



Daniel Niemeyer Teixeira Paula

**Análise Estocástica da Contratação de Energia
Elétrica de Grandes Consumidores no
Ambiente de Contratação Livre Considerando
Cenários Correlacionados de Preços de Curto
Prazo, Energia e Demanda**

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
Agosto de 2020



Daniel Niemeyer Teixeira Paula

**Análise Estocástica da Contratação de Energia
Elétrica de Grandes Consumidores no
Ambiente de Contratação Livre Considerando
Cenários Correlacionados de Preços de Curto
Prazo, Energia e Demanda**

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

Prof. Delberis Araujo Lima

Orientador

Departamento de Engenharia Elétrica – PUC-Rio

Prof. Phillipe Vilaça Gomes

Departamento de Engenharia Elétrica – PUC-Rio

João Carlos de Oliveira Mello

Thymos Energia

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

Daniel Niemeyer Teixeira Paula

Graduou-se em Engenharia Elétrica em 2017 na Universidade Federal Fluminense. Sua área de pesquisa envolve mercados de energia elétrica, otimização e contratação eficiente de energia elétrica para grandes consumidores.

Ficha Catalográfica

Paula, Daniel Niemeyer Teixeira

Análise estocástica da contratação de energia elétrica de grandes consumidores no ambiente de contratação livre considerando cenários correlacionados de preços de curto prazo, energia e demanda / Daniel Niemeyer Teixeira Paula ; orientador: Delberis Araujo Lima. – 2020.

92 f. : il. color. ; 30 cm

Dissertação (mestrado)–Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Elétrica, 2020.

Inclui bibliografia

1. Engenharia Elétrica - Teses. 2. Demanda máxima. 3. Ambiente de contratação livre. 4. Grandes consumidores. 5. SARIMA. 6. PLD. I. Lima, Delberis Araujo. II. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Elétrica. III. Título.

CDD: 621.3

Para a minha avó Elza, a guerreira mais valente que já conheci.

Obrigado por tudo.

Agradecimentos

Agradeço aos meus pais, Helena e Carlos, por todo o carinho e dedicação, e por sempre acreditar em meu potencial.

À minha avó Elza, por todo o amor e por ter sido fundamental em minha criação. Que Deus a tenha.

À minha tia Tania, por estar sempre presente e me apoiando em todas as circunstâncias.

Ao meu orientador Delberis, pela dedicação, paciência, suporte teórico e por toda ajuda recebida durante o curso.

Aos meus amigos mais íntimos, que estiveram sempre presentes.

Aos meus amigos do laboratório, pelo conhecimento e companheirismo durante todo o curso.

Aos professores e funcionários do Departamento de Engenharia Elétrica da PUC-Rio, pela qualidade do ensino e infraestrutura, e pela ajuda prestada durante esse tempo.

À PUC-Rio e ao CNPq pelos auxílios concedidos.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Resumo

Niemeyer Teixeira Paula, Daniel; Lima, Delberis Araújo. **Análise Estocástica da Contratação de Energia Elétrica de Grandes Consumidores no Ambiente de Contratação Livre Considerando Cenários Correlacionados de Preços de Curto Prazo, Energia e Demanda.** Rio de Janeiro, 2020. 92p. Dissertação de Mestrado – Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

No Brasil, grandes consumidores podem estabelecer seus contratos de energia elétrica em dois ambientes: Ambiente de Contratação Regulado e Ambiente de Contratação Livre. Grandes consumidores são aqueles que possuem carga igual ou superior a 2 MW e podem ser atendidos sob contratos firmados em quaisquer um desses ambientes. Já os consumidores com demanda contratada inferior a 2 MW e superior a 500 kW podem ter seu contrato de energia estabelecido no Ambiente de Contratação Livre proveniente de geração de energia renovável ou no Ambiente de Contratação Regulada através das distribuidoras de energia. A principal vantagem do Ambiente de Contratação Livre é a possibilidade de negociar contratos com diferentes parâmetros, como, por exemplo, preço, quantidade de energia e prazo. Eventuais diferenças entre a energia contratada e a consumida, são liquidadas ao preço de energia de curto prazo, que pode ser bastante volátil.

Neste caso o desafio é estabelecer uma estratégia de contratação que minimize os riscos associados a este ambiente. Esta dissertação propõe uma metodologia que envolve a simulação estatística de cenários correlacionados de energia, demanda máxima e preço de curto prazo (também chamado de PLD – Preço de Liquidação das Diferenças) para serem inseridos em um modelo matemático de otimização estocástica, que define os parâmetros ótimos da contratação de energia e demanda. Na parte estatística, um modelo Box & Jenkins é usado para estimar os parâmetros das séries históricas de energia e demanda máxima com o objetivo de simular cenários correlacionados com o PLD. Na parte de otimização, emprega-se uma combinação convexa entre Valor Esperado (VE) e *Conditional Value-at-Risk* (CVaR) como medidas de risco para encontrar os valores

ótimos dos parâmetros contratuais, como a demanda máxima contratada, o volume mensal de energia a ser contratado, além das flexibilidades inferior e superior da energia contratada. Para ilustrar a abordagem proposta, essa metodologia é aplicada a um estudo de caso real para um grande consumidor no Ambiente de Contratação Livre.

Os resultados indicaram que a metodologia proposta pode ser uma ferramenta eficiente para consumidores no Ambiente de Contratação Livre e, dado à natureza do modelo, pode ser generalizado para diferentes contratos e mercados de energia.

Palavras-chave

Demanda máxima; Ambiente de Contratação Livre; Grandes Consumidores; SARIMA; PLD; Modelos Estatísticos; Otimização Estocástica; Valor Esperado (VE); *Conditional Value-at-Risk* (CVaR).

Abstract

Niemeyer Teixeira Paula, Daniel; Lima, Delberis Araújo (Advisor). **Stochastic Analysis of Energy Contracting in the Free Contract Environment for Big Consumers Considering Correlated Scenarios of Spot Prices, Energy and Power Demand**. Rio de Janeiro, 2020. 92p. Dissertação de Mestrado – Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

In Brazil, big consumers can choose their energy contract between two different energy environments: Regulated Contract Environment and Free Contract Environment. Big consumers are characterized by installed load capacity equal or greater than 2 MW and can firm an energy contract under any of these environments. For those consumers with installed load lower than 2 MW and higher than 500 kW, their energy contracts can be firmed in the Free Contract Environment using renewable energy generation or in the Regulated Contract Environment by local distribution companies. The main advantage of the Free Market Environment is the possibility of negotiating contracts with different parameters such as, for example, price, energy quantity and deadlines. Possible differences between contracted energy and consumed energy are settled by the spot price, which can be rather volatile.

In this case, the challenge is to establish a contracting strategy that minimize the associated risks with this environment. This thesis proposes a methodology that involves statistical simulation of correlated energy, peak demand and Spot Price scenarios to be used in a stochastic optimization model that defines the optimal energy and demand contract parameters. In the statistical part, a Box & Jenkins model is used to estimate parameters for energy and peak demand in order to simulate scenarios correlated with Spot Price. In the optimization part, a convex combination of Expected Value (EV) and Conditional Value-at-Risk (CVaR) is used as risk measures to find the optimal contract parameters, such as the contracted peak demand, the seasonal energy contracted volumes, in addition to the upper and lower energy contracted bound. To illustrate this approach, this methodology is

applied in a real case study for a big consumer with an active Free Market Environment contract.

The results indicate that the proposed methodology can be a efficient tool for consumers in the Free Contract Environment and, due to the nature of the model, it can be generalized for different energy contracts and markets.

Keywords

Peak demand; Free Contract Environment; Big consumers; SARIMA; Spot Price; Statistical Models; Stochastic Optimization; Expected Value; *Conditional Value-at-Risk*.

Sumário

1	Introdução	20
1.1	Revisão Bibliográfica	23
1.2	Estrutura da Dissertação	25
2	Modelos de Previsão de Séries Temporais	27
2.1	Séries Temporais	27
2.2	Análise do Domínio do Tempo	28
2.3	Processo Estocástico	30
2.4	Previsão de Séries Temporais	31
2.5	Modelos Box & Jenkins	32
2.5.1	Modelo Auto-Regressivo (AR)	33
2.5.2	Modelo Médias Móveis (MA)	34
2.5.3	Modelo Auto-Regressivo Integrado de Médias Móveis (ARIMA)	34
2.6	Modelo Sazonal Auto-Regressivo Integrado de Médias Móveis (SARIMA)	35
2.6.1	Modelo Sazonal Auto-Regressivo Integrado de Médias Móveis (SARIMA) com Variáveis Explicativas	35
2.7	Critérios de Avaliação dos Modelos	36
2.7.1	Critério de Informação de Akaike (AIC)	36
2.7.2	Critério de Informação Bayesiano (BIC)	36
2.7.3	Erro Médio Absoluto Percentual (MAPE)	36
2.7.4	Coeficiente de Determinação (R^2)	37
2.7.5	Teste de Sobrefixação	37
2.7.6	Análise dos Resíduos	38
3	Ambientes de Contratação	40
3.1	Ambiente de Contratação Regulado	40
3.2	Ambiente de Contratação Livre	42

4	Métricas de Risco	44
4.1	<i>Value at Risk</i> (VaR)	44
4.2	<i>Conditional Value at Risk</i> (CVaR)	45
5	Tratamento das Séries Temporais	48
5.1	Séries de Energia e Demanda Mensais	48
5.2	Análise de Correlação	52
5.3	Modelagem das Séries	54
5.3.1	Modelagem da Série de Energia	56
5.3.2	Modelagem da Série de Demanda	58
5.4	Previsão das Séries Temporais	61
5.4.1	Previsão da Série de Energia	61
5.4.2	Previsão da Série de Demanda	63
5.5	Geração dos Cenários	64
6	Modelos de Otimização	69
6.1	Otimização no ACL considerando bandas de flexibilidade	69
6.2	Otimização no ACL considerando sazonalidade	74
7	Resultados e Discussões	76
7.1	Resultados de Otimização no ACL Considerando Contrato Flat com Flexibilidade da Energia Contratada	76
7.2	Resultados de Otimização no ACL Considerando Contrato Sazonalizado com Flexibilidade da Energia Contratada	81
8	Conclusão e Perspectivas	87
9	Referências Bibliográficas	89

Lista de Figuras

Figura 1.1 – Esquema simplificado dos diferentes ambientes de contratação de energia	22
Figura 2.1 – Geração de uma série temporal	32
Figura 2.2 – Processo de previsão proposto nos modelos Box & Jenkins	33
Figura 3.1 – Curva de custos referente à demanda máxima [14, 33]	41
Figura 4.1 – VaR de uma dada distribuição de probabilidades [37]	45
Figura 4.2 – VaR e CVaR de uma dada distribuição de probabilidades [37]	46
Figura 4.3 – Comparação entre o CVaR de duas distribuições de probabilidade [37]	47
Figura 5.1 – Série de energia (em MWh) de 2002 até 2017	49
Figura 5.2 – Série de demanda máxima (em kW) de 2002 até 2017	49
Figura 5.3 – Série de PLD (em R\$/MWh) de 2002 até 2017.	50
Figura 5.4 – Série decomposta da Energia	50
Figura 5.5 – Série decomposta da Demanda Máxima	51
Figura 5.6 – Série decomposta de PLD	51
Figura 5.7 – Gráfico de correlação entre Energia e PLD	53
Figura 5.8 – Gráfico de correlação entre Energia e Demanda Máxima	54
Figura 5.9 – Fluxograma da metodologia de escolha do melhor modelo SARIMA	55
Figura 5.10 – ACF e PACF dos resíduos da Energia	57
Figura 5.11 – Avaliação da normalidade dos resíduos da série de Energia	57
Figura 5.12 – Dados in sample e pseudo out-of-sample da série de Energia	58
Figura 5.13 – ACF e PACF dos resíduos da Demanda	60
Figura 5.14 – Avaliação da normalidade dos resíduos da série de Demanda	60

Figura 5.15 – Dados in sample e pseudo out-of-sample da série de demanda.	61
Figura 5.16 – Previsão da série de energia	62
Figura 5.17 – Previsão para a série de demanda máxima	63
Figura 5.18 – Simulação dos 200 cenários de PLD	64
Figura 5.19 – 200 cenários de energia sem reamostragem	65
Figura 5.20 – 200 cenários de demanda sem reamostragem	65
Figura 5.21 – Distribuição da série de energia e sua respectiva média em destaque	66
Figura 5.22 – Distribuição das variáveis aleatórias e sua respectiva média em destaque	67
Figura 5.23 – Dados empilhados de histórico e simulação da série de energia	67
Figura 5.24 – Dados empilhados de histórico e simulação da série de demanda máxima	68
Figura 6.1 – Demonstração gráfica do comportamento das variáveis binárias no problema proposto	73
Figura 7.1 – Energia e flexibilidades contratadas para diferentes valores de λ a um preço de energia de 100 R\$/MWh	78
Figura 7.2 – Energia e flexibilidades contratadas para diferentes valores de λ a um preço de energia de 200 R\$/MWh	80
Figura 7.3 – Energia contratada mês a mês para $\lambda = 0$ a um preço de energia de 100 R\$/MWh	82
Figura 7.4 – Energia contratada mês a mês para $\lambda = 0,5$ a um preço de energia de 100 R\$/MWh	83
Figura 7.5 – Energia contratada mês a mês para $\lambda = 1$ a um preço de energia de 100 R\$/MWh	83
Figura 7.6 – Energia contratada mês a mês para $\lambda = 0$ a um preço de energia de 200 R\$/MWh	85
Figura 7.7 – Energia contratada mês a mês para $\lambda = 0,5$ a um preço de energia de 200 R\$/MWh	85
Figura 7.8 – Energia contratada mês a mês para $\lambda = 1$ a um preço de energia de 200 R\$/MWh	86

Lista de Tabelas

Tabela 5.1 – Resultados dos testes de correlação de Pearson	53
Tabela 5.2 – Resultados dos melhores modelos de energia em função do coeficiente K.	56
Tabela 5.3 – Parâmetros estimados do modelo <i>SARIMA</i> 5,1,4 × 0,1,212	56
Tabela 5.4 – Resultados dos melhores modelos de energia em função do coeficiente K.	58
Tabela 5.5 – Parâmetros estimados do modelo <i>SARIMA</i> 4,1,3 × 1,1,112	59
Tabela 5.6 – Comparação dos valores reais e previstos para o ano de 2018 para a série de energia	62
Tabela 5.7 – Comparação dos valores reais e previstos para o ano de 2018 para a série de demanda máxima	63
Tabela 7.1 – Resultados considerando um preço de energia de 100 R\$/MWh	77
Tabela 7.2 – Resultados considerando um preço de energia de 200 R\$/MWh	79
Tabela 7.3 – Resultados considerando um preço de energia de 100 R\$/MWh	81
Tabela 7.4 – Resultados considerando um preço de energia de 200 R\$/MWh	84

Nomenclatura

Caracteres Romanos Maiúsculos

AIC_i	Valor do AIC do modelo testado na iteração i
B	Operador de <i>lag</i>
B^S	Operador de <i>lag</i> sazonal
B^+	Flexibilidade superior
B^-	Flexibilidade inferior
BIC_i	Valor do BIC do modelo testado na iteração i
$C_{s,t}$	Custo total para o cenário s e mês t
$C_{s,t}^1$	Custo acima da flexibilidade superior para o cenário s e mês t
$C_{s,t}^2$	Custo abaixo da flexibilidade inferior para o cenário s e mês t
$C_{s,t}^3$	Custo entre as flexibilidades para o cenário s e mês t
$C_{s,t}^D$	Custo da demanda para o cenário s e mês t
C_t^D	Custo da demanda para o mês t
$C_{s,t}^E$	Custo da energia para o cenário s e mês t
C_t^E	Custo da energia para o mês t
$C_{s,t}$	Função que calcula o custo associado à demanda/energia contratada para o cenário s e mês t
C_t^{verde}	Custo do consumidor cativo da modalidade verde no mês t
C_{ANUAL}	Custo ótimo anual de demanda
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
$E_{s,t}^{fp}$	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

E_t^{fp}	Energia consumida fora da ponta no mês t
E_t^p	Energia consumida na ponta no mês t
M	Número grande (<i>Big M</i>) utilizado como parâmetro auxiliar
P_e	Preço da energia contratada
P_t	Preço da energia contratada no mês t
Q	Quantidade de energia contratada
Q_t	Quantidade de energia contratada no mês t
Q^+	Flexibilidade superior em termos de energia
Q^-	Flexibilidade inferior em termos de energia
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^{ult}	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)
$TUSD_D$	Tarifa do uso do sistema de distribuição pelo uso do fio
$TUSD_D^{ult}$	Tarifa de ultrapassagem do uso do sistema de distribuição pelo uso do fio
$TUSD_E^{fp}$	Tarifa do uso do sistema de distribuição para a energia fora ponta
$TUSD_E^p$	Tarifa do uso do sistema de distribuição para a energia de ponta
$X_{s,t}^1$	Variável binária principal relacionada ao consumo acima da flexibilidade superior de contrato
$X_{s,t}^2$	Variável binária secundária relacionada ao consumo entre as flexibilidades de contrato
$X_{s,t}^3$	Variável binária secundária relacionada ao consumo entre as flexibilidades de contrato
$X_{s,t}^{23}$	Variável binária principal relacionada ao consumo entre as flexibilidades de contrato
$X_{s,t}^4$	Variável binária principal relacionada ao consumo abaixo da flexibilidade inferior de contrato

$Y_{s,t}$ Variável binária que indica a ultrapassagem de demanda contratada no cenário s e mês t

Z_t Série Temporal

Caracteres Romanos Minúsculos

a_t Ruído branco

$d_{s,t}^u$ Ultrapassagem de demanda do cenário s e mês t

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

Caracteres Gregos Maiúsculos

$\Delta_{s,t}^D$ Tolerância de demanda do cenário s e mês t

$\Delta_{s,t}^+$ Diferença entre o consumo no mês t e cenário s e a flexibilidade superior de contrato

$\Delta_{s,t}^-$ Diferença entre a flexibilidade inferior de contrato e o consumo no mês t e cenário s

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

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

ϕ_p Parâmetro do componente autorregressivo de ordem p

Sobrescritos

<i>c</i>	Valor contratado
<i>D</i>	Demanda
<i>E</i>	Energia
<i>fp</i>	Valor fora da ponta
<i>max</i>	Valor máximo
<i>p</i>	Valor na ponta
<i>ult</i>	Valor de ultrapassagem
<i>verde</i>	Consumidor na modalidade verde

Subscritos

<i>cont</i>	Valor contratado
<i>s</i>	Cenário
<i>t</i>	Tempo

Abreviaturas, Siglas e Símbolos

<i>ACF</i>	Função de Autocorrelação
<i>ACL</i>	Ambiente de Contratação Livre
<i>ACR</i>	Ambiente de Contratação Regulada
<i>AIC</i>	Critério de Informação de Akaike
<i>ANEEL</i>	Agência Nacional de Energia Elétrica
<i>AR</i>	Autorregressivo
<i>ARIMA</i>	Modelo Autorregressivo-Integrado de Médias Móveis
<i>ARMA</i>	Modelo Autorregressivo de Médias Móveis
<i>BIC</i>	Critério de Informação Bayesiano
<i>B&J</i>	Box <i>and</i> Jenkins
<i>CCEE</i>	Câmara de Comercialização de Energia Elétrica
<i>CVaR</i>	<i>Conditional Value at Risk</i>
<i>kV</i>	<i>Quilovolt</i>
<i>kW</i>	Quilowatt
<i>MA</i>	Média Móvel
<i>MAPE</i>	Erro Médio Absoluto Percentual
<i>MILP</i>	Programação Linear Inteira Mista

<i>MW</i>	Megawatt
<i>MWh</i>	Megawatt-hora
<i>PACF</i>	Função de Autocorrelação Parcial
<i>PLD</i>	Preço de Liquidação das Diferenças
<i>R\$</i>	Reais
<i>R\$/MWh</i>	Reais por megawatt-hora
<i>R\$/kW</i>	Reais por quilowatt
<i>R²</i>	Coefficiente de Determinação
<i>SARIMA</i>	Modelo Autorregressivo-Integrado de Médias Móveis Sazonal
<i>SIN</i>	Sistema Interligado Nacional
<i>VaR</i>	<i>Value at Risk</i>
<i>VE</i>	Valor Esperado

1 Introdução

No Brasil, a comercialização de energia possui uma aplicação estratégica no mercado de energia, desempenhando o papel de interlocutor nas operações de compra e venda de energia, por meio de contratos. Dessa forma, é atribuição da Agência Nacional de Energia Elétrica (ANEEL) fiscalizar, dentre outras atribuições, a comercialização de energia elétrica, segundo a Lei Nº 9.427/96 [1].

