

**UNIVERSIDADE FEDERAL DE SANTA MARIA
CURSO DE ESPECIALIZAÇÃO EM ESTATÍSTICA E MODELAGEM
QUANTITATIVA**

Marcio Bürger Mansilha

**MODELOS DE PREVISÃO NA OTIMIZAÇÃO DE USINAS
ELÉTRICAS VIRTUAIS**

**Santa Maria, RS
2022**

Marcio Bürger Mansilha

MODELOS DE PREVISÃO NA OTIMIZAÇÃO DE USINAS ELÉTRICAS VIRTUAIS

Monografia apresentada ao curso de Especialização em Estatística e Modelagem Quantitativa, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do título de **Especialista em Estatística e Modelagem Quantitativa.**

Orientadora: Profa. Dra. Roselaine Ruviaro Zanini

**Santa Maria, RS
2022**

Marcio Burger Mansilha

MODELOS DE PREVISÃO NA OTIMIZAÇÃO DE USINAS ELÉTRICAS VIRTUAIS

Monografia apresentada ao curso de Especialização em Estatística e Modelagem Quantitativa, da Universidade Federal de Santa Maria (UFSM, RS) como requisito parcial para obtenção do título de **Especialista em Estatística e Modelagem Quantitativa.**

Aprovada em 20 de julho de 2022:

Profª. Dra. Roselaine Ruviaro Zanini (UFSM)
(Presidente/Orientadora)

Prof. Dr. Adriano Mendonça Souza (UFSM)

Prof. Dra. Lorena Vicini (UFSM)

Santa Maria, RS
2022

RESUMO

MODELOS DE PREVISÃO NA OTIMIZAÇÃO DE USINAS ELÉTRICAS VIRTUAIS

AUTOR: Marcio Burger Mansilha

ORIENTADORA: Profa. Dra. Roselaine Ruviaro Zanini

O trabalho analisou modelos ARIMA para previsão de mercados de compensação de preços do dia seguinte. Os modelos foram baseados em análises de séries temporais e fornecem previsões confiáveis e precisas de preços no mercado. O objetivo foi verificar a qualidade da previsão dos preços da eletricidade que são aspectos inevitáveis de uma Usina virtual (VPP). A metodologia empregada consistiu, em uma revisão bibliográfica das VPP's e no método proposto por Box-Jenkins, o qual também é conhecido como modelo ARIMA, foi utilizado na realização de previsão em séries temporais. Realizou-se, ainda como método, um estudo de caso estruturado para simulação dos modelos de previsão ARIMA com dados reais coletados dos preços spot do dia seguinte da Grã-Bretanha em libra esterlina britânica (GBP). Os dados abrangeram o período de 2015 a 30 de setembro 2020. O resultado da previsão com redes neurais apresentou as melhores medidas de desempenho com o modelo ARIMA NNETAR. Conclui-se que a utilização da metodologia de série temporais constitui um importante suporte e apoio nas previsões das VPP já que possibilita a melhor tomada de decisões.

Palavras-chave: Usina virtual (VPP). Geração distribuída. Séries temporais. ARIMA.

ABSTRACT

FORECAST MODELS IN THE OPTIMIZATION OF VIRTUAL POWER PLANTS

AUTHOR: Marcio Burger Mansilha
ADVISOR: Prof. Dr. Roselaine Ruviano Zanini

The work analyzed ARIMA models for forecasting day-ahead price clearing markets. The models were based on time series analysis and provide reliable and accurate market price predictions. The objective was to verify the quality of forecasting electricity prices, which are unavoidable aspects of a VPP. The methodology used consisted of a bibliographic review of the VPP's and the method proposed by Box-Jenkins, which is also known as ARIMA methodology, was used to perform forecasting in time series. As a method, a structured case study was carried out to simulate ARIMA forecast models with real data collected from the spot prices of the next day in Great Britain in GBP. The data covered the period from 2015 to September 30, 2020. The prediction result with neural networks presented the best performance measures for the ARIMA NNETAR model. It is concluded that the use of the time series methodology constitutes an important support and support in the PPV forecasts as it allows for better decision making.

Keywords: Virtual power plants (VPP). Distributed generation. Time Series. ARIMA.

LISTA DE FIGURAS

Figura 1 - Comportamento da FAC e FACP de processos ARIMA (p; d; q)	14
Figura 2 - Simplificação rede neural com três camada	15
Figura 3 - Gráfico do preço da energia em Grã-Bretanha em GBP.	19
Figura 4 - Gráfico mês a mês para identificação do <i>outliers</i>	20
Figura 5 - Gráfico dia a dia para identificação dos <i>outliers</i>	20
Figura 6 - Gráfico hora a hora para identificação dos <i>outliers</i>	21
Figura 7- Gráfico da subsérie com 2100 observações, no mesmo horário (hora=00).....	21
Figura 8 - Gráfico dia a dia da subsérie com 2100 observações, no mesmo horário (hora=00)	22
Figura 9 - Gráfico subsérie com 2100 observações, após tratamento da função <i>tsclean</i>	22
Figura 10 - Gráfico das médias móveis mensais e semanais.....	23
Figura 11 - Gráfico da decomposição dos dados em sazonalidade, tendência e resíduos.....	23
Figura 12 - Gráfico da FAC - função de autocorrelação	24
Figura 13 - Gráfico da FACP- função de autocorrelação parcial	24
Figura 14 - Gráfico da série temporal com uma diferença (-1) na série temporal.	25
Figura 15 - Gráfico da FAC - função de autocorrelação com diferença (-1) na série temporal.	25
Figura 16 - Gráfico da FACP - função de autocorrelação parcial com diferença (-1).	26
Figura 17 - Gráfico do ajuste, resíduos do modelo ARIMA (5,1,3) com função <i>auto.arima</i> ...	26
Figura 18 - Gráfico do ajuste, resíduos do modelo ARIMA (1,1,12).....	27
Figura 19 - Gráfico da previsão com modelo ARIMA (5,1,3).....	27
Figura 20 - Gráfico do Teste o desempenho do modelo validação da previsão ARIMA (5,1,3)	28
Figura 21 - Gráfico da previsão de h= 100 períodos com sazonalidade com as médias moveis, do modelo SARIMA (2,0,5) (2,2,0).	28
Figura 22 - Gráfico dos resíduos do modelo ARIMA (2,0,5) (2,2,0).....	29
Figura 23 - Gráfico dos resíduos do modelo ARIMA (2,0,5)	29
Figura 24 - Gráfico dos modelos simulados.....	30
Figura 25 - Redes neurais utilizando a função NNETAR (33,1,17).	30
Figura 26 - Raízes inversas do polinômio característico AR e MA.	31

SUMÁRIO

1	INTRODUÇÃO	7
1.1	PROBLEMA	8
1.2	OBJETIVOS	8
1.2.1	Objetivo Geral.....	8
1.2.2	Objetivos Específicos	8
1.3	JUSTIFICATIVA	9
1.4	ESTRUTURA DA MONOGRAFIA.....	9
2	REVISÃO BIBLIOGRÁFICA	10
2.1	USINA ELÉTRICA VIRTUAL (VPP).....	10
2.1.1	Tipos de VPP	10
2.1.1.1	Usina Virtual Comercial.....	10
2.1.1.2	Usina Virtual Técnica.....	11
2.1.2	Desenvolvendo um modelo de VPP	12
2.2	SÉRIES TEMPORAIS E MODELOS ARIMA	12
2.2.1	Rede neural.....	15
2.2.2	Medidas de desempenho de previsão	15
3	MATERIAIS E MÉTODOS	17
3.1.1	Coleta de dados e o processo para a simulação dos modelos	18
4	RESULTADOS E DISCUSSÃO	19
4.1	MODELOS PREVISÃO ARIMA COM DADOS REAIS COLETADOS DE PREÇO <i>SPOT</i> DO DIA SEGUINTE PARA A GRÃ-BRETANHA EM GBP	19
5	CONSIDERAÇÕES FINAIS.....	33
	REFERÊNCIAS	34

1 INTRODUÇÃO

A integração das fontes renováveis de energia é uma tendência mundial em sistemas de distribuição de energia por serem capazes de atender aos desafios energéticos não resolvidos pelas usinas centralizadas tradicionais, diminuir as emissões globais e aumentar a oferta de energia sustentável a longo prazo (KOW et al., 2016). Os recursos energéticos distribuídos (DERs), em especial as energias eólicas e solar fotovoltaica, estão desempenhando papéis cada vez mais importantes nas estruturas energéticas (JU et al., 2016a).

No entanto, restrições a pequenas capacidades instaladas, intermitência de fornecimento, incertezas do fornecimento e outras características, dificultam a entrada e o funcionamento destas centrais no mercado de energia convencional para DERs (JU et al., 2016b). Tomando-se como pressuposto que a energia elétrica deve ser fornecida aos consumidores com a mais alta qualidade, o menor custo e a maior confiabilidade, torna-se necessário fornecer novas formas de controlar a geração e o fornecimento de uma infraestrutura adequada para a participação no mercado de eletricidade. Uma possível solução para satisfazer os aspectos supramencionados é usar o conceito de usinas elétricas virtuais (VPP) (NOSRATABADI; HOOSHMAND; GHOLIPOUR, 2016) já que estas podem efetivamente integrar, agregar e gerenciar DERs incluindo geradores distribuídos (DGs), sistemas de armazenamento de energia, cargas controláveis, e respostas adequadas à demanda (DR) (NOSRATABADI; HOOSHMAND; GHOLIPOUR, 2017).

Diante desse novo cenário, a previsão de preços está se tornando cada vez mais relevante aos produtores e consumidores na nova energia elétrica competitiva de mercados. Tanto para mercados *spot* quanto para contratos de longo prazo, o preço e as previsões são necessários para desenvolver estratégias de licitação ou habilidades de negociação para maximizar o benefício.

As empresas também querem se proteger contra o risco de volatilidade diária dos preços usando contratos bilaterais. Para ambos os casos, prever os preços da eletricidade para um dia ou para os próximos 12 meses é da maior importância para as companhias elétricas ajustarem seus lances diários ou cronogramas de contratos.

Com uma boa previsão de preços para o dia seguinte, um produtor pode desenvolver uma estratégia apropriada para maximizar seu próprio benefício ou um consumidor pode maximizar sua utilidade (ARROYO; CONEJO, 2000); (CONEJO; ARROYO; TORRE, 2002).

Em sistemas de energia, técnicas de modelagem do tipo ARIMA (processos autorregressivos integrados de médias móveis) tem sido usadas para previsão de carga com

bons resultados, como a aplicação dos modelos ARIMA para prever preços de *commodities* (WEISS, 2000), como petróleo ou gás natural.

Neste trabalho apresenta-se modelos ARIMA para prever as 24 horas de mercados de compensação de preços do dia seguinte. Os modelos são baseados em análises de séries temporais e fornecem previsões confiáveis e precisas de preços no mercado.

