

**UNIVERSIDADE DE SÃO PAULO
ESCOLA DE ENGENHARIA DE SÃO CARLOS**

Vinicius Bartholomei Giraldo

**Concavidade do Custo Marginal de Operação em Termos
dos Níveis Hidrológicos nos Reservatórios de Camargos e
Três Irmãos**

São Carlos

2019

Vinicius Bartholomei Giraldo

**Concavidade do Custo Marginal de Operação em Termos
dos Níveis Hidrológicos nos Reservatórios de Camargos e
Três Irmãos**

Monografia apresentada à Escola de Engenharia de São Carlos da Universidade de São Paulo, como parte dos requisitos para obtenção do título de Engenheiro Eletricista.

Área de concentração: Engenharia Elétrica

Orientador: Prof. Dr. Rogério Andrade Flauzino

**São Carlos
2019**

AUTORIZO A REPRODUÇÃO TOTAL OU PARCIAL DESTE TRABALHO,
POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS
DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

Ficha catalográfica elaborada pela Biblioteca Prof. Dr. Sérgio Rodrigues Fontes da
EESC/USP com os dados inseridos pelo(a) autor(a).

Gc Giraldo, Vinicius Bartholomei
 Concavidade do Custo Marginal de Operação em
 Termos dos Níveis Hidrológicos nos Reservatórios de
 Camargos e Três Irmãos / Vinicius Bartholomei Giraldo;
 orientador Rogério Andrade Flauzino. São Carlos, 2019.

 Monografia (Graduação em Engenharia Elétrica com
 ênfase em Sistemas de Energia e Automação) -- Escola de
 Engenharia de São Carlos da Universidade de São Paulo,
 2019.

 1. modelo ARIMA. 2. modelo ETS. 3. planejamento da
 operação. 4. previsão de custo marginal de operação. 5.
 previsão de nível hidrológico. I. Título.

FOLHA DE APROVAÇÃO

Nome: Vinicius Bartholomei Giraldo

Título: "Concavidade do Custo Marginal de Operação em Termos dos Níveis Hidrológicos nos Reservatórios de Camargos e Três Irmãos"

Trabalho de Conclusão de Curso defendido e aprovado

em 04 / 12 / 2019,

com NOTA 8,5 (Oito, cinco), pela Comissão Julgadora:

Prof. Associado Rogério Andrade Flauzino - Orientador - SEL/EESC/USP

Mestre Murilo Eduardo Casteroba Bento - Doutorando - SEL/EESC/USP

Mestre Pedro Henrique Aquino Barra - Doutorando - SEL/EESC/USP

Coordenador da CoC-Engenharia Elétrica - EESC/USP:
Prof. Associado Rogério Andrade Flauzino

AGRADECIMENTOS

Agradeço todas as oportunidades de conhecer as pessoas, professores e colaboradores da USP. Agradeço aos professores da Elétrica que sempre apoiaram os alunos e contribuíram para nosso desenvolvimento pessoal.

Agradeço especialmente aos amigos da República Demorô, que serviram de suporte para meu desenvolvimento acadêmico e acompanharam meu amadurecimento social e construção de senso crítico, orbitando meu dia-a-dia com uma camaradagem genuína e oferecendo um acolhimento emocional.

Agradeço à família por todo o apoio prestado e pela confiança nos desafios que são enfrentados.

E, por fim, agradeço aos amigos do Velazquez pelo carinho que temos pelo grupo, e pela surpresa de um grupo tão heterogêneo cultivando uma amizade tão rica.

RESUMO

GIRALDO, V. B. **Concavidade do Custo Marginal de Operação em Termos dos Níveis Hidrológicos nos Reservatórios de Camargos e Três Irmãos.** 2019. 66p. Trabalho de Conclusão de Curso - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2019.

Esse trabalho aborda os conceitos de Custo Marginal de Operação (CMO) e indicadores hidrológicos na região Sudeste do Brasil e implementa uma modelagem que permite relacionar tais indicadores. Os indicadores tanto de CMO como de níveis hidrológicos são monitorados pelo Operador Nacional do Sistema Elétrico (ONS) e são divulgados dados semanais sobre tais valores. Nesse contexto, a motivação é a de entender como se comportam esses valores e qual a relação entre eles.

Palavras-chave: modelo ARIMA, modelo ETS, planejamento da operação, previsão de custo marginal de operação, previsão de nível hidrológico.

LISTA DE FIGURAS

Figura 1 – Custo Marginal de Operação (CMO), 2005-2018, em BRL por <i>MWh</i>	18
Figura 2 – Nível Hidrológico do reservatório de Camargos, 2005-2018 (%).	19
Figura 3 – Nível Hidrológico do reservatório de Três Irmãos, 2005-2018. (%)	19
Figura 4 – Diagrama simplificado do sistema elétrico. Fonte: El-Hawary (2000)	20
Figura 5 – Diagrama de blocos do sistema de previsão do <i>Alteryx</i>	33
Figura 6 – Níveis Hidrológicos por Semana Operativa de Camargos, Jan-Nov 2019 (%)	34
Figura 7 – Níveis Hidrológicos por Semana Operativa de Camargos, Jan-Nov 2019 (%)	35
Figura 8 – Níveis Hidrológicos por Semana Operativa de Três Irmãos, Jan-Nov 2019 (%)	36
Figura 9 – Níveis Hidrológicos por Semana Operativa de Três Irmãos, Jan-Nov 2019 (%)	37
Figura 10 – PLD por Semana Operativa, Jan-Nov 2019, BRL por <i>MWh</i>	39
Figura 11 – PLD por Semana Operativa, Jan-Nov 2019, BRL por <i>MWh</i>	40
Figura 12 – PLD por Semana Operativa, Jan-Nov 2019, BRL por <i>MWh</i>	40
Figura 13 – PLD por Semana Operativa, Jan-Nov 2019, BRL por <i>MWh</i>	41
Figura 14 – Diagrama de Decisão de Afluência	53

LISTA DE TABELAS

Tabela 1 – Projeção da carga de energia $MW_{\text{médio}}$, 2019-2023	23
Tabela 2 – Acréscimos anuais da carga de energia, $MW_{\text{médio}}$, 2019-2023	24
Tabela 3 – Projeção da Demanda Máxima Integrada, MWh/h	24
Tabela 4 – Projeção da Demanda Máxima Instantânea, MW	24
Tabela 5 – Inflação Acumulada, 2005-2018	32
Tabela 6 – Erros dos modelos apresentados, sobre os dados observados de 2019	41
Tabela 7 – Cotação Semanal dos Indicadores de CMO e PLD, em BRL por MWh , 2005-2018	42
Tabela 8 – Cotação Semanal dos Ativos, em BRL, 2005-2018	43
Tabela 9 – Cotação Semanal dos Ativos, em USD, 2005-2018	43
Tabela 10 – Cotação Semanal dos Ativos, em BRL, 2005-2018	44
Tabela 11 – Acréscimos anuais da carga de energia, $MW_{\text{médio}}$, 2019-2023	47

LISTA DE ABREVIATURAS E SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
ACL	Ambiente de Contratação Livre
ACR	Ambiente de Contratação Regulada
ANEEL	Agência Nacional de Energia Elétrica
BRL	Real do Brasil
CAGR	Taxa Composta Anual de Crescimento (do inglês, <i>Compound Annual Growth Rate</i>)
CCEE	Câmara de Comercialização de Energia Elétrica
CMO	Custo Marginal de Operação
EPE	Empresa de Pesquisa Energética
ONS	Operador Nacional do Sistema Elétrico
PLD	Preço de Liquidação de Diferenças
TCC	Trabalho de Conclusão de Curso
TMO	Tarifa Marginal de Operação
USD	Dólar dos Estados Unidos
USP	Universidade de São Paulo

SUMÁRIO

1	INTRODUÇÃO	17
1.1	Diagrama do sistema elétrico	20
2	PROJEÇÃO DO AUMENTO DE CARGA DE ENERGIA NO BRASIL	23
3	SÉRIES TEMPORAIS	27
3.1	Previsão de séries temporais	27
4	DESENVOLVIMENTO	31
4.1	Ajuste de PLD e CMO para Inflação	31
4.2	Resultados e Discussão	33
4.2.1	Previsão de Níveis Hidrológicos com ARIMA e ETS	34
4.2.2	Previsão de PLD para 2019	37
4.3	Volatilidade e Risco	42
4.3.1	Risco em termos estatísticos	45
4.3.1.1	Modelo CAPM	45
5	CONCLUSÃO	49
	REFERÊNCIAS	51
	APÊNDICE A – EQUAÇÃO DE GERAÇÃO HIDROELÉTRICA	53
	APÊNDICE B – <i>SUMÁRIO</i> DOS COEFICIENTES ARIMA	55
	APÊNDICE C – <i>SUMÁRIO</i> DOS COEFICIENTES ETS	57
	APÊNDICE D – <i>SUMÁRIO</i> DO MODELO SPLINE	61
	APÊNDICE E – <i>SUMÁRIO</i> DO MODELO DE REGRESSÃO LI- NEAR	65

1 INTRODUÇÃO

A energia elétrica é o segundo maior item que compõe a cesta do IPCA que calcula a inflação no Brasil. Segundo dados do IBGE , apenas a gasolina tem maior peso sobre a inflação, com um valor de 5,1% contra 4,0% da energia elétrica residencial. E por que um indicador tão importante como a energia pode ser tão difícil de se prever?

Em se tratando de energia, é muito importante a escolha de um tema em específico que possa ser de interesse para aprofundamento. Para a realização deste trabalho, a motivação surgiu de compreender melhor o que justifica uma variação tão elevada em um indicador importante de energia, chamado de Custo Marginal de Operação (CMO). Esse indicador é monitorado constantemente pelo Operador Nacional do Sistema Elétrico (ONS) e é divulgado semanalmente, separado em categorias de região e carga:

- Região: Sudeste/Centro-Oeste, Sul, Nordeste e Norte

- Carga: Leve, Média ou Pesada

Nas tabelas e modelos utilizados no trabalho, foi utilizado especificamente o CMO de Carga Média da Região Sudeste, por refletir um indicador mais compatível com os demais dados utilizados no modelo, que serão explicados adiante.

É evidente que por se tratar de um indicador marginal, os seus valores não refletem o preço da energia como um todo, então não seria extrapolar o seu valor como um índice geral de preços ao consumidor. Porém, o indicador pode ser importante para incrementos de energia no sistema.




Figura 1: Custo Marginal de Operação (CMO), 2005-2018, em BRL por *MWh*.

Fonte: Elaborada pelo autor.

A Figura 1 mostra o CMO entre 2005 e 2018, com dados de 731 semanas. A concavidade na qual o título do trabalho se refere ilustra a relação entre esse indicador de CMO com os níveis hidrológicos dos reservatórios na mesma região Sudeste. Isso é explicado pela elevada relevância que as bacias hidrelétricas têm no sistema elétrico, em especial no Brasil. Além disso, níveis saudáveis dos reservatórios permitem melhor controle e previsão de consumo de toda essa energia armazenada em forma de volume de água nas barragens.

