uma medida de risco coerente.

¹² Uma métrica de risco é coerente se, satisfaz as propriedades de Subaditividade, Monotonicidade, Homogeneidade Positiva de grau 1, Invariância por Translação e Convexidade. Para mais detalhes ver [61].

6.2

Otimização para o ACR - Verde A4 Considerando Geração Fotovoltaica

Com a inclusão da geração fotovoltaica por parte do consumidor assume-se, como hipótese, que o consumidor não obterá ganhos pela energia excedente gerada. Isto é proposto para evitar que o modelo resulte em um número infinito de painéis quando a tarifa de energia for muito elevada. Por esse motivo, a geração do painel fotovoltaico não poderá ultrapassar a energia mensal consumida, de modo a garantir que o consumidor não se converta em um produtor de energia. É importante ressaltar que as regras vigentes permitem que o consumidor possa gerar energia acima do seu consumo e utilizar os créditos em outros meses ou mesmo em outro ponto de consumo [6]. Além disso, o modelo considera que o valor da demanda contratada pode sofrer redução apenas uma vez ao ano e seu acréscimo pode ser feito a qualquer tempo [24]

A expressão (6.3) corresponde à função objetivo de custo anualizado, obtida pela ponderação entre Valor Esperado (VE) e CVaR.

$$Custo_{Anual} = \min_{\left\{ \begin{array}{l} C_{D_{s,t}}, C_{E_{s,t}}, C_{inv_t}, D_t^c, D_{pv,s,t}^{max}, \Delta_{s,t}, \\ d_{s,t}^u, \mu_{s,t,h}, E_{pv,s,t}^p, E_{pv,s,t}^{fp}, n_{pv}, x_t, \\ y_t, z_{1s,t}, z_{2t}, \delta_{s,t}, w_t \end{array} \right\}} (1 - \lambda) \frac{1}{S} \sum_{t \in T} \sum_{s \in S} C_{s,t} + \lambda \left(\sum_{t \in T} w_t + \sum_{s \in S} \left(\frac{\delta_{s,t}}{1 - \alpha} \right) \frac{1}{S} \right) \quad (6.3)$$

Sujeito a:

$$C_{s,t} = C_{D_{s,t}} + C_{E_{s,t}} + C_{inv_t} \quad \forall s, t \quad (6.4)$$

$$C_{D_{s,t}} = T_D \cdot (D_t^c + \Delta_{s,t} + d_{s,t}^u) + T_D^u \cdot d_{s,t}^u \quad \forall s, t \quad (6.5)$$

$$C_{E_{s,t}} = E_{s,t}^p \cdot T_E^p + E_{s,t}^{fp} \cdot T_E^{fp} \quad \forall s, t \quad (6.6)$$

$$C_{inv_t} = C_{AM} \cdot n_{pv} \quad \forall t \quad (6.7)$$

$$C_{AM} = C_{pv} \frac{j(1+j)^n}{(1+j)^n - 1} \quad (6.8)$$

$$D_t^c + \Delta_{s,t} + d_{s,t}^u \geq D_{pv,s,t}^{max} \quad \forall s, t \quad (6.9)$$

$$D_{pv,s,t}^{max} \geq \mu_{s,t,h} \quad \forall s, t, h \quad (6.10)$$

$$\Delta_{s,t} \leq D_t^c \cdot u \quad \forall s, t \quad (6.11)$$

$$d_{s,t}^u \geq (D_{pv,s,t}^{max} - D_t^c) \cdot x_t \quad \forall t, s \quad (6.12)$$

$$d_{s,t}^u \leq M \cdot x_t \quad \forall s, t \quad (6.13)$$

$$x_t \in \{0,1\} \quad \forall t \quad (6.14)$$

$$D_t^c \geq D_{t-1}^c - M \cdot y_t \quad \forall t > 1 \quad (6.15)$$

$$D_1^c \geq d_0 - M \cdot y_1 \quad (6.16)$$

$$y_t \in \{0,1\} \quad \forall t > 1 \quad (6.17)$$

$$y_1 \in \{0,1\} \quad (6.18)$$

$$\sum_{t \in T} y_t + y_1 = 1 \quad (6.19)$$

$$E_{pv,s,t}^p \geq E_{s,t}^p - G_{s,t}^p \cdot n_{pv} \quad \forall s, t \quad (6.20)$$

$$E_{pv,s,t}^p \leq E_{s,t}^p \quad \forall s, t \quad (6.21)$$

$$\sum_{t \in T} E_{pv,s,t}^p \leq \sum_{t \in T} E_{s,t}^p \quad \forall s \quad (6.22)$$

$$E_{pv,s,t}^{fp} \geq E_{s,t}^{fp} - G_{s,t}^{fp} \cdot n_{pv} \quad \forall s, t \quad (6.23)$$

$$E_{pv,s,t}^{fp} \leq E_{s,t}^{fp} \quad \forall s, t \quad (6.24)$$

$$\sum_{t \in T} E_{pv,s,t}^{fp} \leq \sum_{t \in T} E_{s,t}^{fp} \quad \forall s \quad (6.25)$$

$$\delta_{s,t} \geq C_{s,t} - w_t \quad \forall s, t \quad (6.26)$$

$$\delta_{s,t} \geq 0 \quad \forall s, t \quad (6.27)$$

Sendo:

$Custo_{Anual}$ o custo ótimo anualizado, considerando geração com painel fotovoltaico, (R\$).

$C_{s,t}$ o custo total para o cenário s e o mês t , (R\$).

$C_{D_{s,t}}$ o custo da demanda contratada para o cenário s e o mês t , (R\$).

D_t^c a demanda a ser contratada no mês t , (kW).

$\Delta_{s,t}$ a tolerância de demanda do cenário s e do mês t , (kW).

T_D a tarifa de demanda dada por resolução ANEEL, (R\$/kW).

$d_{s,t}^u$ a ultrapassagem de demanda do cenário s e do mês t , (kW).

T_D^u a tarifa de ultrapassagem de demanda ($T_D^u = 2 \cdot T_D$, R\$/kW, [24]).

$D_{pv,s,t}^{max}$ a demanda máxima com painel fotovoltaico, no cenário s e no mês t , (kW).

$\mu_{s,t,h}$ a demanda máxima com painel fotovoltaico no cenário s , no mês t e na hora h , (kW).

u o percentual tolerado de ultrapassagem de demanda ($u = 5\%$, [24]).

x_t a variável binária indicativa de ultrapassagem de demanda no mês t .

M o número grande (*Big M*) utilizado como parâmetro auxiliar.

y_t a variável binária indicativa de redução da demanda no mês t .

d_0 a demanda contratada no primeiro mês, (kW).

$C_{E,s,t}$ o custo da energia para o cenário s e o mês t , (R\$).

$E_{pv,s,t}^p$ a energia na ponta com painel fotovoltaico no cenário s e no mês t , (kWh).

$E_{s,t}^p$ a energia na ponta simulada no cenário s e no mês t , (kWh).

$G_{s,t}^p$ a energia gerada na ponta pelo painel fotovoltaico no cenário s e no mês t , (kWh).

T_E^p a tarifa de energia na ponta dada pela resolução ANEEL, (R\$/kWh).

$E_{pv,s,t}^{fp}$ a energia fora da ponta com painel fotovoltaico no cenário s e no mês t , (kWh).

$E_{s,t}^{fp}$ a energia fora da ponta simulada no cenário s e no mês t , (kWh).

$G_{s,t}^{fp}$ a energia gerada fora da ponta pelo painel fotovoltaico no cenário s e no mês t , (kWh).

T_E^{fp} a tarifa de energia fora da ponta dada pela resolução ANEEL, (R\$/kWh).

C_{inv_t} o custo de investimento do painel fotovoltaico para o mês t , (R\$).

C_{AM} o custo de amortização do painel fotovoltaico por período, (R\$).

C_{pv} o custo do painel fotovoltaico à vista, dado pela expressão (5.1), (R\$).

n_{pv} o número total de painéis fotovoltaicos.

j a taxa de juros associada ao custo de oportunidade, (%).

n o número de vida útil do painel fotovoltaico.

$\delta_{s,t}$ a variável auxiliar que representa o lado esquerdo de custos a partir do valor de custo w_t no cenário s e no mês t para o período de análise.

w_t a variável auxiliar que atinge o valor em risco (VaR) da distribuição de custos no mês t para o período de análise.

λ a constante que faz a ponderação entre VE e CVaR.

α o parâmetro de aversão ao risco que define o nível de confiança de CVaR.

A restrição (6.4) apresenta o custo final para cada cenário e cada mês do ano. As restrições (6.5) e (6.6) representam os custos para a demanda contratada e a energia consumida respectivamente, para cada cenário s e cada mês t . A restrição (6.7) corresponde ao custo de investimento do sistema fotovoltaico, onde (6.8) apresenta o custo de amortização para um painel, considerando a taxa de juros (j) associada ao custo oportunidade e a vida útil (n) do painel. A restrição (6.9) estabelece que a demanda contratada (D_t^c) mais a tolerância ($\Delta_{s,t}$) mais a demanda de ultrapassagem ($d_{s,t}^u$) deve ser maior ou igual que o valor de demanda máxima com painel ($D_{pv,s,t}^{max}$), para cada cenário s e cada mês t . Nesse caso, o maior valor entre a demanda máxima com painel fotovoltaico e a demanda máxima contratada, é garantido para ser utilizado, de acordo com as expressões (2.1) e (2.2).

A restrição (6.10) determina que a demanda máxima com painel fotovoltaico, para o cenário s e o mês t , deve ser maior ou igual que o valor da demanda máxima com painel para qualquer hora do dia h , não só pelo fato de que algum módulo do sistema fotovoltaico poderia apresentar falhas em diferentes períodos do dia, mas também porque nem todos os dias serão ensolarados. Neste caso, nesses horários h acontecerá a demanda máxima do mês t .

Visto que está-se trabalhando com dados mensais e, além disso, o perfil de geração do painel fotovoltaico adotado neste trabalho (ver Figura 5.1) varia durante o dia, comparou-se a demanda do último ano do histórico (2015) com os dados de geração diária (obtidos para 2015), a fim de saber como será o comportamento da demanda máxima em diferentes horas do dia quando é modificada a quantidade de painéis (potência instalada).

Para conhecer este comportamento, dividiu-se o período de tempo em 12 intervalos de duas horas (0h-1h, 2h-3h, ..., 20h-21h e 22h-23h), com o intuito de mudar o número de painéis (n_{pv}) e identificar as 50 maiores demandas máximas para cada intervalo de tempo¹³ e, após isso, obter a média desse conjunto de demandas máximas. Deste modo, toda vez que mudar n_{pv} , será obtido um único valor, o qual representa o comportamento da demanda máxima em cada intervalo de tempo de duas horas. Para exemplificar, a Tabela 6.1 apresenta os dados de demanda máxima e geração de um painel, para o intervalo de tempo compreendido entre as 14h-15h. Observe que a demanda diminui com a inclusão da geração. Após a inclusão do painel, separam-se as maiores 50 demandas máximas de todo o ano, como é apresentado na Tabela 6.2, a fim de obter a média, e assim, um único valor que representará o comportamento da demanda máxima para o intervalo de tempo compreendido entre as 14h-15h.

Tabela 6.1 – Demanda máxima e geração de um painel fotovoltaico, intervalo de tempo 14h-15h.

Data	Hora	Demanda (kW)	Geração (kW)	Dem. - Ger.
01/01/2015	14:00	793,00	0,19	792,81
01/01/2015	15:00	806,40	0,15	806,25
02/01/2015	14:00	1680,00	0,19	1679,81
02/01/2015	15:00	1639,70	0,16	1639,54
03/01/2015	14:00	1706,90	0,20	1706,70
03/01/2015	15:00	1653,10	0,17	1652,93
04/01/2015	14:00	994,60	0,21	994,39
⋮	⋮	⋮	⋮	⋮
29/12/2015	14:00	1424,60	0,01	1424,59
29/12/2015	15:00	1377,60	0,01	1377,59
30/12/2015	14:00	1290,20	0,02	1290,18
30/12/2015	15:00	1263,40	0,02	1263,38
31/12/2015	14:00	799,70	0,01	799,69
31/12/2015	15:00	766,10	0,01	766,09

Em consequência, se aumentar a quantidade de painéis, a demanda máxima da maioria dos períodos de tempo considerados tenderá a zero.

A Figura 6.2 mostra o comportamento da demanda máxima em cada intervalo de tempo, considerando o sistema fotovoltaico. Note que, se $n_{pv} = 0$, a

¹³ As maiores 50 demandas máximas correspondem ao 7% dos dados totais para cada intervalo de tempo.

maior demanda se apresenta no período das 14h-15h, com um valor de 3348.7 kW. Este valor será a referência para modelar o comportamento da demanda máxima nos demais intervalos de tempo, ou seja, as equações que representam cada intervalo de tempo, serão dependentes da maior demanda máxima de todos os períodos de tempo.

Tabela 6.2 – Maiores 50 demandas máximas considerando um painel fotovoltaico, para o intervalo de tempo 14h-15h.