Foi a partir da Lei Nº 10.848/04 [2] que o Governo Federal instituiu a comercialização de energia sob a forma praticada atualmente, criando dois ambientes de mercado: Ambiente de Contratação Regulada (ACR) e Ambiente de Contratação Livre (ACL), bem como as condições gerais e processos para contratação, regras e mecanismos de proteção ao consumidor, dentre outros tópicos. Assim, ficou definido também que o registro das operações de compra e venda de energia em todo o Sistema Interligado Nacional (SIN) se dá pela Câmara de Comercialização de Energia Elétrica (CCEE) [3]. É atribuição da CCEE manter registrados todos os contratos de energia, tanto no ACR quanto no ACL.

Sob o ponto de vista de mercado, existem dois tipos de consumidores livres: os consumidores livres e os consumidores especiais. Consumidores livres são aqueles com capacidade instalada de 2 MW ou mais e estão elegíveis para diferentes opções de contratação de energia, proveniente de qualquer fonte geradora, segundo portaria MME Nº 514 da ANEEL [4]. Consumidores especiais devem possuir capacidade instalada maior que 500 kW e menor que 2 MW e podem contratar energia proveniente apenas de fontes renováveis, como usinas eólicas, solares, biomassa e pequenas centrais hidrelétricas (PCHs) com potência igual ou inferior a 50 MW [5]. Isso significa que grandes consumidores têm a opção de escolher a modalidade que lhe trará as maiores vantagens.

No ACR, as operações de compra e venda de energia são realizadas entre os agentes vendedores e as distribuidoras de energia, por meio de licitação, de acordo com o Decreto Nº 5.163/04 [6]. Os consumidores, por sua vez, são denominados

cativos e compram a energia diretamente das distribuidoras de energia nas quais são conectadas. Os grandes consumidores cativos podem contar com três alternativas de cobrança tarifária [7]:

- Tarifa Convencional: caracterizada por tarifas de consumo de energia e demanda de potência independentemente das horas de utilização do dia;
- Tarifa Horo-sazonal Verde: caracterizada por tarifas diferenciadas no consumo de energia em função das horas do dia e por uma tarifa única de demanda de potência;
- Tarifa Horo-sazonal Azul: caracterizada por tarifas diferenciadas tanto no consumo de energia quanto na demanda de potência, em função das horas de utilização do dia.

O ACL, por sua vez, é o ambiente onde as operações de compra e venda de energia são realizadas em forma de contratos bilaterais livremente negociados [6]. Os consumidores, agora denominados de consumidores livres, negociam diretamente com as comercializadoras as melhores condições de preço, prazos, quantidade de energia e diversos parâmetros adicionais, como flexibilidade da energia contratada e sazonalidade. No ACL, cada consumidor paga uma fatura referente à compra da energia e outra referente ao serviço de distribuição realizado pela concessionária local. A fatura a ser paga para a distribuidora é cobrada em função da Tarifa do Uso do Sistema de Distribuição (TUSD), ou para todas as transmissoras, em função da Tarifa do Uso do Sistema de Transmissão (TUST), caso o consumidor esteja conectado à rede básica. Caso o consumidor tenha seu contratado associado a alguma fonte alternativa de energia, este pode receber um desconto de até 100% na TUSD [8]. A Figura 1.1 apresenta um esquema simplificado do funcionamento dos dois ambientes de contratação presentes no mercado de energia brasileiro, sob a esfera da CCEE.

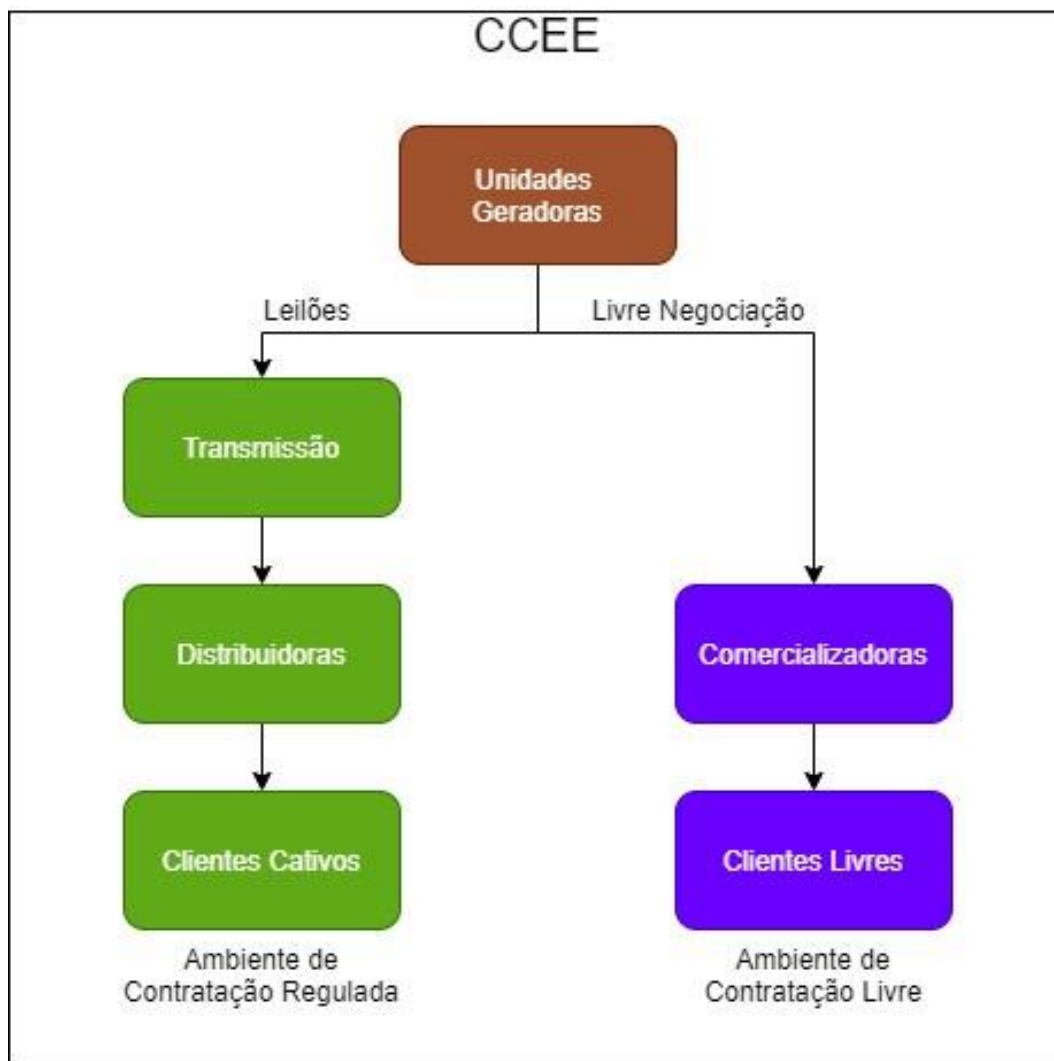


Figura 1.1 – Esquema simplificado dos diferentes ambientes de contratação de energia

A grande vantagem do ACL para o consumidor é a liberdade de escolher o tipo de contrato mais adequado para o perfil de consumo. Entretanto, normalmente o consumidor dispõe de ferramentas limitadas para tomar a melhor decisão de contratação diante dos riscos deste ambiente. Isso ocorre pois, no mercado, não há facilidade de acesso a uma ferramenta capaz de auxiliar esses clientes na tomada de decisão, tendo em vista que se almeja sempre o menor custo aliada à confiabilidade do fornecimento de energia. Os principais fatores de risco no ACL são as incertezas na demanda a ser contratada na distribuidora local; a incerteza no montante de energia a contratar e incerteza em relação ao preço da energia no mercado de curto prazo, chamado de Preço da Liquidação das Diferenças (PLD) [9]; e os parâmetros adicionais do contrato, como flexibilidade e sazonalidade, tratados como variáveis de decisão.

Neste trabalho pretende-se aplicar uma metodologia que auxilie na tomada de decisão estratégica sobre a contratação de energia de um grande consumidor no ACL. Para esse propósito, é formulado um modelo de otimização estocástica que minimize os custos anuais com energia elétrica e determine um perfil de contratação no ACL que possibilite a minimização desses custos.

Para tal, é necessário o uso de cenários de energia e demanda simulados. Essas simulações são construídas em função de seus dados históricos correlacionados com os dados históricos de PLD de mesmo intervalo de tempo. Isso é feito através de modelos estatísticos que permitem estimar a demanda máxima e a energia consumida a partir dos dados históricos e da correlação considerada entre esses dados.

1.1 Revisão Bibliográfica

Nesta seção serão apresentados os trabalhos presentes na literatura que abordam temas correlatos ao trabalho realizado na dissertação tanto na parte que envolve o modelo estatístico como o de otimização.

Em [10], os autores propõem um novo método de previsão de demanda máxima, onde são consideradas diversas variáveis exógenas, como a temperatura, em escalas de 30 minutos, e dados anuais demográficos e econômicos da região. A metodologia foi utilizada para a previsão da distribuição de probabilidades da demanda máxima anual e semanal para a região sul da Austrália até 2007. A performance é comparada com os dados reais do verão de 2007 e 2008. O modelo proposto conseguiu resultados bem próximos dos dados comparativos históricos.

Em [11], é sugerida uma metodologia de otimização estocástica que considera um modelo Auto-regressivo Integrado de Médias Móveis (ARIMA) para gerar cenários de preço e aplicar ao modelo de otimização. A ideia é criar uma metodologia que permita um grande consumidor a decidir o seu perfil ótimo de aquisição de energia, podendo ser feito a partir da geração própria, de contratos bilaterais e de participação no *Pool*. O objetivo é minimizar os custos relacionados à aquisição ao mesmo tempo limitando os riscos associados ao processo, adotando uma metodologia de *Conditional Value-at-Risk* (CVaR) para mensurar tais riscos.

Em [12], um modelo Auto-Regressivo de Médias Móveis (ARMA) é considerado para ajustar um conjunto de dados de demanda utilizando como métrica de análise o Critério de Informação de Akaike Corrigido. Já em [13, 14] é considerado um modelo Auto-Regressivo Sazonal Integrado de Médias Móveis (SARIMA) para ajustar dados de energia e demanda máxima em escala mensal.

Em [15], é apresentado um modelo de Auto-Regressivo (AR) de previsão de demanda máxima e consumo de energia, com o objetivo de estabelecer o melhor contrato de energia para o consumidor, seja no ambiente Livre ou Regulado. Nessa análise também é considerada o uso de energias alternativas, o que proporciona descontos na TUSD, conforme citado anteriormente.

Sob outra perspectiva, para análises considerando um grande volume de dados, técnicas de Aprendizado de Máquina e Inteligência Artificial são utilizadas na abordagem desse tipo de problema, ao invés do uso da metodologia clássica de previsão. Em [16, 17], modelos de redes neurais são aplicados na previsão da demanda diária e de 15 minutos, respectivamente. Os resultados são comparados com a curva real histórica para verificar a acurácia dos modelos.

Em [18], a autora da dissertação desenvolveu uma ferramenta de auxílio para tomada de decisão na contratação de energia elétrica tanto no ACR quanto no ACL. Foram utilizados cenários de demanda e energia consumida a partir de um modelo estatístico. Esses cenários são inseridos no modelo de otimização que minimiza o custo total do consumidor, cujos resultados são os valores ótimos de demanda máxima contratada mensal.

Em [19], é abordada uma aplicação de um modelo de otimização industrial inseridos em uma *smart grid* com o objetivo de minimizar os custos relacionados à energia para esse processo industrial. Abordagem semelhante é apresentada em [20], que leva também em consideração o efeito de energias renováveis para reduzir a dependência da rede e, conseqüentemente, riscos de falta de energia.

Em [13], é apresentado um modelo de otimização usando uma combinação entre Valor Esperado e CVaR calcular a demanda contratada ótima mensal para um grande consumidor no Ambiente Regulado. Em [14], é apresentado um modelo similar para calcular, além do valor ótimo da demanda contratada, a quantidade ótima de painéis solares. Para uso, foi usado um modelo Auto-regressivo Integrado de Médias Móveis Sazonal (SARIMA) para estipular os dados de demanda, energia e geração fotovoltaica de forma correlacionada.

Sob um ponto de vista empresarial, os autores em [21] discutem vários pontos estratégicos na contratação de energia, tendo em vista que o ACL demanda uma organizada gestão de energia, incorporando certo risco. Dessa forma, os autores descrevem melhores práticas dessa gestão pelo lado do consumidor em relação com a regulação presente no ACL, focando em casos reais de gestão de indústrias eletrointensivas.

1.2 Estrutura da Dissertação

A estrutura desta dissertação é formalizada a seguir:

No Capítulo 1, como já visto, está apresentado um panorama geral do mercado de contratação de energia elétrica no Brasil, e suas respectivas subdivisões em ambiente Livre e ambiente Regulado. Também está apresentada uma revisão bibliográfica de alguns trabalhos encontrados na literatura em temas de otimização de contratos e modelos de previsão de energia.

No capítulo 2 estão apresentados alguns conceitos de estatística e de séries temporais, tais como modelos de previsão e critérios de avaliação dos modelos.

No capítulo 3 estão apresentados os ambientes de contratação vigentes no Brasil, em conjunto com a formulação matemática associada a cada um deles.

No capítulo 4, apresenta-se as medidas de risco VaR e CVaR, conceitos necessários para a modelagem do problema apresentado nessa dissertação.

No capítulo 5 é apresentada a metodologia de escolha dos melhores modelos estatísticos para as séries temporais consideradas nesta dissertação. No capítulo também estão apresentadas as previsões dessas séries temporais além do processo de geração de cenários correlacionados necessários para aplicação no modelo de otimização.

No capítulo 6, está apresentado o modelo de otimização estocástico para um grande consumidor faturado no ACL que está inserido na modalidade Verde A4.

No capítulo 7 são apresentados os resultados em decorrência de um estudo de caso real de um grande consumidor no ACL. Os resultados estão relacionados a dois tipos de contrato considerados. O primeiro é um tipo de contrato flat em que se considera um único valor de energia mensal contratado para todos os meses do

contrato. O segundo é um tipo de contrato sazonalizado em que se permite definir um volume de energia contratada diferente para cada mês de contrato.

No capítulo 8 são apresentadas as considerações finais e a conclusão do trabalho, além de sugestões de trabalhos futuros.

No capítulo 9 encontram-se todas as referências bibliográficas utilizadas nessa dissertação.

2 Modelos de Previsão de Séries Temporais

Neste capítulo serão apresentados conceitos fundamentais de séries temporais relevantes para o desenvolvimento do trabalho, bem como alguns modelos de previsão presentes na literatura. Esses modelos consideram diferentes metodologias, como: método ingênuo, método de médias móveis, método de amortecimento exponencial, método de amortecimento direto, método de regressão dinâmica e modelos de Box & Jenkins, sendo este último utilizado no decorrer do trabalho. Por fim, serão apresentados diversos critérios de avaliação dos modelos, necessários na escolha do melhor modelo desta dissertação.

2.1 Séries Temporais

Uma série temporal pode ser definida como um conjunto de observações ordenadas no tempo de uma determinada variável. Denomina-se Z_t o valor da variável aleatória Z no instante t , uma série temporal pode ser escrita por Z_1, Z_2, \dots, Z_N , sendo N o tamanho da série ou o número de observações da variável em questão [13].

Cabe ressaltar que nem todo evento observado no tempo é uma série temporal. Algumas variáveis são de natureza contínua e outras discretas. O foco se mantém nas variáveis discretas, realizando uma observação pontual ao longo do tempo. Por isso, uma série temporal pode representar fenômenos como [14]:

- Energia consumida mensalmente de um cliente;
- Valor das ações de uma empresa na bolsa de valores;
- Número de voos anuais de um determinado aeroporto.

Para caracterizar uma série temporal, considera-se os seguintes componentes:

- Nível: semelhante ao coeficiente linear de uma função matemática;
- Tendência: comportamento ao longo prazo da série temporal, podendo ser linear, exponencial etc.

Sazonalidade: repetição de um padrão durante um período;

Ruído: componente estocástica da série temporal associada a uma distribuição de probabilidade.

No âmbito das séries temporais, existem três objetivos principais, que são [15]:

Simulação: gerar novas realizações no mesmo período do processo estocástico ou gerar cenários futuros de uma série temporal com os dados observados;

Análise: investigar o padrão de comportamento dos dados através de estatísticas descritivas e gráficos;

Previsão: criar um modelo estatístico utilizando os dados para realizar estimativas dos próximos valores da série, em um determinado horizonte de previsão.

Na análise de séries temporais, existem duas perspectivas:

Análise no domínio do tempo, onde os modelos propostos são paramétricos, com um número finito de parâmetros;

Análise no domínio da frequência, onde os modelos propostos são não-parametrizados.

A seguir, é descrita a análise no domínio do tempo, que é a forma de análise adotada neste trabalho.

2.2 Análise do Domínio do Tempo

A análise no domínio do tempo baseia-se no comportamento gráfico dos coeficientes de autocorrelação, também chamados de correlograma, em que são utilizadas funções de autocovariância e autocorrelação. Seus valores podem variar de -1 a 1 e, quanto mais próximo do valor unitário, maior a significância do valor presente em relação ao valor defasado em k lags. Isso possibilita a identificação de padrões de sazonalidade e estacionariedade de uma série temporal.

A autocovariância é a covariância da série com ela mesma, contudo em um intervalo de tempo defasado em k , podendo ser escrita como a covariância entre Z_t e Z_{t+k} . A covariância é representada conforme equação (2.1):

$$\gamma_k = Cov[Z_t, Z_{t+k}] = E\{[Z_t - \mu][Z_{t+k} - \mu]\} \quad (2.1)$$

Onde:

μ é a média do processo;

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

Dada uma série temporal Z_1, Z_2, \dots, Z_N , estima-se a autocovariância pela equação (2.2):

$$\hat{\gamma}_k = \frac{1}{N} \sum_{t=1}^{N-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z}) \quad (2.2)$$

Onde:

$k = 0, 1, \dots, j$, pois $\gamma_k = \gamma_{-k}$;

\bar{Z} é a média de Z_t dada por:

$$\bar{Z} = \frac{1}{N} \sum_{t=1}^N Z_t \quad (2.3)$$

A autocorrelação mede o com a quantidade de defasagens ($t - k$) que depende do valor tomado em t . A autocovariância padronizada, como é definida a autocorrelação, é descrita pela equação ((2.4):

$$\rho_k = \frac{\hat{\gamma}_k}{\gamma_0} = \frac{Cov[Z_t, Z_{t+k}]}{\sqrt{Var(Z_t)Var(Z_{t+k})}} \quad (2.4)$$

Onde:

$\gamma_0 = Var(Z_t) = Var(Z_{t+k})$, a variância do processo;

$\rho_0 = 1$ e $\rho_k = \rho_{-k}$ (a função de autocorrelação é simétrica em relação à origem).