1.1 PROBLEMA

Partindo-se das questões supra referidas, busca-se responder ao seguinte problema nesta pesquisa: qual o modelo mais apropriado para a previsão dos preços da eletricidade do dia seguinte numa usina elétrica virtual (VPP)?

1.2 OBJETIVOS

Nesta seção são apresentados os objetivos gerais e específicos do trabalho.

1.2.1 Objetivo Geral

Propor modelos para prever os preços da eletricidade no dia seguinte com base em processos autorregressivos integrados de médias móveis (ARIMA).

1.2.2 Objetivos Específicos

Para se alcançar o objetivo geral desta pesquisa, foram definidos alguns objetivos específicos que devem ser executados:

- Apresentar um conceito de VPP;
- Analisar os tipos de VPP e os modelos com as técnicas e estratégias de implantação existentes no mercado;
- Ajustar os modelos de previsão apropriados para os preços de eletricidade do dia seguinte;
- Comparar os modelos ARIMA por meio de medidas de desempenho.

1.3 JUSTIFICATIVA

A escassez de recursos e danos ao meio ambiente têm levado a sociedade a repensar o modelo energético. Para o setor de energia, as tecnologias da informação e da comunicação emergentes continuam a penetrar todo o processo de produção, transmissão, distribuição e consumo de energia, formando assim um sistema de energia inteligente (ZHOU; YANG; SHAO, 2016). Os proprietários independentes de recursos energéticos distribuídos (DERs) poderão ser integrados para formar uma coalizão para negociar em bloco nos mercados de varejo (sob tarifas predeterminadas), ou, nos mercados atacadistas usando o conceito de VPP.

A consequente operação coordenada dos DERs implica num lucro excedentário em relação à soma dos seus lucros individuais (RAHMANI-DABBAGH; SHEIKH-EL-ESLAMI, 2016). As usinas elétricas virtuais existentes já transmitem a sua eletricidade a partir de softwares acoplados, distribuindo energia para as instalações dos mercados de energia.

Porém, diferentes estratégias de mercado para melhorar a qualidade da previsão dos preços da eletricidade para redução das incertezas são aspectos inevitáveis de uma VPP, auxiliando na integração de produtores, consumidores e unidades de armazenamento.

A utilização de modelo de ARIMA torna-se eficiente e importante para prever os preços da eletricidade no dia seguinte pois pode trazer melhorias futuras para os beneficiários.

1.4 ESTRUTURA DA MONOGRAFIA

Esta Monografia está estruturada da seguinte forma:

O primeiro capítulo aborda a introdução do tema estudado, problema, objetivos e justificativa da pesquisa.

No segundo capítulo apresenta-se a revisão bibliográfica sobre VPP, séries temporais e modelos de ARIMA.

No terceiro capítulo são apresentados os materiais e métodos, no qual são expostos os procedimentos e técnicas para modelagem de séries temporais.

No quarto capítulo são apresentados os resultados e discussão do estudo.

O quinto capítulo é composto pela conclusão da monografia, finalizando o trabalho com as referências bibliográficas.

2 REVISÃO BIBLIOGRÁFICA

2.1 USINA ELÉTRICA VIRTUAL (VPP)

O conceito de usina elétrica virtual associa-se a várias vantagens por representar uma abordagem mais simples de organização em relação aos modelos desregulados do mercado de energia (MOUTIS; GEORGILAKIS; HATZIARGYRIOU, 2018). A VPP é destinada a obter um comportamento mais confiável da rede por meio da integração de recursos energéticos diferentes (RINALDI et al., 2016) e são propostas considerando a agregação de várias unidades de geração distribuída. A VPP reúne vários recursos, focando numa perspectiva comercial que permite a participação dos consumidores ativos em eventos de resposta à demanda (DR) (MORAIS et al., 2015).

A VPP atua como uma grande usina elétrica mesmo que a participação do mercado de energia da VPP seja obtida pela produção agregada de todas as unidades recurso energético distribuído (DERs). Logo, sua interação com a rede é diferente para cada unidade dependendo da sua localização. Como resultado imediato, a rede limitará a capacidade da VPP para participar do mercado de eletricidade (ETHERDEN; VYATKIN; BOLLEN, 2016).

A aplicação da abordagem VPP a um sistema de trabalho exige a instalação de infraestruturas com tecnologias de informação e comunicação adequadas, compostas por armazenamento de dados distribuídos, potência computacional distribuída e uma infraestrutura de comunicação que suporte a troca de dados (RINALDI et al., 2016).

2.1.1 Tipos de VPP

As VPPs podem ser classificadas em usina virtual comercial e usina virtual técnica.

2.1.1.1 Usina Virtual Comercial

A usina virtual comercial (CVPP) é caracterizada por um perfil agregado de DERs e por uma potência de saída que representa o custo e as características operativas de um conjunto de DERs. É uma representação do portfólio de DERs que pode ser utilizado para participar no mercado atacado de energia na mesma forma que as usinas conectadas ao sistema de transmissão (HERNÁNDEZ, 2015). As funções da usina virtual comercial devem incluir características de manutenção e funcionamento dos DERs; previsão de produção e consumo;

gestão da interrupção na demanda, criar licitações de DERs, participação em licitações no mercado, otimização e programação da geração diária, venda da energia produzida pelos DERs no mercado (HERNÁNDEZ, 2015).

O CVPP fornece a informação que pode ser usada para negociar a energia gerada pela VPP. Uma unidade individual, por exemplo, pode ser pequena demais para participar sozinha, mas, a CVPP, como um grupo, pode ser grande o suficiente para trocar energia. Isso permite ao agente e ao proprietário do GD maximizar as receitas de sua geração (GIUNTOLI; POLI, 2013).

Assim, pode-se observar que o objetivo da CVPP é a maximização do lucro no *day-ahead electricity market* (DAM) em conjunto com a minimização da produção prevista em tempo real e o consumo.

2.1.1.2 Usina Virtual Técnica

A usina virtual técnica (TVPP) é constituída por DERs da mesma localização geográfica. Elas permitem ter a visibilidade das unidades DER ante o operador do sistema; contribuição das DER na gestão do sistema e o uso ótimo da capacidade das DER para fornecer serviços auxiliares incorporando as limitações da rede local (HERNÁNDEZ, 2015).

A TVPP trata da presença física do GD dentro da rede, contido em uma área elétrica. Sua finalidade é servir o DNO, fornecendo informações em relação à rede para obter uma rede de sucesso na operação de gestão e balanceamento. A TVPP requer conhecimento detalhado da rede local, fornecendo resultados precisos e, se conectando à transmissão de distribuição interface como uma única unidade com perfil relevante de geração de energia (GIUNTOLI; POLI, 2013).

A TVPP age no contexto de operação do sistema, está envolvida em sistema de gerenciamento local, fornecendo serviços auxiliar e de balanceamento os operadores das redes de transporte. A influência da rede local sobre o perfil agregado e as características operacionais do portfólio estão incluído nela (ZHAO; SHEN; LI, 2016b).

A CVPP é diferente da TVPP, pois não tem ponto de conexão e não tem que estar limitado a uma área elétrica. É usado como uma entidade comercial construído a partir do portfólio de tecnologias e recursos que ele engloba, tendo a vantagem de reduzir o risco de desequilíbrio associado com a operação isolada. A CVPP é responsável por negociação no mercado de atacado de energia e informar as operações agendadas para as TVPP. O impacto da rede de distribuição não é considerado no perfil da CVPP agregada (ZHAO; SHEN; LI, 2016a).

2.1.2 Desenvolvendo um modelo de VPP

Para desenvolvimento de uma VPP, baseado nos padrões abertos existentes, primeiro exige-se uma análise sistemática da funcionalidade e da necessidade de troca de informações entre VPPs. Em seguida, as funcionalidades e as necessidades de troca de informações devem ser comparadas com a solução padronizada oferecida pelas soluções de comunicação de geração existentes (ETHERDEN; VYATKIN; BOLLEN, 2016).

De acordo com CCEE (2015), no Brasil, o ambiente de contratação livre, assim como as operações na CCEE, tem como característica a viabilização da comercialização de energia no atacado, ou seja, envolve regras e responsabilidades incompatíveis com o grande número de consumidores e os pequenos volumes de energia representados pela micro e minigeração.

A comercialização desses excedentes no mercado é realizada por intermédio de comercializadores varejistas que passarão a atuar como agregadores da geração de diversos consumidores, compondo montantes de energia compatíveis com as negociações do ambiente de contratação livre.

A relação comercial entre os comercializadores e os consumidores é negociada de forma bilateral. Com base nessa negociação, o consumidor cederá o total de seu excedente para o comercializador que, perante o mercado e a CCEE, será o detentor da geração e realizará a contratação no ACL e, os excedentes de geração que forem adquiridos por um determinado comercializador, serão representados na CCEE como uma usina virtual, cuja geração verificada para fins de contabilização do mercado será a soma de todos os consumidores.

Assim, a usina virtual representada na CCEE terá seu lastro para a venda de energia calculado com base na média da geração verificada nos últimos 12 meses. Com isto, compete ao comercializador gerenciar o seu lastro para venda de contratos, inclusive no período dos 12 meses iniciais para composição do histórico, uma vez que novos consumidores com micro e minigeração podem passar a compor a geração dessa usina virtual a cada mês de operação.

2.2 SÉRIES TEMPORAIS E MODELOS ARIMA

O uso de séries temporais para a observação de eventos espaçados de forma regular no tempo foi desenvolvido por Box e Jenkins (1976), a partir de estudos com ênfase em aplicações no campo da estatística, economia, engenharia e ciências sociais.

Uma série temporal é um conjunto de dados ordenados ao longo do tempo, em um intervalo de tempo bem definido (MORETTIN; TOLOI, 2006).

De acordo Granger (1977), o propósito inicial da análise de séries temporais é obter inferências sobre as propriedades ou características básicas do mecanismo gerador do processo estocástico das observações da série.

Os modelos de previsão avaliam dados por meio da análise de séries temporais e atendem a alguns pressupostos por meio da investigação do fator gerador da série temporal, realização de previsões futuras para a série em questão, descrição 14 do comportamento da série, além de indicar a periodicidade dos dados (MORETTIN; TOLOI, 2006).

Os métodos de previsão baseados em séries temporais contam com o clássico Box–Metodologia Jenkins (BOX; JENKINS, 1976), que emprega uma classe geral de modelos como os modelos de média móvel autorregressiva (ARMA (p, q)) ou média móvel integrada autorregressiva (ARIMA (p, d, q)) para obter as previsões. A metodologia geral da abordagem Box-Jenkins envolve (i) identificação do modelo, (ii) estimativa de parâmetros e (iii) verificação diagnóstica seguida de previsão.