Segundo Lima (2018), em razão da predominância de geração por meio de fontes hídricas no país, é esperado que a variabilidade das vazões fluviais e níveis hidrológicos interfiram de forma significativa na oferta de geração disponível. Como há um limite na capacidade de armazenamento dos reservatórios e os níveis dependerem das condições climáticas futuras, existem incertezas relacionadas ao suprimento de energia elétrica, tornando assim o país vulnerável às condições hidrológicas.




Figura 2: Nível Hidrológico do reservatório de Camargos, 2005-2018 (%).

Fonte: Elaborada pelo autor.

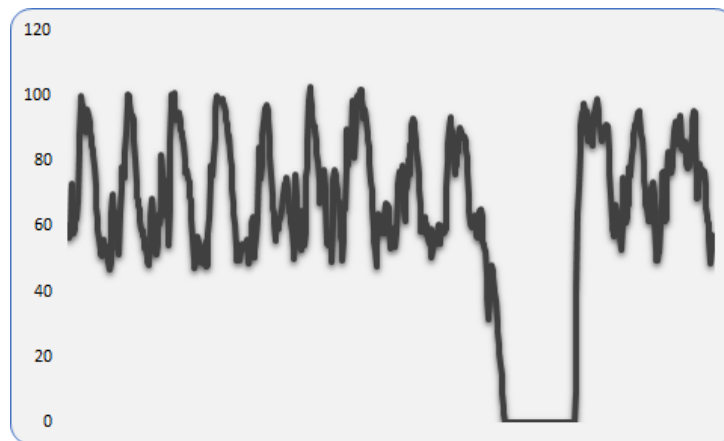


Figura 3: Nível Hidrológico do reservatório de Três Irmãos, 2005-2018. (%)

Fonte: Elaborada pelo autor.

A Figura 2 mostra a variação de seu nível hidrológico entre 2005 e 2018, enquanto a Figura 3 mostra a variação do reservatório de Três Irmãos, sobre o mesmo período. As figuras acima são, por enquanto, ilustrativas, e seus dados serão melhor explorados no decorrer do trabalho. Mas é importante que fique claro com tais ilustrações a grande variação do CMO e a sazonalidade dos níveis hidrológicos. Essas características serão importantes para a construção dos modelos no trabalho.

Portanto, para compreender melhor o que justifica essa variação nos preços do CMO, o trabalho está dividido em capítulos acerca do tema, e a expectativa ao final do trabalho é comparar diferentes modelos de previsão de dados e quantificar o risco associado a preços voláteis. Ao final, são acrescentados temas qualitativos no que diz respeito ao futuro e tendência da energia no Brasil.

Os temas discutidos neste trabalho são:

- Operação e comercialização da energia elétrica no Brasil
- Projeção do aumento da carga de energia no Brasil
- Comparativos de volatilidade, risco e custo de volatilidade
- Modelos de previsão utilizados no *Software Alteryx* e resultados
- Conclusão e Próximos Passos.

1.1 Diagrama do sistema elétrico

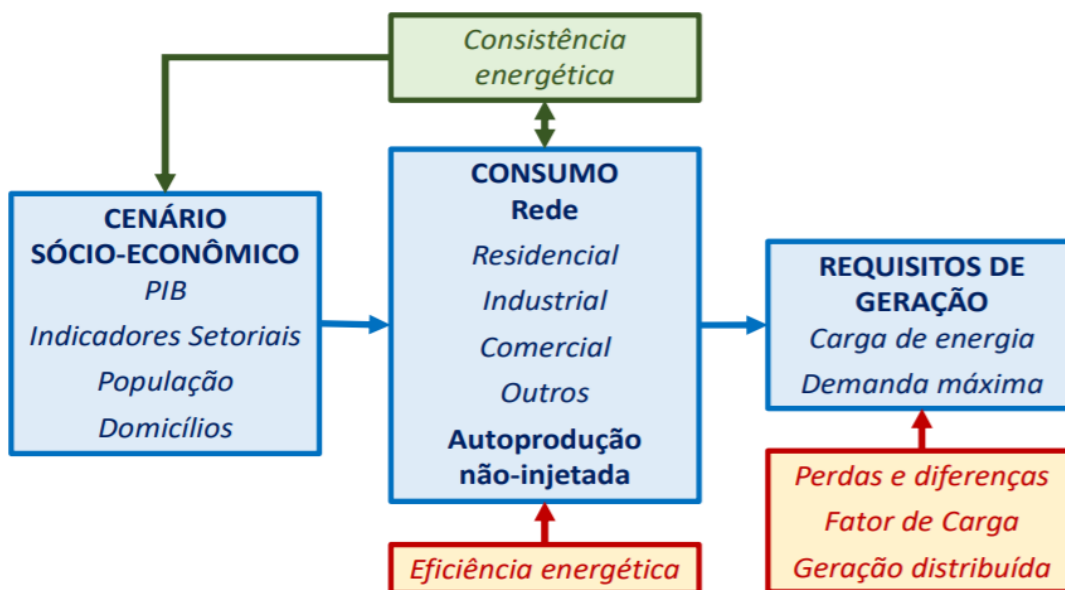


Figura 4: Diagrama simplificado do sistema elétrico. Fonte: El-Hawary (2000)

Na Figura 4, há um diagrama que simplifica os fatores envolvidos no equilíbrio energético. A consistência energética depende desse equilíbrio entre dois lados: primeiro, o consumo da energia, onde os principais usos são residenciais, industriais, comerciais, de iluminação pública, etc; e do outro lado, a geração de energia, que depende de fatores de carga de energia e que suportam uma demanda máxima.

Em adição ao equilíbrio na rede elétrica, e para trazer mais complexidade à consistência energética, pode-se citar fatores de qualidade e de eficiência da energia elétrica, que estão ilustrados pelas caixas laranjas no diagrama.

Há ainda fatores extrínsecos à engenharia elétrica, mas que têm grande influência também, que são os indicadores socio-econômicos como o PIB, além de tendências e hábitos de consumo.

No Brasil, as 4 regiões controladas pelo ONS operam em conjunto, de forma que quando há uma falta de geração na região sudeste, esse consumo pode ser suprido por vias de exportação de energia das outras regiões do Brasil.

2 PROJEÇÃO DO AUMENTO DE CARGA DE ENERGIA NO BRASIL

Em se tratando de um trabalho que envolve o custo marginal da energia, é importante conhecer a projeção de demanda e as cargas previstas para os próximos anos. Nas tabelas abaixo, são mostradas as projeções para o quadriênio 2019-2023 de indicadores de carga e de demanda máxima.

Tabela 1: Projeção da carga de energia $MW_{médio}$, 2019-2023

Subsistema	2019	2020	2021	2022	2023	$\Delta\%$ ao ano
Norte	5.621	6.020	6.235	6.482	6.942	5,2
Nordeste	11.115	11.618	12.125	12.680	13.249	4,2
Sudeste/CO	39.888	41.136	42.553	44.054	45.620	3,2
Sul	11.713	12.091	12.545	13.031	13.527	3,3
SIN	68.338	70.864	73.458	76.246	79.338	3,6

Fonte: EPE/ONS/CCEE.

Na Tabela 1, observamos a projeção de carga segmentada por subsistemas, do ano de 2019 até 2023. O sistema como um todo é composto pelo Sistema Interligado Nacional (SIN). Na última coluna, temos o CAGR (taxa composta anual de crescimento) frente ao ano de 2018. Ou seja, a ONS espera um crescimento de carga média de 3,6% ao ano até 2023. Os dados da ONS projetam uma carga média no SIN de 68.338 MW para o ano de 2019, contra uma carga de 79.338 MW para o ano de 2023.

Nas Tabelas seguintes – aproveitando a mesma fonte e análises da Tabela 1 – encontramos dados de projeção de carga referentes a períodos de pico na operação do sistema. Isso é importante de destacar, em função do custo agregado à variação da carga do sistema ao longo do dia.

Na projeção de demanda máxima sobre um período de uma hora, a ONS avalia um pico em torno de 91 GW e 103 GW para 2019 e 2023, respectivamente, de acordo com a Tabela 3.

Já sobre uma visão de demanda de carga instantânea, os valores são um pouco maiores, segundo a Tabela 4. Ainda de acordo com a ONS, espera-se um pico de até 104 GW até o ano de 2023, representando uma grande acréscimo frente à média de 68 GW de 2019, como mostrado na Tabela 1.

Os períodos de pico são os que apresentam maior desafio para a operação do sistema, por dois motivos principais: primeiro, que objecciona picos de carga na rede que

Tabela 2: Acréscimos anuais da carga de energia,
 $MW_{médio}$, 2019-2023

Subsistema	2019	2020	2021	2022	2023
Norte	244	399	215	247	460
Nordeste	312	503	507	554	569
Sudeste/CO	996	1.247	1.417	1.501	1.566
Sul	227	378	455	486	497
SIN	1.779	2.526	2.594	2.788	3.092

Fonte: EPE/ONS/CCEE.

Tabela 3: Projeção da Demanda Máxima Integrada,
 MWh/h

Subsistema	2019	2020	2021	2022	2023
Norte	6.956	7.231	7.491	7.787	8.302
Nordeste	13.939	14.347	14.974	15.661	16.362
Sudeste/CO	54.012	54.257	56.133	58.160	60.179
Sul	18.997	18.582	19.283	20.039	20.792
SIN	90.686	92.425	95.797	99.429	103.304

Fonte: EPE/ONS/CCEE.

Tabela 4: Projeção da Demanda Máxima Instantânea,
 MW

Subsistema	2019	2020	2021	2022	2023
Norte	7.027	7.330	7.590	7.893	8.478
Nordeste	14.055	14.467	15.099	15.791	16.498
Sudeste/CO	54.396	54.741	56.633	58.642	60.716
Sul	19.165	18.742	19.449	20.212	20.972
SIN	91.279	93.110	96.508	100.167	104.070

Fonte: EPE/ONS/CCEE.

sobrecarregam as redes de distribuição do sistema, em especial nos períodos de altas temperaturas, que mitigam os benéficos efeitos de convecção natural dos transformadores e linhas de distribuição; e segundo, pois são os momentos pico que propiciam o aumento do CMO, já que um pico de carga exige suprimentos temporários de energia.

Os dados encontrados nesse capítulo serão relevantes para, adiante, estudar o risco e volatilidade dos indicadores de energia, além de aplicar métodos de análise financeira

sobre tais indicadores, para que seja possível quantificar o custo envolvidos nesses dados estatísticos de risco e volatilidade.

Na próxima seção, será melhor explorado o sistema elétrico brasileiro e suas regulações, bem como o funcionamento dessa operação atual, explorando os atuais modelos de negócio utilizados. Essas informações serão relevantes para adotar as premissas do trabalho.

3 SÉRIES TEMPORAIS

Neste capítulo, serão introduzidos de forma qualitativa quais os principais modelos de previsão utilizados nos resultados do trabalho, de forma que cada um dos modelos possui suas vantagens específicas.