Data		Hora	Demanda (kW)	Geração (kW)
1	12/03/2015	14:00	3729,39	0,21
2	18/03/2015	14:00	3715,97	0,23
3	25/02/2015	14:00	3702,50	0,20
4	10/03/2015	14:00	3695,80	0,20
5	18/03/2015	15:00	3655,50	0,20
6	25/02/2015	15:00	3635,32	0,18
⋮	⋮	⋮	⋮	⋮
45	21/03/2015	14:00	3440,40	0,20
46	31/10/2015	15:00	3433,72	0,18
47	10/02/2015	14:00	3426,98	0,22
48	05/11/2015	15:00	3413,70	0,10
49	25/11/2015	15:00	3406,87	0,14
50	22/05/2015	14:00	3406,79	0,22
Média			3539,38	-

Por exemplo, quando $n_{pv} = 0$, o valor da demanda máxima no período compreendido entre as 12h-13h é 3306.5 kW, ou seja, 99.3% da referência; para o período compreendido entre as 10h-11h, o valor da demanda máxima é 3280.5 kW, ou seja, 98.5% da referência; para o período compreendido entre as 8h-9h, o valor da demanda máxima é 3048.3 kW, ou seja, 91% da referência, e assim por diante. Desta forma, considera-se esse valor percentual para estimar a demanda máxima com painel em todo intervalo de tempo. Também, mostra-se que o intervalo compreendido entre 12h-13h, é o período que consegue atingir toda a demanda mais rápido ($D_{pv,s,t}^{max} = 0$), isto é, com o menor número de painéis (aproximadamente 22850). Finalmente, há demandas que ficam constantes, devido ao fato de não haver geração do painel nesses intervalos de tempo (0h-1h, 2h-3h, 4h-5h, 20h-21h, 22h-23h).

Assim, pode-se obter uma equação que descreva a variação da demanda máxima simulada considerando a geração fotovoltaica. As restrições (6.28) - (6.35) são utilizadas para representar o comportamento da demanda máxima no cenário s , no mês t e na hora h , sendo considerado o sistema fotovoltaico.




Figura 6.2 – Demanda máxima vs quantidade de painéis fotovoltaicos.

$$\mu_{s,t,h} = (-6.107 \cdot n_{pv})\beta_{1,s,t} + D_{s,t}^{max} \quad \forall s, t, h \in \{15,16\}^{14} \quad (6.28)$$

$$\mu_{s,t,h} = (-7.615 \cdot n_{pv})\beta_{2,s,t} + 0,993 \cdot D_{s,t}^{max} \quad \forall s, t, h \in \{13,14\} \quad (6.29)$$

$$\mu_{s,t,h} = (-6.706 \cdot n_{pv})\beta_{3,s,t} + 0,985 \cdot D_{s,t}^{max} \quad \forall s, t, h \in \{11,12\} \quad (6.30)$$

$$\mu_{s,t,h} = (-3.467 \cdot n_{pv})\beta_{4,s,t} + 0,910 \cdot D_{s,t}^{max} \quad \forall s, t, h \in \{9,10\} \quad (6.31)$$

$$\mu_{s,t,h} = (-2.971 \cdot n_{pv})\beta_{5,s,t} + 0,885 \cdot D_{s,t}^{max} \quad \forall s, t, h \in \{17,18\} \quad (6.32)$$

$$\mu_{s,t,h} = (-0.362 \cdot n_{pv})\beta_{6,s,t} + 0,695 \cdot D_{s,t}^{max} \quad \forall s, t, h \in \{19,20\} \quad (6.33)$$

$$\mu_{s,t,h} = (-0.821 \cdot n_{pv})\beta_{7,s,t} + 0,663 \cdot D_{s,t}^{max} \quad \forall s, t, h \in \{7,8\} \quad (6.34)$$

$$\mu_{s,t,h} = 1925,284 \quad \forall s, t, h \in \{1,2,3,4,5,6,21,22,23,24\} \quad (6.35)$$

Sendo:

$D_{s,t}^{max}$ a demanda máxima simulada no cenário s e no mês t , (kW).

¹⁴ Indica as posições de h na matriz $\mu_{s,t,h}$, ou seja, o horário compreendido entre 0h-1h será a posição {1,2} da matriz, o horário compreendido entre 2h-3h será a posição {3,4} da matriz e assim por diante.

$\beta_{1,s,t}$ a variável binária indicativa de ausência de geração no intervalo de tempo compreendido entre as 14h-15h no cenário s e no mês t .

$\beta_{2,s,t}$ a variável binária indicativa de ausência de geração no intervalo de tempo compreendido entre as 12h-13h no cenário s e no mês t .

$\beta_{3,s,t}$ a variável binária indicativa de ausência de geração no intervalo de tempo compreendido entre as 10h-11h no cenário s e no mês t .

$\beta_{4,s,t}$ a variável binária indicativa de ausência de geração no intervalo de tempo compreendido entre as 8h-9h no cenário s e no mês t .

$\beta_{5,s,t}$ a variável binária indicativa de ausência de geração no intervalo de tempo compreendido entre as 16h-17h no cenário s e no mês t .

$\beta_{6,s,t}$ a variável binária indicativa de ausência de geração no intervalo de tempo compreendido entre as 18h-19h no cenário s e no mês t .

$\beta_{7,s,t}$ a variável binária indicativa de ausência de geração no intervalo de tempo compreendido entre as 6h-7h no cenário s e no mês t .

A restrição (6.11) garante que a ultrapassagem de demanda deve ser menor ou igual que 5% do valor da demanda contratada, a fim de evitar penalidades.

As restrições (6.12) - (6.14) são utilizadas para considerar a não convexidade do modelo, seja para escolher uma regra (sem penalidade) ou outra regra (com penalidade). Se a solução do modelo proposto indica vantagem, em termos de custo pagando penalidade no mês t , a variável x_t será igual a 1 e o valor $d_{s,t}^u$ será diferente de zero. Caso contrário, se x_t é igual a zero, não será aplicada a penalidade. Ressalta-se que se $\Delta_{s,t} = 0$, $d_{s,t}^u$ será diferente de zero e vice-versa. A expressão (6.12) possui dois produtos de duas variáveis de decisão que devem ser manipulados algebricamente. Portanto, realizou-se seu desmembramento em 5 equações, resultando em um modelo linear disjuntivo descrito pelas expressões (6.36) - (6.40).

$$d_{s,t}^u \geq z_{1,s,t} - z_{2,t} \quad \forall t, s \quad (6.36)$$

$$0 \leq D_{pv,s,t}^{max} - z_{1,s,t} \leq (1 - x_t) \cdot M \quad \forall s, t \quad (6.37)$$

$$0 \leq z_{1,s,t} \leq M \cdot x_t \quad \forall t, s \quad (6.38)$$

$$0 \leq D_t^c - z_{2t} \leq (1 - x_t) \cdot M \quad \forall t \quad (6.39)$$

$$0 \leq z_{2t} \leq M \cdot x_t \quad \forall t \quad (6.40)$$

Sendo:

$z_{1s,t}$ a variável auxiliar que trata o produto de variável quando há ultrapassagem de demanda no cenário s e no mês t .

z_{2t} a variável auxiliar que trata o produto de variável quando há ultrapassagem de demanda no mês t .

As restrições (6.15) - (6.19) permitem a redução do valor de demanda contratada para um mês específico, de acordo com o valor inicial (d_0). Por exemplo, se $y_1 = 1$, a D_t^c terá redução em Janeiro. A restrição (6.15) permite a redução da D_t^c para outros meses do ano. Por exemplo se $y_2 = 1$ a redução será feita em Fevereiro e assim por diante. As restrições (6.17) - (6.19) garantem que a redução aconteça unicamente uma vez no ano, considerando as regras no Brasil.

As restrições (6.20) - (6.25) permitem a redução de energia devido ao uso da geração fotovoltaica. Consideram-se as restrições (6.21), (6.22), (6.24), e (6.25), onde a energia gerada na ponta e fora da ponta ($E_{pv,s,t}^p, E_{pv,s,t}^{fp}$) não ultrapassarão a energia consumida na ponta e fora da ponta ($E_{s,t}^p, E_{s,t}^{fp}$), respectivamente, para todo cenário s e todo mês t . Assim, o consumidor não obterá ganhos com a energia gerada.

Finalmente, as restrições (6.26) e (6.27) compreendem as restrições do CVaR considerando os $1 - \alpha\%$ piores cenários de custo a serem aplicados na função objetivo (6.3) [60].

7

Resultados e Discussões

Neste capítulo serão apresentados e discutidos os principais resultados obtidos para um grande consumidor de distribuição.

O modelo de otimização proposto foi implementado no *software* Xpress [64] que, como pode ser encontrado em [65], tem um desempenho competitivo resolvendo MILP. Contudo, é importante destacar que pode ser utilizado qualquer *software* que trabalhe com MILP. A solução foi obtida utilizando a técnica *branch and bound* [66]. O melhor valor para o consumidor, tanto da demanda contratada quanto o número de painéis, foi atingida simulando 2000 cenários de energia, demanda máxima e geração para cada mês. As simulações foram realizadas em computador com processador Intel Core i7, 3,40 GHz com 8 GB de RAM. O tempo médio de otimização girou em torno de 5 minutos.

7.1

Resultados de Otimização ACR - Verde A4 sem Geração Fotovoltaica, para 2016

Para realizar a otimização do custo anualizado, foi adotado o valor de demanda máxima inicial $d_0 = 3800kW$, haja vista este ter sido o valor contratado vigente para o grande consumidor. Além disso, faz-se uma desagregação de energia em ponta e fora da ponta como indica a modalidade verde. Essa desagregação é dada pelas expressões (7.1) - (7.2), onde a energia na ponta corresponde ao consumo de somente três horas do dia e a energia fora da ponta corresponde ao consumo das horas restantes do dia.

$$E_{s,t}^p = \frac{3}{24} \cdot E_{s,t} \quad (7.1)$$

$$E_{s,t}^{fp} = \frac{21}{24} \cdot E_{s,t} \quad (7.2)$$

Também, o parâmetro de aversão ao risco α escolhido é igual a 95%, o que significa que o 5% dos piores cenários de custo serão usados pelo CVaR no processo de otimização. O parâmetro λ foi utilizado para simular os perfis de aversão ao risco. Se $\lambda = 0$, a análise considera apenas o Valor Esperado (VE); se $\lambda = 0.5$, a análise pondera 50% VE e 50% CVaR e; se $\lambda = 1$, na análise considera-se apenas CVaR.

Na Tabela 7.1 estão apresentados os resultados de otimização para o ano de 2016, para os três perfis de aversão ao risco considerados, isto é, λ igual a 0,0,5 e 1. À medida que se aumenta a aversão ao risco da análise, aumenta-se o custo de demanda ligado a ela. Isso era esperado por se tratar de uma contratação mais conservadora do ponto de vista dos piores cenários. Além disso, apresentam-se os custos para cada perfil considerado na análise. A diferença entre o maior custo (quando $\lambda = 1$), e o menor custo (quando $\lambda = 0$) é aproximadamente de 9.4%. Este valor quantifica o impacto do risco tomado pelo consumidor.

Tabela 7.1 – Perfis ótimos de demanda contratada e custo para diferentes valores de λ

Mês	Demanda Contratada (kW) (do=3800kW)		
	$\lambda=0$	$\lambda=0.5$	$\lambda=1$
Janeiro	3800,00	3800,00	3800,00
Fevereiro	3809,22	3809,22	3858,80
Março	3809,22	4078,98	4078,98
Abril	3809,22	4078,98	4078,98
Maio	3809,22	4078,98	4078,98
Junho	2750,11	2853,02	3056,18
Julho	2750,11	2853,02	3056,18
Agosto	3151,20	3361,37	3356,47
Setembro	3239,13	3441,38	3441,37
Outubro	3458,06	3655,30	3655,30
Novembro	3588,51	3826,41	3826,40
Dezembro	3588,51	3826,41	3826,40
Custo (R\$)			
Perfil Aversão	$\lambda=0$	$\lambda=0.5$	$\lambda=1$
Custo Anualizado	8.361.738,16	8.809.152,41	9.233.915,83




Figura 7.1 – Demanda contratada mensal para diferentes valores de λ .

Na Figura 7.1, os resultados do modelo de otimização estão apresentados para o ano 2016, com os perfis de aversão ao risco considerados. Também, são apresentados os cenários, a fim de observar como o valor da demanda contratada se ajusta nos cenários simulados.

É importante destacar que o modelo de otimização minimiza o custo anual para cada valor de risco, portanto, a estratégia envolve todos os meses do ano em conjunto, ao invés de contratar o melhor valor individual para cada mês. Portanto, nem sempre uma solução evidente, Julho neste caso, é a melhor estratégia.

7.2

Resultados de Otimização ACR - Verde A4 com Geração Fotovoltaica, para 2016

Além de assumir os mesmos valores dos parâmetros $d_0 = 3800kW$, $\alpha = 95\%$ e $\lambda = 0, 0.5$ ou 1 , e a desagregação de energia, que foi descrito na seção 7.1, considera-se um sistema fotovoltaico instalado no consumidor. Portanto, são utilizados os cenários de geração, apresentados no Capítulo 5 (ver Figura 5.3). Assim, realizou-se a otimização do custo anualizado para o ano 2016.