O modelo AR(p) é expresso pela Equação 1:

$$\check{Z}_t = \phi_1 \check{Z}_{t-1} + \phi_2 \check{Z}_{t-2} + \dots + \phi_p \check{Z}_{t-p} + \varepsilon_t, \quad (1)$$

Enquanto o modelo MA(q) é dado pela Equação 2:

$$\check{Z}_t = \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t, \quad (2)$$

logo: $\check{Z}_t = Z_t - \mu$

O parâmetro θ_1 explica a relação de \check{Z}_t com o ε_{t-1} , considerando $i = 1, 2, \dots, q$.

A sazonalidade é outra característica que pode ser adicionada aos modelos ARIMA e representa os picos que se repetem anualmente na série temporal. Os modelos com componentes sazonais são denominados ARIMA sazonal ou SARIMA (*Seasonal Autoregressive Integrated Moving Average*) e são denotados como SARIMA (p, d, q) (P,D,Q)s sendo que o "s" representa a ordem da sazonalidade (MORETTIN; TOLOI, 2006).

O modelo SARIMA genérico é expresso pela Equação 3:

$$(1 - \phi_p B^p) (1 - \phi_q B^q) (1 - B^D) y_t = (1 - \theta_q B^q) (1 - \theta_s B^s) \varepsilon_t \quad (3)$$

A construção de um modelo ARIMA obedece a um ciclo iterativo, em que as componentes do modelo inicialmente são escolhidas baseando-se nos próprios dados e,

posteriormente sofrem ajustes até se obter o melhor modelo. Conforme Morettin e Tolo (2006), este ciclo iterativo é composto por quatro etapas: identificação, estimação, verificação e previsão.

- Etapa de identificação: consiste em verificar qual modelo descreve o comportamento da série, valendo-se da interpretação dos correlogramas das funções de autocorrelação (FAC) e das funções de autocorrelação parciais (FACP);

- Etapa de estimação: realiza-se a estimativa dos parâmetros do componente autorregressivo, do componente de médias móveis e da variância;

- Etapa de verificação: consiste em analisar se o modelo escolhido descreve adequadamente o comportamento da série, por meio da análise dos resíduos;

- Etapa de previsão: etapa que representa o objetivo principal, realizada apenas se as etapas anteriores forem satisfatórias.

Na Figura 1, apresenta-se os comportamentos das funções de autocorrelações e autocorrelações parciais, juntamente com as estimativas de cada parâmetro de um modelo genérico ARIMA (p,d,q).

Figura 1 - Comportamento da FAC e FACP de processos ARIMA (p; d; q)

Ordem	(1, d, 0)	(0, d, 1)
Comportamento de $\rho_X(k)$	Decai Exponencialmente	Somente $\rho_X(1) \neq 0$
Comportamento de $\phi_X(k, k)$	Somente $\phi_X(1, 1) \neq 0$	Decaimento Exponencial Dominante
Estimativas Iniciais	$\phi_1 = \rho_X(1)$	$\rho_X(1) = -\frac{\theta_1}{1-\theta_1^2}$
Região de Admissibilidade	$ \phi_1 < 1$	$ \theta_1 < 1$
Ordem	(2, d, 0)	(0, d, 2)
Comportamento de $\rho_X(k)$	Mistura de Exponenciais ou Ondas senoides amortecidas	$\rho_X(k) \neq 0$, para $k \in \{1, 2\}$
Comportamento de $\phi_X(k, k)$	$\phi_X(k, k) \neq 0$, para $k \in \{1, 2\}$	Mistura de Exponenciais ou Ondas senoides amortecidas
Estimativas Iniciais	$\phi_1 = \frac{\rho_X(1)[1-\rho_X(2)]}{1-\rho_X^2(1)}$ $\phi_2 = \frac{\rho_X(2)-\rho_X^2(1)}{1-\rho_X^2(1)}$	$\rho_X(1) = \frac{-\theta_1(1-\theta_2)}{1+\theta_1^2+\theta_2^2}$ $\rho_X(2) = \frac{-\theta_2}{1+\theta_1^2+\theta_2^2}$
Região de Admissibilidade	$\begin{cases} \phi_2 + \phi_1 < 1 \\ \phi_2 - \phi_1 < 1 \\ \phi_2 < 1 \end{cases}$	$\begin{cases} \theta_2 + \theta_1 < 1 \\ \theta_2 - \theta_1 < 1 \\ \theta_2 < 1 \end{cases}$
Ordem	(1, d, 1)	
Comportamento de $\rho_X(k)$	Decai Exponencialmente após o lag 1	
Comportamento de $\phi_X(k, k)$	Decai Exponencialmente após o lag 1	
Estimativas Iniciais	$\rho_X(1) = \frac{[1-\phi_1\theta_1][\phi_1-\theta_1]}{1+\theta_1^2-2\phi_1\theta_1}$, $\rho_X(2) = \phi_1\rho_X(1)$	
Região de Admissibilidade	$ \phi_1 < 1$, $ \theta_1 < 1$	

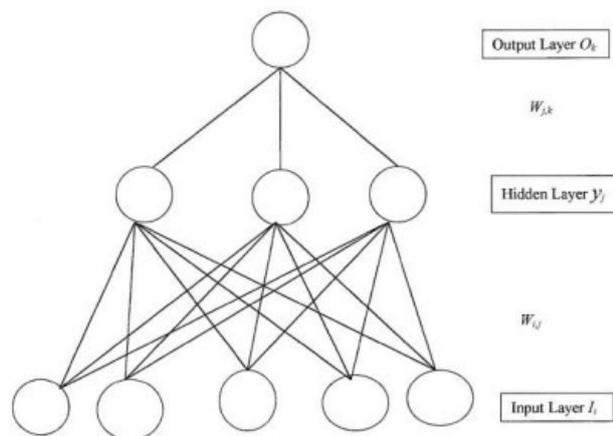
Fonte: Morettin e Tolo (2006)

2.2.1 Rede neural

A rede neural de *feed-forward* constitui-se em camadas: uma de entrada, uma de saída e, de modo geral, uma ou mais camadas escondidas e, a capacidade de aprendizagem em reconhecer padrões desta rede neural, possibilita ser utilizada como um modelo de previsão aplicado nos negócios (LAW, 2000). As entradas constituem a camada inferior e nas saídas formam a camada superior é possível ter camadas ocultas.

O modelo de rede neural aplicado nesta pesquisa pertence ao pacote do *software* R, denominado *forecast* e o modelo de previsão presente no manual do pacote chama-se *nnetar* este modelo funciona de forma semelhante aos neurônios do cérebro, assim a arquitetura da rede neural é composta por camadas. Na Figura 2 apresenta-se a arquitetura geral de uma rede do tipo *feed-forward*.

Figura 2 - Simplificação rede neural com três camadas



Fonte: Elaborado por Law (2000)

2.2.2 Medidas de desempenho de previsão

É importante avaliar a precisão das previsões, pois a magnitude dos resíduos não é uma indicação confiável de quão grandes os erros verdadeiros de previsão podem ser.

Na análise de séries temporais é bastante comum que existam vários modelos que podem ser utilizados para representar um conjunto de dados. O principal objetivo em ajustar um modelo à uma serie temporal é poder prever os seus futuros valores. Com isso, foram criados critérios de seleção de modelos baseados no erro de previsão, dado por Equação 4:

$$e(t) = X_t - \hat{X}_{\mathcal{F}(t-1)}(t), \quad (4)$$

Onde $\mathcal{F}(t-1) = \{X_{t-1}, \dots, X_1\}$, $t = 1, \dots, n$.

(a) Percentual médio de erro – MPE: também pode ser referenciado como vício já que ele mede o vício de previsão, Equação 5.

$$MPE = \left(\frac{1}{n} \sum_{t=1}^n \frac{e(t)}{X_1} \right) \times 100\% \quad (5)$$

(b) Erro médio absoluto de previsão – MAE, Equação 6:

$$MAE = \frac{1}{n} \sum_{t=1}^n |e(t)| \quad (6)$$

(c) Percentual médio absoluto de erro – MAPE: é uma das medidas de acurácia mais utilizada, devido as vantagens de interpretação e independência na escala. Essa medida está expressa na Equação (7).

$$MAPE = \left(\frac{1}{n} \sum_{t=1}^n \left| \frac{e(t)}{X_1} \right| \right) \times 100\% \quad (7)$$

(d) Raiz quadrada da média dos erros quadráticos - RMSE: Se a acurácia de técnicas de previsão é avaliada em séries temporais que apresentam a mesma escala, uma das medidas sugeridas é a raiz quadrada da média dos erros quadráticos (RMSE), Equação 8. Além disto, esta medida tem sido usada como métrico padrão para medir o desempenho de técnicas de previsão em estudos de meteorologia, qualidade do ar e pesquisa climática.

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n [e(t)]^2} \quad (8)$$

3 MATERIAIS E MÉTODOS

A monografia é de natureza exploratória, envolvendo pesquisa bibliográfica, documental e estudo de caso.

Os procedimentos técnicos utilizados foram: a) pesquisa bibliográfica, com material publicado em livros e artigos científicos; b) pesquisa documental, em especial com consulta em documentos e relatórios particulares; e, c) estudo de um caso, a fim de detalhar o conhecimento ao objeto do estudo.

Busca-se, com a pesquisa, a aplicação na prática de previsões das VPPs dirigida à solução de problemas específicos.

A forma de abordagem foi quantitativa para classificação e análise, utilizando modelagem matemática, simulação e análise da operação de cada componente de uma VPP.

A metodologia empregada consistiu, num primeiro momento, em uma revisão bibliográfica das VPP's e, o método proposto por Box-Jenkins, é utilizado na realização de previsão em séries temporais, o qual também é conhecido como metodologia ARIMA.

Em um segundo momento, foram desenvolvidos modelos de previsão ARIMA com dados reais coletados preço *spot* do dia seguinte para a Grã-Bretanha em libra esterlina (GBP - *Great British Pound*).

Os dados foram coletados de acordo com o padrão *Data Package do projeto Frictionless Data*, parte da *Open Knowledge Foundation*, contendo diferentes tipos de dados de séries temporais relevantes para modelagem de sistemas elétricos, nomeadamente preços de eletricidade. Os dados são agregados por país, área de controle ou zona de licitação. Todas as variáveis são fornecidas em resolução horária. Os dados são fornecidos por TSOs e *power* intercâmbios via ENTSO-E Transparência, abrangendo o período de 2015 a 30 de setembro 2020.

Para a estimação dos parâmetros e ajuste do modelo será utilizada a função `nnetar()`, que utiliza o algoritmo baseado na função `nnet()` desenvolvido e publicado por Venables e Ripley (2002). Esta abordagem somente considera a arquitetura *feed-forward networks* com uma camada intermediária usando a notação $NNAR(p,k)$, para séries sem sazonalidade e, $NNAR(p,P,k)[m]$, para séries com sazonalidade, sendo que p representa o número de *lags* na camada de entrada, k o número de nós na camada intermediária da rede, P o número de *lags* sazonais e $[m]$ a ordem sazonal.