Dada uma série temporal Z_1, Z_2, \dots, Z_N , estima-se a autocovariância pela equação ((2.5):

$$\rho_k = \frac{\hat{\gamma}_k}{\gamma_0} = \frac{\sum_{t=1}^{N-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^N (Z_t - \bar{Z})^2} \quad (2.5)$$

Onde:

$k = 0, 1, \dots, j$ pois $\rho_k = \rho_{-k}$.

A reunião dos valores de ρ_k para $k = 0, 1, 2, \dots, K$ é chamada de função de autocorrelação (ACF). O diagrama referente aos valores de autocorrelação é chamado de autocorrelograma.

A autocorrelação parcial é entendida como a medida da correlação entre duas observações seriais Z_t e Z_{t+k} , desconsiderando o efeito das observações intermediárias ($Z_{t+1}, Z_{t+2}, \dots, Z_{t+k-1}$). Ela pode, então, ser representada pela equação (2.6):

$$\rho_k = \text{Cor}((Z_t, Z_{t+k} | Z_{t+1}, \dots, Z_{t+k-1})) \quad (2.6)$$

2.3

Processo Estocástico

Um processo estocástico é definido como um fenômeno do campo estatístico que evolui no tempo de acordo com uma determinada lei probabilística. Os processos estocásticos são uma estrutura matemática que explica o comportamento probabilístico de um conjunto de observações no tempo. Dessa forma, uma série temporal Z_t pode ser definida como uma função Z da variável independente t , gerada por um processo estocástico desconhecido [22].

Matematicamente, um processo estocástico é uma família $Z = Z(t), t \in T$ tal que, para cada $t \in T$, $Z(t)$ é uma variável aleatória [23]. Se $-\infty < t < +\infty$ o processo é contínuo e denota-se como a variável aleatória como $Z(t)$, mas se $t = 0, \pm 1, \pm 2, \dots, T$, o processo é discreto e denota-se a variável aleatória como Z_t .

Assim, tendo um processo estocástico, retira-se uma amostra finita de observações no tempo e, através da correta análise dessa amostra, é possível identificar um modelo apropriado que explique o comportamento da realidade [22].

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

A estacionariedade indica que as leis de probabilidade que atuam no processo estocástico não se modificam com o tempo, mantendo assim um equilíbrio estatístico. Há duas formas de estacionariedade, podendo ser estrita ou fraca.

Em um processo dito estritamente estacionário, suas propriedades não são afetadas por uma mudança na origem do tempo, isto é, a função de densidade deve ser tal que permaneça idêntica quando se varia a origem temporal.

Já em um processo fracamente estacionário (ou estacionário de segunda ordem), a média e a variância do processo são constantes ao longo do tempo e sua estrutura de dependência linear está sujeita somente a distância entre os períodos de tempo (da defasagem). Esse processo, portanto, deve satisfazer as seguintes condições das equações (2.7) a (2.9(2.9):

$$E[Z_t] = \mu \quad \forall t \quad (2.7)$$

$$Var[Z_t] = \sigma^2 \quad \forall t \quad (2.8)$$

$$E\{[Z_t - \mu][Z_{t+k} - \mu]\} = \gamma_k \quad \forall t \quad (2.9)$$

A ergodicidade ocorre quando uma única realização de um processo estocástico é suficiente para obter todas as suas estatísticas. Dessa forma, todo processo ergótico é também estacionário, com média e variância constantes, além das funções de autocovariância e autocorrelação independentes da origem temporal.

Um processo estocástico também pode ser classificado como ruído branco se, além de estacionário de segunda ordem, não apresenta nenhuma dependência serial, ou seja:

$$\rho_k = \begin{cases} 1, & \text{para } k = 0 \\ 0, & \text{para } k > 0 \end{cases} \quad (2.10)$$

2.4 Previsão de Séries Temporais

Um dos objetivos principais no campo de estudo das séries temporais é a previsão, sendo essa determinada em função do horizonte de previsão em questão. Em termos gerais, a previsão de uma série temporal é o estabelecimento dos valores futuros da série [23].

Nesse contexto, denomina-se horizonte de previsão o comprimento de tempo à frente, a partir da última observação, para o qual os valores são estimados [24]. Portanto, dado um conjunto de observações passadas de uma série histórica $Z_t = (Z_1, Z_2, \dots, Z_T)$ e com base nas suas propriedades estatísticas, determina-se quais são os valores prováveis $Z_{t+1}, Z_{t+2}, \dots, Z_{t+k}$, sendo k o horizonte de previsão.

Dentro do objetivo de previsão de uma série temporal, os tipos de modelos de previsão classificam-se em [22]:

- **Univariados:** modelos em que são utilizados apenas os valores passados da própria série para estimar os valores futuros. Dentre os modelos tradicionais na literatura podem-se citar os modelos de Amortecimento [22] e os modelos de Box & Jenkins [25], utilizados neste trabalho;
- **Multivariados:** modelos em que são realizadas as previsões de duas ou mais séries temporais simultaneamente;
- **Causais:** modelos em que são utilizados tanto os valores observados da série que se deseja prever como os valores atuais e observados de outras séries que mantêm uma relação explicativa com a série principal através de funções de transferência;
- **Modelos de Inteligência Computacional:** modelos de previsão criados através da adaptação de ferramentas de inteligência computacional para o campo das séries temporais. O objetivo desses modelos é desenvolver algoritmos que sejam capazes de reproduzir tarefas com forte inspiração nas ciências naturais e biológicas. Dentre os modelos tradicionais na literatura podem-se citar os modelos de Redes Neurais, Lógica Fuzzy, e Algoritmos Genéticos.

2.5 Modelos Box & Jenkins

Os modelos de Box & Jenkins (B&J) surgiram na década de 70 [25], sendo baseado na Teoria Geral dos Sistemas Lineares, na qual um ruído branco, ao passar por um filtro linear de memória infinita, gera um processo estacionário de segunda ordem [26], conforme a Figura 2.1.



Figura 2.1 – Geração de uma série temporal

O objetivo do modelo Box & Jenkins é realizar o caminho inverso, encontrando o sistema capaz de gerar um ruído branco a partir de uma série temporal. Quando isso é alcançado, toda a estrutura de dependência serial é capturada.




Figura 2.2 – Processo de previsão proposto nos modelos Box & Jenkins

A filosofia do modelo segue o princípio da parcimônia (representando o modelo com o menor número de parâmetros possível) e a construção de modelos através de um ciclo iterativo até obter um modelo satisfatório.

A metodologia proposta por Box & Jenkins está fundamentada em quatro passos [23]:

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

2.5.1

Modelo Auto-Regressivo (AR)

Os modelos auto-regressivos foram criados com a ideia de que a observação atual da série Z_t pode ser explicada em função de observações passadas. A estrutura matemática do modelo AR é expressa pela equação (2.11)

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t \quad (2.11)$$

Sendo:

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

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 observação seguinte.

Utilizando o operador de defasagem B , pode-se realizar a seguinte simplificação da equação (2.11).

Considerando $BZ_t = Z_{t-1}$, $B^2 Z_t = Z_{t-2}$, $B^p Z_t = Z_{t-p}$, então:

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) Z_t = a_t \quad (2.12)$$

Por fim, a equação (2.12) pode ser simplificada para:

$$\Phi(B)Z_t = a_t \quad (2.13)$$

2.5.2 Modelo Médias Móveis (MA)

Os modelos de médias móveis são formados pela combinação linear do ruído branco a_t , ocorridos do período atual e nos períodos passados. A estrutura desse modelo pode ser representada pela equação (2.14).

$$Z_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \phi_q a_{t-q} \quad (2.14)$$

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 , pode-se realizar uma simplificação da equação (2.14).

Considerando $B a_t = a_{t-1}$, $B^2 a_t = a_{t-2}$, $B^q a_t = a_{t-q}$

$$Z_t = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) a_t \quad (2.15)$$

2.5.3 Modelo Auto-Regressivo Integrado de Médias Móveis (ARIMA)

O modelo *ARIMA* (p, d, q) é adequado para a previsão de séries temporais que são formadas por um processo estocástico de segunda ordem. Na prática, nem sempre isto ocorre. Portanto, a série original será diferenciada a fim de torná-la estacionária. Dessa forma, a formulação B&J faz uso dos operadores diferença (∇) além do já citado operador de defasagem B . O número necessário de diferenciações para transformar a série é denominado ordem de integração. A estrutura geral do modelo está expressa na equação.

$$\phi(B)\nabla^d Z_t = \theta(B)a_t \quad (2.16)$$

Sendo:

$\nabla^d = (1 - B)^d$ e representa o operador diferença.

d o número de diferenciações.

2.6

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

O modelo $SARIMA(p, d, q) \times (P, D, Q)_S$ adiciona uma correlação serial dentro e entre os períodos sazonais. É devido a isso que este modelo é aplicado na maioria das séries temporais reais.

Neste caso, o modelo pode ser expresso pela equação (2.17):

$$\phi(B)\Phi(B^S)\nabla^d\nabla_S^D Z_t = \theta(B)\Theta(B^S)a_t \quad (2.17)$$

Sendo:

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

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

$\Phi(B^S)$ o componente sazonal auto-regressivo (AR) de ordem P .

$\Theta(B^S)$ 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.

Este modelo segue os mesmos passos da modelagem $ARIMA(p,d,q)$, utilizado em séries não-sazonais. Ou seja, analisa-se as características do ACF e PACF da série da mesma forma que o modelo não-sazonal, porém observando o comportamento nos intervalos sazonais, como 12, 24, 36, etc.

2.6.1

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

O modelo $SARIMA(p, d, q) \times (P, D, Q)$ pode ser estendido adicionando-se uma ou mais variáveis explicativas. Este modelo assume que a variável explicativa tem relação com a variável independente de forma que ocorra no tempo atual, não considerando as relações que acontecem em diferentes intervalos de tempo. O modelo é representado pela expressão a seguir:

$$\phi(B)\Phi(B^S)\nabla^d\nabla_S^D Z_t = \gamma X_t + \theta(B)\Theta(B^S)a_t \quad (2.18)$$

Sendo:

X_t a variável explicativa.

γ o parâmetro associado a variável explicativa.

2.7

Critérios de Avaliação dos Modelos

Nesta seção serão apresentados alguns critérios de avaliação dos modelos de séries temporais. De maneira geral, esses critérios são dados em função dos erros calculados para k passos à frente, onde k é denominado horizonte de previsão.

2.7.1

Critério de Informação de Akaike (AIC)

Proposto por Akaike [27] em 1969, e se baseia na distância de Kullback-Leibler (K-L), a qual é uma distância entre o modelo “verdadeiro” – geralmente utópico – e o modelo candidato. O critério pode ser expresso pela equação (2.19).

$$AIC = -2 \ln(L) + 2k \quad (2.19)$$

Sendo:

L o valor obtido para a máxima verossimilhança do modelo.

k o número de parâmetros do modelo.

2.7.2

Critério de Informação Bayesiano (BIC)

Proposto por Schwarz [28] em 1978, o critério é bastante similar ao AIC. Nesse caso, define-se como a estatística que maximiza a probabilidade de se identificar o modelo dentre os avaliados, de modo a considerar a existência de um modelo verdadeiro que descreve a relação entre a variável dependente e as variáveis explanatórias. O critério é descrito através da equação (2.20).

$$BIC = -2 \ln(L) + k \ln(n) \quad (2.20)$$

Sendo:

n o número de observações da série

2.7.3

Erro Médio Absoluto Percentual (MAPE)

O MAPE é calculado a partir da diferença entre os valores estimados e os valores reais, podendo ser utilizado tanto na análise *in-sample* quanto *out-of-sample*. É uma das métricas mais utilizadas na literatura, pois fornece um resultado percentual de fácil interpretação [25]. O MAPE é expresso pela seguinte equação:

$$MAPE = \frac{\sum_{i=1}^N \frac{|Y(t) - \hat{Y}(t)|}{Y(t)}}{N} \times 100 \quad (2.21)$$

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.

2.7.4 Coeficiente de Determinação (R^2)

O coeficiente de determinação R^2 indica a quantidade de variabilidade nos dados que é explicada no modelo ajustado. Entretanto, o valor do coeficiente de determinação depende do número de observações, tendendo a crescer quando o número de observações diminui.

Esse coeficiente é calculado através da comparação do erro do modelo e da variação dos dados da série (a ser prevista) em torno de sua média [22]. O coeficiente é calculado de acordo com a equação (2.22).

$$R^2 = \left(1 - \frac{\sum_{i=1}^N (Y(t) - \hat{Y}(t))^2}{\sum_{i=1}^N (Y(t) - \bar{Y})^2} \right) \times 100 \quad (2.22)$$

Sendo:

\bar{Y} a média de Y .

2.7.5 Teste de Sobrefixação

O teste consiste na estimação de um modelo com número de parâmetros superior ao modelo fixado. Dessa forma, examina-se se os parâmetros são significativos a ponto de necessitar ou não parâmetros adicionais. Esse teste varia em função do caso de estudo, devendo-se conhecer, a priori, em qual direção incrementar o número de parâmetros.

2.7.6 Análise dos Resíduos

Para dar continuidade na avaliação do modelo mais apropriado para uma série temporal, deve-se também analisar os resíduos desta série. Os resíduos são a diferença entre os dados ajustados pelo modelo e os dados observados.

2.7.6.1 Teste Ljung-Box

O teste foi proposto por Ljung & Box [29] como forma de modificação do teste de Portmanteau abordado por Box & Jenkins [25]. O teste se baseia na verificação residual para determinar se estes resíduos são ruído branco ou não. O teste de hipótese formulado por Ljung & Box é o seguinte:

- H_0 : os resíduos são ruído branco;
- H_1 : os resíduos não são ruído branco;

Se o modelo for adequado, os resíduos deverão ser não-correlacionados, confirmando a hipótese nula H_0 .

A autocorrelação estimada e a formulação do teste de Ljung-Box são dadas respectivamente pelas equações (2.23) e (2.24):

$$\hat{r}_k = \frac{\sum_{t=k+1}^n \hat{\varepsilon}_t \hat{\varepsilon}_{t-k}}{\sum_{t=1}^n \hat{\varepsilon}_t^2} \quad (2.23)$$

$$Q(k) = n(n+2) \sum_{j=1}^k \frac{\hat{r}_j^2}{(n-j)} \quad (2.24)$$

Sendo:

\hat{r}_k e \hat{r}_j as autocorrelações calculadas e a j -ésima autocorrelação estimada.

$\hat{\varepsilon}_t$ os resíduos estimados.

n é o número de observações.

k o número de *lags*.

A estatística terá distribuição Qui-quadrado com $K - p - q$ graus de liberdade. Rejeita-se a hipótese nula se $Q(\text{calculado}) > \chi_k^2(\text{tabelado})$, dado um certo nível de significância ao teste.

2.7.6.2 Teste Jarque-Bera

Teste proposto por Bera & Jarque, baseado na diferença entre os coeficientes de *skewness* e *curtosis* de um determinado conjunto de dados. A hipótese nula e alternativa do teste são:

- H_0 os resíduos possuem distribuição normal;
- H_1 os resíduos possuem distribuição não-normal.

O teste é realizado através do cálculo da expressão (2.25):

$$JB = T \left(\frac{b_1^2}{6} + \frac{(b_2 - 3)^2}{24} \right) \quad (2.25)$$

Sendo:

b_1 os coeficientes amostrais de assimetria.

b_2 os coeficientes amostrais de curtose.

T o tamanho da amostra.

Onde:

$$b_1 = \frac{\sum_{i=1}^n (y_i - \bar{y})^3}{n s^3} \quad (2.26)$$

$$b_2 = \frac{\sum_{i=1}^n (y_i - \bar{y})^4}{n s^4} \quad (2.27)$$

$$s^2 = \frac{\sum_{i=1}^n (y_i - \bar{y})^2}{n} \quad (2.28)$$

2.7.6.3 Gráfico Quantil-Quantil (Q-Q)

Por ser um método gráfico, é um dos mais utilizados na verificação da normalidade residual. Este método compara duas distribuições de probabilidade, traçando seus quantis em um mesmo espaço gráfico [30]. Aplicado neste caso, os quantis teóricos da distribuição normal são comparados com os quantis dos resíduos em questão. Sua interpretação é feita de forma visual pois, se os resíduos possuírem distribuição normal, todos os pontos do gráfico devem estar posicionados formando uma reta.

3 Ambientes de Contratação

Neste capítulo são apresentados os modelos de contratação associáveis a grandes consumidores.

Para este trabalho, são consideradas a modalidade verde para o ACR e contratos com flexibilidade no ACL.

3.1 Ambiente de Contratação Regulado

Também conhecido como Ambiente Cativo, a energia elétrica é adquirida por parte das distribuidoras nos leilões de energia e é repassada aos seus consumidores cativos sob uma tarifa de energia elétrica. O custo referente a demanda é repassado aos consumidores sob uma tarifa de demanda. Na prática, o funcionamento do mercado regulado pode ser enxergado como uma distribuidora, que agrega as demandas de diversos clientes, e que mantém o fornecimento de energia através de contratos firmados com um conjunto de agentes geradores.

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) [7]. Além disso, como já foi descrito no Capítulo 1, as tarifas do Grupo A contemplam três modalidades de fornecimento (Convencional, Horo-Sazonal Azul e Horo-Sazonal Verde) que definem o tipo de contratação do consumidor. Neste trabalho, foi estudado um consumidor enquadrado na modalidade Verde A4.

A modalidade verde, como descrita no Capítulo 1, estabelece tarifas diferenciadas de consumo de energia para os grupos de horários chamados de ponta e fora da ponta e uma única tarifa de demanda de potência. O posto tarifário ponta corresponde ao período de maior consumo de energia elétrica, que costuma ocorrer entre 17 e 20 horas dos dias úteis no Brasil. O posto tarifário fora da ponta

compreende as demais horas dos dias úteis e as 24 horas dos sábados, domingos e feriados. Assim, o custo associado ao consumidor cativo nesta modalidade, para um mês qualquer é obtido conforme equação (3.1).

$$C_t^{verde} = E_t^p T_E^p + E_t^{fp} T_E^{fp} + TUSD_E^{fp} E_t^p + TUSD_E^{fp} E_t^{fp} + C_t^D \quad (3.1)$$

Onde:

C_t^{verde} é o custo no mês t (R\$);

E_t^p é a energia consumida na ponta no mês t (MWh);

T_E^p é a tarifa de consumo na ponta por resolução da ANEEL (R\$/MWh);

E_t^{fp} é a energia consumida fora ponta no mês t (MWh);

T_E^{fp} é a tarifa de consumo fora ponta por resolução da ANEEL (R\$/MWh);

$TUSD_E^p$ é a tarifa do uso do sistema de distribuição para a energia de ponta (R\$/MWh);

$TUSD_E^{fp}$ é a tarifa do uso do sistema de distribuição para a energia fora ponta (R\$/MWh);

C_t^D é o custo referente à demanda (em R\$/kW).