Apesar de contar com valores teóricos do painel fotovoltaico, obtidos em condições padrão (*Standard Testing Conditions* - STC), não se garante que a potência indicada pelo fabricante seja a geração real, devido a diversos fatores que

influenciam no desempenho do sistema fotovoltaico, por exemplo, condições ambientais, diferenças de fabricação nos módulos, perdas no inversor, etc. Consequentemente, realizaram-se algumas modificações nos cenários de geração, a fim de comparar o custo/benefício de cada análise realizado.

7.2.1

Resultados de Otimização sem redução nos cenários de Geração

Para realizar a otimização do custo desta análise, dispõem-se de todos os dados de geração, sem modificações dos cenários, isto é, o sistema fotovoltaico operando 100%.

Considerando apenas o VE para a análise ($\lambda = 0$), o número de painéis ótimos (n_{pv}) a serem instalados é de 18350. No caso em que $\lambda = 0.5$, $n_{pv} = 19092$. Finalmente, $n_{pv} = 21074$, considerando somente CVaR na análise. Verifica-se que à medida que o risco aumenta o número de painéis é maior, portanto, quanto maior o risco maior o sistema fotovoltaico.

Para avaliar o impacto produzido pelo sistema fotovoltaico, a Figura 7.2 apresenta o comportamento da média dos cenários simulados de energia consumida e a média da energia produzida pelo sistema fotovoltaico, para $\lambda = 0$, 0,5 e 1. Note que quanto maior o número painéis instalados maior é a energia gerada e, portanto, maior será o desconto na energia consumida. Isto pode ser ilustrado na Figura 7.3, que exibe a energia anual consumida após a inclusão do sistema fotovoltaico.

Na Tabela 7.2 apresenta-se a demanda contratada para $\lambda = 0$, 0.5 e 1. Note que a demanda contratada para todo mês é igual em todos os perfis de aversão considerados, quer dizer, no período de tempo em que o sistema fotovoltaico pode produzir energia, consegue-se atender toda a demanda. Consequentemente, só pode contratar o valor mínimo de demanda, dado pela restrição (6.35), o qual é 1925.284 kW. Além disso, apresentam-se os custos para cada perfil considerado na análise. Como é esperado, à medida que se aumenta o risco da análise, aumenta-se o custo anual atrelado a ela. A diferença entre o maior custo (quando $\lambda = 1$), e o menor custo (quando $\lambda = 0$) é aproximadamente de 12.14%, o qual quantifica o impacto do risco tomado pelo consumidor.




Figura 7.2 – Energia média consumida e energia média gerada sem redução nos cenários de geração.




Figura 7.3 – Redução de energia pelo uso do sistema fotovoltaico para diferentes valores de λ sem redução nos cenários de geração.

Tabela 7.2 – Perfis ótimos de demanda contratada e custo para diferentes valores de λ . Sem redução nos cenários de geração.

Mês	Demanda Contratada (kW) (do=3800kW)		
	$\lambda=0$	$\lambda=0.5$	$\lambda=1$
Janeiro	1925,284	1925,284	1925,284
Fevereiro	1925,284	1925,284	1925,284
Março	1925,284	1925,284	1925,284
Abril	1925,284	1925,284	1925,284
Maio	1925,284	1925,284	1925,284
Junho	1925,284	1925,284	1925,284
Julho	1925,284	1925,284	1925,284
Agosto	1925,284	1925,284	1925,284
Setembro	1925,284	1925,284	1925,284
Outubro	1925,284	1925,284	1925,284
Novembro	1925,284	1925,284	1925,284
Dezembro	1925,284	1925,284	1925,284
Custo (R\$)			
Perfil Aversão	$\lambda=0$	$\lambda=0.5$	$\lambda=1$
Quant. Painéis	18350	19092	21074
Custo Anualizado	7.228.964,02	7.760.553,75	8.228.139,23

7.2.2

Resultados de Otimização com redução de 10% nos cenários de Geração

Nesta análise, propõe-se alterar a produção de energia (cenários descritos no Capítulo 4) do sistema fotovoltaico, a fim de observar o impacto causado, tanto na demanda quanto na energia, devido à redução de geração de energia.

Por um lado, tratam-se os dados de geração de energia escolhendo-se aleatoriamente 2400 dados dos cenários de geração, que são equivalentes a 10% do total. Após, reduz-se 10% do valor desses elementos. Por exemplo, caso aleatoriamente se escolha o dado 7 (Julho) do cenário 5, que tem um valor de 795266,134 kWh, diminui-se 10%. Consequentemente, o valor considerado nesta análise, para o mês 7 do cenário 5, será 715739,52 kWh.

Assim, consideram-se diferentes cenários com redução na geração de energia. A Figura 7.4 apresenta os cenários de geração com as modificações realizadas.

Com o objetivo de comparar a geração total considerada na seção 7.2.1 (ver Figura 5.3), ou seja, 100% do que pode gerar um painel, em relação aos cenários de geração modificados (Figura 7.4), somou-se todos os valores da energia gerada de todos os cenários, para observar a diferença percentual que foi reduzida comparado com os dados inicialmente considerados. Assim, ao descontar 10% dos dados da energia gerada de um painel fotovoltaico, diminui-se 2% do total, ou seja, esta análise considera 98% da energia dos cenários de geração inicialmente considerados.




Figura 7.4 – Redução de 10% dos dados de geração.

Por outro lado, a demanda máxima é tratada de outra maneira, já que ela pode acontecer em qualquer hora do dia. Portanto, é modificada considerando as restrições (6.28) - (6.34). Utilizam-se as variáveis binárias $\beta_{1,t}, \beta_{2,t}, \dots, \beta_{7,t}$, para realizar as alterações em cada intervalo do dia considerado (6h-7h, 8h-9h, 10h-11h, 12h-13h, 14h-15h, 16h-17h, 18-19h), onde 1 indica geração e 0 corresponde à não geração do painel. Portanto, modificam-se randomicamente 10% dos dados de cada variável binária β , isto é, cada variável β terá 2400 dados modificados aleatoriamente, nos quais serão alocados zeros. Assim, será assumida uma falha ou ausência de geração em diferentes períodos do dia.

O resultado do número de painéis (n_{pv}), considerando apenas o CVaR para a análise ($\lambda = 1$), é de 9199. Para a análise realizada com 50% do VE e 50% do CVaR, $n_{pv} = 18225$. Finalmente, $n_{pv} = 18358$ considerando uma análise apenas com VE ($\lambda = 0$). Verifica-se que o otimizador propõe instalar menor quantidade de painéis à medida que o risco aumenta, devido ao fato de que o CVaR dá importância no 5% dos piores cenários (100 cenários), e provavelmente instalar um número maior de painéis não faça muita diferença no consumo e no custo.

A Figura 7.5 apresenta o comportamento da média dos cenários de energia consumida e a média da energia produzida pelo sistema fotovoltaico, para os três perfis de aversão considerados, com o propósito de observar a influência do sistema fotovoltaico no consumo.




Figura 7.5 – Energia média consumida e energia média gerada com redução de 10% dos dados de geração.




Figura 7.6– Redução de energia pelo uso do sistema fotovoltaico para diferentes valores de λ com redução de 10% dos dados de geração.

Esse impacto causado pelo sistema fotovoltaico pode ser visto na Figura 7.6. Observa-se que para $\lambda = 1$, a redução de energia é menor comparada com os outros perfis, devido que o sistema fotovoltaico contém menor quantidade de painéis.

Na Figura 7.7, apresenta-se a demanda contratada para o ano 2016, com os perfis de aversão ao risco considerados. Também, ilustram-se os cenários de demanda máxima, a fim de observar como o valor da demanda contratada se ajusta aos cenários simulados. Neste caso, os cenários de demanda máxima modificados pela ausência de geração influenciam na seleção da quantidade de painéis e, consequentemente, na contratação. Para $\lambda = 0$, a redução da demanda contratada ocorre em Janeiro, posteriormente, aumenta somente 9,24 kW e permanece constante até Julho com um valor de 2670,13 kW, a demanda aumenta levemente desde Agosto até Novembro, onde alcança um valor de 3141,03 kW, permanecendo constante até Dezembro. Para $\lambda = 0,5$ e $\lambda = 1$ o comportamento é bastante similar, tendo maiores valores de demanda considerando uma análise com CVaR. A Tabela 7.3, apresenta o valor da demanda contratada mensal e o custo anualizado para cada perfil considerado na análise. Como esperado, quanto maior o risco da análise, maior o custo anual atrelado à ela. A diferença entre o maior custo (quando $\lambda = 1$), e o menor custo (quando $\lambda = 0$) é aproximadamente de 16,32%, o qual quantifica o impacto do risco tomado pelo consumidor.




Figura 7.7 – Demanda contratada mensal para diferentes valores de λ com redução de 10% dos dados de geração.

Tabela 7.3 – Perfis ótimos de demanda contratada e custo para diferentes valores de λ com redução de 10% dos dados de geração.

Mês	Demanda Contratada (kW) (do=3800kW)		
	$\lambda=0$	$\lambda=0.5$	$\lambda=1$
Janeiro	2660,89	3800,00	3800,00
Fevereiro	2670,13	3800,00	3800,00
Março	2670,13	3800,00	3817,17
Abril	2670,13	3800,00	3817,17
Maio	2670,13	3800,00	3817,17
Junho	2670,13	2577,96	2638,68
Julho	2670,13	2577,96	2638,68
Agosto	2762,22	2770,33	2892,01
Setembro	2894,50	2897,92	2938,48
Outubro	3038,28	3043,17	3171,25
Novembro	3141,03	3449,02	3604,65
Dezembro	3141,03	3449,02	3604,65
Custo (R\$)			
Perfil Aversão	$\lambda=0$	$\lambda=0.5$	$\lambda=1$
Quant. Painéis	18358	18225	9199
Custo Anualizado	7.608.278,08	8.377.672,53	9.092.994,28

7.2.3

Resultados de Otimização com redução de 20% nos cenários de Geração

Do mesmo modo que na seção 7.2.2, propõe-se alterar em 20% a produção de energia do sistema fotovoltaico. Assim, tratam-se os dados de geração de energia escolhendo-se randomicamente 4800 dados dos cenários de geração, que são equivalentes a 20% do total. Após, reduz-se 20% do valor desses elementos. Considerando o exemplo da seção 7.2.2, caso aleatoriamente se escolha o dado 7 (Julho) do cenário 5, que tem um valor de 795266,134 kWh, diminui-se 20%. Consequentemente, o valor considerado nesta análise, para o mês 7 do cenário 5, será 636212,907 kWh.

Desta forma, consideram-se diferentes cenários com redução na geração de energia. Na Figura 7.8 apresentam-se os cenários de geração com as alterações realizadas.




Figura 7.8 – Redução de 20% dos dados de geração.

A fim de comparar a geração total considerada na seção 7.2.1 (ver Figura 5.3), ou seja, 100% do que pode gerar um painel, em relação aos cenários de geração modificados (Figura 7.8), somaram-se todos os valores da energia gerada em todo cenário. Assim, quando desconta-se 20% dos dados da energia gerada de um painel fotovoltaico, diminui-se 4% do total, isto é, esta análise considera 96% da energia dos cenários de geração inicialmente considerados.

Também, a demanda máxima é modificada considerando as restrições (6.28) - (6.34). Usaram-se as variáveis binárias $\beta_{1,s,t}, \beta_{2,s,t}, \dots, \beta_{7,s,t}$, para realizar as alterações em cada intervalo do dia considerado (6h-7h, 8h-9h, 10h-11h, 12h-13h, 14h-15h, 16h-17h, 18-19h), onde 1 indica geração e 0 corresponde à não geração do painel. Portanto, modificam-se randomicamente 20% dos dados de cada variável binária β , isto é, cada variável β terá 4800 dados modificados aleatoriamente, nos quais serão colocados zeros. Assim, será assumida ausência de geração ou uma falha nos módulos em diferentes períodos do dia.

O resultado do número de painéis (n_{pv}), considerando apenas o CVaR para a análise ($\lambda = 1$), é de 10. Para a análise realizada com 50% do VE e 50% do CVaR, $n_{pv} = 3698$. Finalmente, $n_{pv} = 18125$ considerando uma análise com VE. Como era esperado, o otimizador sugere instalar menor quantidade de painéis à medida que o risco aumenta, devido ao fato de que o CVaR dá importância no 5% dos piores cenários (100 cenários), e provavelmente seja desvantagem instalar maior quantidade de painéis.

Na Figura 7.9 apresenta-se o comportamento da média dos cenários de energia consumida contra a média da energia produzida pelo consumidor, para os três perfis de aversão considerados, com o propósito de observar o impacto produzido pelo sistema fotovoltaico no consumo. Essa influência causada pelo sistema fotovoltaico pode ser visto na Figura 7.10. Para $\lambda = 1$ a redução de energia é insignificante. Além disso, para $\lambda = 0,5$, a redução de energia é mínima devido à quantidade de painéis instalados. Finalmente para $\lambda = 0$ o desconto é bastante considerável, obtendo-se alguns cenários zerados.




Figura 7.9– Energia média consumida e energia média gerada com redução de 20% dos dados de geração.