3.1.1 Coleta de dados e o processo para a simulação dos modelos

Referente à coleta de dados do modelo 1, a amostra considerou 50.401 observações em períodos de 24 horas do dia 01 de janeiro de 2015 a 30 de setembro 2020 do banco de dados *Frictionless Data project* coletados a cada 60 minutos. Foram coletados preço *spot* do dia seguinte para a Grã-Bretanha em libra esterlina (GBP - *Great British Pound*).

- Para analisar os dados de séries temporais, foram importados os dados em formato “csv” para o *software* Rstudio e plotada a série temporal utilizando-se a função `plot.ts` em R;
- Com as 50.401 observações foram plotados gráficos para identificação de *outliers*;
- Para tratamento da série foi criada uma subsérie com 2100 observações, selecionando todas as observações na mesma hora=”00”, e utilizada a função `tsclean` que identifica e substitui outliers e valores ausentes;
- Em seguida foram calculadas as médias móveis mensais e semanais;
- Foi considerada a decomposição dos dados em sazonalidade, tendência e resíduos;
- Foram realizados os testes de estacionariedade, *Dickey- Fuller Test*;
- Foram apresentadas as FAC - função de autocorrelação e FACP- função de autocorrelação parcial;
- Foi aplicada uma diferença simples na série temporal;
- Novamente foi realizado o teste *Augmented Dickey-Fuller* para verificar a estacionariedade da série temporal;
- Foi calculado novamente a FAC - função de autocorrelação e FACP- função de autocorrelação parcial;
- Ajustou-se um modelo ARIMA (5,1,3), com a função `auto.arima`;
- Ajustou-se um modelo ARIMA (1,1,12);
- Foi ajustado um modelo de previsão com sazonalidade do modelo ARIMA (2,0,5) (2,2,0);
- Foi realizada simulação para previsão com redes neurais utilizando a função `NNETAR` (33,1,17).
- Foram obtidas as raízes inversas do polinômio característico AR e MA.
- Foram realizados testes e análises adicionais dos modelos; teste contra os valores originais do PDQ de ARIMA automático.
- Por fim, foram calculadas as medidas de desempenho para cada modelo.

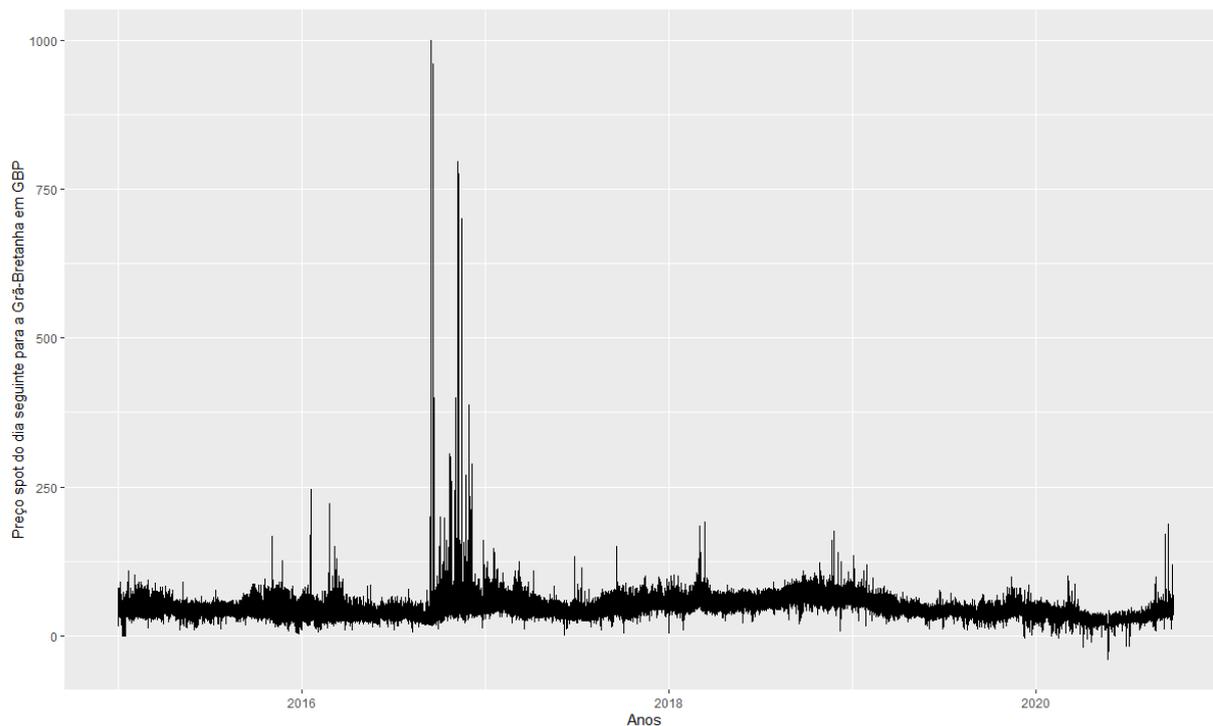
4 RESULTADOS E DISCUSSÃO

Neste capítulo, apresenta-se um estudo de caso estruturado com resultado da simulação dos Modelos de Previsão ARIMA com dados reais coletados de Preço *spot* do dia seguinte para a Grã-Bretanha em libra esterlina (GBP).

4.1 MODELOS PREVISÃO ARIMA COM DADOS REAIS COLETADOS DE PREÇO *SPOT* DO DIA SEGUINTE PARA A GRÃ-BRETANHA EM GBP

O gráfico do preço da energia na Grã-Bretanha em GBP é apresentado Figura 3. A amostra contém 50.401 observações em períodos de 24 horas do dia 01 de janeiro de 2015 a 30 de setembro 2020.

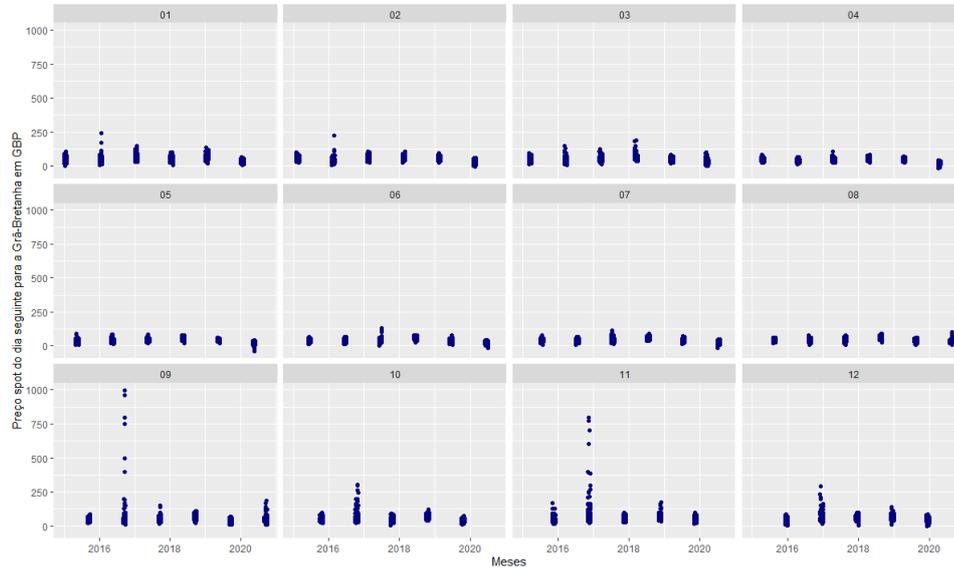
Figura 3 - Gráfico do preço da energia em Grã-Bretanha em GBP.



Na Figura 3 é possível observar o comportamento do preço da energia na Grã-Bretanha. Destaca-se que a série não apresentou evidências de estacionariedade.

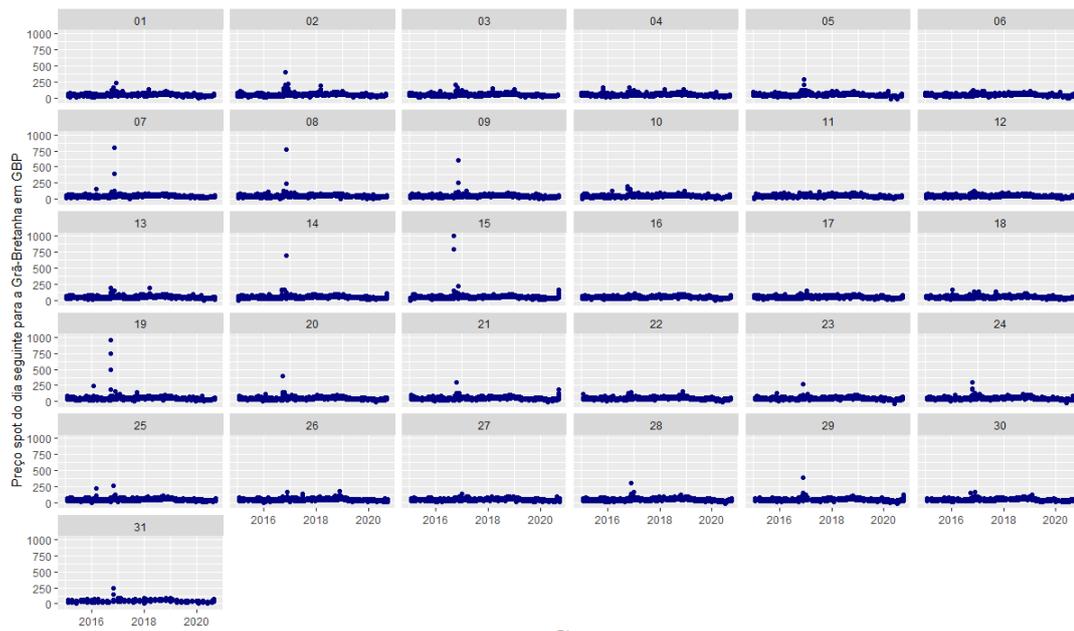
O gráfico mês a mês para identificação do *outliers* são apresentados na Figura 4.

Figura 4 - Gráfico mês a mês para identificação dos *outliers*



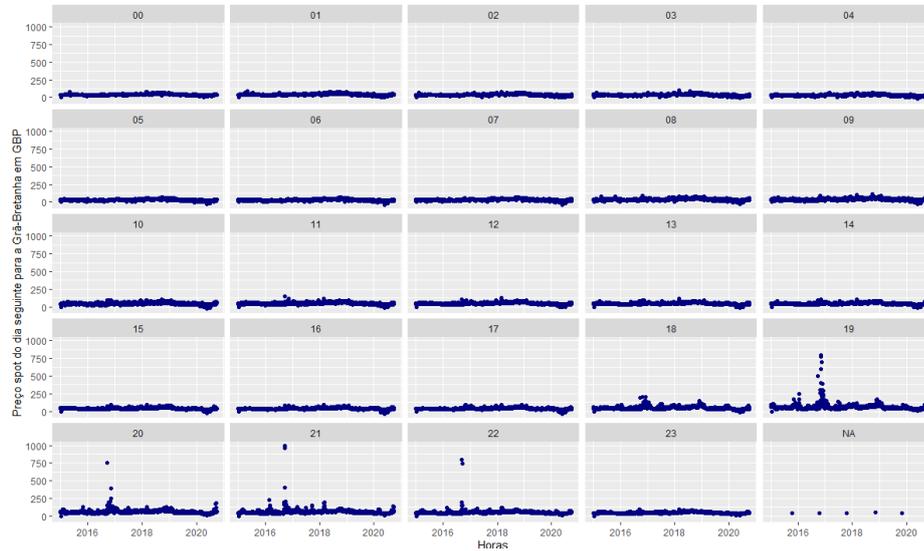
A identificação dos *outliers* são importantes pois são observações que desviam muito de outras observações, despertando suspeitas de que são geradas por um mecanismo diferente. O gráfico dia a dia para identificação dos *outliers* são apresentados na Figura 5.