O custo referente à demanda é calculado de formas diferentes em função da demanda máxima no mês t . Se $0 < D_t^{max} \leq 1,05D_t^c$, então:

$$C_t^D = \max(D_t^c, D_t^{max}) T_D \quad (3.2)$$

Se $D_t^{max} \geq 1,05D_t^c$, então:

$$C_t^D = D_t^{max} T_D + (D_t^{max} - D_t^c) T_D^{ult} \quad (3.3)$$

A Figura 3.1 a seguir, elaborada em [14, 33], ilustra o comportamento da função de custos referentes à demanda.




Figura 3.1 – Curva de custos referente à demanda máxima [14, 33]

Nota-se que o custo é uma função definida por partes. Na primeira parte, partindo de zero até D_t^c , o custo é constante independentemente do valor da

demanda D_t^{max} . Para valores de demanda compreendidos entre D_t^c e $1,05D_t^c$, o excesso de demanda acima de D_t^c será faturado pela tarifa de demanda padrão, sem aplicação de penalidade, e acrescido ao custo referente a D_t^c . Finalmente, quando a demanda excede o valor de $1,05D_t^c$, o excesso é penalizado, sendo faturado pela tarifa de ultrapassagem.

3.2 Ambiente de Contratação Livre

No Ambiente de Contratação Livre, o consumidor conta com a possibilidade de negociação dos termos do contrato junto à comercializadora de energia. Contratos típicos envolvem uma definição do montante de energia a ser contratado e da flexibilidade, muitas vezes para evitar a exposição ao mercado de curto prazo, definido pelos preços de PLD.

De maneira geral, os parâmetros básicos de contrato, e que podem ser negociados livremente, são [36]:

- Preços de energia;
- Prazo do contrato;
- Volume de energia;
- Sazonalidade;
- Flexibilidade;
- Modulação.

O preço de energia se refere ao preço pago pela energia fornecida em determinado tempo. O prazo do contrato se refere à duração do contrato entre o agente e fornecedor. Já o volume de energia se refere ao volume mensal que a unidade tende a consumir de acordo com seu histórico.

A sazonalidade permite que os valores contratados mensais sejam alterados, desde que não ultrapassem o limite da sazonalidade estipulado em contrato (geralmente o mercado trabalha com 10%) e o volume de energia contratado anual [36].

A flexibilidade é composta pelos limites mínimos e máximos que são aplicados montante contratado. Esses limites também são acordados em contrato, e dentro dessa faixa o fornecedor garante o volume e o preço de contrato, além da não exposição ao PLD.

A modulação, por fim, permite que os valores horários do contrato sejam registrados de acordo com a curva de consumo da unidade. Existem limites de máximo e mínimo que também são estipulados em contrato.

Nesse trabalho, será considerado um contrato com flexibilidade, de acordo com a expressão a seguir.

$$C_t^{livre} = C_t^E + C_t^D + TUSD_E^p E_t^p + TUSD_E^{fp} E_t^{fp} + TUSD_D D_t + (D_t^{max} - D_t^c) TUSD_D^{ult} \quad (3.4)$$

Onde:

C_t^E é o valor do custo da energia (R\$/MWh).

$TUSD_D$ é a tarifa do uso do sistema de distribuição pelo uso do fio (R\$/kW).

$TUSD_D^{ult}$ é a tarifa de ultrapassagem do uso do sistema de distribuição pelo uso do fio (R\$/kW).

O custo referente à energia é calculado de formas diferentes em função da posição do consumo no mês t em relação às flexibilidades do contrato. Ou seja, se E_t está dentro da flexibilidade contratada, o custo é calculado de uma forma. Se estiver acima da flexibilidade superior, é calculado de outra forma. Por fim, se estiver abaixo da flexibilidade inferior, é calculado de uma terceira forma.

Denominando Q_t^+ (MWh) e Q_t^- (MWh) como as flexibilidades superior e inferior de um determinado contrato, então as três possibilidades de valor para C_t^E são:

Se $Q_t^- < E_t < Q_t^+$:

$$C_t^E = E_t P_t \quad (3.5)$$

Se $E_t > Q_t^+$:

$$C_t^E = Q_t^+ P_t + (Q_t^+ - E_t) \pi_t \quad (3.6)$$

Se $E_t < Q_t^-$:

$$C_t^E = Q_t^- P_t + (E_t - Q_t^-) \pi_t \quad (3.7)$$

Onde:

E_t é a energia consumida no mês t (MWh).

P_t é o preço da energia contratada (R\$/MWh).

π_t é o valor do PLD para o mês t (R\$/MWh).

4 Métricas de Risco

A utilização de medidas de risco em problemas de contratação de energia e demanda está associada à incerteza inerente à variabilidade futura destes dados. A incerteza é caracterizada como em que não é possível determinar, de forma segura, o valor de uma ou mais grandezas futuras [37]. No âmbito desse trabalho, os preços de mercado de curto prazo são grandezas sujeitas a fatores de incerteza.

Por sua vez, o risco é o impacto da combinação de incertezas em uma variável de interesse, como, por exemplo, no custo em um problema de contratação. Este impacto pode levar a resultados com perdas significativas, no qual o tratamento destas informações considerando as estimativas dos riscos associados pode indicar uma postura mais ou menos conservadora. Desta forma, mapear o risco e mensurá-lo é altamente desejável nos problemas que envolvem uma alta variabilidade de custo. Como usualmente os agentes têm aversão ao risco, é necessário mapeá-lo e mensurá-lo através de algum instrumento que permita obter o nível de exposição ao qual esses agentes estão sujeitos a cenários pessimistas [37]. Assim, o VaR e o CVaR são medidas que buscam atingir esse objetivo.

Portanto, neste capítulo são apresentados os conceitos de *Value-at-Risk* (VaR) e de *Conditional Value-at-Risk* (CVaR) como medidas de risco, tendo sido adotado o CVaR no processo de otimização no capítulo posterior.

4.1 **Value at Risk (VaR)**

De acordo com [38], o VaR é um método de medida de risco que utiliza técnicas estatísticas para tal. O VaR mede a pior perda esperado ao longo de determinado intervalo de tempo, sob determinado nível de confiança ($\alpha\%$). Em uma distribuição de probabilidades, o VaR corresponderá ao quantil $(100 - \alpha\%)$ dessa distribuição.

Matematicamente, o VaR pode ser definido pela expressão (4.1), onde, para uma distribuição de probabilidade de uma variável aleatória R e dado um nível de confiança α entre 0% e 100%, o VaR será o menor valor r tal qual a probabilidade de ocorrência de um cenário R de valor inferior seja, no máximo, de $(100 - \alpha)\%$ [37].

$$VaR(R) = \inf \{r \in \mathbb{R} | P(R < r) \leq (1 - \alpha)\} \quad (4.1)$$

A figura a seguir apresenta, de forma gráfica, o conceito por trás do VaR dada uma distribuição de probabilidades qualquer.




Figura 4.1 – VaR de uma dada distribuição de probabilidades [37]

Essa métrica de risco deve ser vista como um procedimento necessário, mas não suficiente para o controle do risco. Mesmo tendo a vantagem de resumir, através de um número apenas, a exposição aos riscos e aplicável a qualquer tipo de ativo, o VaR não quantifica a magnitude dos resultados gerados no caso da ocorrência de um cenário muito ruim, além de não possuir propriedades desejáveis em algoritmos de otimização, como convexidade e diferenciabilidade.

4.2

Conditional Value at Risk (CVaR)

O *Conditional Value-at-Risk* (ou Valor de Risco Condicional) é uma métrica derivada do VaR e tem sido bastante utilizada em função da capacidade de capturar a presença e a magnitude de cenários mais adversos, além de apresentar convexidade, possibilitando uma implementação relativamente fácil em algoritmos

de otimização. O CVaR consegue definir a média das piores perdas esperadas ao longo de um intervalo de tempo, sob condições normais de mercado, e dentro de um determinado nível de confiança [38]. Na prática, o CVaR é considerado uma métrica mais pessimista que o VaR.

Em termos matemáticos, para um determinado nível de confiança $\alpha \in (0,1)$, o CVaR da distribuição de probabilidade da variável aleatória R é dado pela média dos valores menores que o VaR da distribuição em questão, conforme a equação (4.2). Em termos simples, CVaR é a média dos $(100 - \alpha)\%$ piores cenários da distribuição de probabilidade de uma variável aleatória.

$$CVaR_{\alpha}(R) = E(R|R \leq VaR_{\alpha}(R)) \quad (4.2)$$

A figura a seguir apresenta, de maneira gráfica, a relação dos conceitos de VaR e CVaR em função de um dado nível de confiança α .




Figura 4.2 – VaR e CVaR de uma dada distribuição de probabilidades [37]

Se forem considerados dois investimentos A e B, com duas distribuições de probabilidade genéricas geradas, conforme a Figura 4.3, observa-se que o VaR leva o agente a uma conclusão equivocada, como se investimentos de mesmo VaR tivessem exposição igual. Contudo, comparando os valores de $CVaR_{\alpha}(A)$ e $CVaR_{\alpha}(B)$, fica evidente que a distribuição de probabilidade de B possui eventos mais extremos que a de A, ainda que em menor probabilidade.

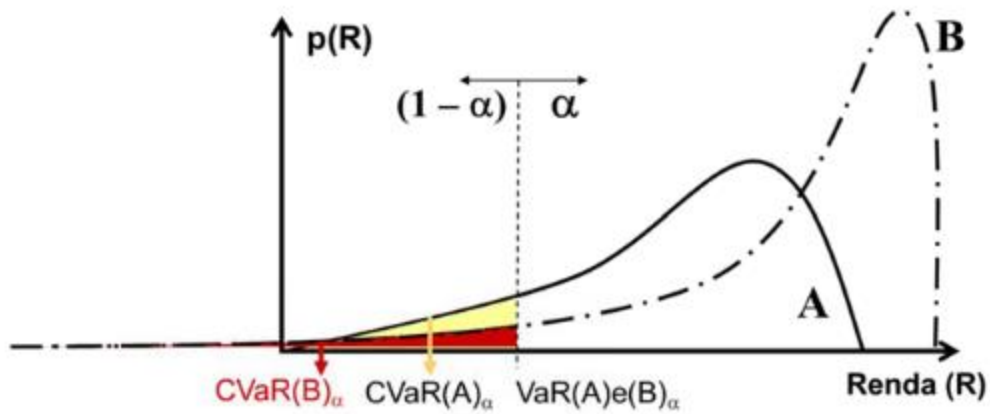


Figura 4.3 – Comparação entre o CVaR de duas distribuições de probabilidade [37]

Para modelo de otimização proposto nessa dissertação, a questão das incertezas inerentes aos cenários correlacionados de energia e demanda será tratada pelo CVaR em função das vantagens apresentadas até aqui e, em especial, por se tratar de uma medida de risco aderente aos conceitos de otimização contratual por parte do consumidor.

5 Tratamento das Séries Temporais

Neste capítulo, será apresentado todo o processo de modelagem estatística das séries temporais presentes na dissertação, bem como a metodologia utilizada a escolha dos melhores modelos de cada série. Por fim, será apresentado o processo de geração dos cenários futuros, que são necessários para o modelo de otimização.

O modelo Box & Jenkins com variáveis explicativas foi aplicado neste capítulo devido característica sazonal nas séries, além de permitir a modelagem de uma série temporal como variável explicativa para outra série.

Finalmente, as simulações foram realizadas no software Rstudio [31].

5.1 Séries de Energia e Demanda Mensais

Ambas as séries foram retiradas dos dados medição de consumo e demanda de um grande consumidor localizado no município do estado do Rio de Janeiro, partindo do ano de 2002 até dezembro de 2017. Esses dados são apresentados de forma mensal, agregando 12 observações por ano e 192 observações no total. O maior valor de consumo no mês t será a demanda máxima mensal para esse mês, e a soma do consumo de todos os intervalos de tempo no mês t será a energia mensal para esse mês.

As figuras a seguir apresentam as séries de energia, demanda máxima e PLD, respectivamente. Cada uma das séries se inicia em janeiro de 2002 e vão até dezembro de 2017, conforme explicado anteriormente. Os dados de PLD mensal podem ser encontrados em [9].




Figura 5.1 – Série de energia (em MWh) de 2002 até 2017

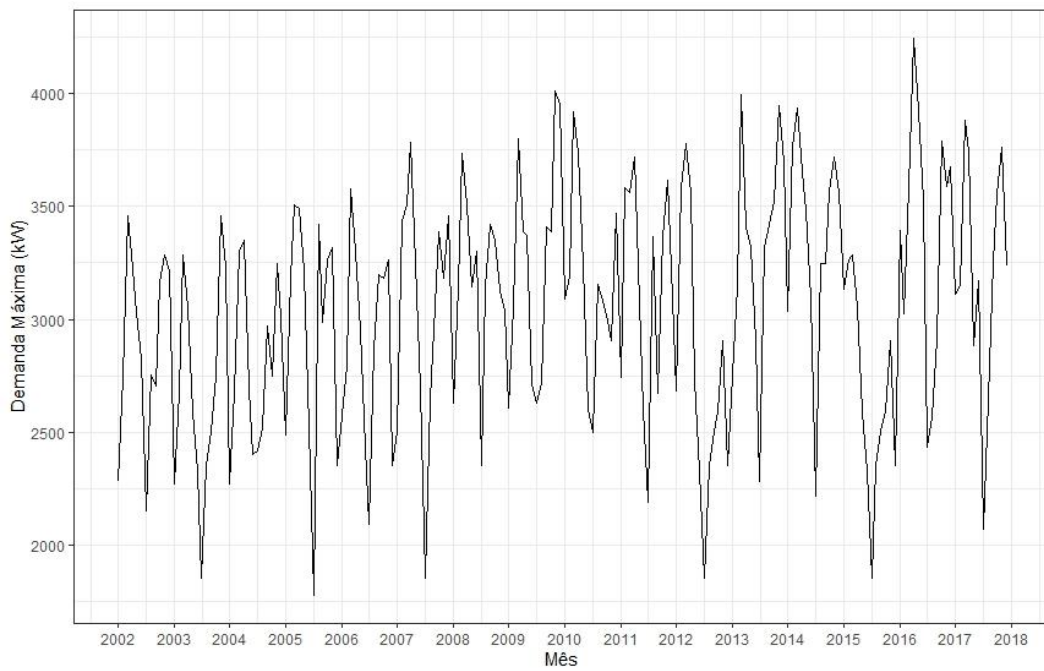


Figura 5.2 – Série de demanda máxima (em kW) de 2002 até 2017




Figura 5.3 – Série de PLD (em R\$/MWh) de 2002 até 2017.

As séries podem ser decompostas em suas componentes estocásticas, de tendência e de sazonalidade. Essa decomposição ajuda a entender o comportamento das séries ao longo do tempo.

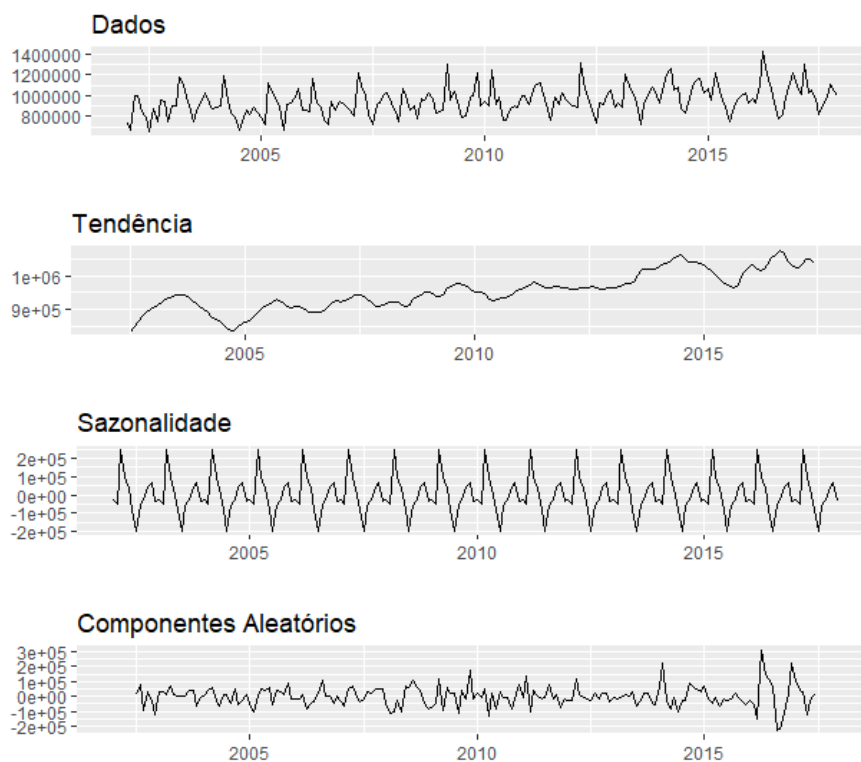


Figura 5.4 – Série decomposta da Energia

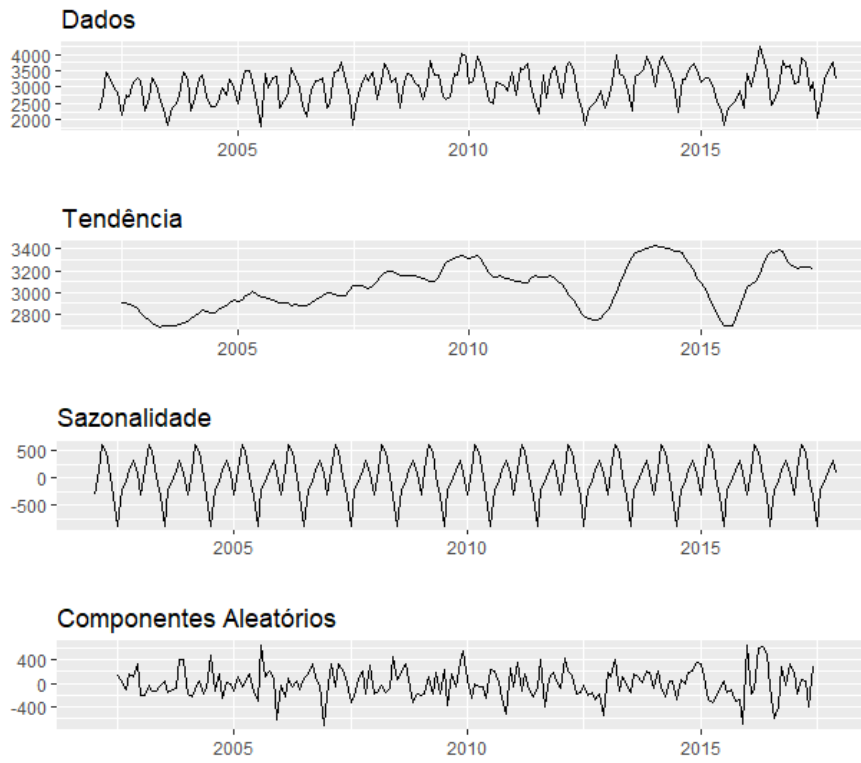


Figura 5.5 – Série decomposta da Demanda Máxima

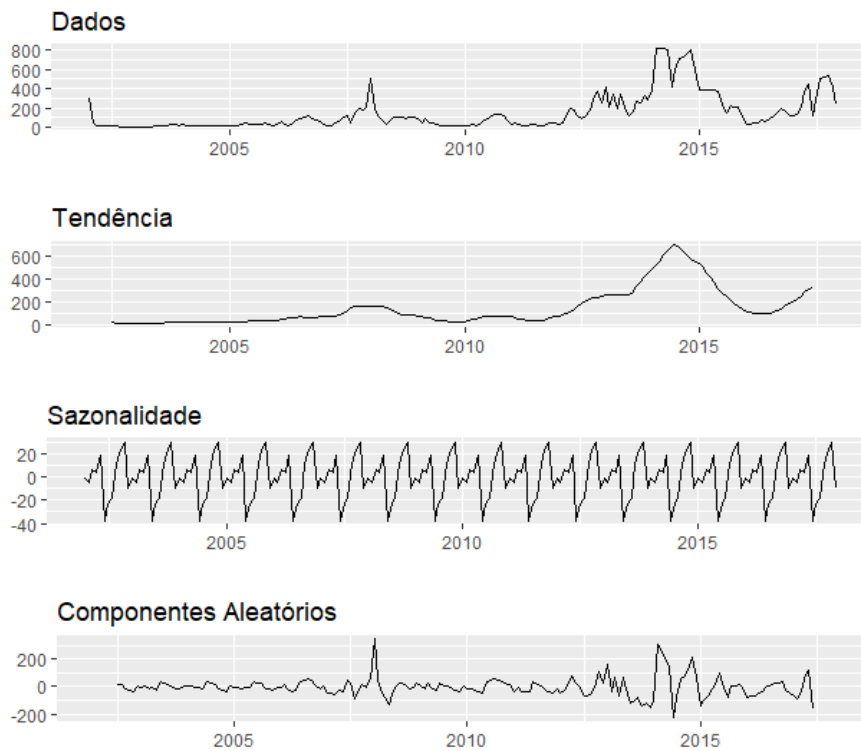


Figura 5.6 – Série decomposta de PLD

5.2 Análise de Correlação

Para analisar a correlação entre as séries em questão, utiliza-se o Teste de Correlação de Pearson [32]. Esse teste consiste em medir o grau de correlação (e o sinal dessa correlação, podendo ser positiva, negativa ou neutra) entre dois conjuntos de dados.