3.1 Previsão de séries temporais

Uma série temporal é uma sequência de previsões onde a sua métrica é medida sobre intervalos regulares de tempo. Dependendo da frequência, uma série temporal pode ser anual (como um orçamento anual), trimestral (despesas, por exemplo), mensal (tráfego aéreo), semanal (quantidade de vendas), diária (previsão do tempo), de hora em hora (preço de ativos), a cada minuto (número de chamadas em um call center) ou até a cada segundo (monitoramento do tráfego da internet). A chamada previsão é a próxima etapa, onde é necessário prever os valores futuros da série que está sendo avaliada.

A vantagem de um tipo de estudo desses é de que a previsão de séries temporais (como vendas e demanda) pode ter um enorme valor comercial. Tomando como exemplo, em uma empresa de manufatura, as previsões afetam o planejamento do negócio e as atividades de produção. Qualquer erro na medida de previsão pode afetar toda a cadeia produtiva. Então é importante se utilizar uma previsão rigorosa que seja capaz de evitar eventuais custos extras ao negócio. Não apenas na manufatura, mas as técnicas e conceitos por trás das séries temporais podem ser aplicadas para quaisquer negócios, e nesse trabalho será utilizado para prever os níveis hidrológicos.

As séries temporais podem ser divididas em dois tipos. Utilizando como entrada do modelo somente o histórico passado para prever os valores futuros, temos neste caso o modelo de Previsão de Séries Temporais Univariável. Porém, se forem utilizadas outras variáveis, como variáveis exógenas, para a previsão, neste caso teremos o modelo de Previsão de Séries Temporais Multivariável.

Os dois principais modelos utilizados no trabalho são o modelo ARIMA e o ETS.

O modelo ARIMA, que é uma abreviação para (*AutoRegressive Integrated Moving Average*), é um algoritmo de previsão baseado na premissa de que a informação dos valores passados da série temporal podem ser suficientes para prever os valores futuros.

O modelo ETS (do inglês, *Exponential Smoothing Time Series Forecasting*), assim como o modelo ARIMA, também é um modelo utilizado para predição e previsão de dados.

Modelos como o ARIMA apresentam uma característica onde a previsão utiliza o histórico de dados por uma soma ponderada dos valores observados.

O modelo ETS é semelhante no sentido de utilizar uma soma ponderada do histórico de dados, porém o modelo utiliza um decrescimento exponencial das observações passadas. Especificamente, observações passadas são ponderadas por meio de uma taxa geometricamente decrescente.

Pode-se definir o modelo ETS como um modelo onde os valores mais recentes têm maior peso sobre a construção do modelo utilizado.

Portanto, nesse trabalho será observado qual dos modelos se comporta de forma mais próxima à real e tentar explicar o motivo desse resultado.

Existem três métodos principais de séries do tipo ETS.

- Suavização Exponencial Simples
- Suavização Exponencial Dupla
- Suavização Exponencial Tripla.

Um método do tipo simples assume que não há uma estrutura sistemática, uma extensão que explicitamente lida com tendências, e é um modelo avançado que traz suporte para dados com sazonalidade. O modelo de Suavização Exponencial Simples é um método ETS para dados univariáveis sem uma tendência ou sazonalidade. Nesse modelo, é necessário apenas um único parâmetro, chamado de α , também conhecido como fator de suavização ou coeficiente de suavização.

Esse parâmetro controla a taxa na qual a influência das observações no histórico observado decaem exponencialmente. O α é normalmente um valor entre 0 e 1. Altos valores de α indicam que o modelo é focado principalmente nas observações mais recentes; já um α mais próximo de zero indica um modelo onde os valores mais distantes do presente também têm grande influência na previsão de dados. Nos extremos dessa faixa, então, ocorre o seguinte: valores próximos a 1 indicam rápido aprendizado (ou seja, apenas os valores mais recente influenciam na previsão), já um valor próximo de zero indica aprendizado lento, porque observações passadas também possuem grande influência.

Para o segundo modelo, tem-se a Exponencial de Suavização Dupla. Nesse método, há uma extensão do método ETS que explicitamente dá suporte para tendências no histórico de séries observado.

Em adição ao coeficiente α , conforme explicado acima para o controle do fator de suavização, há um fator adicional para essa suavização que é adicionado ao controle do decaimento da influência de mudança na tendência introduzida. Esse segundo fator possui o nome de beta (β).

O método de Suavização Exponencial Dupla suporta tendências que variam de jeitos diferentes: tanto de forma aditiva como multiplicativa, dependendo conforme essa tendência

seja linear ou exponencial, respectivamente. Quanto à modelagem dessa tendência em si, é possível utilizar os mesmos princípios de amortecimento utilizado para o α .

Também existe um terceiro método, chamado de Suavização Exponencial Tripla, que é uma extensão do modelo tradicional que também traz suporte para a sazonalidade de séries temporais univariáveis.

Nesse modelo, há um novo fator gamma (γ) para controle. Além do α , utilizado como coeficiente de suavização dos valores observados, e do β , utilizado como coeficiente de suavização da sazonalidade observada, o terceiro fator γ controla a influência dessa componente sazonal. Assim como na tendência verificada, a sazonalidade também pode ser modelada seja com um processo aditivo ou multiplicativo para uma mudança linear ou exponencial na sazonalidade apresentada.

Esse modelo, com os três fatores, é a variação mais avançada nos métodos de ETS, e um modelo desse também é capaz de entregar modelos de suavização simples e dupla. Sendo um modelo adaptativo, é possível que os padrões tanto de influência, como de tendência e de sazonalidade se alterem ao longo do tempo. Adicionalmente, para garantir que tal sazonalidade seja modelada corretamente, o número de observações dentro de um mesmo período deve ser especificado. Por exemplo, se a série é observada mensalmente e a sazonalidade ocorre todos os anos, então o período dessa modelagem será 12.

No caso desse trabalho, como as observações disponíveis na ONS de forma mais granular é de frequência semanal, então o modelo utilizado seria para um período igual a 52. Esse método, entretanto, pode ser bastante desafiador para iniciantes na modelagem. Ao invés, é comum a utilização de otimização numérica para pesquisa de coeficientes no modelo ETS que resultem no menor erro possível.

Um jeito mais robusto e objetivo de obter valores para parâmetros desconhecidos em qualquer método de suavização exponencial é estimá-los a partir de dados já observados. Os parâmetros desconhecidos e seus valores iniciais para qualquer método de suavização exponencial pode ser estimado pela minimização do método de soma dos erros ao quadrado.

4 DESENVOLVIMENTO

4.1 Ajuste de PLD e CMO para Inflação

Para utilizar como entrada dos modelos utilizados, será preciso realizar um ajuste nos valores de PLD e CMO, de forma que o preço-base utilizado para todas as semanas foi o de 2019.

Como o modelo trata de um espectro de tempo de 731 semanas, espalhadas por 14 anos, a influência da inflação ao longo do tempo será ajustada para trabalhar todo o espectro com a mesma base.

Os dados utilizados no desconto da inflação são oficiais do IBGE, utilizando os dados de série histórica nacional. Por simplificação, foi utilizado o valor de inflação acumulado no ano, cuja variação semanal ao longo desse ano foi feita com uma extrapolação linear. Ou seja, foi considerado que em um mesmo ano a inflação de cada semana sofreu a mesma variação.

$$I(k, n) = i(ac_k - 1) + \left(1 + i(k)\right)^{\frac{n}{N}} - 1 \quad (4.1)$$

Onde,

- $I(k, n)$ é a inflação acumulada na semana n do ano correspondente k
- $I(ac_k - 1)$ é o valor da inflação acumulada até o final do ano anterior, disponível na tabela abaixo
- $i(k)$ é a inflação no ano correspondente
- N é o total de semanas no ano correspondente, que podem ser 52 ou 53.

A Equação 4.1 descreve como os registros de valores passados serão reajustados de acordo com a inflação. Quanto maior a inflação acumulada no período, maior o valor reajustado, de forma que os dados de 2005 serão os mais influenciados no modelo.

Tabela 5: Inflação Acumulada, 2005-2018

Ano	Inflação no Ano (%)	Inflação Acumulada (%)
2005	5,69	5,7
2006	3,14	9,0
2007	4,46	13,9
2008	5,90	20,6
2009	4,31	25,8
2010	5,91	33,2
2011	6,50	41,9
2012	5,84	50,2
2013	5,91	59,0
2014	6,41	69,2
2015	10,67	87,3
2016	6,29	99,1
2017	2,95	104,9
2018	3,75	112,6

Fonte: IBGE.

Na Tabela 5, há o histórico dos valores da inflação a cada ano. Para exemplificar a simplificação que foi utilizada, pode ser realizado um exemplo. Na semana 22 do ano de 2015, a inflação acumulada pode ser calculada da seguinte forma:

$$I(2015, 22) = i(ac_{2014}) + \left(1 + i(2015)\right)^{\frac{22}{52}} - 1 = 69,2\% + (1 + 0,1067)^{0,4231} - 1 = 77,0\%$$

O valor do PLD na CCEE dessa semana em específico é de R\$ 374,07, conforme histórico de dados. Porém, para ajustar os valores conforme base 2019, esse preço será ajustado pela razão entre a inflação acumulada total no período (112,6%) pela inflação acumulada até $I(k, n)$:

$$PLD_{ajustado} = 374,07 \cdot \frac{77,0}{112,6} = 449,38$$

Esse método foi utilizado em todos os valores de preços nas análises para ajustá-los ao ano de 2019.

Seria possível também utilizar os dados do IBGE de inflação acumulada mês a mês, de todos os anos avaliados. Porém, por ser uma aproximação boa o suficiente, foi utilizado o método explicado acima.

4.2 Resultados e Discussão

Os resultados encontrados, que serão discutidos nesta seção, foram desenvolvidos com o suporte do *Alteryx*, que é um programa semelhante ao *Simulink* no sentido de inserir caixas de funções em uma malha que tem uma sequência de etapas. A motivação para utilização deste *software* ocorre em função da grande quantidade de modelos de regressões nele disponível. Ao final da simulação, são retornados os dados das simulações, junto com os coeficientes e métodos utilizados para cada uma delas. Os coeficientes encontram-se no apêndice do trabalho, e podem ser consultados para comparar com outros modelos.