Na Figura 7.11, apresenta-se a demanda contratada para o ano 2016, com os perfis de aversão ao risco considerados. Também, mostram-se os cenários de demanda máxima, a fim de observar como o valor da demanda contratada se ajusta nos cenários simulados. Como era esperado, os cenários de demanda máxima com 20% dos dados de geração modificados influenciam na seleção da quantidade de painéis e, conseqüentemente, na contratação.




Figura 7.10 – Redução de energia consumida pelo uso do sistema fotovoltaico para diferentes valores de λ com redução de 20% dos dados de geração.




Figura 7.11– Demanda contratada mensal para diferentes valores de λ com redução de 20% dos dados de geração.

Nos três perfis de aversão ao risco considerado verifica-se um comportamento bastante similar, tendo maiores valores de demanda considerando uma análise com CVaR. Também, ocorre a redução do valor da demanda contratada em Junho para os três perfis, mantendo-se constante para Julho, após aumenta moderadamente até Novembro onde é contratado o mesmo valor para Dezembro.

Na Tabela 7.4, apresenta-se o valor da demanda contratada mensal e o custo anualizado para cada perfil considerado na análise. Igualmente que nas análises anteriores, o custo anual aumenta quando o risco é maior. A diferença entre o maior custo (quando $\lambda = 1$), e o menor custo (quando $\lambda = 0$) é aproximadamente de 15,12%.

Tabela 7.4 – Perfis ótimos de demanda contratada e custo para diferentes valores de λ com redução de 20% dos dados de geração.

Mês	Demanda Contratada (kW) (do=3800kW)		
	$\lambda=0$	$\lambda=0.5$	$\lambda=1$
Janeiro	3800,00	3800,00	3800,00
Fevereiro	3800,00	3800,00	3800,00
Março	3800,00	3800,00	4078,98
Abril	3800,00	3800,00	4078,98
Maio	3800,00	3800,00	4078,98
Junho	2540,87	2736,94	3032,81
Julho	2540,87	2736,94	3032,81

Agosto	3046,25	3197,71	3355,09
Setembro	3144,79	3341,06	3570,80
Outubro	3349,01	3515,51	3655,30
Novembro	3404,02	3595,24	3826,41
Dezembro	3404,02	3595,24	3826,41
Custo (R\$)			
Perfil Aversão	$\lambda=0$	$\lambda=0.5$	$\lambda=1$
Quant. Painéis	18125	3698	10
Custo Anualizado	7.834.547,23	8.776.222,73	9.230.375,57

7.3

Análise de Viabilidade Econômica

Geralmente, o principal entrave para os consumidores interessados na instalação de sistemas fotovoltaicos é o custo. Para avaliar a viabilidade econômica do sistema fotovoltaico, foram realizadas três análises, para verificar a atratividade do investimento. Os resultados econômicos apresentados nas seguintes seções levam em conta os perfis de aversão ao risco considerados, isto é, $\lambda = 0, 0,5$ e 1 . Além disso, consideram-se os resultados obtidos na otimização, ou seja, calcula-se o custo anual multiplicando-se a redução do consumo da energia elétrica e o valor da demanda contratada pela tarifa, adicionalmente, considera-se o custo anualizado do sistema fotovoltaico, isto é, o custo para 12 meses, devido a que a otimização foi realizada para todo o período de tempo (vida útil do painel fotovoltaico).

7.3.1

Vantagem do Pannel em Relação ao não Uso do Pannel

Para comparar o custo real do consumidor em 2016 com os resultados obtidos na otimização de cada análise realizada, além de considerar o perfil de aversão $\lambda = 0$, apresenta-se o custo anualizado na Figura 7.12. Note que todos os custos obtidos foram menores que o valor real. Mesmo sem incluir a geração (análise apresentada na seção 7.1), o consumidor está obtendo ganho anual, tanto de energia quanto de demanda contratada. Além disso, observa-se que o custo da energia diminui significativamente com o uso do sistema fotovoltaico. Igualmente, a demanda tem uma redução considerável. Adicionalmente, pode-se

verificar como o otimizador sugere pagar mais pela energia e comprar menos painéis à medida que se realiza o desconto de geração (10% e 20%), sendo esta a melhor estratégia a fim de alcançar o custo ótimo (menor preço).




Figura 7.12 – Comparação de custo anualizado para $\lambda = 0$.

Finalmente, a Tabela 7.5 apresenta os custos, número de painéis a serem instalados e os ganhos, em porcentagem, que foram obtidos em cada análise. Esses ganhos têm como referência o custo real do consumidor em 2016, por exemplo, considerando 100% da geração do sistema fotovoltaico (análise apresentada na seção 7.2.1), o consumidor poderia ter reduzido em até 20,73% do valor pago.

Tabela 7.5 – Comparação de custo anualizado e quantidade de painéis fotovoltaicos para $\lambda = 0$.

ANÁLISE	CUSTO (R\$)			Quantidade Paineis	Ganho (%)
	Demanda Máx.	Energia	Painel		
Custo Real	896.941,00	8.222.054,65	0,00	0	0%
Sem Painel	786.662,07	7.575.076,09	0,00	0	8,30%
100% Painel	437.282,89	1.186.813,02	5.604.868,10	18350	20,73%
98% Painel	637.065,62	1.363.900,82	5.607.311,64	18358	16,57%
96% Painel	765.223,60	1.533.180,07	5.536.143,56	18125	14,09%

Do mesmo modo, a Figura 7.13 ilustra os custos das análises feitas considerando $\lambda = 0,5$. Pode-se verificar o mesmo comportamento que o da análise considerando somente VE $\lambda = 0$. Mesmo aumentando o risco, o consumidor conseguiria redução da sua conta. Não obstante, com o maior nível de risco

($\lambda = 1$) a redução no custo, tanto da demanda como da energia, é menos significativa para o consumidor, como pode ser visto na Figura 7.14.




Figura 7.13 – Comparação de custo anualizado para $\lambda = 0.5$.

Finalmente, as Tabelas 7.6 e 7.7 apresentam os custos, número de painéis a serem instalados e os ganhos, em porcentagem, que foram obtidos em cada análise para $\lambda = 0,5$ e $\lambda = 1$. Observa-se em todas as análises redução na conta da demanda comparada com o valor real do consumidor, o que indica a adequada contratação realizada pelo modelo. Não obstante, mesmo diminuindo esse custo de demanda, duas análises não apresentaram ganhos anuais devido ao escasso uso de painéis que não causaram impacto na energia consumida.

Tabela 7.6 – Comparação de custo anualizado e quantidade de painéis fotovoltaicos para $\lambda = 0.5$.

ANÁLISE	CUSTO (R\$)			Quantidade Paine	Ganho (%)
	Demanda Máx.	Energia	Paine		
Custo Real	896.941,00	8.222.054,65	0,00	0	0%
Sem Paine	826.419,79	7.982.732,62	0,00	0	3,40%
100% Paine	437.282,89	1.491.764,49	5.831.506,37	19092	14,90%
98% Paine	752.647,42	2.058.337,31	5.566.687,80	18225	8,13%
96% Paine	789.617,17	6.857.079,55	1.129.526,01	3698	3,76%




Figura 7.14 – Comparação de custo anualizado para $\lambda = 1$.

Tabela 7.7 – Comparação de custo anualizado e quantidade de painéis fotovoltaicos para $\lambda = 1$.

ANÁLISE	CUSTO (R\$)			Quantidade Paineis	Ganho (%)
	Demanda Máx.	Energia	Painel		
Custo Real	896.941,00	8.222.054,65	0,00	0	0%
Sem Painel	834.956,19	8.398.959,64	0,00	0	-1,26%
100% Painel	437.282,89	1.353.963,13	6.436.893,21	21074	9,77%
98% Painel	767.307,11	5.515.922,50	2.809.764,67	9199	0,29%
96% Painel	835.381,82	8.391.939,32	3.054,42	10	-1,22%

7.3.2

Variação da Tarifa de Energia

Nesta análise, compara-se o custo anualizado do consumidor sem geração fotovoltaica (análise apresentada na seção 7.1), e quando é considerado o sistema fotovoltaico (análise apresentada na seção 7.2). Assumem-se como valores fixos a demanda contratada, a energia com redução devido ao uso do sistema fotovoltaico, a tarifa da demanda e o número de painéis. Além disso, só se considera o mínimo e o máximo perfil de aversão ao risco, isto é, $\lambda = 0$ e $\lambda = 1$, com o objetivo de avaliar as condições com menor e maior risco. Assim, varia-se a tarifa da energia, para identificar até que percentual dessa tarifa vale a pena fazer o investimento no sistema fotovoltaico.

Na Figura 7.15 estão ilustrados os resultados de custos associados ao consumidor para $\lambda = 0$. É importante destacar no momento em que a tarifa de

energia é zero, o custo só depende da demanda contratada (quando não é considerada a geração de energia) e do número de painéis (quando é considerado o sistema fotovoltaico). À medida que aumenta o valor da tarifa de energia o custo total anualizado das análises aumenta. No entanto, o custo anual sem painéis possui uma taxa de inclinação maior que o custo quando são considerados painéis.

Assim, o valor de indiferença entre o consumidor sem geração e o consumidor com sistema fotovoltaico, quando produz-se 100% da geração, gira em torno de 81% do valor da tarifa de energia. Portanto seria mais vantajoso para o consumidor considerar painéis quando a tarifa de energia for maior de 81% do preço, ou seja, vale a pena instalar painéis a partir de 81% da tarifa de energia.

Por outro lado, a Figura 7.16 apresenta os resultados de custos associados ao consumidor para $\lambda = 1$. Note que a taxa de inclinação do custo é mínima quando o consumidor considera painéis, mas o custo quando a tarifa da energia é igual a zero é muito alto, contudo um maior risco envolve maiores custos. Neste sentido, o valor de indiferença gira em torno de 88% do valor da tarifa de energia. Portanto seria mais vantajoso considerar o sistema fotovoltaico quando a tarifa de energia estiver na faixa de 88% - 100% do preço, isto é, até 88% da tarifa de energia vale a pena o investimento.




Figura 7.15 – Comparação custos anuais com variação da tarifa de energia e $\lambda = 0$.




Figura 7.16 – Comparação custos anuais com variação da tarifa de energia e $\lambda = 1$.

Adicionalmente realizou-se o comparativo do custo no momento em que o sistema fotovoltaico produz 96% da geração total (análise apresentada na seção 7.2.3). Os resultados são apresentados nas Figuras 7.17 e 7.18. Quando é considerado $\lambda = 0$, vale a pena o uso do sistema fotovoltaico a partir de 90.5% da tarifa da energia. Finalmente, para $\lambda = 1$, é evidente que não convém comprar essa quantidade de painéis (10) em qualquer valor da tarifa de energia. Consequentemente, nessa análise o consumidor teria ganho nenhum, dado que o custo anual, quando se considera o sistema fotovoltaico, seria 1% maior.




Figura 7.17 – Comparação custos anuais com variação da tarifa de energia e $\lambda = 0$.




Figura 7.18 – Comparação custos anuais com variação da tarifa de energia e $\lambda = 1$.

7.3.3 Análise de Retorno Financeiro (*Pay-Back*)

É indiscutível que um sistema fotovoltaico deve ser visto como um investimento, aplicando-se recursos no presente para colher retornos futuros de longo prazo. Desta forma, assume-se que a forma de pagamento do sistema fotovoltaico será financiada, já que o primeiro parcelamento suaviza o desembolso inicial. Assim, o valor total será dividido em 36 parcelas sem considerar taxa de juros.

Para essa análise somente foram considerados os resultados obtidos nas seções 7.2.1 e 7.2.3 para o perfil de aversão ao risco que considera 50% VE e 50% CVaR ($\lambda = 0.5$), devido ao fato de serem resultados repetitivos com os outros perfis.

Nesse sentido, a Tabela 7.8 apresenta o custo mensal quando o consumidor compra o sistema fotovoltaico com 19092 painéis. Destaca-se o ganho que obtém o consumidor, ou seja, a economia no mês, a qual irá cobrir parte da dívida do financiamento. Assim, o tempo de retorno sobre o investimento ocorrerá no mês 66, isto é, 5 anos e 6 meses após a instalação dos painéis.

Tabela 7.8 – Retorno do investimento considerando 100% da geração para $\lambda = 0.5$.

Mês	Custo Sem Pannel (R\$)	Custo Com Pannel (R\$)	Economia (R\$)	Pagamento Financiamento (R\$)	Saldo (R\$)
-----	------------------------	------------------------	----------------	-------------------------------	-------------

1	Jan.	611.620,11	39.698,94	571.921,17	-1.060.666,67	-488.745,50
2	Fev.	634.457,88	54.321,48	580.136,40	-1.060.666,67	-969.275,76
3	Mar.	851.334,86	267.025,11	584.309,74	-1.060.666,67	-1.445.632,69
4	Abr.	800.789,30	225.530,87	575.258,43	-1.060.666,67	-1.931.040,92
5	Mai.	707.653,99	117.943,42	589.710,58	-1.060.666,67	-2.401.997,01
⋮	⋮	⋮	⋮	⋮	⋮	⋮
35	Nov.	790.448,32	217.034,86	573.413,46	-1.060.666,67	-16.813.749,15
36	Dez.	697.233,48	98.781,53	598.451,95	-1.060.666,67	-17.275.963,86
37	Jan.	611.620,11	39.698,94	571.921,17		-16.704.042,69
⋮	⋮	⋮	⋮	⋮	⋮	⋮
65	Mai.	707.653,99	117.943,42	589.710,58		-435.936,78
66	Jun.	626.611,57	97.700,97	528.910,60		<u>92.973,82</u>
67	Jul.	544.265,25	39.804,73	504.460,51		<u>597.434,34</u>

Por outro lado, a Tabela 7.9 apresenta o custo mensal quando o consumidor compra o sistema fotovoltaico que contém 3698 painéis. Mesmo que a parcela de financiamento não seja grande (comparada com a parcela anterior), a economia do mês não consegue cobrir a totalidade do financiamento mensal. Nesta análise, o consumidor terá um período maior do retorno sobre o investimento que será no mês 70, isto é, 5 anos e 10 meses após a instalação dos painéis.