Figura 5 - Gráfico dia a dia para identificação dos *outliers*



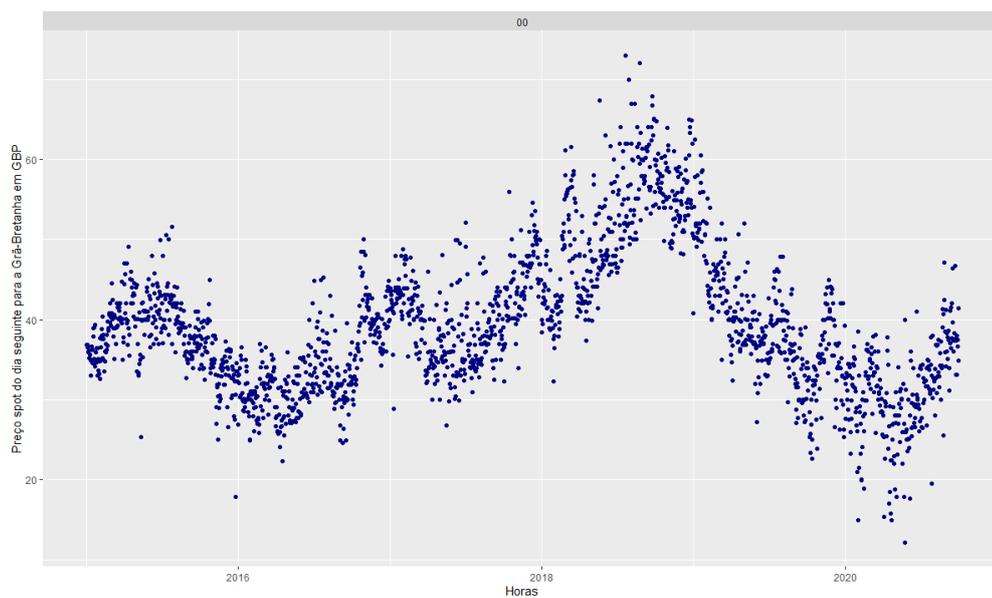
O gráfico hora a hora para identificação dos *outliers* são apresentados na Figura 6.

Figura 6 - Gráfico hora a hora para identificação dos *outliers*



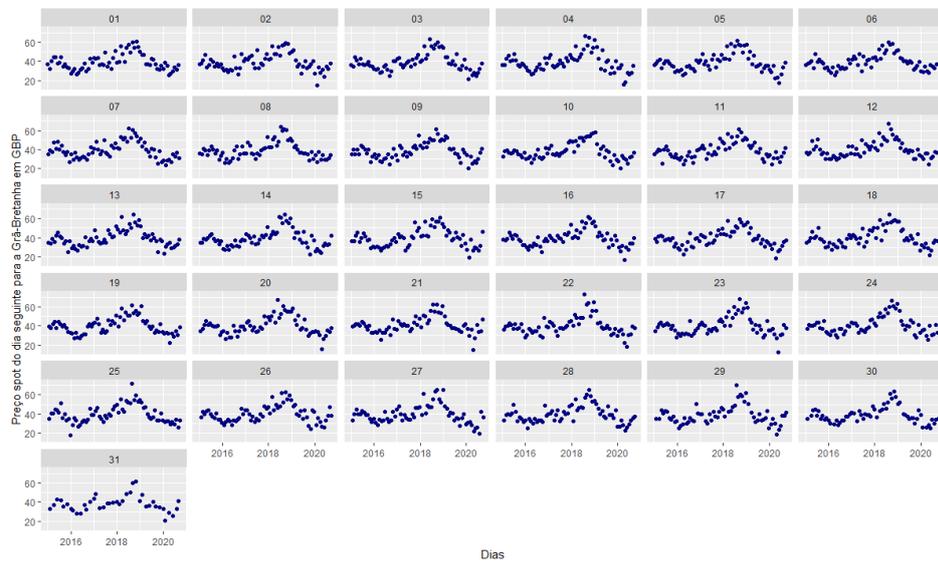
Para tratamento da série foi criada um subsérie com 2100 observações selecionando-se todas no mesmo horário (hora=00) e aplicada a função *tsclean* para substituir valores discrepantes e inserir valores ausentes, conforme Figura 7.

Figura 7- Gráfico da subsérie com 2100 observações, no mesmo horário (hora=00)



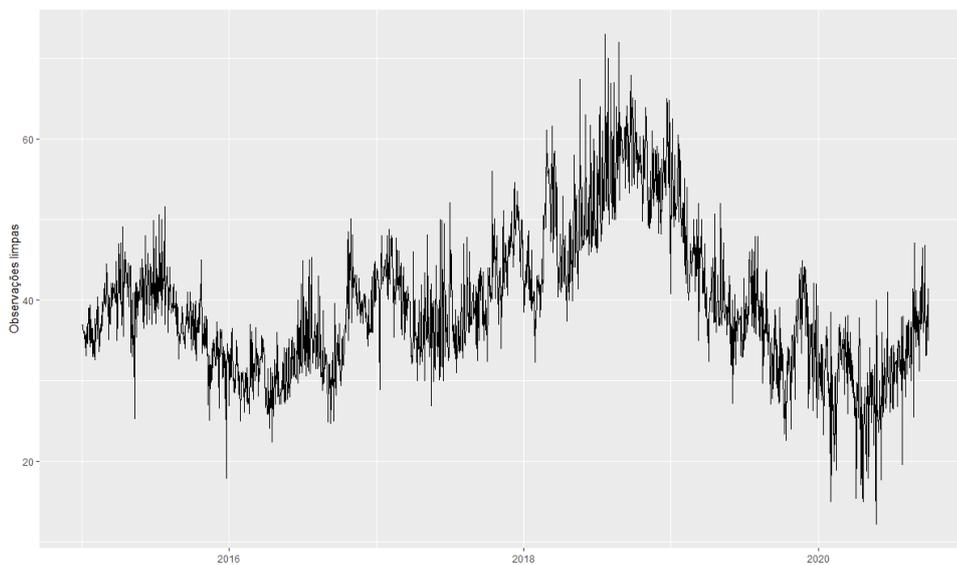
O Gráfico dia a dia da subsérie com 2100 observações, no mesmo horário é apresentado na Figura 8.

Figura 8 - Gráfico dia a dia da subsérie com 2100 observações, no mesmo horário (hora=00)



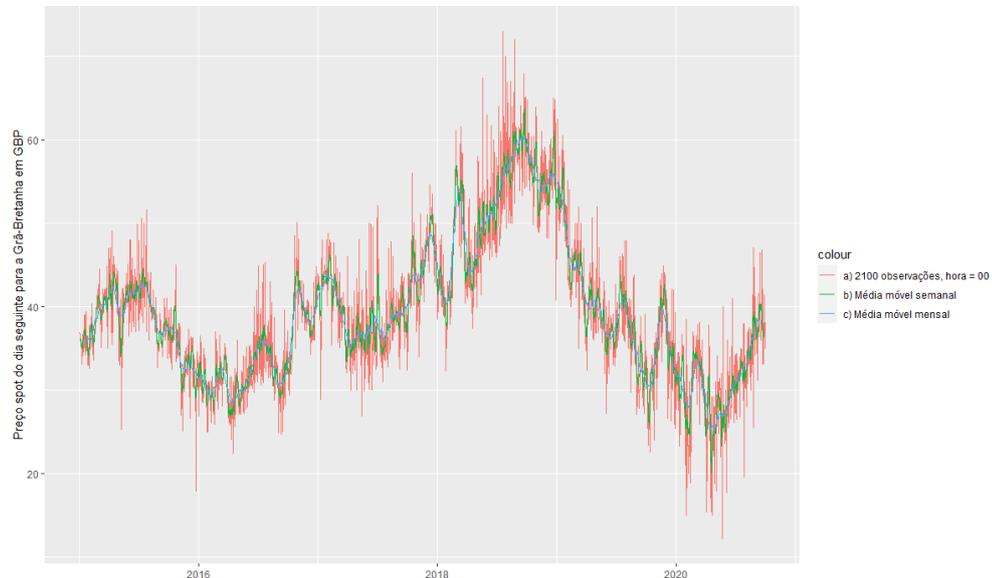
Com a função *tsclean* removeu-se *outliers* identificados e os substituiu por interpolação linear. O modelo foi testado com e sem a presença dos *outliers* para verificar a melhoria ou não da precisão, conforme Figura 9.

Figura 9 - Gráfico subsérie com 2100 observações, após tratamento da função *tsclean*.



Na Figura 10 é apresentado o gráfico das médias móveis mensais e semanais.

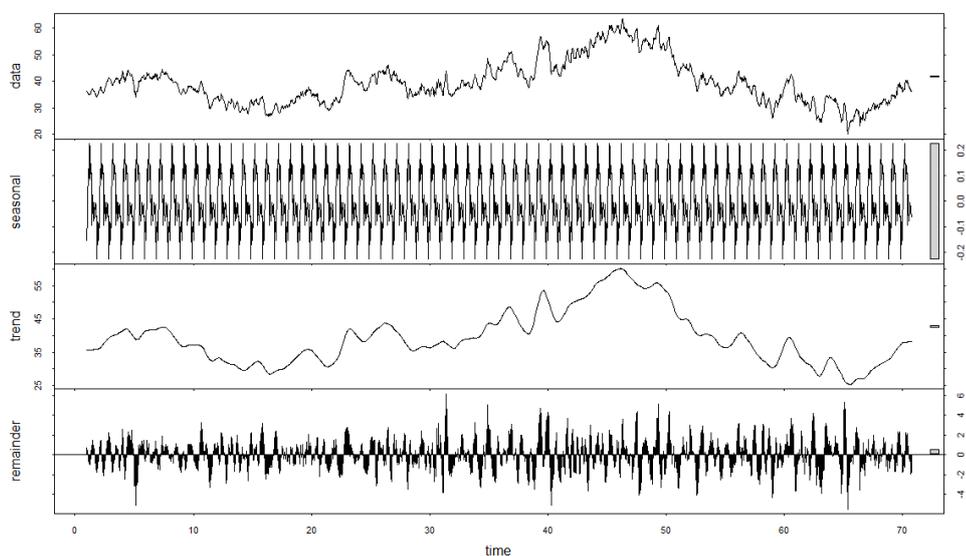
Figura 10 – Gráfico das médias móveis mensais e semanais



As séries temporais podem exibir uma grande variedade de padrões, os quais podem ser modelados separadamente, o que pode ajudar o analista a entender melhor os dados e, até mesmo, melhorar as previsões.