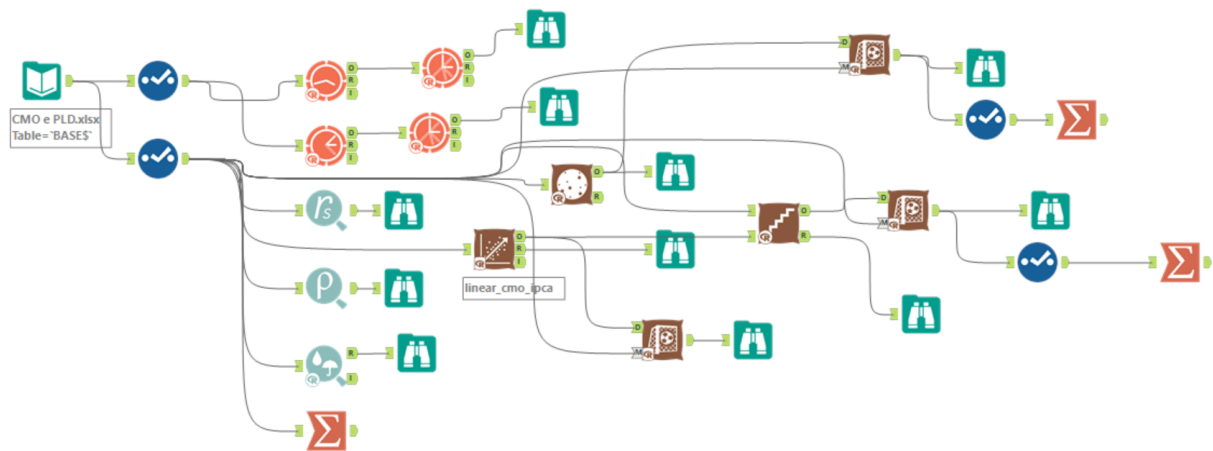


Figura 5: Diagrama de blocos do sistema de previsão do *Alteryx*

Fonte: Elaborada pelo autor.

A Figura 14 mostra o modelo utilizado para as simulações, com os dados de níveis hidrológicos e os dados de preços da energia ajustados pela inflação. A entrada do sistema foram os históricos de dados de três fatores: PLD ajustado, Nível Hidrológico de Camargos e Nível Hidrológico de Três Irmãos, todos com os dados semanais de 2005 até o final de 2018, totalizando 731 linhas para cada uma das entradas.

Nos 8 gráficos apresentados a seguir, há um total de 43 valores reais medidos de 2019, que se estendem de Janeiro a Novembro de 2019. No caso dos modelos de previsão, foram utilizados um total de 52 valores de previsão, por serem equivalentes a todo ano de 2019.

O objetivo será de descrever brevemente cada resultado obtido nessas simulações e explicar o motivo de cada resultado encontrado. Ao final dos gráficos apresentados, será mostrada uma tabela que compare os resultados, quantificando os erros observados em cada uma das medições.

Todas as curvas em preto destacam os valores reais de 2019, obtidos tanto pelo

site da ONS como pelo site da CCEE.

O objetivo dos modelos foi de entender se é possível um modelo de previsão que acompanhe ao menos metade da curva sazonal, ou seja, acompanhe os dados reais em 26 medidas.

Porém, para dar mais consistência aos dados, o modelo foi comparado não só com as 26 primeiras semanas do ano como também das semanas seguintes, permitindo um total de 43 semanas avaliadas.

Os valores de coeficientes e um sumário dos modelos utilizados em cada gráfico estão na apêndice desse trabalho.

4.2.1 Previsão de Níveis Hidrológicos com ARIMA e ETS

Nos gráficos abaixo, serão apresentados os resultados encontrados dos modelos ARIMA e ETS para os níveis hidrológicos de dois reservatórios da região Sudeste: Camargos e Três Irmãos.

Portanto, foram gerados um total de 4 gráficos.

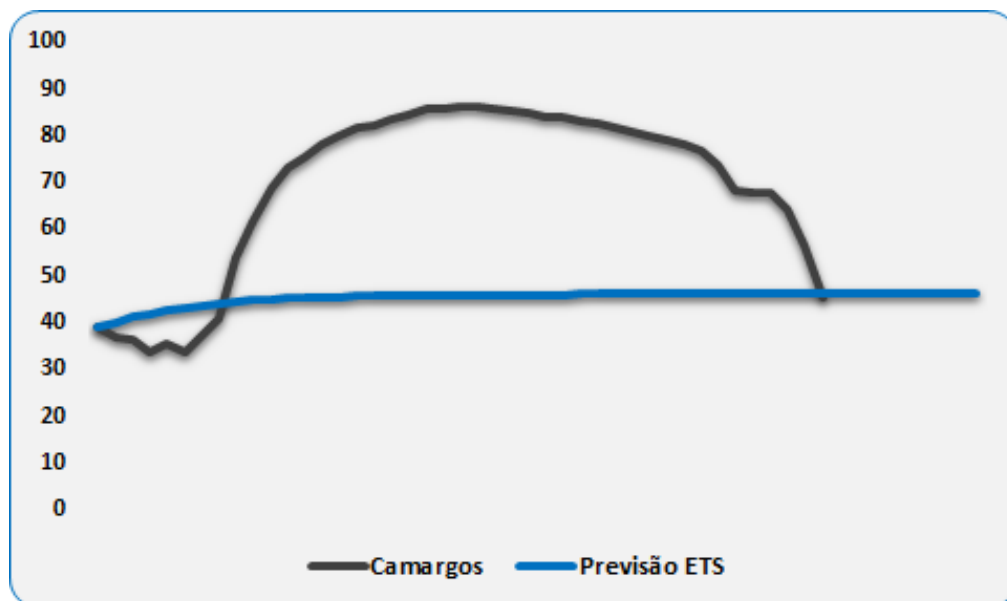


Figura 6: Níveis Hidrológicos por Semana Operativa de Camargos, Jan-Nov 2019 (%)

Fonte: Elaborada pelo autor.

Na Figura 6, tem-se a curva de previsão com o modelo ETS e a curva real bastante defasadas entre si. Isso ocorreu, principalmente, porque não foi possível encontrar coeficientes adequados para o modelo. Na seção do tipo do modelo em *Alteryx*, não foi possível encontrar valores favoráveis de tipo de erro, tipo de tendência e tipo de amortecimento que pudessem diminuir o erro do modelo. Com isso, no modelo utilizado no *software* todos

esses parâmetros ficaram no modo *Auto*, de modo que o próprio algoritmo do programa que realizou a modelagem. E por essas limitações, não foi possível a variação desses dados para obter resultados mais coerentes.

E justamente por ser um modelo que leva mais em conta os últimos valores observados na série histórica, nota-se que os valores obtidos no modelo variam muito pouco em relação ao último dado observado.

Já os dados dos níveis hidrológico de Camargos apresenta uma variação expressiva ao longo do ano, e essa variação é realmente uma observação esperada e que deveria ter sido computada num modelo mais próximo dos resultados reais.

Apesar de tudo isso, porém, para o modelo em ARIMA foram encontrados resultados muito mais coerentes.

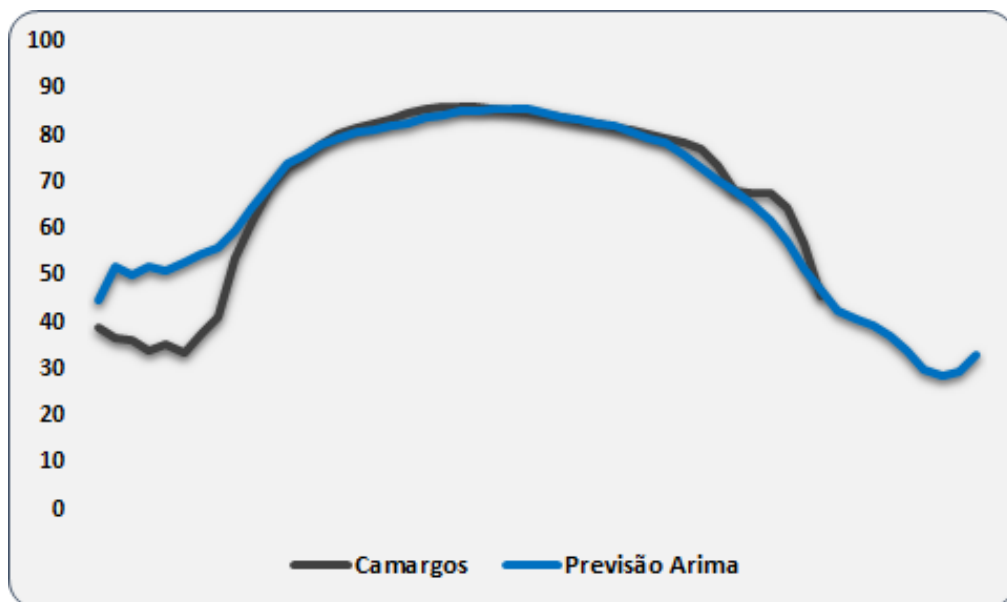


Figura 7: Níveis Hidrológicos por Semana Operativa de Camargos, Jan-Nov 2019 (%)

Fonte: Elaborada pelo autor.

Na Figura 7, tem-se os resultados obtidos de previsão com o modelo ARIMA, os valores em azul estão bem próximos dos valores reais observados nas primeiras 43 semanas de 2019. Apenas no início do ano de 2019 que houve uma variação que não foi acompanhada pelo modelo.

Nesse segundo modelo, os parâmetros também foram obtidos de forma *Auto* pelo *Alteryx*, de forma que nesse caso foi possível um resultado onde o modelo entende que há uma sazonalidade na série histórica de 2005 a 2018 do nível hidrológico de Camargos.

Apesar do bom resultado observado, contudo, não seria possível que o modelo fosse tão robusto caso o ano de 2019 fosse atípico em relação à média dos anos em relação à

volumes pluviométricos e vazões afluentes.

Ou seja, é possível que o modelo deva ser melhor avaliado, possivelmente comparando com os dados até o final de 2019 e até mesmo de 2020, para questionar a robustez do modelo apresentado.

Ainda assim, na tabela ao final dos resultados apresentados será evidente que os erros contidos nesse modelo ficou mais adequado que os outros gráficos obtidos no projeto.

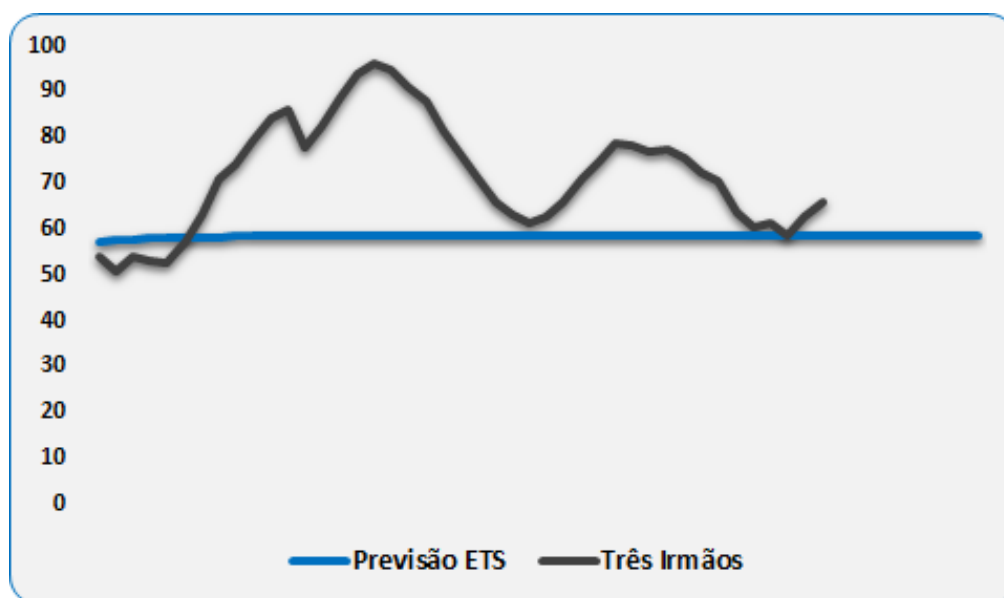


Figura 8: Níveis Hidrológicos por Semana Operativa de Três Irmãos, Jan-Nov 2019 (%)

Fonte: Elaborada pelo autor.