Este coeficiente, normalmente representado por ρ , assume valores entre -1 e 1. A interpretação deste coeficiente é a seguinte:

- $\rho = 1$ Significa uma correlação perfeita positiva entre as duas variáveis.
- $\rho = -1$ Significa uma correlação negativa perfeita entre as duas variáveis. Ou seja, se uma aumenta, a outra sempre diminui.
- $\rho = 0$ Significa que as duas variáveis não dependem linearmente uma da outra. No entanto, pode existir uma dependência não linear. Assim, o resultado $\rho = 0$ deve ser investigado por outros meios.

Além disso, pode-se classificar a intensidade de correlação como forte, moderada ou fraca, em função do módulo do valor de ρ .

Calcula-se o coeficiente de correlação de Pearson de acordo com a expressão (5.1):

$$\rho = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} = \frac{cov(X, Y)}{\sqrt{var(X) var(Y)}} \quad (5.1)$$

Além do valor do coeficiente, o resultado do teste deve possuir um nível de significância, que deve ser comparado com o intervalo de confiança admitido para o teste. Dessa forma, além do teste retornar o valor do coeficiente de Pearson, ele também retorna o seu p-valor. O p-valor é a probabilidade de se obter uma estatística de teste igual ou mais extrema que aquela observada em uma amostra, sob a hipótese nula. Se o p-valor for menor que o nível de significância de 0,05 considerado para o teste, descarta-se a hipótese nula e aceita-se a hipótese alternativa.

O uso do teste de correlação de Pearson nessa dissertação é importante para embasar o modelo estatístico proposto. Esse modelo propõe casar os dados de PLD, energia e demanda máxima, e essa proposta só tem sentido se houver correlação

entre esses dados. Portanto, os testes de correlação foram realizados entre os dados de PLD e Energia, e entre Energia e Demanda Máxima. Dessa forma, a série de PLD seria a variável explicativa do modelo estatístico para a série de Energia, e a série de Energia seria a variável explicativa do modelo estatístico para a série de Demanda Máxima.

Os valores para os testes de correlação, ao mesmo tempo dos seus respectivos p-valores, estão apresentados abaixo:

Tabela 5.1 – Resultados dos testes de correlação de Pearson

Séries testadas	Coefficiente de Pearson	p-valor
PLD e Energia	0,2871553	9,291e-05
Energia e Demanda Máxima	0,7258662	2,2e-16

A seguir estão apresentados os gráficos de correlação entre PLD e Energia e correlação entre Energia e Demanda Máxima.




Figura 5.7 – Gráfico de correlação entre Energia e PLD




Figura 5.8 – Gráfico de correlação entre Energia e Demanda Máxima

Como os p-valores são menores do que 0,05, rejeita-se a hipótese nula de que não há correlação entre os dados. Dessa forma, apesar de haver uma correlação fraca, as correlações entre as séries não serão ignoradas neste trabalho.

5.3 Modelagem das Séries

Conforme dito anteriormente, a modelagem Box & Jenkins permite o uso de variáveis explicativas, conceito esse que será usado para formar a correlação entre as séries de demanda e energia e PLD. As análises serão feitas em 2 subgrupos: treinamento e teste. O modelo apropriado será escolhido através do uso dos dados de treinamento, que posteriormente será avaliado, de acordo com as métricas de erro pertinentes, pelos dados de teste. Na prática, foi selecionado 70% dos dados para o grupo de treinamento, e 30% para o grupo de teste. Dessa forma, os dados de treinamento partem de janeiro de 2002 até dezembro de 2013 e os dados de teste acumulam entre janeiro de 2014 até dezembro de 2017. Os dados do ano de 2018 foram separados para a simulação dos cenários futuros.

Uma estratégia usualmente utilizada na construção do modelo Box & Jenkins é o uso de um método iterativo, onde diversos modelos são testados até que se obtenha um modelo satisfatório [26]. Porém, como há muitos critérios de avaliação de modelos que podem ser utilizados como base para escolher o melhor modelo, foi

sugerido em [14] e em [33] um coeficiente que possa levar em consideração vários critérios e atribuir um peso igual a cada um deles. Este coeficiente considera os critérios de informação AIC e BIC, além do coeficiente de determinação R^2 . Para esta dissertação, adiciona-se ao coeficiente o cálculo do *MAPE*. A expressão que calcula o coeficiente K é expressa na equação (5.2):

$$K = \frac{AIC_i}{\sum_i AIC_i} + \frac{BIC_i}{\sum_i BIC_i} + \frac{MAPE_i}{\sum_i MAPE_i} + \frac{(1 - R_i^2)}{\sum_i (1 - R_i^2)} \quad (5.2)$$

Cabe ressaltar que todos os modelos testados devem garantir a normalidade de seus resíduos, verificados através do teste Jarque-Bera. Se o p-valor desse teste for maior que o nível de significância de 0,05, aceita-se a hipótese nula de que há a normalidade dos resíduos. Se o resultado não for maior do que o nível de significância tratado, então o modelo é descartado e prossegue-se para a próxima iteração i . A Figura 5.9 apresenta um fluxograma que resume os passos realizados na escolha do modelo SARIMA adequado.

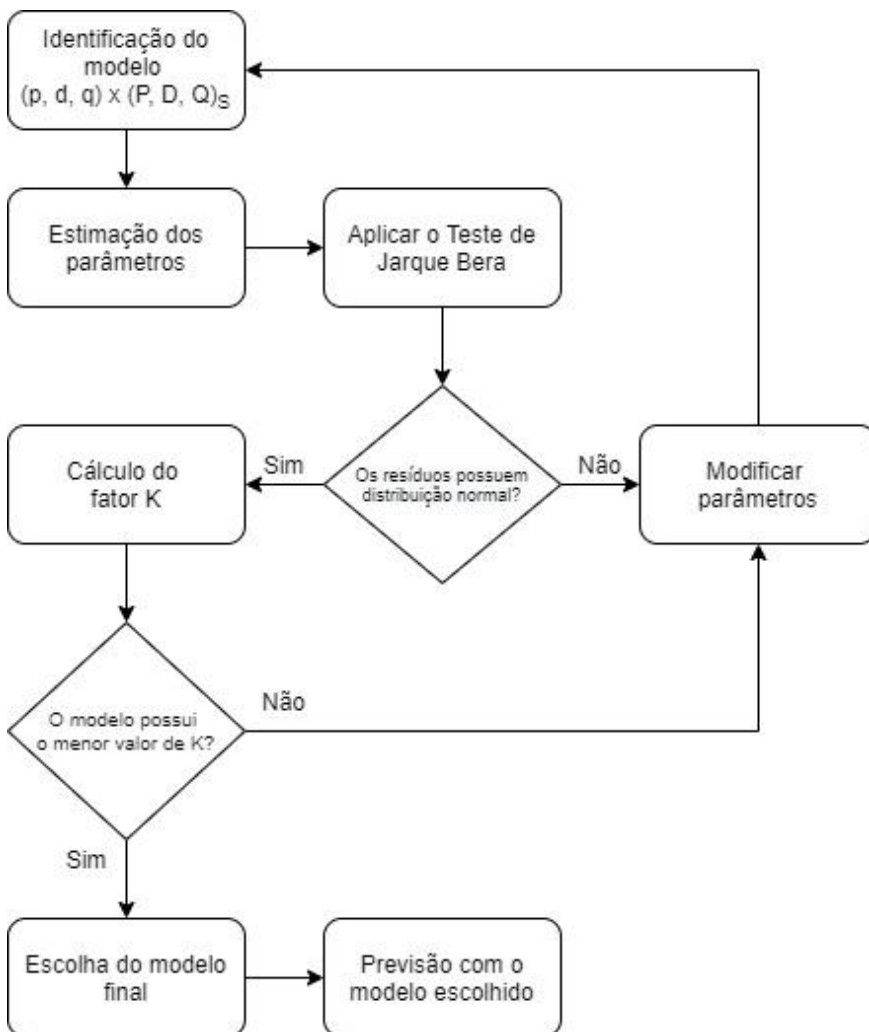


Figura 5.9 – Fluxograma da metodologia de escolha do melhor modelo SARIMA

5.3.1 Modelagem da Série de Energia

Para a série de energia, o modelo SARIMA possui como variável explicativa os dados de PLD de mesmo intervalo de tempo. Dessa forma, o modelo deverá possuir três componentes principais: componente autorregressivo (AR), componente de médias móveis (MA) e variável explicativa (PLD). A seleção dos modelos que obtiveram os menores valores de K estão apresentados na tabela a seguir.

Tabela 5.2 – Resultados dos melhores modelos de energia em função do coeficiente K.

Modelo	AIC	BIC	MAPE	R ²	(1-R ²)	K
$(4,1,3) \times (0,1,1)_{12}$	3310,561	3339,313	4,48	0,810	0,190	0,443513
$(4,1,4) \times (0,1,1)_{12}$	3310,174	3341,802	4,47	0,814	0,186	0,441002
$(5,1,3) \times (0,1,1)_{12}$	3312,605	3344,232	4,52	0,809	0,191	0,445318
$(4,1,3) \times (1,1,2)_{12}$	3312,725	3347,228	4,28	0,822	0,178	0,431901
$(4,1,3) \times (1,1,3)_{12}$	3309,557	3346,935	4,42	0,820	0,180	0,436414
$(4,1,3) \times (2,1,3)_{12}$	3310,506	3350,759	4,25	0,820	0,180	0,432368
$(4,1,4) \times (1,1,0)_{12}$	3345,529	3377,154	5,58	0,717	0,283	0,527408
$(4,1,4) \times (0,1,2)_{12}$	3309,600	3344,102	4,33	0,828	0,172	0,429428
$(5,1,4) \times (0,1,2)_{12}$	3299,326	3336,704	4,10	0,846	0,154	0,412647

O modelo SARIMA $(5,1,4) \times (0,1,2)_{12}$ foi escolhido, e pode ser representado em forma de equação pelos seus parâmetros e pela variável explicativa PLD.

$$\begin{aligned}
 E_t = & \gamma PLD + (1 - \phi_1)E_t - (\phi_1 - \phi_2)E_{t-2} - (\phi_2 - \phi_3)E_{t-3} \\
 & - (\phi_3 - \phi_4)E_{t-4} - (\phi_4 - \phi_5)E_{t-5} - \phi_5 E_{t-6} \\
 & + E_{t-12} - (1 + \phi_1)E_{t-13} - (\phi_2 - \phi_1)E_{t-14} \\
 & - (\phi_3 - \phi_2)E_{t-15} - (\phi_4 - \phi_3)E_{t-16} \\
 & - (\phi_5 - \phi_4)E_{t-17} + \phi_5 E_{t-18} + a_t - \theta_1 a_{t-1} \\
 & - \theta_2 a_{t-2} - \theta_2 a_{t-3} - \theta_3 a_{t-4} - \theta_1 a_{t-12} \\
 & + \theta_1 \theta_1 a_{t-13} + \theta_2 \theta_1 a_{t-14} + \theta_3 \theta_1 a_{t-15} \\
 & + \theta_4 \theta_1 a_{t-16} - \theta_2 a_{t-24} + \theta_1 \theta_2 a_{t-25} \\
 & + \theta_2 \theta_2 a_{t-26} + \theta_3 \theta_2 a_{t-27} + \theta_4 \theta_5 a_{t-28}
 \end{aligned} \tag{5.3}$$

Os valores dos parâmetros estimados para esse modelo estão apresentados na tabela a seguir.

Tabela 5.3 – Parâmetros estimados do modelo SARIMA $(5,1,4) \times (0,1,2)_{12}$

Coefficiente	Valor	Coefficiente	Valor
γ	-0,0571	θ_1	-0,7303
ϕ_1	-0,1591	θ_2	-0,5338
ϕ_2	-0,5116	θ_3	-0,7303
ϕ_3	0,9455	θ_4	0,9999

ϕ_4	-0,1875	θ_1	-1,2931
ϕ_5	-0,3584	θ_2	0,2931

Para garantir a validade do modelo selecionado, as funções de autocorrelação (ACF) e de autocorrelação parcial (PACF) foram analisadas. Para garantir a normalidade dos resíduos, foi utilizado o gráfico Quantil-Quantil e o gráfico de distribuição dos resíduos, conforme pode ser constatado nas figuras a seguir.





Figura 5.10 – ACF e PACF dos resíduos da Energia

QQ-Plot



Histograma dos Resíduos




Figura 5.11 – Avaliação da normalidade dos resíduos da série de Energia

Adicionado a isso, o teste de Ljung-Box retornou um p-valor de 0,701, confirmando a hipótese, com 95% de confiança, de que os resíduos podem ser tratados como ruído branco.

Através do modelo SARIMA escolhido, pode-se realizar uma análise *pseudo out-of-sample* comparando a performance do modelo com os dados de teste separados.




Figura 5.12 – Dados in sample e pseudo out-of-sample da série de Energia

5.3.2 Modelagem da Série de Demanda

Para o caso da demanda, a metodologia aplicada é a mesma, de forma que a variável explicativa utilizada seja a série de energia. Portanto, o modelo escolhido para a série de demanda é um $SARIMA(4,1,3) \times (1,1,1)_{12}$, e a tabela com as seleção dos modelos com menores valores de K está apresentada a seguir.

Tabela 5.4 – Resultados dos melhores modelos de energia em função do coeficiente K.

Modelo	AIC	BIC	MAPE	R ²	(1-R ²)	Fator K
$(4,1,3) \times (0,1,1)$	1878,104	1906,856	6,04	0,760	0,240	0,439002267
$(4,1,3) \times (1,1,1)$	1880,350	1912,978	6,04	0,766	0,234	0,436767392
$(4,1,3) \times (0,1,2)$	1879,133	1910,76	6,12	0,767	0,233	0,437641007
$(4,1,3) \times (1,1,2)$	1887,513	1922,016	6,19	0,749	0,251	0,448079513
$(4,1,3) \times (1,1,3)$	1885,626	1923,004	6,15	0,753	0,247	0,445536972
$(3,1,3) \times (0,1,1)$	1882,758	1908,635	6,20	0,751	0,249	0,446339231

(3,1,3) × (0,1,2)	1883,813	1912,565	6,21	0,750	0,251	0,447490113
(4,1,2) × (0,1,1)	1883,513	1909,39	6,38	0,749	0,251	0,450523815
(4,1,2) × (1,1,1)	1884,737	1913,489	6,33	0,752	0,248	0,448619689

O modelo SARIMA (4,1,3)x(1,1,1)₁₂ pode ser representado em forma de equação pelos seus parâmetros e pela variável explicativa Energia.

$$\begin{aligned}
 D_t = & \gamma E_t + (1 + \phi_1)D_{t-1} - (\phi_1 - \phi_2)D_{t-2} - (\phi_2 - \phi_3)D_{t-3} \\
 & - (\phi_3 - \phi_4)D_{t-4} - \phi_4 D_{t-5} + (1 + \Phi_1)D_{t-12} \\
 & - (\phi_1 + \phi_1 \Phi_1 + 1 + \Phi_1)D_{t-13} \\
 & - (\phi_2 + \phi_2 \Phi_1 - \phi_1 - \phi_1 \Phi_1)D_{t-14} \\
 & - (\phi_3 + \phi_3 \Phi_1 - \phi_2 - \phi_2 \Phi_1)D_{t-15} \\
 & - (\phi_4 + \phi_4 \Phi_1 - \phi_3 - \phi_3 \Phi_1)D_{t-16} \\
 & + (\phi_4 + \phi_4 \Phi_1)D_{t-17} - \Phi_1 D_{t-24} \\
 & + (\phi_1 \Phi_1 - \Phi_1)D_{t-25} - (\phi_1 \Phi_1 - \phi_2 \Phi_1)D_{t-26} \\
 & - (\phi_2 \Phi_1 - \phi_3 \Phi_1)D_{t-27} \\
 & - (\phi_3 \Phi_1 - \phi_4 \Phi_1)D_{t-28} + \phi_4 \Phi_1 D_{t-29} + a_t \\
 & - \theta_1 a_{t-1} - \theta_1 a_{t-2} - \theta_3 a_{t-3} - \Theta_1 a_{t-12} \\
 & + \theta_1 \Theta_1 a_{t-13} + \theta_2 \Theta_1 a_{t-14} + \theta_3 \Theta_1 a_{t-15}
 \end{aligned}
 \tag{5.4}$$

Os valores dos parâmetros estimados para esse modelo estão apresentados na tabela a seguir.

Tabela 5.5 – Parâmetros estimados do modelo SARIMA (4,1,3) × (1,1,1)₁₂

Coefficiente	Valor	Coefficiente	Valor
γ	1,2817	θ_1	-1,2569
ϕ_1	0,5712	θ_2	-1,2569
ϕ_2	-0,8146	θ_3	-1,0000
ϕ_3	0,3222	Φ_1	0,0638
ϕ_4	0,2272	Θ_1	-1,0000

Para garantir a validade do modelo selecionado, as funções de autocorrelação (ACF) e de autocorrelação parcial (PACF) foram analisadas. Para garantir a normalidade dos resíduos, foi utilizado o gráfico Quantil-Quantil e o gráfico de distribuição dos resíduos, conforme pode ser constatado na Figura 5.13 e na Figura 5.14.