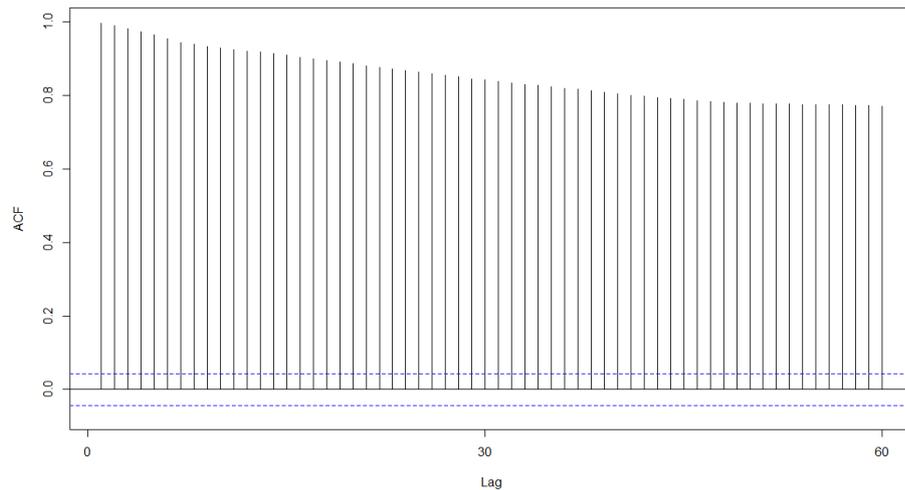
Na Figura 11 é apresentada a decomposição dos dados em sazonalidade, tendência e resíduos. Para o cálculo do componente de sazonalidade foi utilizado a função `stl`.

Figura 11 – Gráfico da decomposição dos dados em sazonalidade, tendência e resíduos



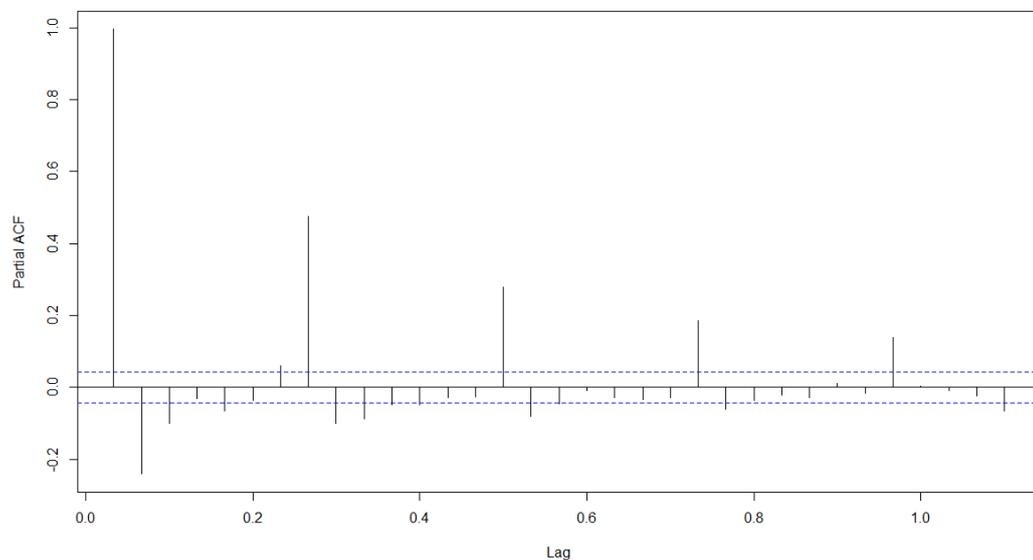
Aplica-se o teste *Augmented Dickey-Fuller* para verificar a estacionariedade das séries temporais. *Augmented Dickey-Fuller Test* : *Dickey-Fuller* = -2.5595, *Lag order* = 12, *p-value* = 0.3414. Na Figura 12 – Gráfico da FAC - função de autocorrelação.

Figura 12 – Gráfico da FAC - função de autocorrelação



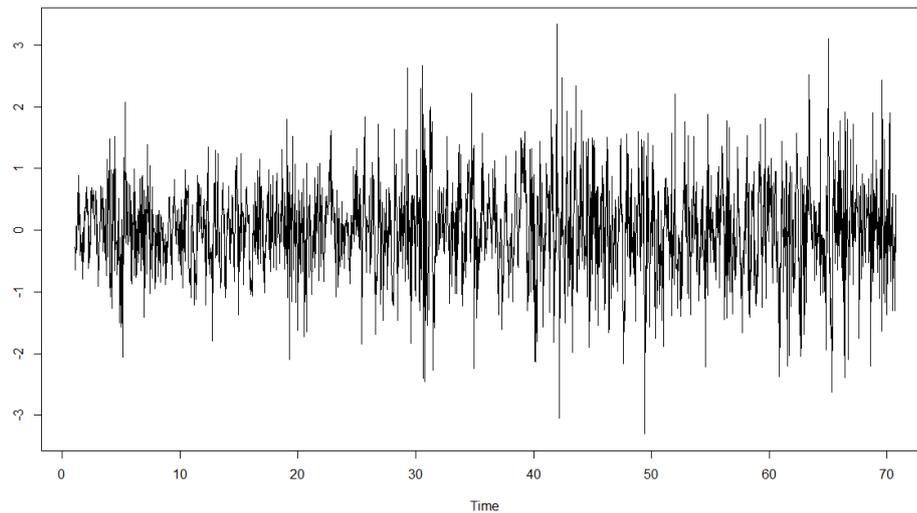
Foi realizada a primeira etapa da metodologia de Box-Jenkins, a análise das funções de autocorrelação (FAC) e autocorrelação parcial (FACP), com o objetivo de verificar a condição de estacionariedade para a série temporal analisada. O Gráfico da FACP- função de autocorrelação parcial é apresentado na Figura 13.

Figura 13 – Gráfico da FACP- função de autocorrelação parcial



Como valor $p = 0.3414 > \alpha = 0.05$ não se rejeita a hipótese nula, ou seja, a série temporal possui uma raiz unitária. Desta forma, aplicou-se uma diferença na série temporal.

Figura 14 – Gráfico da série temporal com uma diferença (-1) na série temporal.



Aplicou-se novamente o teste *Augmented Dickey-Fuller* para verificar a estacionariedade da série temporal. *Dickey-Fuller* = -12.119, *Lag order* = 12, *p-value* = 0.01 *alternative hypothesis: stationary*.

Na Figura 15, se observa a FAC da série diferenciada e os limites de confiabilidade

Figura 15 - Gráfico da FAC - função de autocorrelação com diferença (-1) na série temporal.

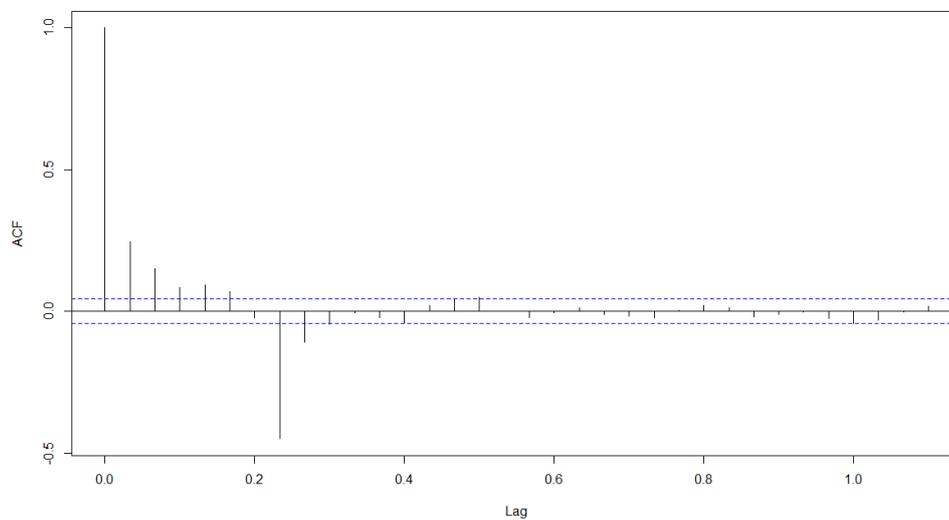
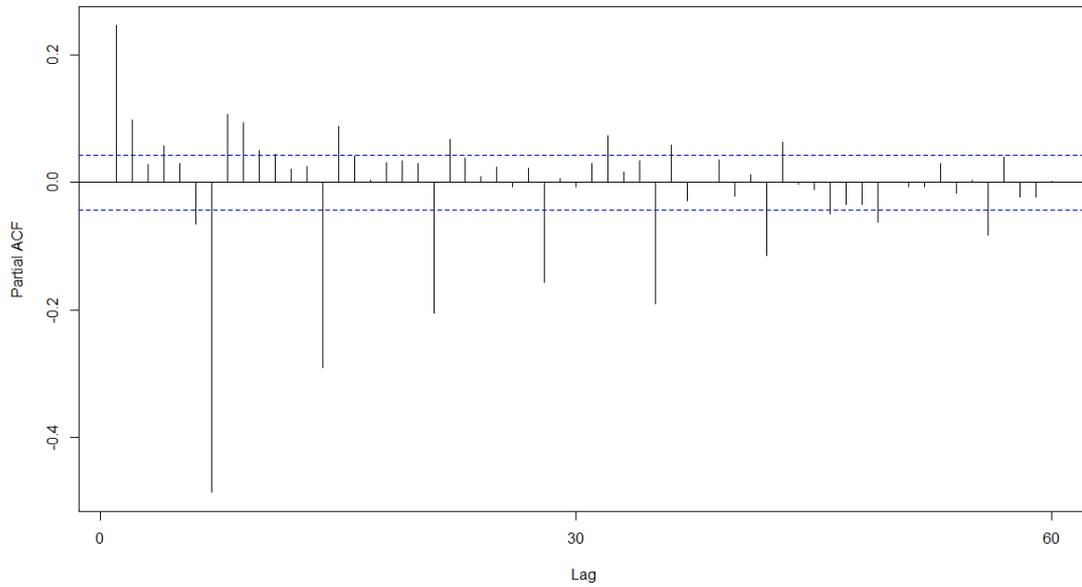


Figura 16 - Gráfico da FACP - função de autocorrelação parcial com diferença (-1).