Na Figura 8, como forma de comparar os resultados do reservatório de Camargos com outros reservatórios, os dados do reservatório de Três Irmãos para servir de uso para os modelos.

No modelo ETS, nota-se novamente uma curva que pouco varia nas 52 semanas simuladas em relação ao último dado observado de 2018.




Figura 9: Níveis Hidrológicos por Semana Operativa de Três Irmãos, Jan-Nov 2019 (%)

Fonte: Elaborada pelo autor.

A figura 9 mostra a simulação do modelo ARIMA para os dados de Três Irmãos. Para avaliar a robustez do modelo ARIMA, que apresentou resultados mais satisfatórios com o reservatório de Camargos, também foi utilizado o mesmo modelo para prever os níveis de Três Irmãos. O modelo também apresentou resultados mais satisfatórios do que o modelo ETS.

Novamente, os erros e desvios apresentados no modelo de previsão em relação aos dados reais serão disponibilizados na tabela ao final da apresentação dos gráficos. Com os resultados encontrados nesses 4 primeiros gráficos, fica evidente o modelo ARIMA como de maior valor para os próximos passos do trabalho. Portanto, ele será utilizado para a previsão dos preços de energia para 2019.

4.2.2 Previsão de PLD para 2019

O objetivo dos resultados anteriores foi de observar se existe um modelo de previsão do nível dos rios que fosse confiável. Agora que foi escolhido o modelo ARIMA, os resultados obtidos do modelo, tanto para os 52 dados estimados de Camargos como os 52 dados estimados de Três Irmãos, serão utilizados a seguir para prever o preço futuro de energia a partir das estimativas encontradas.

No caso a seguir, então, nos modelos de previsão de PLD, **há duas incertezas no modelo**. Primeiro, são utilizados os dados de previsão obtidos com o modelo ARIMA anteriormente, que se aproximaram melhor da curva real em comparação ao modelo ETS.

A partir dos dados previstos para 2019, foram realizados modelos de regressão

linear sobre o histórico de dados, de 2005 a 2018, e sobre os dados previstos, de Janeiro a Dezembro de 2019. Nesse caso, **os modelos utilizaram um total de 783 dados, sendo 731 dados históricos e 52 dados obtidos no ARIMA.**

A ideia com esses gráficos é entender se é possível, dado um conhecimento da sazonalidade dos rios no Sudeste, estimar com precisão tanto o nível futuro dos rios como o preço futuro da energia (utilizando, neste caso, o PLD). É evidente que os dados aqui obtidos contém incertezas e premissas que não permitiriam a um investidor se confortar e se apoiar em tal modelo. Mas conhecendo os fatores predominantes que afetam o preço da energia, pode-se lançar luz nesse tema de previsão, que com a evolução dos modelos de negócio no setor de energia podem se tornar mais relevante.

Para estimativas de preços futuros de energia, novamente foram utilizados dois modelos em *Alteryx*, com o objetivo de comparar ambos os modelos com os dados reais disponíveis de 2019.

Os modelos utilizados foram o de **regressão linear e o modelo Spline**, que são ferramentas que podem auxiliar um engenheiro na construção de modelos robustos.

A regressão linear pode criar tanto um modelo simples para estimar valores, como estabelecer relações entre variáveis baseado em uma relação linear. Por exemplo, o modelo pode ser eficiente para avaliar o impacto financeiro do valor de uma casa em função do número de banheiros e quartos que a mesma contém, para um mercado em específico.

O modelo Spline, por outro lado, permite prever o valor de uma variável de interesse baseado em uma ou mais informações que possam estabelecer uma relação não-linear com a variável de interesse.

Novamente, os resultados em azul refletem as estimativas dos modelos, enquanto que os resultados em preto são os valores reais disponíveis no site da CCEE.




Figura 10: PLD por Semana Operativa, Jan-Nov 2019, BRL por *MWh*

Fonte: Elaborada pelo autor.

Na Figura 10, temos o modelo Spline utilizando os resultados de Camargos para prever o PLD Médio da região Sudeste para 2019. Apesar de o modelo apresentar um resultado em que a média é próxima dos valores reais, o modelo não foi capaz de endereçar as flutuações que existiram ao longo do ano no valor do PLD. E, infelizmente, é justamente esses valores de pico e de vale que seriam de mais interesse para a previsão para um investidor que se interesse pelo mercado de energia.

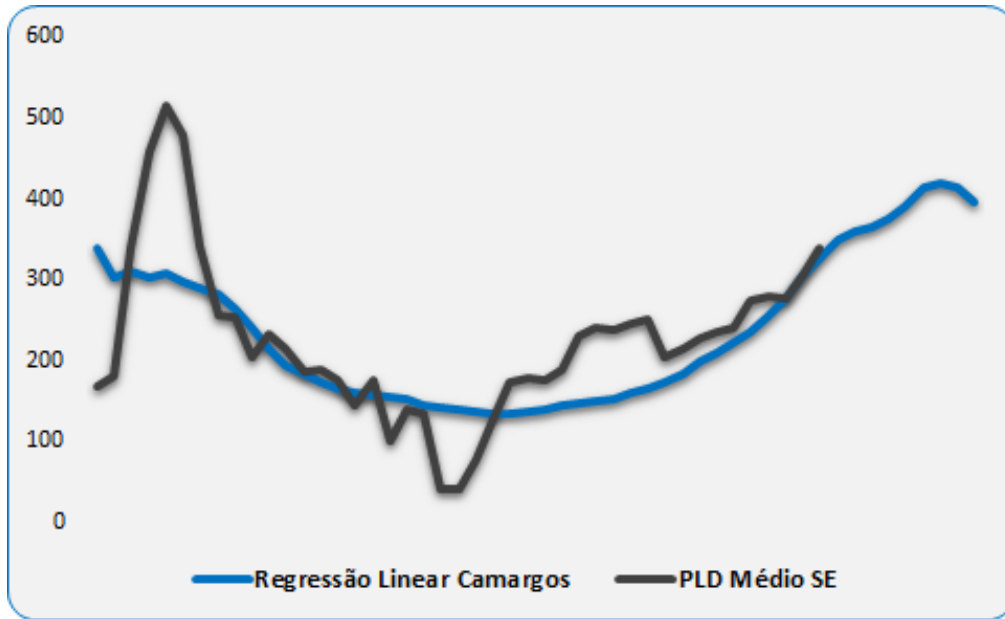


Figura 11: PLD por Semana Operativa, Jan-Nov 2019, BRL por *MWh*

Fonte: Elaborada pelo autor.

Para o modelo de regressão linear, temos na Figura 11 uma curva suavizada que acompanha melhor a tendência do preço de PLD. Os erros aqui encontrados foram, evidentemente, inferiores ao modelo Spline, porém ainda assim o modelo não foi capaz de prever os picos e vales contidos no ano de 2019.

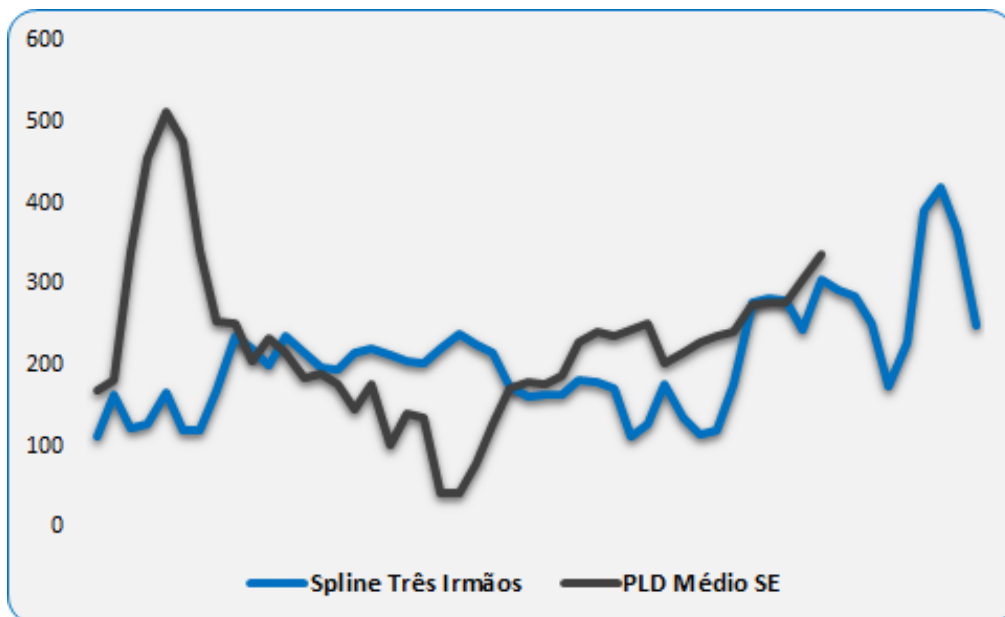


Figura 12: PLD por Semana Operativa, Jan-Nov 2019, BRL por *MWh*

Fonte: Elaborada pelo autor.

Na Figura 12, temos a mesma curva de PLD para o ano de 2019 e o mesmo modelo Spline utilizado na Figura 10. Porém, os dados estimados de PLD foram baseados no reservatório de Três Irmãos. Novamente, os resultados encontrados foram insuficientes para descrever um bom modelo de previsão, e seria necessário um modelo que englobasse outros reservatórios para um modelo um pouco melhor.