Figura 5.13 – ACF e PACF dos resíduos da Demanda

PUC-Rio - Certificação Digital N° 1721484/CA

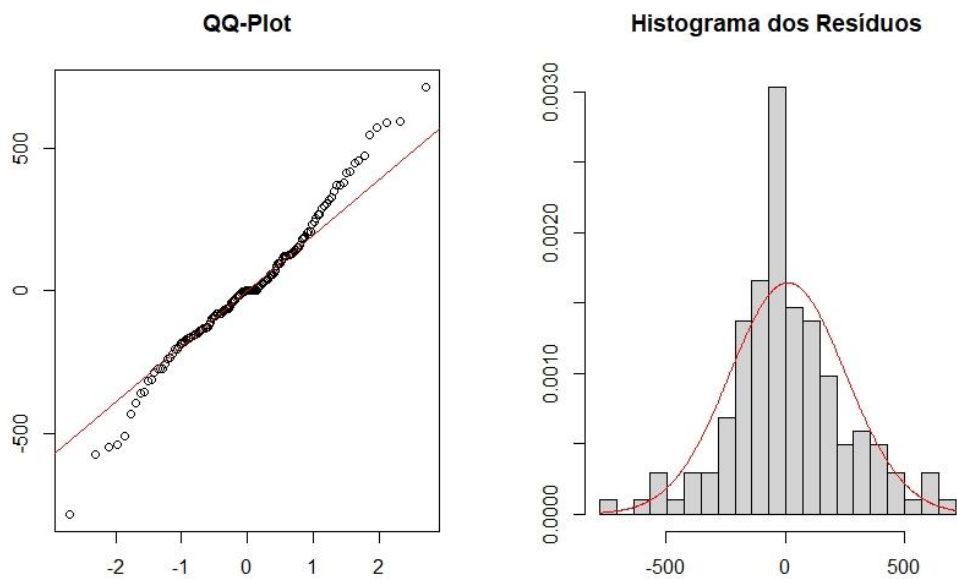


Figura 5.14 – Avaliação da normalidade dos resíduos da série de Demanda

O teste de Ljung-Box retornou um p-valor de 0,479, confirmando a hipótese, com 95% de confiança, de que os resíduos podem ser tratados como ruído branco.

Através do modelo SARIMA escolhido, pode-se realizar uma análise *pseudo out-of-sample* comparando a performance do modelo com os dados de teste separados.




Figura 5.15 – Dados in sample e pseudo out-of-sample da série de demanda.

5.4 Previsão das Séries Temporais

Após encontrar o melhor modelo para cada uma das séries, o próximo passo é realizar a previsão das mesmas para o ano de 2018. Dessa forma, os dados de demanda, energia e PLD serão utilizados para realizar as previsões em função dos modelos SARIMA obtidos anteriormente.

5.4.1 Previsão da Série de Energia

Com o uso do modelo encontrado na seção anterior, a previsão da série foi realizada para o ano de 2018. A Figura 5.16 apresenta a energia prevista para o ano em questão.




Figura 5.16 – Previsão da série de energia

A tabela a seguir mostra o erro percentual da previsão em relação aos dados reais de energia.

Tabela 5.6 – Comparação dos valores reais e previstos para o ano de 2018 para a série de energia

Mês	Valor real (MWh)	Valor previsto (MWh)	Erro percentual (%)
Janeiro	1008,57	1012,91	0,43
Fevereiro	845,21	996,54	17,90
Março	1250,79	1231,33	1,56
Abril	1114,52	1175,97	5,51
Mai	1048,00	1097,15	4,69
Junho	931,81	980,24	5,20
Julho	846,47	851,08	0,54
Agosto	863,92	962,05	11,36
Setembro	935,37	1011,76	8,17
Outubro	1068,46	1087,27	1,76
Novembro	1005,61	1119,29	11,30
Dezembro	1032,66	1029,98	0,26

5.4.2 Previsão da Série de Demanda

Com o uso do modelo para a demanda encontrado anteriormente, a previsão da série foi realizada para o ano de 2018. A Figura 5.17 apresenta a energia prevista para o ano em questão.




Figura 5.17 – Previsão para a série de demanda máxima

A tabela a seguir mostra o erro percentual da previsão em relação aos dados reais de demanda máxima.

Tabela 5.7 – Comparação dos valores reais e previstos para o ano de 2018 para a série de demanda máxima

Mês	Valor real (kW)	Valor previsto (kW)	Erro percentual (%)
Janeiro	2970,00	2968,446	0,0052
Fevereiro	3145,00	3294,366	4,75
Março	3924,00	3869,930	1,38
Abril	3837,00	3696,965	3,65
Mai	3300,00	3272,183	0,84
Junho	3205,00	2977,771	7,09
Julho	2488,00	2326,097	6,51
Agosto	2688,00	3027,377	12,62
Setembro	3219,00	3195,228	0,74
Outubro	3588,00	3448,106	3,89
Novembro	3798,00	3639,679	4,43
Dezembro	3474,00	3323,672	4,32

5.5 Geração dos Cenários

A geração dos cenários se dá a partir de 200 cenários de PLD mensais previamente operacionalizada pelos softwares NEWAVE [34] e DECOMP [35]. Cada cenário de PLD irá gerar um cenário de Energia, que por sua vez irá gerar um cenário de Demanda e Demanda de Ponta, de acordo com os modelos SARIMA com variáveis explicativas previamente definidos. De forma didática, o cenário 1 de PLD será correlacionado com o cenário 1 de Energia, e correlacionado aos cenários 1 de Demanda, e assim por diante.

A figura a seguir apresenta todos os 200 cenários de PLD. Cabe destacar a importância do valor médio desse conjunto de valores de PLD para os próximos capítulos deste trabalho, que fica em R\$ 120,85/MWh.




Figura 5.18 – Simulação dos 200 cenários de PLD

Após a simulação dos cenários de energia, observou-se uma baixa variabilidade nos mesmos devido à abordagem conservadora utilizada na correlação serial, em função do baixo valor do Teste de correlação de Pearson. Para contornar esse problema, os cenários de energia foram reamostrados mantendo-se a média e o desvio padrão da série histórica de energia. A Figura 5.19 e a Figura 5.20

apresentam os 200 cenários de energia e demanda simulados sem o uso dessa reamostragem.




Figura 5.19 – 200 cenários de energia sem reamostragem




Figura 5.20 – 200 cenários de demanda sem reamostragem

A reamostragem consiste em analisar curva de distribuição da série de energia, incluindo média e o desvio padrão. A partir desses dados, gera-se um conjunto de 200 variáveis através de uma distribuição normal, centrado na média 1, com o desvio padrão igual ao da série histórica de energia. Cada variável será

acoplada a uma curva de energia, contribuindo, assim, para o aumento do grau de esparsidade entre os cenários. Nota-se que essa reamostragem não afeta as características auto-regressivas presentes nos cenários, ou seja, o *shape* das curvas não é alterado.

A curva de densidade de probabilidade da série histórica de energia, tal qual os valores de média e desvio padrão, estão apresentadas a seguir.




Figura 5.21 – Distribuição da série de energia e sua respectiva média em destaque

Os parâmetros da distribuição da série de energia são os seguintes:

- Média: 951,553
- Desvio Padrão: 138,527

A partir disso, as variáveis, centradas na média 1, foram geradas, conforme a Figura 5.22:




Figura 5.22 – Distribuição das variáveis aleatórias e sua respectiva média em destaque

Os cenários finais de energia, já considerando o método de reamostragem proposto, estão apresentados de forma empilhada na Figura 5.23. Os dados históricos de energia também estão apresentados como forma de comparação visual.




Figura 5.23 – Dados empilhados de histórico e simulação da série de energia

Com os cenários de energia calculados, os cenários de demanda máxima foram gerados diretamente, ou seja, os cenários de energia foram utilizados como variável explicativa dos modelos SARIMA previamente ajustados.

A Figura 5.24 apresenta os cenários empilhados de demanda máxima a lado a lado com seus dados históricos.




Figura 5.24 – Dados empilhados de histórico e simulação da série de demanda máxima

6 Modelos de Otimização

Neste capítulo será apresentado o modelo de otimização proposto para um contrato no ACL com bandas de flexibilidade considerando cenários correlacionados de energia e demanda. Será apresentado também um modelo semelhante que considera um contrato com sazonalidade.

6.1 Otimização no ACL considerando bandas de flexibilidade

O modelo de otimização para o ACL foi concebido considerando um contrato de quantidade, considerando limites de flexibilidade no consumo de energia. Como já descrito anteriormente, o consumidor está sujeito a penalidades caso o seu consumo não esteja dentro da flexibilidade contratada. Essas penalidades estão diretamente relacionadas à exposição ao mercado de curto prazo, ou seja, aos preços praticados pelo PLD no mês em que houver violação das bandas de flexibilidade.

O modelo considera que o custo da energia pode ser calculado de três formas, cujo valor depende do consumo no cenário s e mês t . Conforme dito anteriormente na dissertação, isso significa que, se o valor de energia for maior que o valor de flexibilidade superior, o custo é calculado de uma forma. Se o valor de energia for menor que a flexibilidade inferior, o custo é calculado de outra forma. Por fim, se o valor de energia estiver entre as flexibilidades do contrato, o custo é calculado de uma terceira forma. Dessa maneira, a função de custo cobre todas as possibilidades de faturamento que um determinado valor de energia no cenário s e mês t pode assumir neste contrato.

Portanto, o modelo tem o objetivo de encontrar os valores ótimos de flexibilidade superior e inferior que minimizem a função objetivo de custo anual, obtida por uma combinação linear entre CVaR e VE, dadas as incertezas geradas pelos cenários utilizados. Pelo lado da demanda, o modelo também considera encontrar o valor ótimo de demanda a ser contratada, tendo em conta as correlações entre energia e demanda nos cenários simulados

A expressão (6.1) corresponde a função objetivo de custo anualizado, obtida pela ponderação entre Valor Esperado (VE) e CVaR.

$$C_{ANUAL} = \min_{\Delta_{s,t}^+, \Delta_{s,t}^-, B^+, B^-, X_{s,t}^1, X_{s,t}^2, X_{s,t}^3, X_{s,t}^4, X_{s,t}^{23}, C_{s,t}^1, C_{s,t}^2, C_{s,t}^3, D_{cont}, \Delta_{s,t}^D, du_{s,t}, \gamma_t, C_{s,t}^D, C_{s,t}, \delta_{s,t}, w_t} (1 - \lambda) \frac{1}{S} \sum_{t \in T} \sum_{s \in S} C_{s,t} + \lambda \left[\sum_{t \in T} w_t + \sum_{s \in S} \left(\frac{\delta_{s,t}}{1 - \alpha} \right) \frac{1}{S} \right] \quad (6.1)$$

Sujeito a:

$$0 \leq B^+ \leq 1 \quad (6.2)$$

$$0 \leq B^- \leq 1 \quad (6.3)$$

$$Q^+ = (1 + B^+) \times Q \quad (6.4)$$

$$Q^- = (1 - B^-) \times Q \quad (6.5)$$

$$\Delta_{s,t}^+ = (E_{s,t} - Q^+) \times X_{s,t}^1 \quad (6.6)$$

$$\Delta_{s,t}^+ \geq 0 \quad (6.7)$$

$$(Q^+ - E_{s,t}) \times X_{s,t}^2 \geq 0 \quad (6.8)$$

$$\sum_{s \in S} \sum_{t \in T} X_{s,t}^1 + X_{s,t}^2 = 1 \quad (6.9)$$

$$(E_{s,t} - Q^-) \times X_{s,t}^3 \geq 0 \quad (6.10)$$

$$\Delta_{s,t}^- = (Q^- - E_{s,t}) \times X_{s,t}^4 \quad (6.11)$$

$$\Delta_{s,t}^- \geq 0 \quad (6.12)$$

$$\sum_{s \in S} \sum_{t \in T} X_{s,t}^3 + X_{s,t}^4 = 1 \quad (6.13)$$

$$\sum_{s \in S} \sum_{t \in T} X_{s,t}^2 + X_{s,t}^3 - 1 = X_{s,t}^{23} \quad (6.14)$$

$$X_t^1, X_t^2, X_t^3, X_{s,t}^4, X_{s,t}^{23} \in \{0,1\} \quad (6.15)$$

$$C_{s,t}^1 = Q^+ \times P_e + \Delta_{s,t}^+ \times \pi_{s,t} \quad (6.16)$$

$$C_{s,t}^2 = Q \times P_e - \Delta_{s,t}^- \times \pi_{s,t} \quad (6.17)$$

$$C_{s,t}^3 = E_{s,t} \times P_e \quad (6.18)$$

$$D_{cont} + \Delta_{s,t}^D + du_{s,t} \geq D_{s,t} \quad (6.19)$$

$$\Delta_{s,t}^D \leq D_{cont} \times u \quad (6.20)$$

$$du_{s,t} \geq (D_{t,s} - (1 + u) \times D_{cont}) \times Y_{s,t} \quad (6.21)$$

$$Y_{s,t} \in \{0,1\} \quad (6.22)$$

$$du_{s,t} \leq M \times Y_{s,t} \quad (6.23)$$

$$C_{s,t}^D = (D_{cont} + \Delta_{s,t}^D) \times TUSD_D + du_{s,t} \times TUSD_D^{ult} \quad (6.24)$$

$$C_{s,t}^E = E_{s,t}^p \times TUSD_{Ep} + E_{s,t}^{fp} \times TUSD_{Efp} \quad (6.25)$$

$$C_{s,t} = C_{s,t}^1 \times X_{s,t}^1 + C_{s,t}^2 \times X_{s,t}^{23} + C_{s,t}^3 \times X_{s,t}^4 + C_{s,t}^D + C_{s,t}^E \quad (6.26)$$

$$\delta_{s,t} \geq C_{s,t} - w_t \quad (6.27)$$

$$\delta_{s,t} \geq 0 \quad (6.28)$$

Sendo:

C_{ANUAL} o custo ótimo anual, em R\$;

$C_{s,t}$ o custo no cenário s e mês t ;

B^+ a flexibilidade superior do contrato;

B^- a flexibilidade inferior do contrato;

Q a quantidade de energia contratada, em MWh;

Q^+ a quantidade de energia da flexibilidade superior, em MWh;

Q^- a quantidade de energia da flexibilidade inferior, em MWh;

$E_{s,t}$ o consumo no cenário s e mês t , em MWh;

$\Delta_{s,t}^+$ a diferença entre o consumo no mês t e cenário s e a flexibilidade superior de contrato;

$\Delta_{s,t}^-$ a diferença entre a flexibilidade inferior de contrato e o consumo no mês t e cenário s ;

$X_{s,t}^1$ a variável binária principal relacionada ao consumo acima da flexibilidade superior de contrato;

$X_{s,t}^2$ e $X_{s,t}^3$ as variáveis binárias secundárias relacionadas ao consumo entre as flexibilidades de contrato;

$X_{s,t}^{23}$ a variável binária principal relacionada ao consumo entre as flexibilidades de contrato;

$X_{s,t}^4$ a variável binária principal relacionada ao consumo abaixo da flexibilidade inferior de contrato;

$C_{s,t}^1$ o custo para o cenário s e mês t relacionado ao consumo acima da flexibilidade superior de contrato;

$C_{s,t}^2$ o custo para o cenário s e mês t relacionado ao consumo abaixo da flexibilidade inferior de contrato;

$C_{s,t}^3$ o custo para o cenário s e mês t relacionado ao consumo entre as flexibilidades de contrato;

$\pi_{s,t}$ o valor de PLD no cenário s e mês t ;

P_e o preço da energia contratada, em R\$/MWh;

D_{cont} a demanda contratada, em kW;

$\Delta_{s,t}^D$ a tolerância de demanda no mês t e cenário s ;

$d_{s,t}^u$ a ultrapassagem da demanda no mês t e cenário s ;

M um número muito grande (*Big M*) utilizado como parâmetro auxiliar;

$D_{s,t}$ a demanda máxima simulada no mês t e cenário s ;

u o percentual de ultrapassagem de demanda tolerado (5%);

$Y_{s,t}$ a variável binária que indica a ultrapassagem de demanda contratada no cenário s e mês t ;

$C_{s,t}^D$ o custo em função da demanda no cenário s e mês t ;

$TUSD_D$ a tarifa do uso do sistema de distribuição, em R\$/kW;

$TUSD_D^{ult}$ a tarifa de ultrapassagem do uso do sistema de distribuição, em R\$/kW;

$C_{s,t}^E$ o custo em função das tarifas relacionadas aos encargos de energia;

$E_{s,t}^p$ o consumo na ponta no cenário s e mês t , em MWh;

$E_{s,t}^{fp}$ o consumo na fora ponta no cenário s e mês t , em MWh;

$TUSD_{Ep}$ a tarifa do uso do sistema de distribuição referente aos encargos na ponta, em R\$/MWh;

$TUSD_{Efp}$ a tarifa do uso do sistema de distribuição referente aos encargos na fora ponta, em R\$/MWh;

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

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

λ a constante de ponderação entre VE e CVaR;

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

As expressões (6.2) e (6.3) representam a definição de flexibilidade superior e inferior, enquanto que as expressões (6.4) e (6.5) estabelecem essas flexibilidades em termos de MWh.

As restrições (6.6) a (6.15) definem as variáveis necessárias para o cálculo do custo da energia de um cenário s e mês t , através do uso de variáveis binárias. As variáveis binárias $X_{s,t}^1, X_{s,t}^2, X_{s,t}^{23}, X_{s,t}^3$ e $X_{s,t}^4$ possuem valor unitário em função do valor de $E_{s,t}$. Se $E_{s,t}$ estiver acima da flexibilidade superior, então a variável $X_{s,t}^1$ possui valor unitário. A restrição (6.9) garante que, $X_{s,t}^1$ ou $X_{s,t}^2$ deverá possuir valor unitário, enquanto que a outra terá valor nulo obrigatoriamente.

Se $E_{s,t}$ estiver abaixo da flexibilidade inferior, o raciocínio é análogo, em que $X_{s,t}^4$ terá valor unitário. Dessa forma, a restrição (6.13) garante que apenas $X_{s,t}^3$ ou $X_{s,t}^4$ terá valor unitário dado um cenário s e mês t .

Se $E_{s,t}$ estiver entre as bandas de flexibilidade devido às restrições (6.9) e (6.13), as variáveis binárias $X_{s,t}^2$ e $X_{s,t}^3$ terão valor unitário. Quando isso ocorre, o valor da variável binária $X_{s,t}^{23}$ será unitário devido à restrição (6.14).

As restrições (6.16) a (6.18) apresentam as funções de custo referente às 3 possibilidades de faturamento da energia: acima da flexibilidade superior, abaixo da flexibilidade inferior e entre as duas flexibilidades, respectivamente.

Para ilustrar o comportamento das variáveis binárias na solução do problema, a Figura 6.1 demonstra quais variáveis serão ativas para cada valor possível de $E_{s,t}$.




Figura 6.1 – Demonstração gráfica do comportamento das variáveis binárias no problema proposto

Analisando o lado da demanda, a restrição (6.19) determina que a demanda de potência no cenário s e mês t é composta pela demanda contratada, a tolerância de demanda ($\Delta_{s,t}^D$) e pela demanda de ultrapassagem ($d_{s,t}^u$). A restrição (6.20) define que a tolerância de demanda equivale a um percentual u (no caso, 5%). As restrições (6.21) a (6.23) definem a ocorrência de ultrapassagem da tolerância em um cenário s e mês t através do uso da variável binária $Y_{s,t}$, que terá valor unitário se houver ultrapassagem. Por fim, o custo associado à demanda nesse contrato é calculado através da restrição (6.24).

Os custos associados ao uso do sistema de distribuição são calculados pela restrição (6.25). De acordo com a restrição (6.26), o custo total do contrato no cenário s e mês t é determinado em função da variável binária ativa, conforme explicado anteriormente, e pelos custos de demanda e do uso do sistema de distribuição.