Tabela 7.9 – Retorno do investimento considerando 96% da geração para $\lambda = 0.5$.

Mês		Custo Sem Paineis (R\$)	Custo Com Paineis (R\$)	Economia (R\$)	Pagamento Financiamento (R\$)	Saldo (R\$)
1	Jan.	611.620,11	505.790,46	105.829,65	-205.444,44	-99.614,80
2	Fev.	634.457,88	531.450,10	103.007,78	-205.444,44	-202.051,46
3	Mar.	851.334,86	745.003,93	106.330,93	-205.444,44	-301.164,98
4	Abr.	800.789,30	696.267,36	104.521,94	-205.444,44	-402.087,49
5	Mai.	707.653,99	600.359,49	107.294,51	-205.444,44	-500.237,42
⋮	⋮	⋮	⋮	⋮	⋮	⋮
35	Nov.	790.448,32	685.996,19	104.452,13	-205.444,44	-3.474.663,21
36	Dez.	697.233,48	588.083,91	109.149,57	-205.444,44	-3.570.958,08
37	Jan.	611.620,11	505.790,46	105.829,65		-3.465.128,44
⋮	⋮	⋮	⋮	⋮	⋮	⋮
69	Set.	710.210,67	598.507,21	111.703,45		-77.308,87
70	Out.	746.497,23	628.706,23	117.791,00		<u>40.482,13</u>
71	Nov.	790.448,32	685.996,19	104.452,13		<u>144.934,26</u>

8

Conclusão e Perspectivas

Neste trabalho foi apresentado um estudo de contratação de demanda e energia elétrica, considerando fontes de geração fotovoltaica para atender a um grande consumidor em um esquema de autoprodução. O estudo proposto envolve um modelo de previsão de demanda máxima e outro de energia consumida do grande consumidor. Após a simulação dos cenários futuros de demanda e energia consumida e gerada, foi desenvolvido um modelo de otimização com o emprego de Programação Linear Mista-Inteira (MILP) para definir a demanda a ser contratada cada mês e o número de painéis viável para o sistema fotovoltaico do grande consumidor. Assim, busca-se minimizar o custo de contratação do consumidor além do número de painéis ideal, considerando uma análise que leva em conta o risco da contratação. A métrica escolhida para avaliação foi uma combinação convexa do Valor Esperado e CVaR.

Desse modo, mostrou-se eficaz a otimização realizada, fornecendo uma solução ótima e robusta para os custos de demanda, energia e investimento do sistema fotovoltaico do grande consumidor.

Considerando-se geração fotovoltaica, utilizaram-se dados simulados em 2015 de um painel fotovoltaico de 330Wp. A demanda também apresenta bons resultados, quando se reduz o contrato nos meses onde a geração consegue atender a demanda do consumidor. Por outro lado, em cada análise de viabilidade econômica realizada, observou-se a vantagem de instalar um sistema fotovoltaico, obtendo uma redução na conta do consumidor de até 20,73% no caso mais favorável, tendo sido comparados com o custo real de 2016. Não obstante, com o maior perfil de risco o maior ganho obtido foi 9% para a análise realizada com 100% de geração de energia. Além disso, os resultados indicam que pena é viável economicamente instalar painéis fotovoltaicos a partir de 81% da tarifa de energia, no caso mais favorável obtido nas análises realizadas.

Em estudos futuros pretende-se fazer a previsão futura da demanda em intervalos de 15 em 15 minutos e aplicar o desconto de geração fotovoltaica

aleatoriamente nesses intervalos de tempo, de forma que a redução tanto na demanda como na energia seja feito ao mesmo tempo. Além disso, quer-se incluir baterias com o intuito de armazenar energia para suprir horários nos quais o sistema fotovoltaico não produz energia. Adicionalmente, pretende-se considerar a utilização de créditos pela energia gerada excedente, o que tornaria o modelo dinâmico. Também, abordar o contrato ACL a fim de comparar e definir o melhor ambiente de contratação quando se considera geração distribuída para o grande consumidor. Finalmente, pretende-se levar em conta dados reais de produção de energia fotovoltaica e/ou outros tipos de fontes renováveis para o modelo proposto.

- 1 LEI N°10.847. Brasília-DF, 15 mar, 2004. Disponível em: <http://www.planalto.gov.br/ccivil_03/_ato2004-2006/2004/lei/110.847.htm>. Acesso em: 28 set. 2017.
- 2 LEI N°10.848. Brasília-DF, 15 mar, 2004. Disponível em: <http://www.planalto.gov.br/ccivil_03/_ato2004-2006/2004/lei/110.848.htm>. Acesso em: 28 set. 2017.
- 3 DECRETO N°5.163. Brasília-DF, 30 JUL, 2004. Disponível em: <http://www.planalto.gov.br/ccivil_03/_ato2004-2006/2004/Decreto/D5163.htm>. Acesso em: 28 set. 2017.
- 4 Câmara de Comercialização de Energia Elétrica, CCEE. Disponível em: <<http://www.ccee.org.br>>. Acesso em: 28 set. 2017.
- 5 Instituto Nacional de Eficiência Energética, INEE. Disponível em: <<http://www.inee.org.br>>. Acesso em: 28 set. 2017.
- 6 RESOLUÇÃO NORMATIVA ANEEL N°482. Abril, 2012. Disponível em: <<http://www.aneel.gov.br/cedoc/ren2012482.pdf>>. Acesso em: 28 set. 2017.
- 7 PLANO DECENAL DE EXPANSÃO DE ENERGIA 2024, Brasília: MME/EPE, 2015.
- 8 Associação Brasileira de Energia Solar Fotovoltaica, ABSOLAR. Disponível em: <<http://www.absolar.org.br>>. Acesso em: 28 set. 2017.
- 9 Nota Técnica DEA 19/14: Inserção da geração fotovoltaica distribuída no Brasil – condicionantes e impactos. EPE. Rio de Janeiro, 2014.
- 10 CARRIÓN, M. et al. A stochastic programming approach to electric energy procurement for large consumers. IEEE Transactions on power systems, v. 22, n. 2, p. 744-754, Mai. 2007.
- 11 CARLOS, E. T.; LIMA, D. A.; OCHOA, L. F. Energy contracting for large consumers in Brazil: a real case study. CIRED (22nd International Conference on Electricity Distribution), Stockholm, 10-13 June 2013.

- 12 LIMA, D. et al. Contratação de energia elétrica de grandes consumidores: uma abordagem estatística e de otimização para definição da melhor estratégia de contratação. SNPTEE (XXII Seminário Nacional de Produção e Transmissão de Energia Elétrica), Foz do Iguaçu, 18-21 Out. 2015.
- 13 BITTERCOURT, E. M. M. Simulação e otimização estocástica para contratação de energia elétrica de grandes consumidores. Dissertação (mestrado) Departamento de Engenharia Elétrica, PUC-Rio, Rio de Janeiro, 2016.
- 14 NOGUEIRA, P. C. Análise da inserção de geração solar fotovoltaica em grandes consumidores do Rio de Janeiro: Um Estudo de Caso. Dissertação (mestrado) Engenharia Urbana e Ambiental, PUC-Rio, Rio de Janeiro, 2016.
- 15 AALAMI, H. A.; NOJAVAN, S. Energy storage system and demand response program effects on stochastic energy procurement of large consumers considering renewable generation. The Institution of Engineering and Technology, IET. V. 10. P 107-114, July 2016.
- 16 LAOUAFI, A. et al. Online electricity demand forecasting based on an effective forecast combination methodology. Energy Power System Research. V 148, p 35-47, Julho, 2017.
- 17 STREET, A.; BARROSO, S. GRANDVILLE E PEREIRA, M. V. Bidding strategy under uncertainty for risk-averse generator companies in a long-term forward contract auction. IEEE Power Engineering Society General Meeting 2009. p 26-30. Outubro 2009.
- 18 MCSHARRY, P. E.; BOUWMAN, S.; BLOEMHOF, G. Probabilistic forecast of the magnitude and timing of peak electricity demand. IEEE Trans. Power Syst. V 20, p 116-1172, Maio, 2005.
- 19 BRADLEY, P.; COKE, A.; LEACH, M. Financial incentive approaches for reducing peak electricity demand, experience from pilot trials with a UK energy provider. Energy Policy. V 98, p 108-120, Novembro 2016.
- 20 STRENGERS, Y. Peak electricity demand and social practice theories: reframing the role of change agents in the energy sector. Energy Policy. V 44, p 226-234, Maio, 2012.
- 21 CHU, K.; KAIFUKU, K. SAITOU, K. Optimal integration of alternative energy sources in production system with customer demand forecast. IEEE

- Trans. Autom. Sci. Eng. V 13, p 206-214, Janeiro, 2016.
- 22 AALAMI, H.; NOJAVAN, S. Energy storage system and demand response program effects on stochastic energy procurement of large consumers considering renewable generation. IET Generation, Transmission & Distribution. V 10, p 107-114, Janeiro, 2016.
- 23 STREET, A. Equivalente certo e medidas de risco em decisões de comercialização de energia elétrica. 2008. 174 f. Tese (doutorado) Centro Técnico Científico, Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2008.
- 24 LIMA, D. A.; CESPEDES, A. M. G.; TELLES, E.; BITTERCOURT, E. M. M. Peak demand contract for big consumers computed based on the combination of a statistical model and a mixed integer linear programming stochastic optimization model. Electric Power Systems Research. V. 154, p. 122-129, Janeiro 2018.
- 25 AMBIENTE LIVRE E AMBIENTE REGULADO. Disponível em: <http://www.ccee.org.br/portal/faces/pages_publico/como-participar>. Acesso em: 25 Out. 2017.
- 26 FREIRE, L. Modelo de comercialização de energia renovável no ambiente de contratação livre via teoria de jogos cooperativos. Dissertação (mestrado) Faculdade de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2013.
- 27 RESOLUÇÃO NORMATIVA ANEEL N°255. Mar, 2007. Disponível em: <<http://www2.aneel.gov.br/cedoc/ren2007255.pdf>>. Acesso em: Outubro. 2017.
- 28 RESOLUÇÃO NORMATIVA ANEEL N°414. Set, 2010. Disponível em: <<http://www.aneel.gov.br/cedoc/ren2010414comp.pdf>>. Acesso em: Set. 2017.
- 29 GUEDES, J. C. Manual de tarifação da energia elétrica. ELECTROBRAS, Agosto, 2011.
- 30 BERTSIMAS, D.; TSITSIKLIS J. N. Introduction to linear optimization. Athena Scientific, Belmont, Massachusetts, 1997.
- 31 KIRCHGASSNER, G.; WOLTERS, J. Introduction to modern time series analysis. St Gallen, Berlin, Abril 2007.
- 32 ZANINI, A. Redes neurais e regressão dinâmica: um modelo híbrido para

- previsão de curto prazo da demanda de gasolina automotiva no brasil, Dissertação de mestrado, PUC-RJ. 2000.
- 33 SOUZA, R. C.; OLIVEIRA, F. L. C. Análise de séries temporais: os modelos de amortecimento exponencial. Rio de Janeiro, RJ [s.n.], 2015.
 - 34 MORETTIN, P. A.; TOLOI, C. M. C. Análise de séries temporais, 2. ed. São Paulo: Blucher, 2006.
 - 35 CHATFIELD, C. The analysis of time series: an introduction. Chapman & Hall. London, 1966.
 - 36 KOOPMANS, L.,H. The spectral analysis of time series, 2. ed. Academic Press, San Diego, 1995.
 - 37 JENKINS, G. M.; WATTS, D. G. Spectral analysis and its applications. Holden-Day, Inc. San Francisco, 1968.
 - 38 SOUZA, R. C.; CAMARGO, M. E. Análise e previsão de séries temporais: os modelos ARIMA, 2. ed. Rio de Janeiro: Regional, 2004.
 - 39 MONTGOMERY, D. C.; JOHNSON, L. A. Forecasting and time series analysis, 2. ed. New York: McGraw-Hill Book Co., 1990.
 - 40 BROCKWELL, P., J.; DAVIDS, R., A. Introduction to time series and forecasting, 2. ed. Springer-Verlag, New York, 2002.
 - 41 SOUZA, R. C. Métodos automáticos de amortecimento exponencial para previsão de séries temporais. Relatório técnico GSM-10/83, Departamento de engenharia elétrica, Pontifícia Universidade Católica do Rio de Janeiro, Mai. 1983.
 - 42 MIRANDA, C. V. C. Previsão de dados de alta frequência para carga elétrica usando Holt-Winters com dois ciclos. 2007. 114 f. Dissertação (mestrado) Centro Técnico Científico, Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2007.
 - 43 BOX, G. E. P.; JENKINS, G. M. Time series analysis: forecasting and control. California: Holden Day, 1976.
 - 44 HAMILTON, J. D. Time series analysis. Princeton University Press, 1994.
 - 45 SOUZA, R. C. Modelos estruturais para previsão de séries temporais: abordagens clássica e bayesiana, 17º Colóquio Brasileiro de Matemática, IMPA, 1989.
 - 46 CRYER, D.; CHAN, K., S. Time series analysis with application in R, 2. ed. Springer Science + Business Media, New York, 2008.