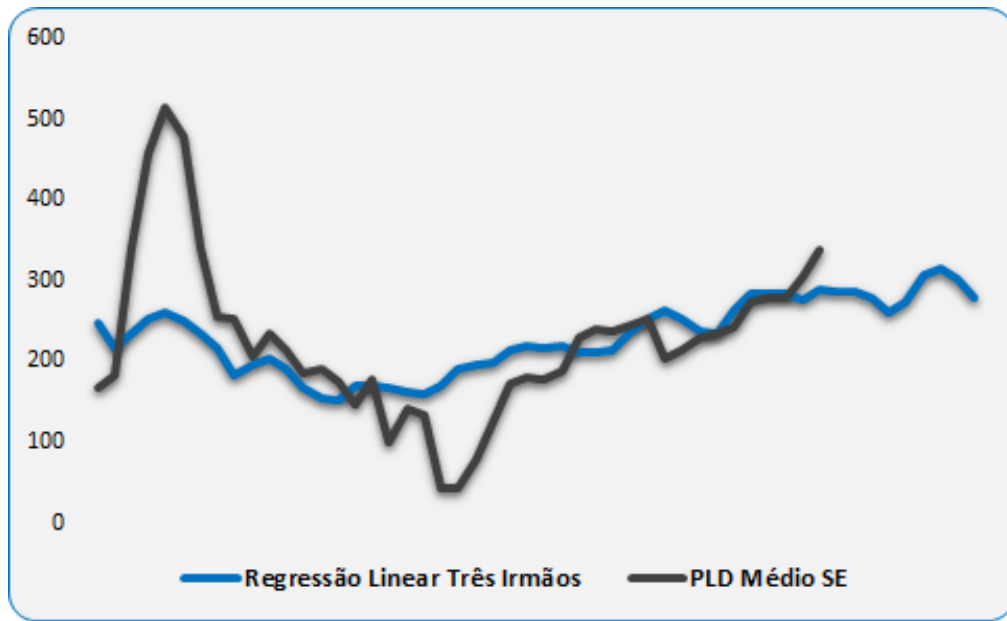


Figura 13: PLD por Semana Operativa, Jan-Nov 2019, BRL por *MWh*

Fonte: Elaborada pelo autor.

Na Figura 13, o modelo de regressão linear também se comportou de forma superior ao Spline. Porém, também não foi capaz de prever picos e vales dos valores de PLD.

Tabela 6: Erros dos modelos apresentados, sobre os dados observados de 2019

	Erro Relativo (%)	Erro Absoluto Médio	Erro Quadrático Médio
ARIMA - Camargos	9,7	4,2	49,6
ETS - Camargos	34,4	26,0	855,4
ARIMA - Três Irmãos	10,7	7,5	79,5
ETS - Três Irmãos	18,5	14,5	323,9
Spline - Camargos	37,3	60,5	7896
Regressão Linear - Camargos	31,6	51,8	5237,1
Spline - Três Irmãos	54,1	87,1	15927,7
Regressão Linear - Três Irmãos	36,4	54,0	6476,3

Fonte: Tabela elaborada pelo autor.

Conforme a Tabela 6 apresentada, o modelo mais próximo dos valores reais foi o ARIMA com os níveis hidrológicos de Camargos. O erro relativo foi de 9,7%, enquanto o erro absoluto médio foi de 4,2.

Quando se observa os modelos que visam estimar o PLD, nota-se que os erros nesses modelos foram muito maiores. Isso se deve, entre outros, ao fato de que o modelo está utilizando os dados obtidos pelas previsões que já contém erros em si. Dessa forma, o erro final apresentado por esses modelos foi maior.

Observando esses erros apresentados, poder-se-ia minimizar tais erros com algumas medidas, entre elas:

- Agregar os principais reservatórios no modelo, ponderando o peso de cada um dos reservatórios
- Ajuste fino nos parâmetros dos modelos utilizados
- Utilizar outros tipos de modelos que possam ser mais adequados
- Utilizar um intervalo diferente e mais extenso de dados como entrada do modelo
- Considerar outras variáveis de predição do modelo além do nível hidrológico, como índices de pluviometria, energia armazenada, vazões afluentes e defluentes, etc.

4.3 Volatilidade e Risco

Nesta seção, serão comparados os indicadores utilizados nesse trabalho de PLD e CMO e compará-los com índices do mercado financeiro, para entender como variam esses índices de forma comparativa. O objetivo, nessa seção, é de que seja possível calcular o risco associado à volatilidade dos preços de energia.

Tabela 7: Cotação Semanal dos Indicadores de CMO e PLD, em BRL por *MWh*, 2005-2018

Variável Estatística	PLD	PLD ajustado	CMO	CMO ajustado
Média	186,3	247,2	214,4	281,0
Máximo	822,8	1.092,2	2.158,6	2.675,3
Mínimo	12,1	18,2	0,0	0,0
Desvio Padrão	200,1	249,1	300,4	374,2
Volatilidade Histórica	234,1%	233,9%	562,9%	562,3%

Fonte: CCEE/ONS.

A Tabela 7 observa a cotação dos valores de energia para o período entre 2005 e 2018. Um dos termos apresetados, Volatilidade Histórica, é uma medida estatística de

Tabela 8: Cotação Semanal dos Ativos, em BRL, 2005-2018

Variável Estatística	Índice Ibovespa ¹	Milho ²	Ouro ³	Petróleo WTI ⁴
Média	55.399,56	997,28	2.810,75	167,18
Máximo	91.840,79	1.668,46	5.161,82	296,60
Mínimo	23.818,37	419,02	983,60	79,69
Desvio Padrão	10.802,16	260,36	1.097,44	30,64
Volatilidade Histórica	25,4%	31,6%	20,8%	34,7%

Fonte: Séries históricas retiradas de investing.com.

Nota: 1. Unidade adimensional de pontos; 2. unidade de 1 celemim, equivalente a 4625 L; 3. unidade de onças, equivalentes a 31,1035 g; 4. unidade de barril, equivale a 158,9873 L

Tabela 9: Cotação Semanal dos Ativos, em USD, 2005-2018

Variável Estatística	USD/BRL	Índice Ibovespa	Milho	Ouro	Petróleo WTI
Média	2,43	24.558,83	429,03	1.149,24	73,22
Máximo	4,17	44.631,11	824,50	1.873,70	145,29
Mínimo	1,55	8.865,29	189,75	414,00	29,42
Desvio Padrão	0,58	7.500,08	119,01	308,86	18,87
Volatilidade Histórica	15,0%	37,3%	31,2%	18,1%	36,2%

Fonte: Séries históricas retiradas de investing.com.

dispersão de retorno para um dado ativo ou índice de mercado durante um período definido de tempo. Essa medida é calculada determinando a média de desvio sobre a média do preço do ativo ou índice. Utilizando-se o desvio padrão é o método mais comum. Quanto maior a volatilidade histórica do ativo, maior o seu risco. Contudo, essa medida não é necessariamente um resultado negativo, já que o risco varia para ambos os lados, tanto para mais como para menos do que o esperado.

A Tabela 10 e a Tabela 9 observam a cotação de outros ativos, como Índice Ibovespa e outras *commodities*, no mesmo período, e para as moedas de BRL e USD, respectivamente.

A volatilidade histórica não mede especificamente a probabilidade de uma perda, embora possa ser usada para tal finalidade. O que a variável mede é quão longe o valor do ativo pode se desviar do seu valor médio.

Para mercados em potencial, a volatilidade histórica mede quão longe os preços negociados se moveram em relação à média, ou média móvel, do preço. É assim que um mercado em potencial mas que tenha curvas suaves de preço pode ter tanto uma

Tabela 10: Cotação Semanal dos Ativos, em BRL, 2005-2018

Variável Estatística	Índice Ibovespa ¹	Milho ²	Ouro ³	Petróleo WTI ⁴
Média	55.399,56	997,28	2.810,75	167,18
Máximo	91.840,79	1.668,46	5.161,82	296,60
Mínimo	23.818,37	419,02	983,60	79,69
Desvio Padrão	10.802,16	260,36	1.097,44	30,64
Volatilidade Histórica	25,4%	31,6%	20,8%	34,7%

Fonte: Séries históricas retiradas de investing.com.

Nota: 1. Unidade adimensional de pontos; 2. unidade de 1 celemim, equivalente a 4625 L; 3. unidade de onças, equivalentes a 31,1035 g; 4. unidade de barril, equivale a 158,9873 L

volatilidade baixa como uma mudança dramática de preço ao longo do tempo. O seu valor não variou drasticamente em uma visão diária, mas se moveu de forma constante e equilibrada ao longo do tempo.

Essa medida é normalmente comparada com a volatilidade implícita para determinar se o preço do ativo está sub ou sobre-precificado. A volatilidade histórica também é utilizada para todos os tipos de cálculo de risco. Ações com alta volatilidade histórica normalmente requerem uma maior tolerância a risco. E mercados de maior volatilidade também costumam utilizar modelos de *stop-loss* com maiores margens.

Além da utilização em precificação de ativos, a volatilidade histórica normalmente é utilizada como um *input* em modelos de estudos técnicos, como o Bollinger Bands. As faixas de *Bollinger Bands* podem se estreitar ou se expandir ao redor de uma média em resposta às mudanças da volatilidade, como uma medida de desvio padrão.

Volatilidade possui, normalmente, uma conotação ruim, porém muitos investidores podem gerar grandes retornos justamente na época de maiores volatilidades. Afinal de contas, se um ativo muda pouco de preços terá uma baixa volatilidade, mas também terá um baixo potencial de retorno de capital. E do outro lado do argumento, um ativo com muito alta volatilidade pode ter retornos muito grandes, mas ao preço de um risco elevado. O *timing* para esses mercados deve ser considerado de forma minuciosa, e mesmo uma negociação boa no mercado pode acabar perdendo dinheiro se o ativo oscilar sobre uma faixa de preço que gatilhe o *stop loss* do investidor Siegel (2014).

Portanto, os níveis de volatilidade devem estar em algum patamar moderado, e esse patamar pode variar de acordo com o mercado que está inserido. Comparativos com outros ativos correspondentes podem ajudar a determinar que nível de volatilidade é considerado normal.

A partir dos modelos de projeção de precificação futura de PLD, os próximos

passos envolvem estudar o impacto desses valores sobre um mercado de comercialização de energia, ou seja, sobre uma visão de investimento.

Por esse motivo, será apresentado o conceito de risco e volatilidade, e como que esses valores se comparam com outros índices do mercado.

Ao avaliar ativos e empresas, é preciso utilizar taxas de desconto que reflitam a incerteza do investidor. Em particular, o custo de dívida deve ser incorporado ao valor do retorno esperado do ativo, e o custo do ativo deve incluir um bônus de risco sobre essa empresa. Dessa forma, é necessário medir o risco de uma empresa e seu risco de falência.

O objetivo neste capítulo será de explicar o risco, e, de certa forma, extrapolar esses conceitos para uma análise dentro do mercado de energia. Conforme explicado anteriormente, o mercado de energia possui uma série de particularidades. Porém, por premissas de modelo será utilizado um método que é o mesmo utilizado no mercado financeiro, e nesse modelo não será incorporado por simplificação as particularidades da energia no Brasil.

4.3.1 Risco em termos estatísticos

Risco é definido em termos estatísticos como sendo a variância de retornos reais sobre um retorno esperado. Quanto maior essa variância, mais arriscado será percebido esse investimento [Damodaran \(2012\)](#).