Finalmente, as restrições (6.27) e (6.28) definem o CVaR para os $(1 - \alpha\%)$ piores cenários que serão aplicados na função objetivo (6.1).

6.2 Otimização no ACL considerando sazonalidade

O modelo de otimização para esse tipo de contrato é bastante similar ao modelo para o contrato anterior, com pequenas mudanças nas variáveis de decisão e em algumas restrições específicas.

Devido a limitações do modelo de otimização, não é possível considerar a quantidade de energia contratada e as flexibilidades como variáveis de decisão simultaneamente. Portanto, as flexibilidades desse modelo serão fixadas enquanto que a quantidade de energia contratada será considerada como a variável de decisão com discretização mensal. Dessa forma, quantidade de energia contratada Q será subdividida em Q_t , onde t é o mês de análise.

Primeiramente, a função objetivo apresentada em (6.1) é alterada para retirar as flexibilidades inferior e superior como variáveis de decisão e inserir a quantidade de energia mensal a ser contratada Q_t .

$$C_{ANUAL} = \min_{\substack{\Delta_{s,t}^+, \Delta_{2,s,t}^-, Q_t, Q_t^+, Q_t^-, X_{s,t}^1, X_{s,t}^2, X_{s,t}^3, X_{s,t}^4, X_{s,t}^{23}, \\ C_{s,t}^1, C_{s,t}^2, C_{s,t}^3, D_{cont}, A_{s,t}^D, du_{s,t}, \gamma_t, C_{s,t}^D, C_{s,t}, \delta_{s,t}, w_t}} (1 - \lambda) \frac{1}{S} \sum_{t \in T} \sum_{s \in S} C_{s,t} + \lambda \left[\sum_{t \in T} w_t + \sum_{s \in S} \left(\frac{\delta_{s,t}}{1 - \alpha} \right) \frac{1}{S} \right] \quad (6.29)$$

As restrições (6.4) e (6.5) que estabelecem a flexibilidade em termos de MWh são alteradas conforme as equações a seguir.

$$Q_t^+ = (1 + B^+) \times Q_t \quad (6.30)$$

$$Q_t^- = (1 - B^-) \times Q_t \quad (6.31)$$

As restrições (6.6),(6.8),(6.10) e (6.11) são alteradas para adaptar o uso das variáveis binárias para um contrato sazonalizado.

$$\Delta_{s,t}^+ = (E_{s,t} - Q_t^+) \times X_{s,t}^1 \quad (6.32)$$

$$(Q_t^+ - E_{s,t}) \times X_{s,t}^2 \geq 0 \quad (6.33)$$

$$(E_{s,t} - Q_t^-) \times X_{s,t}^3 \geq 0 \quad (6.34)$$

$$\Delta_{s,t}^- = (Q_t^- - E_{s,t}) \times X_{s,t}^4 \quad (6.35)$$

Por fim, as restrições que determinam o custo para um cenário s e mês t são alteradas para adaptar o cálculo desses custos para um contrato sazonalizado.

$$C_{s,t}^1 = Q_t^+ \times P_e + \Delta_{s,t}^+ \times \pi_{s,t} \quad (6.36)$$

$$C_{s,t}^2 = Q_t \times P_e - \Delta_{s,t}^- \times \pi_{s,t} \quad (6.37)$$

Com essas alterações realizadas no modelo de otimização anterior, consegue-se obter os valores ótimos da quantidade mensal de energia a ser contratada que minimizem o custo anual para o consumidor, considerando valores pré-determinados de flexibilidade inferior e superior.

7 Resultados e Discussões

Neste capítulo, serão apresentados e discutidos os resultados obtidos para um grande consumidor localizado na cidade do Rio de Janeiro. O modelo de otimização previamente apresentado foi implementado no *software* Xpress [39] devido ao bom desempenho em solucionar problemas de MILP. Os resultados obtidos foram alcançados utilizando os 200 cenários de PLD, Energia e Demanda Máxima simulados anteriormente.

Em todas as simulações, o parâmetro de aversão ao risco α escolhido é igual a 0,95, o que significa que os 5% piores cenários de custo serão utilizados pelo CVaR no processo de otimização.

A aversão ao risco nas análises aumenta de forma diretamente proporcional ao parâmetro λ . Isso significa que, à medida que o parâmetro λ se aproxima de 1, a aversão ao risco se torna maior. Se $\lambda = 0$, a análise considera apenas o Valor Esperado (VE); se $\lambda = 0,5$, a análise pondera 50% para VE e 50% para CVaR e; se $\lambda = 1$, a análise considera apenas CVaR. Dessa forma, o consumidor consegue avaliar diferentes estratégias de acordo com o risco que está disposto a tomar.

7.1 Resultados de Otimização no ACL Considerando Contrato Flat com Flexibilidade da Energia Contratada

Tendo sido realizadas as simulações dos cenários de energia, demanda máxima e PLD, procedeu-se ao problema de otimização do custo anual no ACL considerando um contrato flat com flexibilidade da energia contratada. Além disso, para satisfazer à restrição (6.25), realiza-se uma desagregação nos valores mensais dos cenários de energia, com o objetivo de utilizar os valores de energia na ponta e na fora ponta. As expressões (7.1) e (7.2) representam os cálculos dessa desagregação, de forma que o horário de ponta representa 3 horas do dia e, por consequência, o horário de fora ponta representa 21 horas.

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

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

Para esse tipo de contrato, a quantidade de energia contratada é fixa para todo o horizonte de análise, enquanto os valores ótimos de flexibilidade são encontrados pelo otimizador. O preço de contrato é um fator determinante nos resultados e influencia diretamente no processo de otimização. Devido a isso, foram escolhidos dois valores de preço de contrato: 100 R\$/MWh e 200 R\$/MWh. Enquanto o primeiro foi escolhido para analisar os resultados com o preço de energia estando menor que o valor médio de PLD, o segundo foi escolhido por se aproximar bastante dos preços praticados no contrato vigente deste consumidor.

De forma simplificada, se o valor de PLD for menor do que o preço da energia praticado no contrato, a tendência é que a flexibilidade superior seja reduzida e que a inferior se mantenha mais alta. Isso ocorre pois se torna mais favorável economicamente comprar energia no mercado de curto prazo do que pagar ao preço do contrato.

Por outro lado, com valores altos de PLD, a tendência é que o otimizador aplique uma flexibilidade superior maior, com o objetivo de manter o consumidor pagando os preço de contrato, e uma flexibilidade inferior menor, para que o consumidor consiga vender o que não consumiu à preços elevados de PLD.

Obviamente, em um contexto estocástico, a análise se prova mais complexa devido à quantidade de cenários envolvidos. A Tabela 7.1 e a Figura 7.1 apresentam os resultados encontrados de acordo com um preço de energia de 100 R\$/MWh no contrato e com os três perfis de aversão ao risco.

Tabela 7.1 – Resultados considerando um preço de energia de 100 R\$/MWh

	Preço = 100 R\$/MWh		
	$\lambda = 0$	$\lambda = 0,5$	$\lambda = 1$
Quantidade de energia contratada (MWmed)	1,00	1,20	1,80
Quantidade de energia contratada (MWh)	720	864	1296
Energia Média (MWh)	1038,10	1162,06	1285,65
Demanda Contratada (kW)	3474,02	3663,23	3752,47
Demanda Média (kW)	3278,23	3470,57	3662,34

PLD Médio (R\$/MWh)	120,85	307,05	490,43
Limite Inferior	19,39%	31,57%	0,00%
Limite Superior	100,00%	82,22%	21,49%
Custo Anual (R\$)	R\$ 3.814.278,10	R\$ 4.244.521,28	R\$ 4.410.612,31

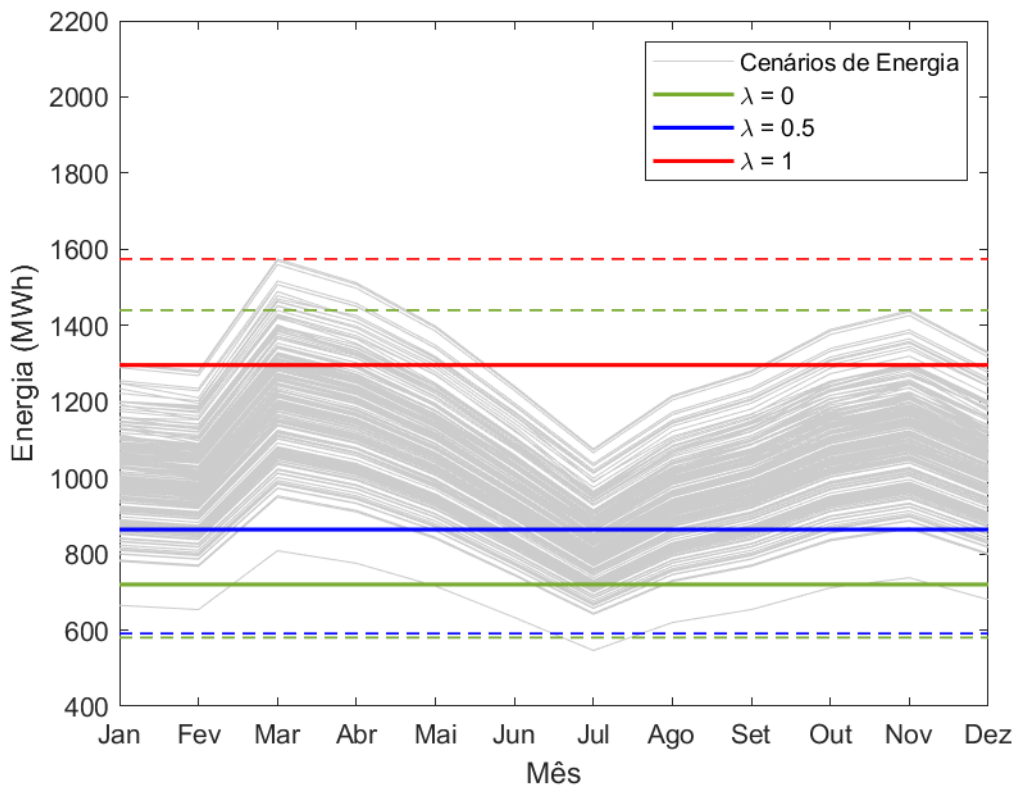


Figura 7.1 – Energia e flexibilidades contratadas para diferentes valores de λ a um preço de energia de 100 R\$/MWh

À medida que a aversão ao risco da análise aumenta, o custo anual associado ao contrato também aumenta. É um resultado esperado sob o ponto de vista conservador, por se tratar de uma análise que leva em consideração os 5% piores cenários de custo. A diferença entre o maior custo (quando $\lambda = 1$) e o menor (quando $\lambda = 0$) é de aproximadamente 16%, valor esse que quantifica o impacto do risco tomado pelo consumidor.

O valor do PLD para diferentes valores de λ tem impacto direto com a otimização dos intervalos de flexibilidade. Para todos os valores de λ , vemos que o otimizador tende a se proteger de qualquer possibilidade de compra ao PLD, tendo em vista que o preço de contrato de 100 R\$/MWh é menor que os valores de PLD calculados para os cenários de risco analisados. Para $\lambda = 1$, pode-se verificar que a amplitude (a diferença entre a flexibilidade superior e inferior) se reduz

principalmente para se aproveitar da venda ao PLD, no caso de valores de Energia consumida menores do que a flexibilidade inferior.

O aumento dos valores médios de PLD em função de λ se dá pela correlação existente entre os cenários de energia e os cenários de PLD. Ou seja, os 5% piores cenários de energia estão correlacionados aos 5% cenários com PLD mais elevados. Da mesma forma que os melhores cenários de energia para o custo final estão correlacionados aos melhores cenários de PLD.

É importante destacar o comportamento da demanda contratada, que também aumenta conforme o valor de λ . Devido a correlação dos cenários de demanda com os cenários de energia, o mesmo comportamento que foi observado entre energia e PLD pode ser analisado nesse caso. Portanto, conforme analisamos os piores cenários de custo total, estamos analisando os piores cenários de energia e demanda de forma conjunta, o que justifica o aumento da demanda contratada em função do valor de λ .

A seguir, estão apresentados os resultados encontrados de acordo com um preço de energia de 200 R\$/MWh no contrato e com os três perfis de aversão ao risco.

Tabela 7.2 – Resultados considerando um preço de energia de 200 R\$/MWh

	Preço = 200 R\$/MWh		
	$\lambda = 0$	$\lambda = 0,5$	$\lambda = 1$
Quantidade de energia contratada (MWmed)	1,00	1,20	1,80
Quantidade de energia contratada (MWh)	720	864	1296
Energia Média (MWh)	1038,10	1162,06	1285,65
Demanda Contratada (kW)	3474,06	3691,59	3752
Demanda Média (kW)	3278,23	3470,57	3662,34
PLD Médio (R\$/MWh)	120,85	307,05	490,43
Limite Inferior	15,14%	31,63%	0,00%
Limite Superior	0,00%	82,23%	21,45%
Custo Anual	R\$ 4.118.510,62	R\$ 5.639.075,00	R\$ 6.022.629,35

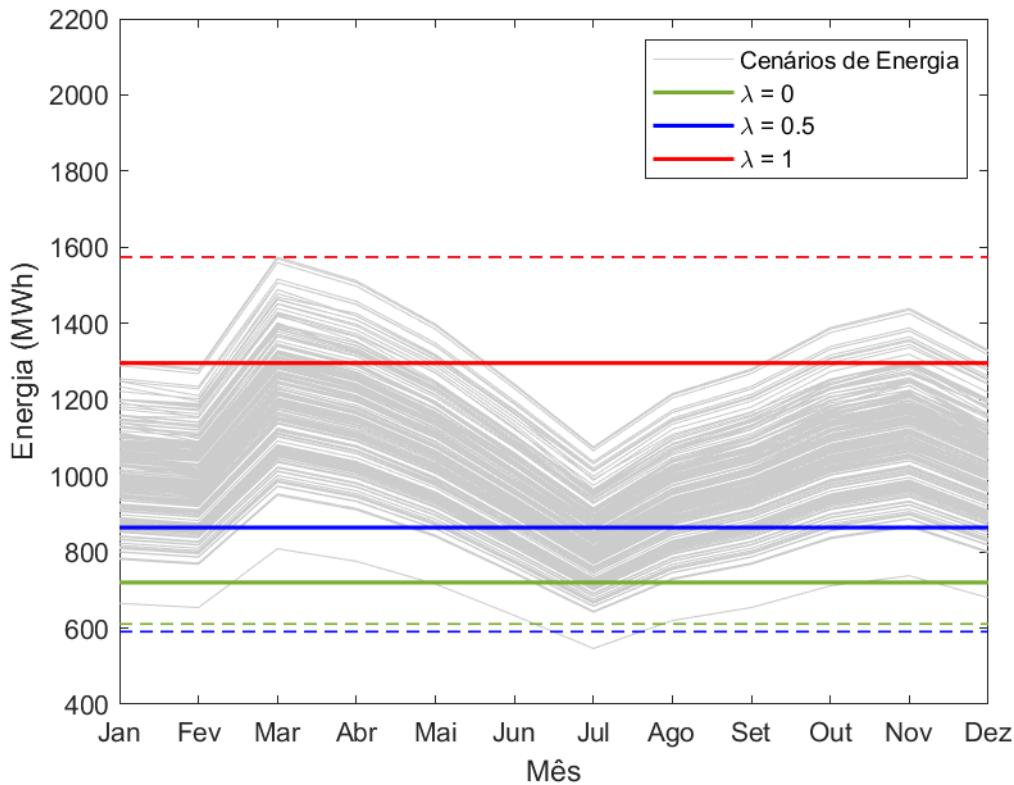


Figura 7.2 – Energia e flexibilidades contratadas para diferentes valores de λ a um preço de energia de 200 R\$/MWh

Sob estas condições de contrato, a diferença entre o maior e o menor custo se acentua, ficando em 46%, valor esse que quantifica o impacto do risco tomado pelo consumidor.

Para $\lambda = 0$, o valor do PLD médio de 120,85 R\$/MWh é bem inferior do que o preço de 200 R\$/MWh contratado, induzindo o otimizador a se expor ao máximo ao PLD, se aproveitando de preços menores praticados no mercado de curto prazo. Em contrapartida, a flexibilidade inferior tenta prevenir que ocorra venda ao PLD, que nesse caso não se torna vantajoso tendo em vista de que, segundo o modelo de otimização, quando o valor da energia no mês t e cenário s é menor do que a flexibilidade contratada, o contrato exige que, além de haver venda ao PLD, o consumidor pague a quantidade de energia contratada Q faturado ao preço contratado de energia (no caso, 200 RS/MWh).

Para $\lambda = 0,5$, o PLD médio já se torna superior ao preço de energia e, conforme esperado, o otimizador se protege do risco associado à compra ao PLD. O mesmo ocorre para $\lambda = 1$, mas nesse caso o otimizador se aproveita da venda ao PLD, justamente por ter um valor de PLD médio elevado.

7.2

Resultados de Otimização no ACL Considerando Contrato Sazonalizado com Flexibilidade da Energia Contratada

Neste modelo de contrato, a sazonalidade permite que os valores mensais contratados sejam alterados dentro de um intervalo pré-definido. Isso permite que esses valores possam estar de acordo com perfil mensal de consumo do consumidor, além de estratégias mais ousadas, como a exposição ao mercado *spot*, possam ser utilizadas em alguns meses.

Conforme realizado na seção 7.1, os preços de contrato foram definidos em 100 R\$/MWh e 200 R\$/MWh. Devido a uma limitação no modelo matemático, os valores de flexibilidade serão fixados ao mesmo tempo que Q_t se torna uma variável de decisão. O valor da flexibilidade inferior e superior foi fixado como 20%, que é um valor comum em muitos contratos de energia.

A Tabela 7.3 apresenta os resultados encontrados para um preço de contrato de 100 R\$/MWh e diferentes valores de λ . Essa tabela também apresenta os valores médios de PLD mensal com o objetivo de entender o comportamento do otimizador em propor os valores de energia contratada encontrados.

Tabela 7.3 – Resultados considerando um preço de energia de 100 R\$/MWh

	$\lambda = 0$			$\lambda = 0,5$			$\lambda = 1$		
	Mwmed	MWh	PLD Médio	Mwmed	MWh	PLD Médio	Mwmed	MWh	PLD Médio
Janeiro	1,44	1036,92	123,86	1,54	1109,91	269,02	1,55	1112,51	451,40
Fevereiro	1,38	995,86	116,31	1,50	1079,87	253,26	1,51	1089,35	422,77
Março	1,72	1235,70	105,87	1,83	1315,97	270,86	1,90	1366,98	461,67
Abril	1,67	1199,58	108,90	1,74	1256,34	290,33	1,76	1267,90	492,00
Mai	1,49	1071,95	110,94	1,67	1201,27	299,77	1,88	1353,94	505,26
Junho	1,34	966,53	117,83	1,45	1047,08	316,44	1,69	1214,20	519,23
Julho	1,15	830,79	114,13	1,29	928,61	324,21	2,00	1440,00	499,30
Agosto	1,29	931,41	126,71	1,41	1015,42	329,22	1,56	1120,31	501,29
Setembro	1,38	991,43	130,60	1,46	1049,18	332,45	1,70	1227,49	499,67
Outubro	1,49	1075,13	136,06	1,59	1143,76	335,18	1,87	1349,56	508,44
Novembro	1,58	1138,08	136,64	1,66	1195,19	335,47	1,80	1296,95	510,55
Dezembro	1,46	1048,72	122,39	1,54	1107,50	328,34	1,65	1191,25	520,89
Flexibilidade	20%								
Demanda (kW)	3482,80			3650,03			3752,02		
Custo Anual	R\$ 3.832.301,89			R\$ 4.267.596,46			R\$ 4.651.737,54		

As figuras a seguir representam a sazonalização deste contrato para cada valor de λ analisado.