- 47 AKAIKE, H. Information theory and an extension of the maximum likelihood principle. 2nd International Symposium on Information Theory, 1973.
- 48 SCHWARZ, G. Estimating the dimension of a model. *Annals of Statistics*, v. 6, 1978.
- 49 LJUNG, G.,M.; BOX, G., E., P. The likelihood function of stationary autoregressive-moving average models. *Biometrika*, vol. 66, 1979.
- 50 JARQUE, C. M.; BERA, A., K. A test for normality of observations and regression residuals. *International Statistical Review*, Malden, Vol 55, 1987.
- 51 CIRILLO, M. A.; FERREIRA, D., F. Extensão do teste para normalidade univariado baseado no coeficiente de correlação quantil-quantil para o caso multivariado. *Matemática e Estatística*, vol. 21, 2003.
- 52 RStudio Team (2016), versão 1.0.143. RStudio: Integrated Development for R. RStudio, Inc., Boston, MA URL: < <http://www.rstudio.com>>.
- 53 JENKINS, N.; EKANAYAKE, J. B.; STRBAC, G. Distributed generation. The Institution of Engineering and Technology, London, 2010.
- 54 SOUZA, M. E. M. Impactos da geração distribuída nas redes de baixa tensão. Monografia de conclusão de curso de Especialização em Engenharia de Sistemas Elétricos de Potência – CESEP, ênfase em Supervisão, Controle e Proteção de SEP, UFMG, Belo Horizonte, 2012.
- 55 TAVARES, D. Micro e minigeração eólica e solar no Brasil, propostas para desenvolvimento do setor. Dissertação (mestrado). USP, São Paulo, 2015.
- 56 GOETZBERGER, A.; HOFFMANN, V. U. Photovoltaic solar energy generation. Springer-Verlag, Berlin, 2005.
- 57 HOURLY POWER OUTPUT FROM WIND AND SOLAR GERATION. Disponível em: <<http://renewables.ninja>>. Acesso em: Maio. 2017.
- 58 SECURATO, J. R. Decisões financeiras em condições de risco. 2. ed. Saint Paul, São Paulo, 2007.
- 59 MANSANI, R.; OGRYCZAK, W.; SPERANZA, M. G. Linear and mixed integer programming for portfolio optimization. Springer, New York, 2015.
- 60 ROCKAFELLAR, R. T.; URYASEV, S. Conditional Value-at-Risk for general loss distributions. *Journal of Banking & Finance*, N°26, 2002.
- 61 NUNES DA ROCHA, J. E. Sistema inteligente de diagnósticos energéticos e de análise de investimentos em projetos de eficiência energética

- gerenciados pelo lado da demanda. Tese (doutorado), Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2013.
- 62 ARTZNER, P.; DELBAEN, F.; EBER, J.; HEATH, D. Coherent measures of risk. *Mathematical Finance*, Vol 9, N°3, 1999.
- 63 YAMAI, Y.; YOSHIBA, T. Comparative analyses of expected shortfall and Value-at-Risk. *Journal of the Operations Research Society of Japan*, Vol 45, N°4, pp. 490-506, 2002.
- 64 XPRESS, versão 7.5. FICO™ Xpress Optimization Suite.
- 65 KOCH, T. MIPLIB 2010 - Mixed Integer Programming library version 5, *Math. Program. Comput*, 2011.
- 66 WOLSEY, L. A. *Integer programming*, first ed. Jhon Wiley & Sons, New York, 1998.

Anexo Artigo

No anexo desta dissertação é apresentado o artigo referente ao trabalho desenvolvido. O artigo foi apresentado na revista Electric Power System Research (EPSR) que será publicado em Janeiro de 2018 e está presente na listagem de referências deste trabalho.

Peak Demand Contract for big consumers computed based on the combination of
a Statistical Model and a Mixed Integer Linear Programming Stochastic
Optimization Model

Delberis A. Lima^{a*}, Andres Maurício Céspedes^a, Érica Telles Carlos^a, Eidy
Marianne Matias Bittencourt^a

^a Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, Brasil

* corresponding author: delberis@ele.puc-rio.br

* telephone: +55-21-35271211

* fax: +55-21-35271232

Abstract

One of the main objectives of Demand Response Programs is to mitigate the effect of peak electricity demand by inducing consumers to shift or reduce their electricity consumption in peak times. In Brazil, big energy consumers should contract peak demand for the upcoming months with the utility distribution companies under a set of rules defined by the System Regulator. Based on this, the utility will have more information to reinforce the system accordingly. The

challenge for consumers is to compute the best value of the peak demand contracted before the peak demand realization. One way to solve this problem is to simulate future scenarios of peak demand and optimize the value of the peak demand contracted in compliance with the current rules. In this paper, a support decision system is proposed to help consumers in this task.

The proposal is divided into two parts, which are a statistical model, for estimating and simulating future scenarios of peak demand, and a stochastic optimization model, to compute the value of the peak demand contracted.

In the first part, a Box & Jenkins model is used to estimate the parameters of the statistical model and to simulate it based on the historical electricity bill data. In the second part, a stochastic optimization model is applied using a convex combination of the Expected Value and Conditional Value-at-Risk, as the risk metrics for the cost uncertainty, in order to obtain the monthly values of peak demand contracted. The results achieved corroborate the importance of using an appropriate mathematical model to address the problem. To illustrate the proposed approach, a real case study for a big consumer in Brazil is presented.

Keywords: Peak demand contracted; Demand Response Program; Big consumer; Statistical model; Stochastic optimization model.

1. NOTATION

C_t	Cost of peak demand contract in the month t (in R\$).
D_t^{max}	Peak demand in the month t (in kW).
D_t^c	Value of the peak demand contracted in the month t (in kW).
$D_t^{AR(1)}$	Peak demand in the month t computed by AR(1) model (in kW).
T_D	Tariff of peak demand, (in R\$/kW). For this paper, $T_D = \frac{R\$}{kW} 18.12$.
T_D^{exc}	Tariff of exceeded peak demand (in R\$/kW). For this paper, $T_D^{exc} = 2T_D$.
T	Time horizon of analysis. For this paper, $T = 12$ (months).

$AR(p)$	Autoregressive model of order “p” (number of time lags).
B	Lag operator.
$\phi(B)$	Non-seasonal autoregressive operator (AR) $(1 - \phi_1 B - \dots - \phi_p B^p)$.
$\Phi(B^S)$	Seasonal autoregressive operator (AR) $(1 - \Phi_1 B^P - \dots - \Phi_P B^{PS})$.
∇^d	Non-seasonal difference operator of degree d .
∇_S^D	Seasonal difference operator of degree D .
Z_t	Time series.
$\theta(B)$	Non-seasonal moving average operator (MA) $(1 - \theta_1 B - \dots - \theta_q B^q)$.
$\Theta(B^S)$	Seasonal moving average operator (MA) $(1 - \Theta_1 B^S - \dots - \Theta_Q B^{QS})$.
a_t	White noise.
C_D	Optimum annual cost of peak demand contract (in R\$).
n_S	Number of scenarios.
\mathcal{S}	Scenarios set.
$\Delta_{s,t}$	Peak demand tolerance to avoid penalty in the month t and in the scenario s (in kW).
$d_{s,t}^{exc}$	Exceeding demand in the month t and in the scenario s (in kW).
$D_{s,t}^{max}$	Maximum peak demand simulated in month t and scenario s (in kW).
u	Maximum percentage of the peak demand contracted acceptable to avoid penalty due to subcontracting ($u = 5\%$)
x_t	Binary variable that indicates if the peak demand contracted will be violated in the month t .
M	Big M used as an auxiliary parameter.
y_t	Binary variable that indicates if the peak demand contracted will be reduced in the month t .
d_0	Initial value of the peak demand contracted (in kW).
$C_{s,t}$	Cost of the peak demand contract in the month t and scenario s (in R\$).
$\delta_{s,t}$	Auxiliary variable that represents the left side of the distribution costs in month t and in the scenario s .
w_t	Auxiliary variable that reaches the value-at-risk (VaR) of the distribution costs in the month t for the period of analysis.
λ	Constant that makes the balance between Expected Value (EV) and the Conditional Value-at-Risk (CVaR).
α	Aversion to risk parameter that defines the confidence level of the CVaR.

2. INTRODUCTION

Peak demand is one of the most important issues for utilities, because it directly

affects the investments to reinforce the system. It can be defined as the greatest value of the energy consumed verified over a period within the month¹⁵. This issue is so important that in [1] and [2], the authors propose a peak shaving strategy based on a storage system to reduce or postpone new investments on distribution system. In [3] and [4], the behavior of the consumers was studied in order to implement an effective Demand Response Program (DRP) to create incentives for them to shift or reduce their consumption on peak times. In [5] and [6], different aspects involving peak demand reduction are studied, however, as mentioned in [7], to tackle this problem from the consumer viewpoint, a forecast of peak demand is required.

Peak demand may be associated with external variables, such as temperature, humidity, economic variables or even a combination of these. Notwithstanding, it is important to highlight that the quality of the simulation depends on the forecast of the external variables or of the seasonal variables. The more accurate the forecast is, the better the result of the peak demand simulation will be. On the other hand, due to the nature of the consumer's activity, the seasonal variation can be considered to explain the peak demand behavior.

In order to design the additional capacity of the system to accommodate the peak demand of the consumer, a probabilistic forecast model is presented in [8] to estimate and to forecast the peak demand over the year using temperature, wind speed and luminosity as external variables.

In [9], peak demand was analyzed under a perspective of density of scenarios using a stochastic approach. The authors stated that utilities should assess the risk considering the density of scenarios produced by the statistical model because it is

¹⁵ For some cases, a maximum 15 minutes is used and the unit associated to the peak demand is kW15min, or, for simplicity, kW.

suitable for long-term applications. In [10], the authors proposed a method based on a multi-model partitioning technique and compared it with traditional well-known statistic methods.

Other applications, apart from system planning were proposed using peak demand forecast, as in [11], where the authors evaluated the optimal integration of renewable energy produced in the system considering future scenarios of peak demand.

One way to implement a DRP is to create a mechanism to encourage consumers to reduce their peak demand. A peak demand contract between consumers and utility can be used for this objective. In this way, from the consumers' viewpoint, the challenge is to compute the value of the peak demand contracted before the peak demand realization. After the application of the statistical model to simulate scenarios of peak demand, a stochastic optimization model can be applied to compute the peak demand contracted.

There aren't many projects dedicated to optimizing peak demand contracted in literature, thus, the model proposed in this paper was inspired in the optimization energy contract for consumers from other papers. In [12], a stochastic programming model is presented to solve the electricity procurement problem for big consumers, accounting self-production, pool market and bilateral contracts as well. Recently, in a pilot project in Canada [13], the authors highlighted the importance of taking into account the peak demand in the optimization of the daily load profile of an industrial consumer. The corresponding reductions in this study, by re-scheduling the industrial process and, consequently, changing the load daily profile, in peak demand and energy consumption were 32.82% and 11.95% respectively. *Similar idea had been applied in [14] for reducing costs of*

energy and/or peak demand of another industrial consumer. In this case, the mathematical model took into account some constraints such as the industrial process, storage units, distribution system components and operator's requirements.

A risk aversion profile is implemented using the Conditional Value-at-Risk (CVaR) as a risk measurement. In [15] and [16], a preliminary version of the combination between the statistical model and the optimization model were formulated to contract energy and peak demand.

In this paper, both models were improved in order to achieve the best value of the peak demand contracted. Here, a Box & Jenkins model ([17]) was used to estimate and simulate future scenarios of peak demand for the consumer. Moreover, an optimization model was developed, considering the rules applied in Brazil for the contract between the utility and the consumer, and a convex combination of Expected Value (EV) and CVaR was used to optimize the cost by using the peak demand contracted. As will be seen in section 4, due to the nature of the problem, the optimization model was adapted to consider integer variables and the scenarios simulated. Therefore, the proposed problem is a Mixed Integer Linear Programming.

Based on the aforementioned, the main contributions of the paper are:

- To propose a new approach from the consumer's viewpoint to address the DRP used in Brazil to encourage them to reduce their peak demand;
- To propose a statistical model to estimate and simulate future scenarios of peak demand for big consumers using historical electricity bill data;
- To propose a stochastic optimization model to compute the best peak demand contracted in a monthly basis using EV and CVaR as risk

measures.