4.3.1.1 Modelo CAPM

O modelo CAPM (do inglês, *Capital Asset Pricing Model*) foi desenvolvido na década de 60 e vem sendo utilizado para diversos fins. Nesse modelo, é realizada uma especificação da relação risco e retorno, onde a medida de risco é chamada de *Beta*. Esse valor de *Beta* diz que o retorno requerido de um ativo deve ser a taxa livre de risco acrescida de um prêmio.

$$r_i = r_{RF} + (r_M - r_{RF}) \cdot \beta_{i,M} \quad (4.2)$$

Onde,

- r_i é o retorno esperado do ativo i
- r_{RF} é a taxa de retorno livre de riscos
- r_M é o risco de mercado, que será sempre superior ao valor da taxa livre de riscos
- $\beta_{i,M}$ é a medida de risco do ativo em relação ao mercado

De modo geral, a taxa de desconto apropriada para refletir o risco futuros tem dois componentes: o seu valor no tempo *risk free* e o prêmio sobre o risco. Quanto mais arriscado um projeto, maior seu prêmio de risco, maior o seu retorno esperado.

A melhor medida de risco para determinado ativo, que faz parte de uma carteira amplamente diversificada, mede a volatilidade de um ativo relativamente ao mercado (mede o risco sistemático).

$$\beta_i = \frac{Cov(r_{i,t}, r_{M,t})}{Var(r_{M,t})} \quad (4.3)$$

O numerador da equação compara a covariância entre o ativo i avaliado com a covariância do mercado. Para duas série de dados, a covariância fornece uma medida de grau pela qual o ativo e o mercado se movimentam juntos ou não.

O denominador da equação calcula a variância de um indicador do mercado, sendo utilizados normalmente o Índice Ibovespa ou o Índice SP 500 dos Estados Unidos.

O β mede a sensibilidade das taxas de retorno de um portfólio ou de um título individual em relação aos movimentos de mercado. O resultado dessa equação representa a proporção entre a variação do mercado, representada por um índice (variável independente) e a variação do ativo (variável dependente).

Como um exemplo prático, o resultado de um β igual a 1 indica que uma mudança de 1% no mercado implica na mudança de 1% no ativo. Um valor de β igual a 2 indica que a mudança de 1% no mercado implica no dobro de mudança no ativo, igual a 2%. Um beta negativo indica uma relação inversamente proporcional dos ativos, de forma que quando o mercado cresce o ativo cai.

Esses indicadores financeiros tem o intuito de demonstrar a importância de incentivar uma variação de preços menos volátil, visto que a incerteza incorporada nos modelos pode exigir mais riscos para o investidor.

Para noção de ordem de grandeza, podemos estimar qual o impacto da uma variação na volatilidade que impacte o cálculo de retorno em apenas 1% nos próximos anos.

Tomando como base o acréscimo de energia nos próximos anos e o valor médio do PLD no ano de 2019, podemos calcular o impacto financeiro.

A Tabela 11 contém o acréscimo de energia esperado para os próximos anos na região Sudeste do Brasil.

PLD médio para 2019 por MWh :

$$PLD_{2019} = R\$225,53$$

Com o valor de MWh , calcula-se o número de horas no ano como $24 \times 365 = 8760$.

Tabela 11: Acréscimos anuais da carga de energia,
 $MW_{\text{médio}}$, 2019-2023

Subsistema	2019	2020	2021	2022	2023
Acumulado					
Sudeste/CO	996	1.247	1.417	1.501	1.566
	6.727				

Fonte: EPE/ONS/CCEE.

Acréscimo de 1% de retorno esperado sobre o total do preço da energia:

$$225,53 \times 6727 \times 8760 \times 0,01 \approx 132 \text{ milhões de reais}$$

5 CONCLUSÃO

Esse trabalho teve como objetivo comparar as sazonalidades de nível de volume útil das bacias de Camargo e de Três Irmãos com o PLD Médio da região Sudeste ajustado pela inflação, entre os anos 2005 a 2018. Os dados são notórios no sentido de que o nível das bacias hidroelétricas afetam o custo de operação de energia, em especial em um país de grande dependência hidroelétrica como o Brasil.

Porém, apesar da concavidade negativa observada nos valores cruzados, foi evidenciado o alto índice de volatilidade nos preços de energia, tanto no CMO como no PLD.

As eventuais incertezas associadas a um ambiente de precificação tão volátil como o mercado de energia pode trazer um custo maior ao consumidor, ainda mais se essa volatilidade for recorrente ao longo dos anos.

É importante ressaltar as premissas adotadas ao longo do projeto, que sempre causarão simplificações no modelo que fogem da realidade. Porém, o trabalho serviu mais para lançar luz ao tema, e demais estudos seriam necessários para resultados mais concretos e aplicáveis.

Agora, é importante trazer ao trabalho alguns exemplos, opiniões e vozes de pessoas relevantes nessa indústria de energia no Brasil e que possam contribuir para compreender os próximos passos nesse mercado de energia no Brasil, bem como inserir novas complexidade nesse modelo e mercado com as tendências dos últimos anos. Esse próximo passo e discussão é importante nesse trabalho porque são justamente medidas macroeconômicas e decisões estratégicas a nível Nacional que serão os principais influenciadores do setor elétrico, não tão somente a sazonalidade dos níveis hidrológicos.

REFERÊNCIAS

DAMODARAN, A. **Investment Valuation: Tools and Techniques for Determining the Value of any Asset, University Edition**. Wiley, 2012. ISBN 1118130731. Disponível em: <<https://www.xarg.org/ref/a/B007MF15ZA/>>.

EL-HAWARY, M. E. **Electrical Energy Systems, Second Edition (Electric Power Engineering Series)**. CRC Press, 2000. ISBN 0849321913. Disponível em: <<https://www.xarg.org/ref/a/0849321913/>>.

LIMA, D. R. M. **Previsões de Vazões Afluentes e Usinas Hidrelétricas Aplicada à Programação da Operação do Sistema Elétrico Brasileiro**. 2018. 138 f. Dissertação (Mestrado – Programa de Pós-Graduação em Engenharia Elétrica e Área de Concentração em Sistemas Dinâmicos) — Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2018.

SIEGEL, J. **Stocks for the Long Run 5/E: The Definitive Guide to Financial Market Returns Long-Term Investment Strategies**. McGraw-Hill Education, 2014. ISBN 0071800514. Disponível em: <<https://www.xarg.org/ref/a/0071800514/>>.

APÊNDICE A – EQUAÇÃO DE GERAÇÃO HIDROELÉTRICA

A produção de energia, em qualquer sistema hidroelétrico, é influenciado pela sua vazão afluente e pelas demais usinas que eventualmente compõe o sistema. A série cronológica de tais dados pode ser muito valiosa para projeções futuras e estratégias e tomadas de decisão do sistema como um todo.

As vazões afluentes representam o fluxo de água médio que flui em postos de medição estrategicamente localizados nas redondezas da usina durante determinados intervalos discretizados de tempo. No Brasil, há um histórico capturado de tais dados desde 1931.

As séries históricas são os dados mais relevantes utilizados para modelos de otimização e simulação de operação de um sistema hidroenergético, possuindo, entretanto, a limitação de ser incapaz de calcular a probabilidade de situações mais severas do que aquelas observadas e registrados no passado.

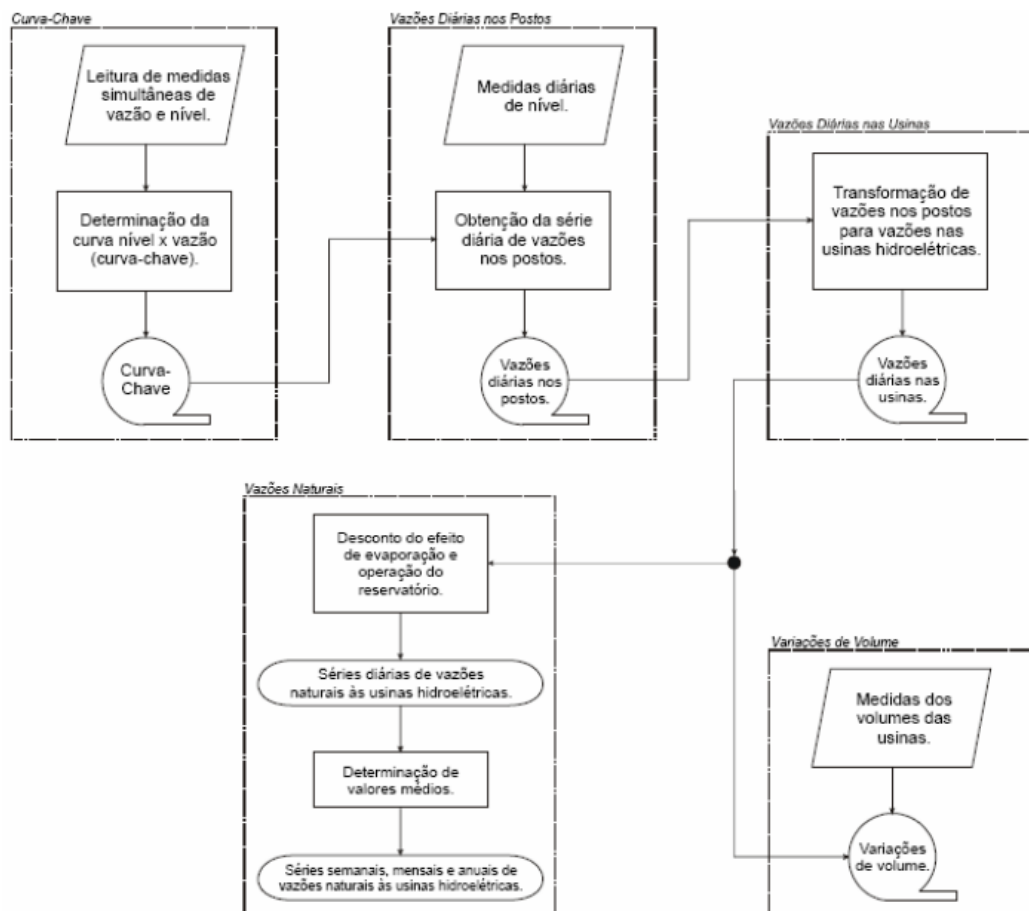


Figura 14: Diagrama de Decisão de Afluência

Há cinco componentes principais utilizadas para o diagrama de afluência.

- Curva-Chave
- Vazões diárias nos postos
- Vazões diárias nas usinas
- Vazões naturais
- Variações de Volume

O primeiro fator, *curva-chave*, incorre da determinação da curva de nível *versus* a vazão da usina. Com a leitura de medidas simultâneas de vazão e nível é possível conhecer essa importante curva.

O segundo fator, *vazões diárias nos postos*, incorre também das medidas diárias de nível, que deverão trazer uma obtenção da série diária de vazões nos postos. Com essas vazões diárias nos postos, é possível chegar ao terceiro fator.

As *vazões diárias nas usinas* serão obtidas a partir da transformação desses dados obtidos com os postos de medição.

Agora com a informação das vazões diárias nas usinas é possível chegar aos dois últimos componentes do diagrama.

As *vazões naturais* são calculadas a partir da vazão tanto da usina como do efeito de evaporação e operação do reservatório, que serão descontados para o cálculo de vazão natural. Com tais dados, é possível saber a série diária de vazões naturais às usinas hidrelétricas e, pela determinação de seus valores médios, é possível calcular as séries semanais, mensais, anuais de vazões naturais.