Ajustou-se um modelo ARIMA com a função `auto.arima` `ARIMA(5,1,3)`. σ^2 *estimated* as 0.4402: $\log \text{likelihood} = -2109.36$, $\text{AIC} = 4236.72$, $\text{AICc} = 4236.81$ $\text{BIC} = 4287.54$.

Foi avaliado o modelo ARIMA de acordo a análise dos resíduos do modelo Figura 17 e Figura 18.

Figura 17 – Gráfico do ajuste, resíduos do modelo ARIMA (5,1,3) com função `auto.arima`

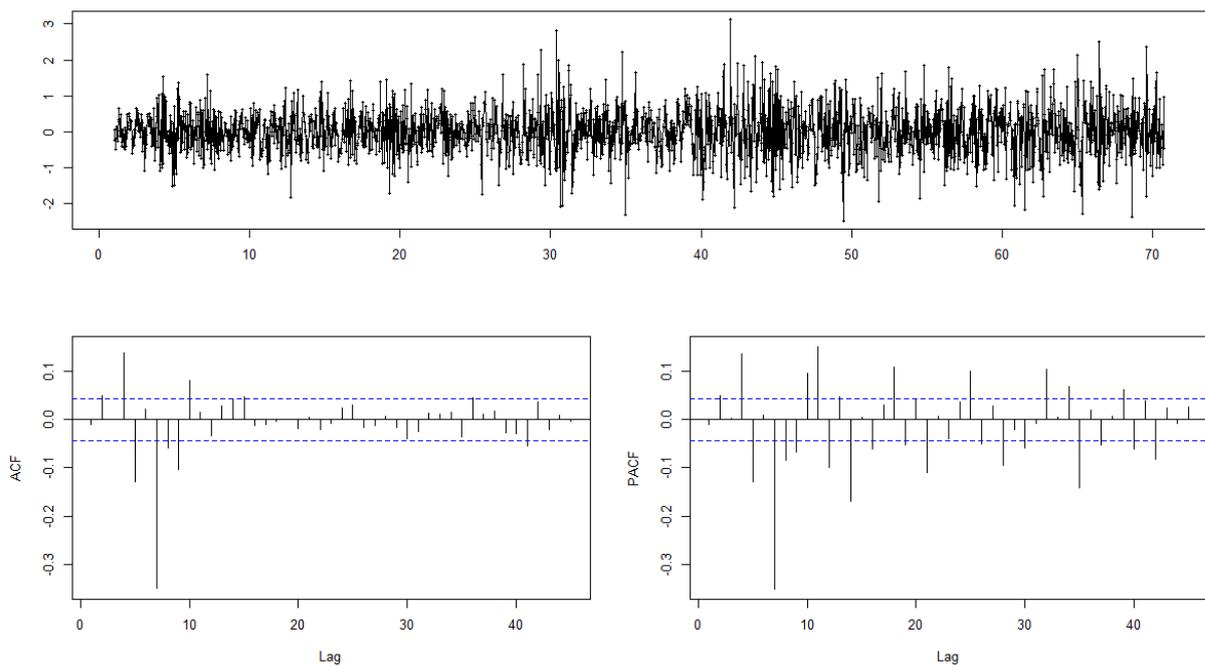
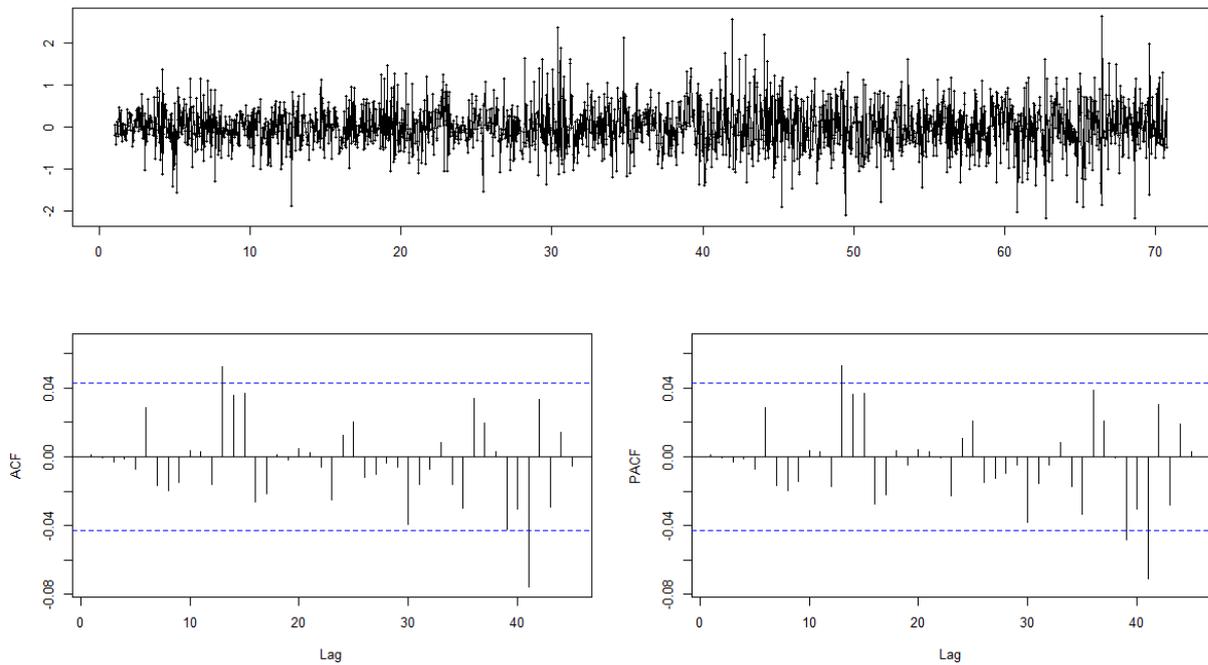
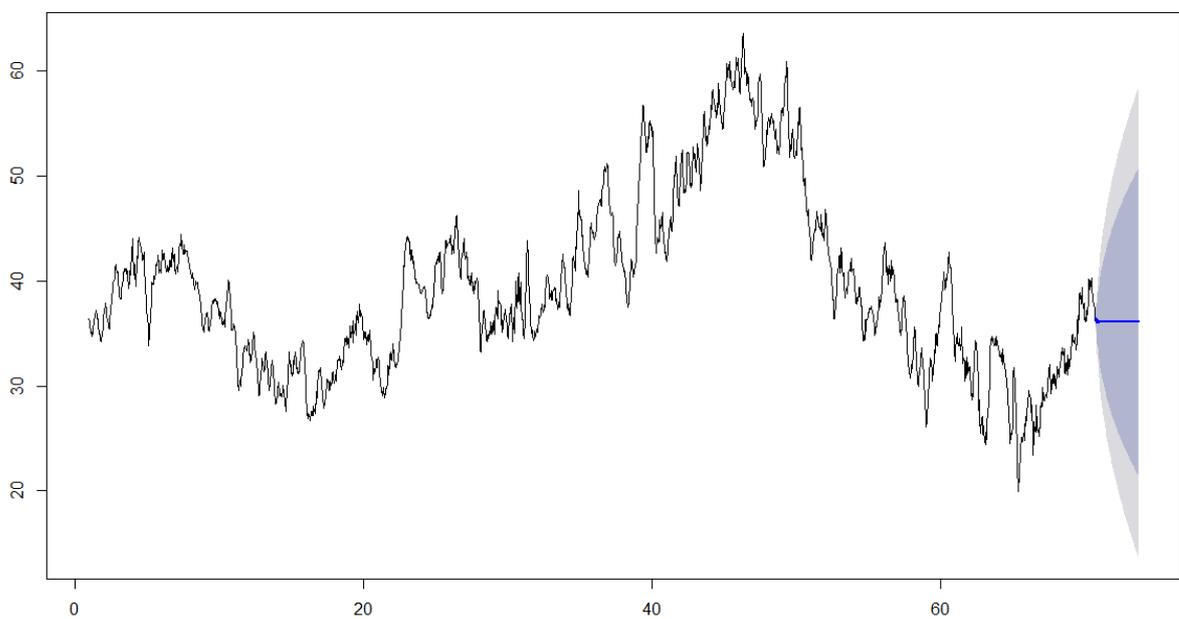


Figura 18- Gráfico do ajuste, resíduos do modelo ARIMA (1,1,12)



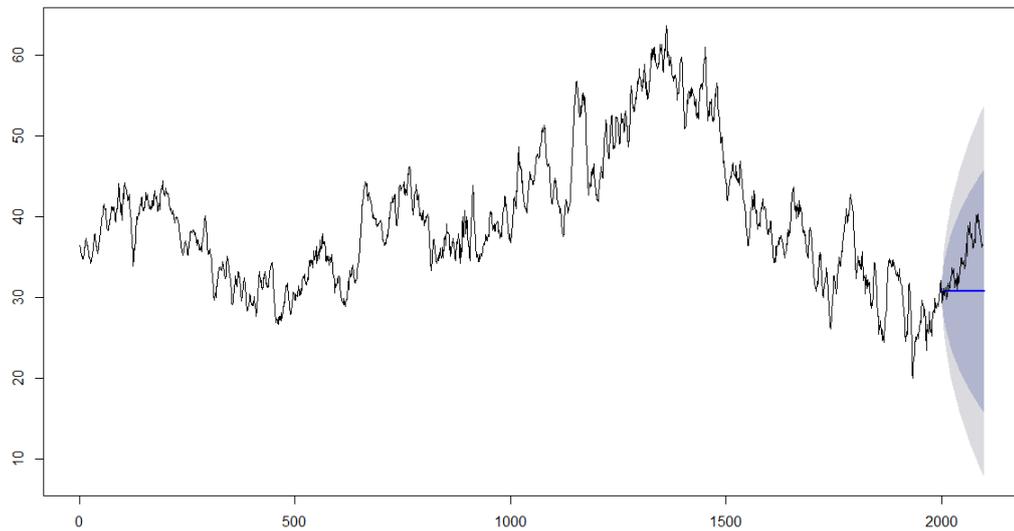
Obtida a série estacionária, procedeu-se a definição da ordem do modelo ARIMA (p , d , q), visando estimar os parâmetros que melhor se ajustassem à série. Na Figura 19 é apresentado gráfico da previsão com modelo ARIMA (5,1,3).

Figura 19 - Gráfico da previsão com modelo ARIMA (5,1,3)



Na Figura 20 é apresentado o teste de desempenho do modelo.

Figura 20 – Gráfico do Teste de desempenho do modelo validação da previsão ARIMA (5,1,3)



O modelo precisa de sazonalidade adicionada novamente, pois não é realista para o conjunto de dados. Conforme apresentado na Figura 21.

Figura 21 – Gráfico da previsão de $h=100$ períodos com sazonalidade com as médias moveis, do modelo SARIMA (2,0,5) (2,2,0).