To reach the objectives, this paper is organized as follows. Section 2 presents the rules applied in Brazil to contract peak demand; section 3 presents a statistical model used to estimate and simulate future scenarios of peak demand; section 4 presents the optimization model to compute the value of the peak demand contracted using EV and CVaR; section 5 presents the results of the problem using real data of a big consumer in Brazil; and finally, in section 6 the conclusions of this work are presented.

3. POLICY FOR PEAK DEMAND CONTRACT IN BRAZIL

According to [18], there are different kinds of peak demand contracts in Brazil. One of the most representative contracts is called Green A4 (Verde A4 – *in Portuguese*). The cost computed for this contract accounts for the greatest value between the peak demand (D_t^{max}) and the peak demand contracted (D_t^c), both for the month t . The rule to compute the cost of this contract can be written as follows:

If $0 < D_t^{max} \leq 1.05D_t^c$:

$$C_t = \max(D_t^c, D_t^{max}) T_D \quad (1)$$

Otherwise, if $D_t^{max} > 1.05D_t^c$:

$$C_t = D_t^{max} T_D + (D_t^{max} - D_t^c) T_D^{exc} \quad (2)$$

Observe that the tolerance for violating the value of the peak demand contracted is 5%, which means that if the D_t^{max} value is greater than 105% D_t^c , a cost penalty will take place. To illustrate the aforementioned formulation, Figure 1 presents the cost variation of the contract in the month t (C_t) with peak demand variation (D_t^{max}).

Note that the cost is divided in three parts, in accordance with D_t^{max} value. In the first part, from zero to D_t^C value, the consumer is overcontracted and, consequently, the cost is constant, regardless of the D_t^{max} value. In the second part, from D_t^C to $1.05D_t^C$, D_t^{max} value is greater than D_t^C value, but not enough to apply the penalty. Therefore, the cost will depend exclusively on the D_t^{max} value. Finally, with D_t^{max} value greater than $105\%D_t^C$ value, the total cost will involve two parts: in the first part, it will depend on the D_t^{max} value and, in the second part, it will depend on the difference between the D_t^{max} value and the D_t^C value.

Note that the cost function changes in each stage and the main challenge to model it as an optimization problem is the changing of the rule when D_t^{max} value violates the tolerance of 5%, creating a non-convexity for the problem. Thus, an MILP (Mixed integer Linear Programming) formulation should be used. More details about this formulation is presented in section 6.




Figure 1: Peak demand cost variation with peak demand variation.

Finally, one important information about the Brazilian rules is that the value of the peak demand contracted can be reduced only once a year. In the rest of the year, the consumer can increase this value or keep it constant, if it is suitable. These rules should be agreed previously with the utility and, in this paper, they were modelled as a set of constraints. Details of the model are presented in section 6.

4. DATA ANALYSIS

The peak demand time series used in this paper is based on a typical commercial consumer in Brazil. Because this paper aims to help big consumers to compute the value of the peak demand contracted, only data available on their bills are used and historical data from measurement equipment are not considered available. Thus, a set of 144 monthly observations, from January 2004 to December 2015 was used. However, it is important to mention that the model can be generalized to consider smaller intervals, such as daily or weekly. Figure 2 illustrates the time series studied.

The annual seasonality of this time series can be identified by the annual peak demand, which regularly occurs in the first semester, specifically from March to June, and its annual valley demand, which frequently occurs in July.

Additionally, a steady tendency of growth in this time series can be observed. To apply the time series technique and to simulate future scenarios of peak demand, this trend was removed by the application of an Autoregressive model of order one, AR(1). The AR(1) model is:

$$D_t^{AR(1)} = 3.148t + 2891.5 \quad (3)$$




Figure 2: Peak demand from 2004 to 2015.

The equation (3) is the trend line obtained directly from the time series presented in Figure 2. After removing the time series trend component, the statistical model is applied and future scenarios of peak demand can be simulated. As a result of the removal, the time series becomes stationary, as presented in Figure 3. At the end of the simulation process, the trend component was incorporated in the simulation.




Figure 3: Peak demand from 2004 to 2015 without the trend component.

5. STATISTICAL MODEL

In this work, to identify and to estimate the appropriate statistical model to tackle the problem, an ARIMA (Autoregressive Integrated with Moving Average) model [17] was applied.

The seasonal ARIMA models can be written as $ARIMA(p, d, q) \times (P, D, Q)_S$, where the parameter p is the order of the autoregressive model, q is the order of the moving average model and d is the degree of differencing, i.e, the number of times the data have had past values subtracted. On the other hand, the parameter P , Q and D correspond to autoregressive, moving average and the differencing terms for the seasonal part of the ARIMA model. Overall, a generalization of an $ARIMA(p, q, d) \times (P, Q, D)_S$ model can be presented in the following way:

$$\phi(B)\Phi(B^S)\nabla^d\nabla_S^D Z_t = \theta(B)\Theta(B^S)a_t \quad (4)$$

One way to select the best model, which corresponds to define the best parameters of the model, is using the AIC and BIC test [19]-[20]. In this paper, the tests were performed using different combination of parameters for the ARIMA model, selecting the model with the lowest AIC and BIC values. The ARIMA function, built-in on Matlab software [21], version 2013, was used to compute the set of parameters. The final model is the $ARIMA(3,0,3) \times (1,0,1)_{12}$ and the complete model with all parameters can be written as follows:

$$\begin{aligned} Z_t = & (1.25862B - 0.478722B^3 + 0.99738B^{12} - 1.255322B^{13} \\ & + 0.477467B^{15})Z_t \\ & + (1 + 1.24172B - 0.556198B^3 - 0.651008B^{12} \\ & + 0.808369B^{13} - 0.3620899B^{15})a_t \end{aligned} \quad (5)$$

In order to assess the quality of the selected model, the residues were analysed by the ACF (Auto Correlation Function) and the PACF (Partial Auto Correlation

Function) as well as the quantile-quantile plot (QQ-plot) and the Normal distribution Standard. Figure 4 and Figure 5 depict the aforementioned analysis. The QQ-plot produces an approximately straight line, suggesting that the peak demand series follow a normal distribution.

According to the results, there is strong evidence to consider that the residues of the model are normally distributed and the model is suitable to represent the time series. Additionally, to quantify the quality of the model, some statistical tests for In-Sample and Pseudo Out-of-Sample data were performed. To do that, the model was estimated from 2004 to 2014, leaving the year of 2015 for the pseudo out-of-sample analysis. The results are presented in Table 1, comparing them with their reference values. The tests indicated good adherence in both cases, In-sample and Pseudo Out-of-Sample analysis.

To illustrate the statistical tests, Figure 6 presents the time series and the estimate model applied for In-Sample and Pseudo Out-of-Sample analysis. It is important to mention that for this analysis the trend was incorporated. In addition, for the final application (presented in section 7), all data, from 2004 to 2015, were used to estimate and simulate future scenarios of peak demand. The obtained parameters are the same presented in the equation (5).




Figure 4: ACF and PACF of the Peak Demand Residues. The blue lines represent the Upper and lower confidence bounds.

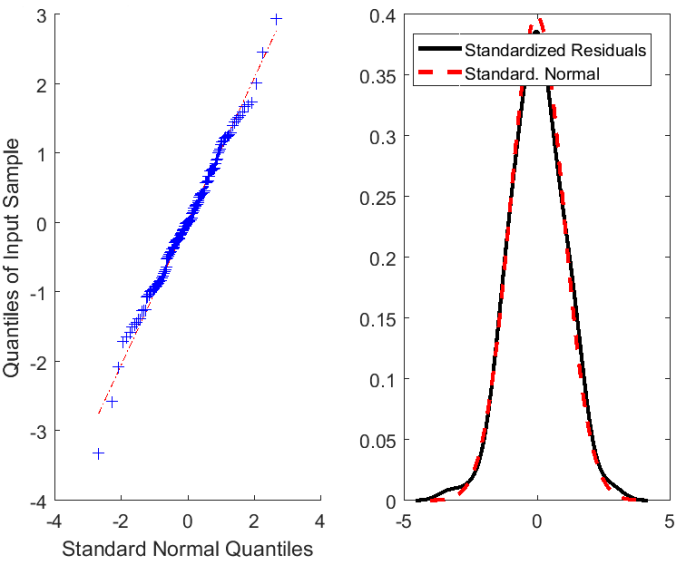


Figure 5: QQ-plot and Normal distribution of the residues.

Table 1: Statistical tests for In-Sample and Pseudo Out-of-Sample

Statistical Test	In-Sample	Pseudo Out-of-Sample	Ideal values
Mean of the series	4.733	23.481	0
R^2	0.8139	0.7908	1
MAPE	0.0475	0.0461	0
Kurtosis	3.50	1.807	3
Skewness	-0.0866	0.3832	0
Jarque-Bera	0	0	0




Figure 6: Time series and in-sample and pseudo out-of-sample analysis.

6. STOCHASTIC OPTIMIZATION MODEL

For the proposed problem, the optimization model uses the scenarios simulated of peak demand to decide the value of the peak demand contracted. In this paper, the consumer uses EV and CVaR as risk measurements to consider the different levels of cost risk acceptable. Apart from that, the rules to consider the costs, from equations (1)-(2), as well as the flexibility for changing the value of the peak demand contracted were also modeled as follows:

$$C_D = \min_{D_t^c, \Delta_{s,t}, d_{s,t}^{exc}, x_t, y_t, \delta_{s,t}, w_t} (1 - \lambda) \frac{1}{n_s} \sum_{t \in T} \sum_{s \in S} C_{s,t} + \lambda \left(\sum_{t \in T} w_t + \sum_{s \in S} \left(\frac{\delta_{s,t}}{1 - \alpha} \right) \frac{1}{n_s} \right) \quad (6)$$

Subject to:

$$D_t^c + \Delta_{s,t} + d_{s,t}^{exc} \geq D_{s,t}^{max} \quad \forall t, s \quad (7)$$

$$\Delta_{s,t} \leq D_t^c \cdot u \quad \forall t, s \quad (8)$$

$$d_{s,t}^{exc} \geq (D_{s,t}^{max} - D_t^c) \cdot x_{s,t} \quad \forall t, s \quad (9)$$

$$d_{s,t}^{exc} \leq M \cdot x_{s,t} \quad \forall t, s \quad (10)$$

$$x_{s,t} \in \{0,1\} \forall t, s \quad (11)$$

$$D_1^c \geq d_0 - M \cdot y_1 \quad (12)$$

$$D_t^c \geq D_{t-1}^c - M \cdot y_t, \quad \forall t > 1 \quad (13)$$

$$\sum_{t \in T} y_t + y_1 = 1 \quad (14)$$

$$y_t \in \{0,1\}, \quad \forall t \quad (15)$$

$$\delta_{s,t} \geq C_{s,t} - w_t \quad \forall t, s \quad (16)$$

$$\delta_{s,t} \geq 0 \quad \forall t, s \quad (17)$$

$$C_{s,t} = T_D \cdot (D_t^c + \Delta_{s,t} + d_{s,t}^{exc}) + T_D^{exc} \cdot d_{s,t}^{exc} \quad \forall t, s \quad (18)$$

As mentioned in Section 3, the presented model is an MILP problem.

Expression (6) aims to minimize the convex combination between EV and CVaR of the cost scenarios $C_{s,t}$. The risk level of the consumer can be decided by adjusting the λ parameter. The greater the λ value is, the higher the risk aversion will be.

The constraint (7) establishes that the peak demand contracted (D_t^c) plus tolerance ($\Delta_{s,t}$), plus excess of peak demand ($d_{s,t}^{exc}$) should be greater or equal than the peak demand value for each scenario s and each month t . In this case, the maximum value between the peak demand contracted and the peak demand is guaranteed to be used, in accordance with the expression (1) and in the first part of the expression (2).

The constraint (8) guarantees that the maximum excess of the peak demand to avoid penalty should be lesser or equal than 5% ($u = 5\%$) of the value of the peak demand contracted, as previously mentioned.

The constraints (9)-(11) are used to account for the non-convexity of the model to choose one rule (without penalty) or the other rule (with penalty). If the

solution of the proposed model indicates an advantage in terms of cost to pay the penalty in the month t , the $x_{s,t}$ value is equal to 1 and a value of $d_{s,t}^{exc}$ different of zero takes place. Otherwise, if $x_{s,t} = 0$ the penalty is not applied. It is important to highlight that there is a tradeoff between the $\Delta_{s,t}$ value and the $d_{s,t}^{exc}$ value. If one of them is zero, the other one is different from zero.

The constraints (12)-(15) allow the reduction of the value of the peak demand contracted for a specific month, in accordance with the initial value (d_0). If, for example, $y_1 = 1$, the peak demand contracted will be reduced in January. The constraint (13) is used to allow the reduction of the peak demand contracted for other months over the year. If, for example, $y_2 = 1$, the reduction will be in February and so on. Constraints (14) and (15) guarantee that the peak demand reduction will occur only once a year, respecting the Brazilian rules.

Expression (16)-(17) involve the CVaR constraints to account the $1 - \alpha\%$ worst scenarios of costs to be applied in the objective function, which was inspired in [21]. Finally, constraint (18) presents the final cost for each scenario and each month of the year.