O último bloco envolve as *variações de volume*, que são obtidas através das medidas de nível e vazão a priori observadas.

Para a função de Produção Hidráulica, portanto, são necessários:

- Quantificar a geração de energia elétrica, deduzida da energia potencial armazenada no reservatório
- a produtibilidade específica k do projeto
- a altura de queda líquida h
- a vazão turbinada q

APÊNDICE B – *SUMÁRIO* DOS COEFICIENTES ARIMA

Summary of ARIMA Model ARIMA

Method: ARIMA(2,1,2)(1,1,0)[52]

Call:

```
auto.arima(Volume.Útil.TI....., d = 1, D = 1, max.p = 2, max.q = 2, max.P = 1, max.Q = 1, ic = "aicc", allowdrift = TRUE)
```

Coefficients:

	ma1	ar1	ar2	ma2	sar1
Value	0.925087	-0.558229	-0.238058	0.39517	-0.485615
Std Err	0.259965	0.263242	0.102902	0.137715	0.033962

sigma² estimated as 29.14225: log likelihood = -2109.78295

Information Criteria:

AIC	AICc	BIC
4231.5659	4231.6911	4258.6808

In-sample error measures:

ME	RMSE	MAE	MPE	MAPE	MASE	ACF1
-0.0225229	5.1797688	3.658507	NaN	Inf	0.1838591	0.0034197

Ljung-Box test of the model residuals:

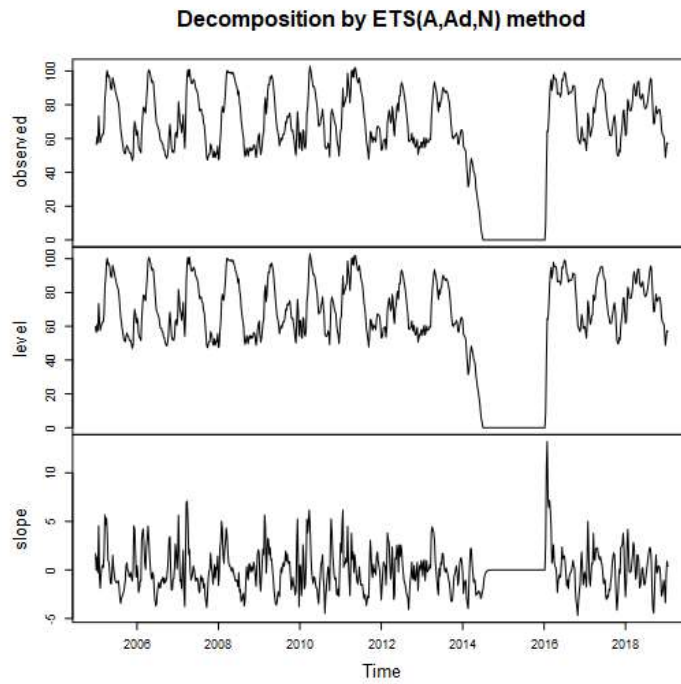
Chi-squared = 24.6098, df = 19, p-value = 0.17379

Plots

APÊNDICE C – *SUMÁRIO* DOS COEFICIENTES ETS

Plots of Time Series Exponential Smoothing Model ETS

In statistics, a time series is a sequence of data points measured at successive points in time spaced at uniform intervals. Examples of time series are the daily closing value of a stock market index or the annual flow volume of a river. Time series analysis comprises methods for analyzing time series data in order to extract meaningful statistics and other characteristics of the data.




Decomposition Plot separates time series data into several components. Decomposition method is often used to yield information about time series components i.e. trend, cycle, seasonal, etc.

- Observed: This is the actual data.
- Level: This is the overall baseline without seasonal trends.
- Slope: This is the rate of change associated with the Level.
- Season: This shows the seasonal trend of the data.

Not all of the above components will occur each time.

Forecasts from ETS(A,Ad,N)



The Forecast Plot shows the historic data in black and the expected value in blue. The orange in the plot shows the 90% confidence interval, and the yellow shows the 95% confidence interval.

4

Summary of Time Series Exponential Smoothing Model ETS

5

Method:
ETS(A,Ad,N)

6

In-sample error measures:

ME	RMSE	MAE	MPE	MAPE	MASE	ACF1
-0.0047989	4.7113493	3.2501875	NaN	Inf	0.1633389	0.1632559

7

Information criteria:

AIC	AICc	BIC
7098.5787	7098.6947	7126.1452

Record
8

Report

Smoothing parameters:

Parameter	Value
alpha	0.999899
beta	0.295036
phi	0.8

9

Initial states:

State	Value
I	59.636028
b	1.64953

APÊNDICE D – *SUMÁRIO* DO MODELO SPLINE

Record Report

1 **Summary Report for Spline Model previsaoprecospline**

2 Call:
earth(formula = PLD.SE.IPCA.BASE.2019 ~ TI.Arima, data = the.data, glm =
list(family = gaussian), minspan = 0)

3 Coefficients:

Term	Value
(Intercept)	776.451
h(TI.Arima-63.81)	37.853
h(63.81-TI.Arima)	-3.617
h(TI.Arima-37.04)	-25.523
h(TI.Arima-75.91)	-18.766

4 Selected 5 of 5 terms, and 1 of 1 predictors

5 Importance:

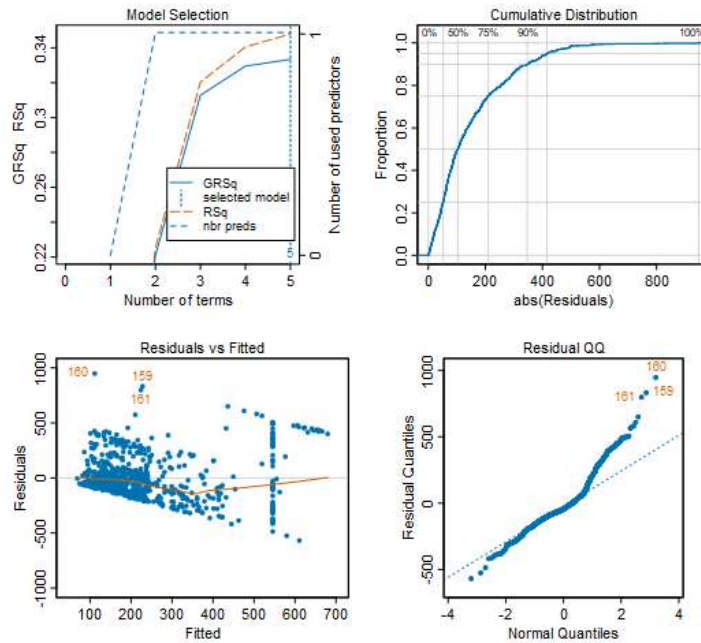
6 GCV 41470 RSS 29572562 GRSq 0.3334 RSq 0.3479

7 GLM null.deviance 45349603 (730 dof) deviance 29572562 (726 dof)

8 GLM Model McFadden R-Squared: 0.3479

9 Plots:

Diagnostic Plots for previsaoprecospline



The four plots in the set of diagnostic plots are: (1) the Model Selection plot; (2) the Cumulative Distribution plot; (3) Residuals vs Fitted plot; and (4) the Normal Q-Q plot.

The Model Selection plot gives the RSq (R-Squared) and GRSq (penalized R-Squared of the model), while the dashed line gives the number of terms in the model.

The model with the highest GRSq value is selected, and the vertical dotted line indicates the number of model terms included in this best model.

The Cumulative Distribution plot shows the cumulative distribution of the absolute values of the model residuals, which ideally starts at zero and quickly rises to one.

The Residuals vs Fitted value plot shows the residual for each value of the predicted response. By comparing the scales of the two axes, one can quickly gain a sense of the size of the residuals relative to the predictive values. The thin line in the plot indicates how the average magnitude of the residuals changes with the

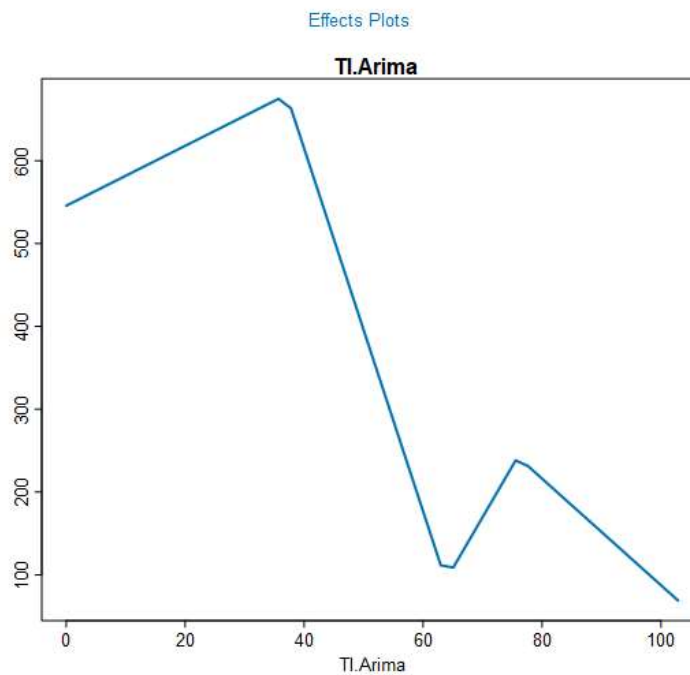
Record

Report

size of the predictive value. Ideally, this would be essentially a horizontal line centered at zero of the Residuals (vertical) axis of the plot.

The Normal Q-Q plot compares the distribution of the residual to a normal distribution. Deviations for normality are only critical when the target is continuous, and the Gaussian GLM family is selected. Its value for other models is the ability to see potential outliers in the data.

10



The Variable Importance Plot provides information about the relative importance of each predictor field. The measures are normalized to sum to 100, and the value for each field gives the relative percentage importance of that field to the overall model.

APÊNDICE E – *SUMÁRIO* DO MODELO DE REGRESSÃO LINEAR

Record Report

1
2
3
4
5
6
7
8
9
10

Report for Linear Model linear_cmo_ipca

Basic Summary

Call:

lm(formula = PLD.SE.IPCA.BASE.2019 ~ TI.Arima, data = the.data)

Residuals:

Min	1Q	Median	3Q	Max
-483.5	-137.4	-46.9	76.0	827.3

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	542.818	19.8548	27.34	< 2.2e-16 ***
TI.Arima	-4.678	0.2883	-16.23	< 2.2e-16 ***

Significance codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 213.77 on 729 degrees of freedom

Multiple R-squared: 0.2654, Adjusted R-Squared: 0.2644

F-statistic: 263.4 on 1 and 729 degrees of freedom (DF), p-value < 2.2e-16

Type II ANOVA Analysis

Response: PLD.SE.IPCA.BASE.2019

	Sum Sq	DF	F value	Pr(>F)
TI.Arima	12035287.59	1	263.36	< 2.2e-16 ***
Residuals	33314315.08	729		

Significance codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1