Figura 7.3 – Energia contratada mês a mês para $\lambda = 0$ a um preço de energia de 100 R\$/MWh




Figura 7.4 – Energia contratada mês a mês para $\lambda = 0,5$ a um preço de energia de 100 R\$/MWh




Figura 7.5 – Energia contratada mês a mês para $\lambda = 1$ a um preço de energia de 100 R\$/MWh

Para $\lambda = 0$, os valores encontrados estão dentro do esperado para os casos em que os valores de PLD são superiores ao preço de contrato. Dessa forma, com o objetivo de proteger o consumidor da exposição ao mercado de curto prazo, o otimizador propõe uma sazonalização seguindo o formato da curva de consumo e utiliza dos intervalos de flexibilidade para agregar o maior número de cenários possível dentro desse intervalo.

Para $\lambda = 0,5$, o raciocínio é o mesmo, mas com valores mensais de energia contratada levemente superiores do que no caso anterior. Isso ocorre pois o CVaR agora é considerado na análise, obrigando o otimizador a realizá-la com uma aversão maior ao risco.

Para $\lambda = 1$, o resultado é interessante especialmente pelo mês de julho. Nesse mês, o otimizador determina que é mais interessante que a energia consumida esteja abaixo da flexibilidade inferior, vendendo à PLD. Mesmo que o valor do PLD médio em outros meses da análise seja até superior ao PLD médio do mês de julho,

esse é o único mês em que é mais vantajoso ser penalizado pela energia não consumida e ter essa sobra vendida ao mercado de curto prazo. Nos outros meses, a decisão entre vender à PLD, mas pagar uma penalidade ou não se expor ao mercado *spot*, pesa mais para a segunda opção.

A Tabela 7.4 apresenta os resultados encontrados para um preço de contrato de 100 R\$/MWh e diferentes valores de λ . Essa tabela também apresenta os valores médios de PLD mensal com o objetivo de entender o comportamento do otimizador em propor os valores de energia contratada encontrados.

Tabela 7.4 – Resultados considerando um preço de energia de 200 R\$/MWh

	$\lambda = 0$			$\lambda = 0,5$			$\lambda = 1$		
	Mwmed	MWh	PLD Médio	Mwmed	MWh	PLD Médio	Mwmed	MWh	PLD Médio
Janeiro	0,80	576,14	123,86	1,50	1077,43	269,02	1,56	1121,12	414,18
Fevereiro	0,80	576,23	116,31	1,47	1058,74	253,26	1,58	1138,55	390,21
Março	0,80	576,48	105,87	1,82	1311,31	270,86	1,95	1404,65	435,85
Abril	0,80	576,41	108,90	1,74	1255,68	290,33	1,76	1270,67	471,75
Mai	0,80	576,07	110,94	1,61	1161,09	299,77	1,66	1198,63	488,61
Junho	0,80	576,19	117,83	1,43	1032,36	316,44	1,69	1218,29	515,05
Julho	0,80	576,06	114,13	1,25	900,04	324,21	1,50	1078,79	534,30
Agosto	0,80	577,92	126,71	1,40	1005,93	329,22	1,63	1174,08	531,73
Setembro	0,80	576,29	130,60	1,47	1061,12	332,45	1,68	1212,59	534,30
Outubro	0,80	576,45	136,06	1,59	1144,48	335,18	1,73	1245,30	534,30
Novembro	0,80	576,92	136,64	1,67	1199,90	335,47	1,74	1249,93	534,30
Dezembro	0,80	576,37	122,39	1,54	1105,66	328,34	1,71	1232,70	534,30
Flexibilidade	20%								
Demanda (kW)	3499,05			3687,01			3751,91		
Custo Anual	R\$ 4.898.525,99			R\$ 5.675.079,57			R\$ 6.212.297,51		

As figuras a seguir representam a sazonalização deste contrato para cada valor de λ analisado.

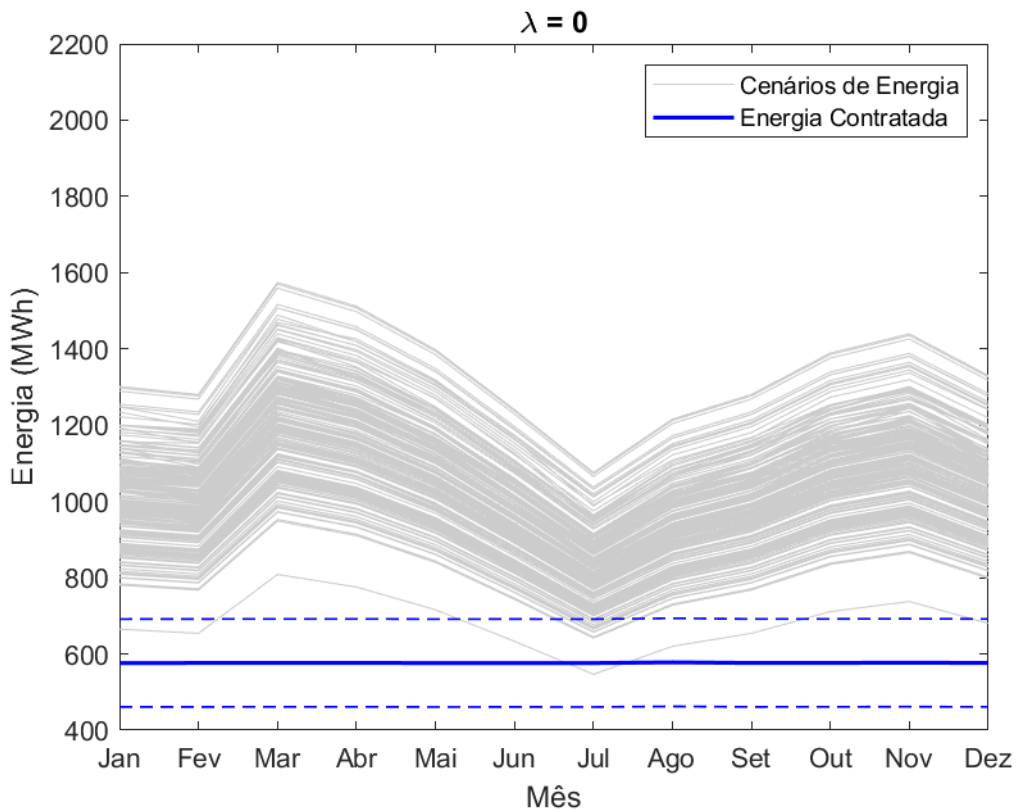


Figura 7.6 – Energia contratada mês a mês para $\lambda = 0$ a um preço de energia de 200 R\$/MWh




Figura 7.7 – Energia contratada mês a mês para $\lambda = 0,5$ a um preço de energia de 200 R\$/MWh




Figura 7.8 – Energia contratada mês a mês para $\lambda = 1$ a um preço de energia de 200 R\$/MWh

Percebe-se que, para $\lambda = 0$, o resultado tende a minimizar a curva de carga para o menor valor possível. Nos doze meses do ano, a tendência é que haja a maior exposição possível ao mercado de curto prazo que, conforme podem ser vistos na Tabela 7.4, constam com valores mais atraentes do que o preço da energia contratada.

A partir de $\lambda = 0,5$, percebe-se que o valor médio do PLD aumenta significativamente. Dessa forma, a estratégia é de reduzir a exposição do mercado de curto prazo. Nota-se que, pela Figura 7.7, a Sazonalização acompanha a curva de consumo anual de modo que a flexibilidade de 20% consiga agrupar os valores mais altos de energia e evitar o PLD.

O mesmo ocorre para $\lambda = 1$, os valores de PLD são ainda maiores e a compra de energia a esse valor aumentaria muito os custos anuais do consumidor. E, pelo fato de que a análise é apenas pela métrica CVaR, o otimizador considera menos cenários, todos eles localizados dentro da banda de flexibilidade. Portanto, a energia é cobrada pelo valor do preço de contrato, o que representa vantagem nesse caso.

8 Conclusão e Perspectivas

Esta dissertação apresentou um estudo de contratação no Ambiente Livre considerando cenários estocásticos correlacionados de demanda, energia e PLD. A proposta do trabalho consiste em um método de apoio à decisão para a contratação ótima de energia e demanda para diferentes tipos de contrato no Ambiente Livre. Dessa forma, buscou-se obter parâmetros ótimos de contrato em função do risco associado ao mesmo de forma que os custos anuais sejam minimizados. A métrica de avaliação utilizada foi uma combinação convexa de Valor Esperado e CVaR.

Um modelo de otimização foi construído com o uso de programação inteira mista capaz de fornecer resultados robustos de acordo com os dados inseridos de demanda, energia e PLD. Este modelo foi utilizado para dois tipos de contrato, sendo o primeiro considerando um volume fixo de energia mensal contratada com flexibilidade, e outro considerando sazonalização do volume de energia contratado. Para o segundo tipo de contrato, foi necessário modificar algumas restrições e variáveis de decisão de forma que os custos anuais desse tipo de contrato pudessem ser corretamente calculados.

A metodologia apresentada foi analisada considerando 200 cenários de PLD escolhidos aleatoriamente, entretanto, pode-se utilizar uma quantidade maior de cenários no modelo proposto, ou até mesmo o uso de cenários mais estressados de PLD. A partir disso, considerando a correlação entre PLD, energia e demanda máxima, cenários de energia e demanda foram gerados através de modelos SARIMA com variáveis exógenas. Os cenários gerados foram inseridos como dados de entrada do modelo de otimização proposto.

Em função dos dados de entrada, o modelo de otimização define os parâmetros ideais de acordo com o nível de risco desejado pelo consumidor, obtendo resultados satisfatórios quando comparados com os custos anuais reais deste consumidor. Pode-se afirmar que os resultados têm relação direta com o preço da energia contratada e os valores de PLD, e que os parâmetros dos contratos analisados podem sofrer mudanças significativas em função desses preços.

Para estudos futuros, sugere-se realizar uma previsão da energia e demanda em intervalos horários, correlacionado ao uso dos dados de PLD horário. Adicionalmente, sugere-se abordar o uso de geração distribuída no ACL e seus impactos nos custos do consumidor. Aliado a isso, também seria possível analisar outros tipos de contrato dentro do Ambiente Livre, além do refino do modelo de otimização para que se possa otimizar os parâmetros relacionados a sazonalização e flexibilidade simultaneamente.

9

Referências Bibliográficas

- 1 PLANALTO. **Lei nº 9427, 26 de dezembro de 1996**. Disponível em: <http://www.planalto.gov.br/ccivil_03/leis/l9427cons.htm>.
- 2 PLANALTO. **Lei Nº 10.848, de 15 de março de 2004**. 2004. Disponível em: <http://www.planalto.gov.br/ccivil_03/_ato2004-2006/2004/lei/l10.848.htm>.
- 3 CÂMARA DE COMERCIALIZAÇÃO DE ENERGIA ELÉTRICA. **Câmara de Comercialização de Energia Elétrica**. Disponível em: <https://www.ccee.org.br/portal/faces/pages_publico/inicio?_afLoop=156785660706875&_adf.ctrl-state=4hp9kjzyl_1#!%40%40%3F_afLoop%3D156785660706875%26_adf.ctrl-state%3D4hp9kjzyl_5>.
- 4 ANEEL. **PORTARIA Nº 514, de 27 de Dezembro de 2018**. . [S.l: s.n.], 2018.
- 5 ASSOCIAÇÃO BRASILEIRA DOS COMERCIALIZADORES DE ENERGIA (ABRACEEL). **Cartilha Mercado Livre de Energia Elétrica**. p. 28, 2017.
- 6 PLANALTO. **Decreto Nº 5.163 de 30 de julho de 2004**. Disponível em: <http://www.planalto.gov.br/ccivil_03/_ato2004-2006/2004/decreto/d5163.HTM>.
- 7 ANEEL. **Resolução Normativa Nº 414**. . [S.l: s.n.], 24AD.
- 8 ANEEL. **Resolução Normativa Nº 77, de 18 de Agosto de 2004**. . [S.l: s.n.], [S.d.].
- 9 CÂMARA DE COMERCIALIZAÇÃO DE ENERGIA ELÉTRICA. **Preço de Liquidação de Diferenças (PLD)**. Disponível em: <https://www.ccee.org.br/portal/faces/pages_publico/o-que-fazemos/como_ccee_atua/precos?_afLoop=809494309857128&_adf.ctrl-

- state=n68xzskyg_87#!%40%40%3F_afrLoop%3D809494309857128%26_adf.ctrl-state%3Dn68xzskyg_91>. Acesso em: 10 out 2019.
- 10 HYNDMAN, Rob J e FAN, Shu. **Density Forecasting for Long-Term Peak Electricity Demand**. IEEE Transactions on Power Systems, v. 25, n. 2, 2010. Disponível em: <<http://ieeexplore.ieee.org>>.
 - 11 CARRIÓN, Miguel e colab. **A stochastic programming approach to electric energy procurement for large consumers**. IEEE Transactions on Power Systems, v. 22, n. 2, p. 744–754, Maio 2007.
 - 12 PAPPAS, S. Sp e colab. **Electricity demand load forecasting of the Hellenic power system using an ARMA model**. Electric Power Systems Research, v. 80, n. 3, p. 256–264, Mar 2010.
 - 13 LIMA, Delberis A. e colab. **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, Jan 2018. Disponível em: <<https://doi.org/10.1016/j.epsr.2017.08.017>>.
 - 14 LIMA, Delberis A. e CÉSPEDES G., Andrés Maurício. **Stochastic analysis of economic viability of photovoltaic panels installation for big consumers in Brazil**. Electric Power Systems Research, 2019.
 - 15 CARLOS, Érica Telles e LIMA, Delberis A. e OCHOA, Luis F. **Energy contracting for large consumers in Brazil: A real case study**. IET Conference Publications, v. 2013, n. 615 CP, p. 10–13, 2013.
 - 16 MORDJAOUI, Mourad e colab. **Electric load forecasting by using dynamic neural network**. International Journal of Hydrogen Energy, v. 42, n. 28, p. 17655–17663, 13 Jul 2017.
 - 17 LAOUAFI, Abderrezak e colab. **Daily peak electricity demand forecasting based on an adaptive hybrid two-stage methodology**. International Journal of Electrical Power and Energy Systems, v. 77, p. 136–144, 1 Maio 2016.
 - 18 MATIAS BITTENCOURT, Eidy Marianne. **Simulação e Otimização Estocástica para Contratação de Energia Elétrica de Grandes Consumidores**. 2016. 95 f. Pontifícia Universidade Católica do Rio

- de Janeiro, 2016.
- 19 MUNOZ, Juan C. e colab. Applications of optimal industrial load management modeling in smart grids. 13 Jul 2017, [S.l.]: Institute of Electrical and Electronics Engineers Inc., 13 Jul 2017.
- 20 CHU, Kang Ching e KAIFUKU, Kazuhide e SAITOU, Kazuhiro. **Optimal integration of alternative energy sources in production systems with customer demand forecast**. IEEE Transactions on Automation Science and Engineering, v. 13, n. 1, p. 206–214, 1 Jan 2016.
- 21 MELLO, João Carlos e colab. **Uma Visão de Mercado na Gestão de Riscos de Contumidores Eletrointensivos - Melhores Práticas**. XXIII SNPTEE, Fev 2015. Disponível em: <<http://arxiv.org/abs/1011.1669>>.
- 22 CASTRO SOUZA, Reinaldo e CYRINO DE OLIVEIRA, Fernando Luiz. **Análise de Séries Temporais: Os Modelos de Amortecimento Exponencial**. [S.l: s.n.], 2015.
- 23 MORETTIN, Pedro e TOLOI, Clélia. **Análise de Séries temporais**. [S.l: s.n.], 2006.
- 24 SOUZA, R. C. e BRASIL, G. H. **Formulação estrutural - abordagens clássica e bayeseiana: semelhanças e dessemelhanças**. Brazilian Review of Econometrics, v. 8, n. 1, p. 111, 1988.
- 25 BOX, George E. P. e colab. **Time Series Analysis: Forecasting and Control**. 5. ed. [S.l: s.n.], 2015.
- 26 SOUZA, R. C. e CAMARGO, M. E. **Análise e previsão de séries temporais: os modelos ARIMA**. 2. ed. [S.l: s.n.], 2004.
- 27 AKAIKE, Hirotugu. **Fitting autoregressive models for prediction**. Annals of the Institute of Statistical Mathematics, v. 21, n. 1, p. 243–247, 1969.
- 28 SCHWARZ, Gideon. **Estimating the Dimension of a Model**. The Annals of Statistics, v. 6, n. 2, p. 461–464, Mar 1978.
- 29 LJUNG, Greta M. e BOX, George E.P. **The likelihood function of stationary autoregressive-moving average models**. Biometrika, v. 66, n. 2, p. 265–270, 1979.

- 30 WILK, M. B. e GNANADESIKAN, R. **Probability plotting methods for the analysis for the analysis of data**. *Biometrika*, v. 55, n. 1, p. 1–17, 1968.
- 31 RSTUDIO INC. **RStudio**. . Boston: [s.n.]. Disponível em: <<https://rstudio.com/>>. Acesso em: 28 out 2019. , 2019
- 32 SEDGWICK, Philip. **Pearson's correlation coefficient**. *BMJ* (Online), v. 345, n. 7864, 2012.
- 33 CÉSPEDES G., Andrés Maurício. **Análise Estocástica da Viabilidade Econômica da Instalação de Painéis Fotovoltaicos em Grandes Consumidores de Energia Elétricae**. 2017. 133 f. Pontifícia Universidade Católica do Rio de Janeiro, 2017.
- 34 **NEWAVE - Modelo de Planejamento da Operação de Sistemas Hidrotérmicos Interligados de Longo e Médio Prazo**. Disponível em: <http://www.cepel.br/pt_br/produtos/newave-modelo-de-planejamento-da-operacao-de-sistemas-hidrotermicos-interligados-de-longo-e-medio-prazo.htm>. Acesso em: 10 mar 2020.
- 35 **DECOMP - Modelo de Planejamento da Operação de Sistemas Hidrotérmicos Interligados de Curto Prazo**. Disponível em: <http://www.cepel.br/pt_br/produtos/decomp-modelo-de-planejamento-da-operacao-de-sistemas-hidrotermicos-interligados-de-curto-prazo.htm>. Acesso em: 10 mar 2020.
- 36 **Contratos | Mercado Livre de Energia Elétrica**. Disponível em: <<https://www.mercadolivredeenergia.com.br/consumidores-livres-e-especiais/contratos/>>. Acesso em: 11 mar 2020.
- 37 SILVA, Paula A. V. **Construção de um Mecanismo de Realocação de Energia para Renováveis com Repartição de suas Cotas Baseada no Método do Benefício Marginal Considerando a Volatilidade da Produção de seus Participantes**. 2014. Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2014.
- 38 TYRRELL ROCKAFELLAR, R e URYASEV, Stanislav. **Optimization of Conditional Value-at-Risk**. . [S.l: s.n.], [S.d.]. Disponível em: <<http://www.gloriamundi.org/>>. Acesso em: 23 jan 2020.
- 39 FICO. **Xpress Optimization**. . [S.l: s.n.]. Disponível em: <<https://www.fico.com/br/products/fico-xpress-optimization>>. , 1956