7. CASE STUDY

In order to apply the optimization model, 2000 scenarios of peak demand were simulated. The simulation technique for the monthly peak demand was to choose, randomly, 2000 residual values and apply them around the estimated scenario for 2016. To illustrate, Figure 7 presents the simulation of 2000 scenarios for the forthcoming months, beginning in January of 2016.

The proposed optimization model (6)-(18) was implemented in Xpress [23], which has a competitive performance in solving MILP problems [24]. However, it is important to highlight that any other software could be used as long as it has a

built-in MILP function. The solution was obtained by using a branch and bound technique with cutting planes approach [25]. The best value of the peak demand contracted for the consumer was achieved by simulating 2000 peak demand scenarios for each month. On average, the problem was solved in 252.4 s in a computer with a processor Intel® Core™ i7-3770 CPU 3.40 GHz and the optimality gap was 0%.

In terms of parameters, the initial value of the peak demand contracted was arbitrarily chosen in $d_0=3800\text{kW}$. The risk aversion parameter α was chosen to be equal to 95%, which means that the 5% worst-case cost scenarios will be used by the CVaR in the optimization process. The λ value was used to simulate the risk aversion profiles. In Figure 8, the results of the optimization model are presented for the year of 2016 for some representative λ values, varying from zero to one. The quantiles from 1% to 99% of the simulated scenarios are also presented to observe how the values of peak demand contracted fit in the simulated scenarios.

Before analysing the results, it is important to mention that the consumer is a University in Brazil. In general, the vacation months for students are January, February and July, which means that the peak demand in these months tend to be lower compared to the rest of the months over the year. Consequently, a trivial solution would be to reduce the value of the peak demand contracted in one of these months. More specifically, the valley demand has historically occurred in July, due to the combination of vacation period and winter. Thus, it is expected that the reduction occurs in July.




Figure 7: Peak demand simulation of 2000 scenarios for the year of 2016.

According to Figure 8, for $\lambda = 0.5$, the optimization model indicates that the annual peak demand reduction should be in July, as expected. From August to December, the value of the peak demand contracted for $\lambda = 0.5$ is exactly the same value observed for $\lambda = 0.7$ in the same period. Because of this, the green line is behind the red line in this period. For other λ values, the results are quite different, with the reduction in June, taking the advantage of this month to remain the value until July.

Notwithstanding, the optimization model defines the minimum annual cost for the chosen risk parameters, thus the strategy involves all months over the year together, instead of the best contract value for each month, individually. These results highlight the importance of a system to compute the value of the peak demand contracted, since the naïve solution, which is the reduction of the peak demand contracted in one specific month (in this case, in July), is not always the best strategy.

To investigate the results in detail, Table 2 presents the values of the peak demand contracted for three representative risk aversion profiles, which are

$\lambda = \{1, 0.5, 0\}$, and the annual cost for each one. The values are presented in reais (R\$). According to [25], US\$ 1 corresponds to R\$ 3.198 in May of 2017.




Figure 8: Monthly peak demand contract for different λ values, 2000 scenarios and $d_0 = 3800$ kW.

For the most conservative risk profile ($\lambda = 1$), in which only the CVaR takes place in the objective function (6), the peak demand contracted rises continually during the first quarter, from 3800 kW to 4134 kW, and remaining constant until May, in 4134 kW. The value is reduced to 3392 kW in June and no variation of this value is observed in July. It grows again in August, achieving 3710 kW, remaining constant in September. A slightly increased is observed from September to October, reaching 3756 kW. Finally, from October to December the value rises again, achieving 4009 kW.

For $\lambda = 0.5$ the value of the peak demand contracted slightly increases from 3800 kW, in January, to 3864 kW, in February. From March to June, the value remains constant in 3911 kW. After that, a strong reduction takes place in July of 2723 kW. A tendency of growth is observed in August, reaching 3710 kW, remaining constant in September. The value slightly rises until November, reaching 3931 kW. Finally, this value remains constant until December.

For $\lambda = 0$, that is the less conservative profile with only the EV in (6), the annual peak demand contracted profile is quite similar to $\lambda = 1$. The main difference occurs in the first semester, when the value remains constant from January to June, in 3800 kW. On the other hand, in the second semester, the tendency of growth of the contract profile is quite similar to $\lambda = 1$, but with different values.

In terms of cost, the difference between the highest cost, for $\lambda = 1$, and the lowest cost, $\lambda = 0$, is approximately 8.12%. This value quantifies the impact of the risks taken by the consumer.

In order to simulate the sensitivity of the value of the peak demand contracted due to the initial value of the contract, different initial values were used. In Figure 9 and Figure 10, the contract simulation is depicted for $d_0 = 3700 \text{ kW}$ and $d_0 = 3900 \text{ kW}$, respectively.

In the first case ($d_0 = 3700 \text{ kW}$), the annual contract profile, for all λ values, is quite similar to the case of $d_0 = 3800 \text{ kW}$. On the other hand, in the case of $d_0 = 3900 \text{ kW}$ and $\lambda = 0$, the reduction of the peak demand contracted occurs in January, due to the combination of the vacation month and the higher initial value. In February, the value grows and remains almost the same during the rest of the year.

Table 2: Peak demand contracted and annual cost for different λ values.

Month	Peak Demand Contracted (kW) ($d_0 = 3800 \text{ kW}$)		
	$\lambda = 1$	$\lambda = 0.5$	$\lambda = 0$
Jan.	3800	3800	3800
Feb.	3961	3864	3800
Mar.	4134	3911	3800
Apr.	4134	3911	3800
May	4134	3911	3800
Jun.	3392	3911	2902

Jul.	3392	2723	2902
Aug.	3710	3710	3302
Sept.	3710	3710	3302
Oct.	3756	3751	3432
Nov.	3945	3931	3574
Dec.	4009	3931	3574
Annual Cost C_D	Cost (R\$)		
	$\lambda = 1$	$\lambda = 0.5$	$\lambda = 0$
2016	942,001.00	927,506.14	865,499.70

For the cases where no agreement between utility and consumer is reached, in terms of flexibility for reduction of peak demand contract over the year, the financial impact of such constraint is presented in Table 3, considering the values of the peak demand contracted fixed in 3700 kW, 3800 kW and 3900 kW, respectively.

The aforementioned situation represents the typical behaviour of the consumers, because, in general, they don't have a mathematical tool to support their decision. Comparing the cost obtained by a fixed contract with $d_0 = 3800 \text{ kW}$ and $\lambda = 1$, and its correspondent flexible contract, the difference is 8.1% in terms of cost saved in favour of the flexible contract. For the other cases presented in Table 3, similar analysis can be done. In order to allow the reproduction of this work, all data used and the results obtained are available on free access in [27].




Figure 9: Monthly peak demand contracted for different λ values, 2000 scenarios and $d_0 = 3700 \text{ kW}$.




Figure 10: Monthly peak demand contract for different λ values, 2000 scenarios and $d_0 = 3900 \text{ kW}$.

Table 3: Annual cost for fixed contracts and different λ values.

$D_t^c \text{ (kW)}$	Annual Cost C_D (R\$)		
	$\lambda = 1$	$\lambda = 0.5$	$\lambda = 0$
3700	1059,173.92	979,074.01	898,974.10
3800	1018,685.75	967,733.89	916,782.03
3900	996,127.07	967,031.87	937,936.67

8. CONCLUSION

In this paper a new method to contract peak demand for big consumers using a statistical and an optimization model was presented. The results obtained by the proposed method proved the importance of using a mathematical approach to solve the problem and achieve the global optimal solution. However, the results showed that depending on the initial value of peak demand contracted and the risk aversion profile, more than one year would be needed to reach the best result using the proposed method.

In addition, a saving of 8% was observed when the proposed system is compared with the typical solution used for many consumers, which uses the same value of the contract over the year. Due to the costs with electricity, the result can affect strongly the income of big consumers and the planning of the utility.

The proposed approach can be applied in any system, as long as a peak demand contract would be established between the utility and the consumer. Finally, in the authors' viewpoint, the relevance of the peak demand contract will increase with the expansion of the local renewable generation. In this scenario, the financial impact for utilities with a high penetration of renewable energy will be provoked by peak demand volatility and reduction of the electricity transportation.

9. ACKNOWLEDGEMENTS

The authors acknowledge the partial financial support from CNPq (Project n ° 471394/2010-6).

10. REFERENCES

- [1] Y. Levron, D. Shmilovitz, Power systems' optimal peak-shaving applying secondary storage, *Electric Power Systems Research*, 89 (2012) 80 – 84.
- [2] A. Zhuk et al., Managing peak loads in energy grids: Comparative economic analysis, *Energy Policy*, 88 (2016) 39 – 44.
- [3] S. Gyamfia, S. Krumdieck, Scenario analysis of residential demand response at network peak periods, *Electric Power Systems Research*, 93 (2012) 32 – 38.
- [4] J. Vuelvas, F. Ruiz, Rational consumer decisions in a peak time rebate program, *Electric Power Systems Research*, 143 (2017) 533 – 543.
- [5] P. Bradley, A. Coke, M. Leach, Financial incentive approaches for reducing peak electricity demand, experience from pilot trials with a UK energy provider, *Energy Policy*, 98 (2016) 108 – 120.
- [6] Y. Strengers, Peak electricity demand and social practice theories: Reframing the role of change agents in the energy sector, *Energy Policy* 44 (2012) 226 – 234.
- [7] Laouafi, A. et al, Online electricity demand forecasting based on an effective forecast combination methodology, *Electric Power Systems Research*, 148 (2017) 35 – 47.
- [8] P. E. McSharry, S. Bouwman, G. Bloemhof, Probabilistic Forecasts of the Magnitude and Timing of Peak Electricity Demand, *IEEE Transactions on Power Systems*, Vol. 20, n° 2 (2005) 1166 - 1172.
- [9] R. J. Hyndman, S. Fan, Density Forecasting for Long-Term Peak Electricity Demand, *IEEE Transactions on power systems*, Vol. 25, n° 2 (2010) 1142 - 1153.

- [10] S.Sp. Pappas et.al, Demand load forecasting of the Hellenic power system using an ARMA model, *Electric Power Systems Research*, 80 (2010) 256 – 264.
- [11] K. Chu, K. Kaifuku, K. Saitou. Optimal Integration of Alternative Energy Sources in Production Systems with Customer Demand Forecast. *IEEE Transactions on Automation Science and Engineering*, Vol. 13, nº 1 (2016) 206 - 214.
- [12] M. Carrión, et al, A stochastic programming approach to electric energy procurement for large consumers, *IEEE Transactions on Power Systems*, Vol. 22, nº 2 (2007) 744 - 754.
- [13] J. C. Munoz et. al, Applications of Optimal Industrial Load Management Modeling in Smart Grids, *Powertech 2017*, Manchester, 2017.
- [14] S. Paudyal, C. A. Cañizares and K. Bhattacharya, *Optimal Operation of Industrial Energy Hubs in Smart Grids*, in *IEEE Transactions on Smart Grid*, vol. 6, no. 2, pp. 684-694, March 2015.
- [15] E. T. Carlos; D. A. Lima, L. F. Ochoa, Energy contracting for large consumers in Brazil: a real case study, *CIREN (22nd International Conference on Electricity Distribution)*, Stockholm, 2013.
- [16] D. A. Lima et. al, Contract of electricity for large consumers: a statistical and optimization approach to define the best contract strategy. *SNPTEE (XXII National Seminar on the Production and Transmission of Electric Power)*, Foz do Iguaçu, October 2015.
- [17] G. E. P. Box, G. M. Jenkins, and G. C. Reinsel, *Time Series Analysis Forecasting and Control*, Third ed. Englewood Cliffs, NJ: PrenticeHall, 1994.

- [18] Aneel, Normative resolution 414, September, 2010. Available in: <http://www2.aneel.gov.br/cedoc/ren2010414comp.pdf>. Last access in April, 2016.
- [19] G. Schwarz, Estimation of the dimension of the model, *Annals of Statistics*, 6 (1978) 461–464.
- [20] H. Akaike, Fitting autoregressive models for prediction, *Annals of the Institute of Statistical Mathematics*, 21 (1969) 243 – 247.
- [21] MATLAB (Matrix Laboratory), version 8.1.0.604, 1994. Mathworks. Online access: <https://www.mathworks.com/>.
- [22] R. T. Rockafellar, e S. P. Uryasev, “Optimization of conditional value-at-risk”, *The Journal of Risk*, (2000) 21 - 41.
- [23] XPRESS, version 7.5. FICO™ Xpress Optimization Suite, 1956. Online access: <http://www.fico.com/br/products/fico-xpress-optimization-suite>.
- [24] T. Koch et. al, MIPLIB 2010 - Mixed Integer Programming Library version 5, *Mathematical Programming Computation*, Issue 3, (2011) 103–163.
- [25] L. A. Wolsey, *Integer Programming*, first ed., John Wiley & Sons, New York 1998.
- [26] Brazilian Central Bank. Online access: <http://www.bcb.gov.br/pt-br/#!/busca/valor%2520do%2520d%25C3%25B3lar>. Last access in May 2017.
- [27] D. Lima, “Data and results of the simulation for a big consumer in Brazil”, Maxwell Research Data Repository. Available on: https://www.maxwell.vrac.puc-rio.br/Busca_etds.php?strSecao=resultado&nrSeq=29920@1.