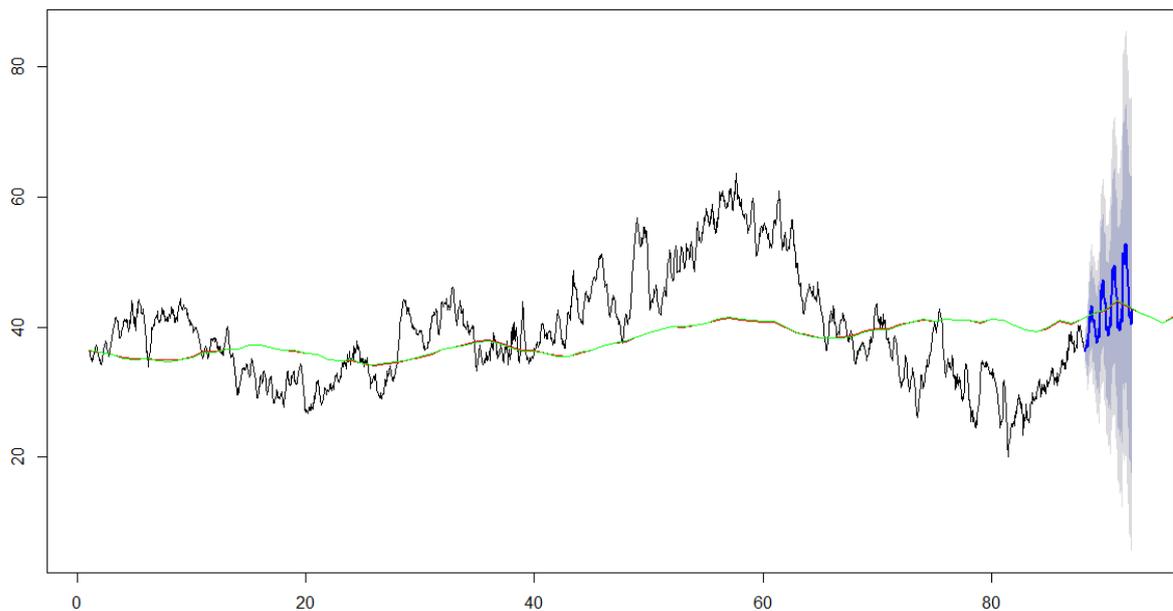
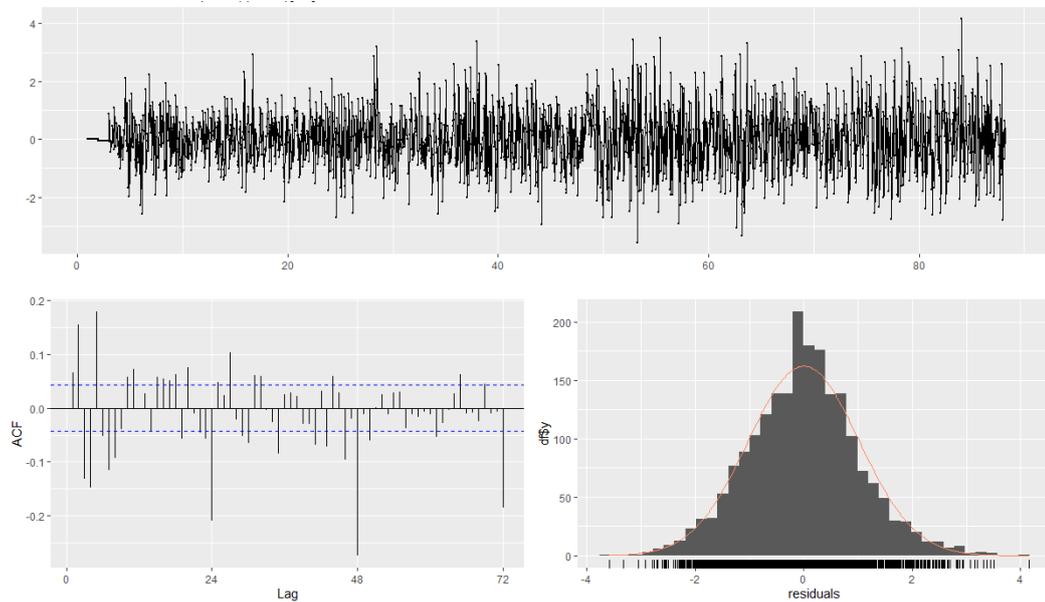
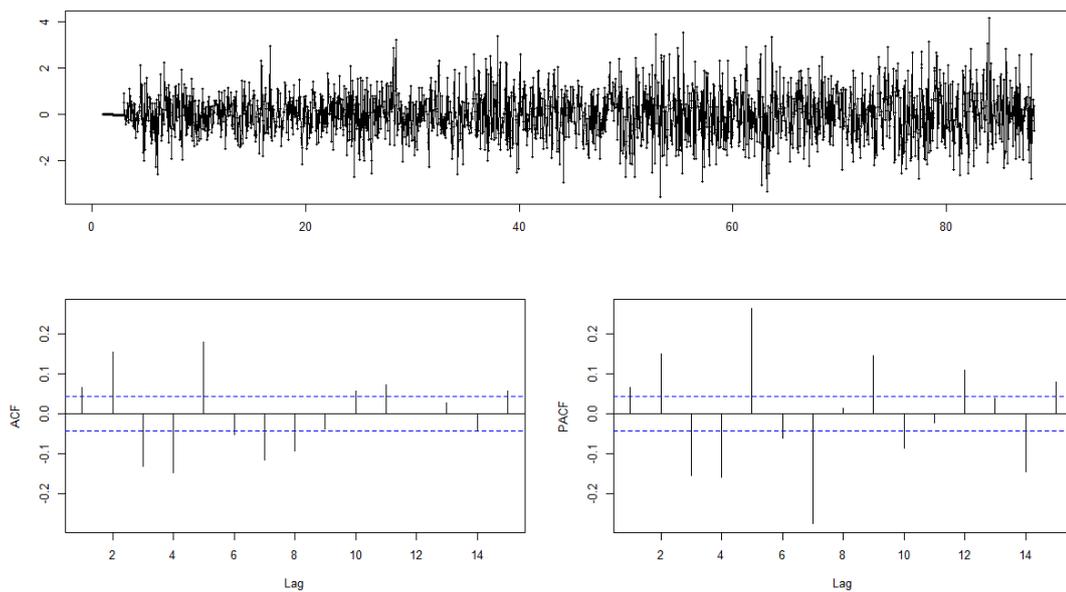


Figura 22 - Gráfico dos resíduos do modelo ARIMA (2,0,5) (2,2,0).



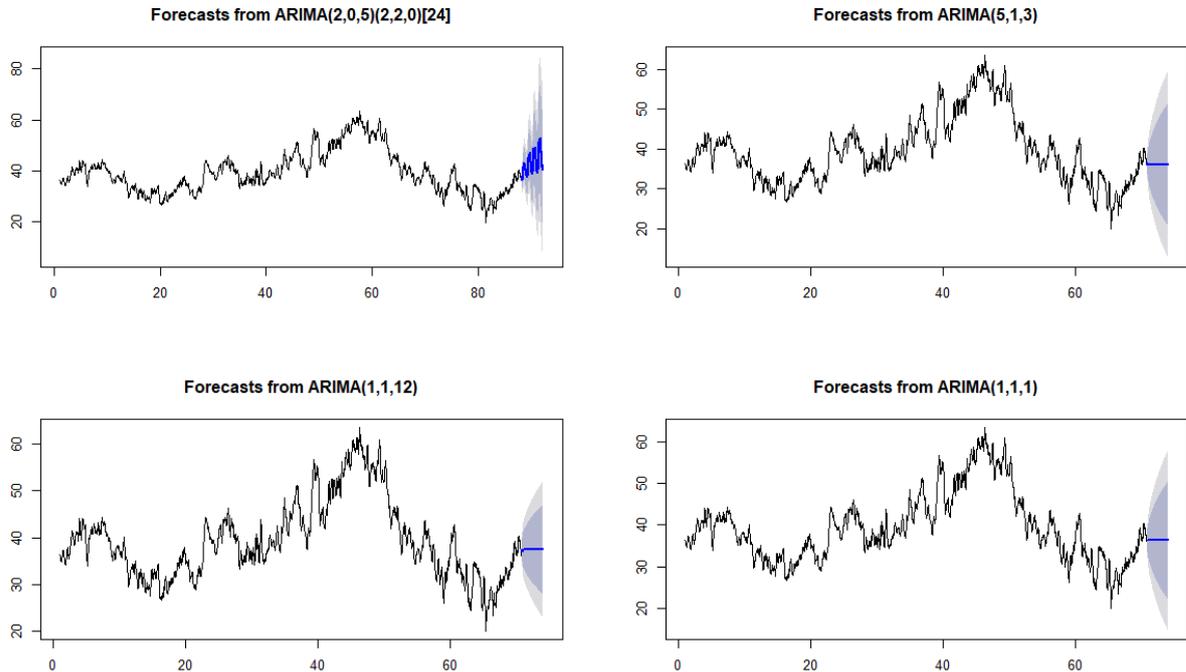
Considerando-se os testes e análises adicionais do modelo, foi possível identificar que os resíduos apresentaram-se não correlacionados.

Figura 23- Gráfico dos resíduos do modelo ARIMA (2,0,5)



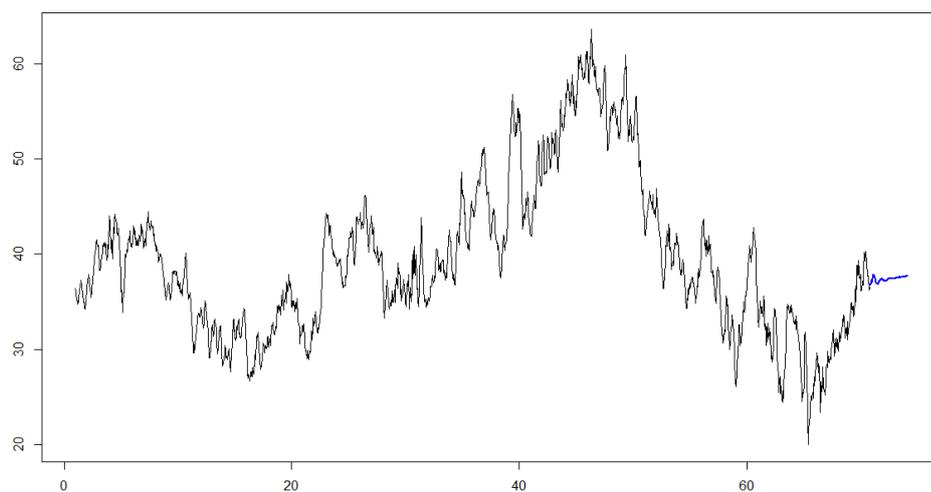
Tendo em vista que a análise dos resíduos se mostrou adequada à validação do modelo, realizou-se a previsão.

Figura 24- Gráfico dos modelos simulados



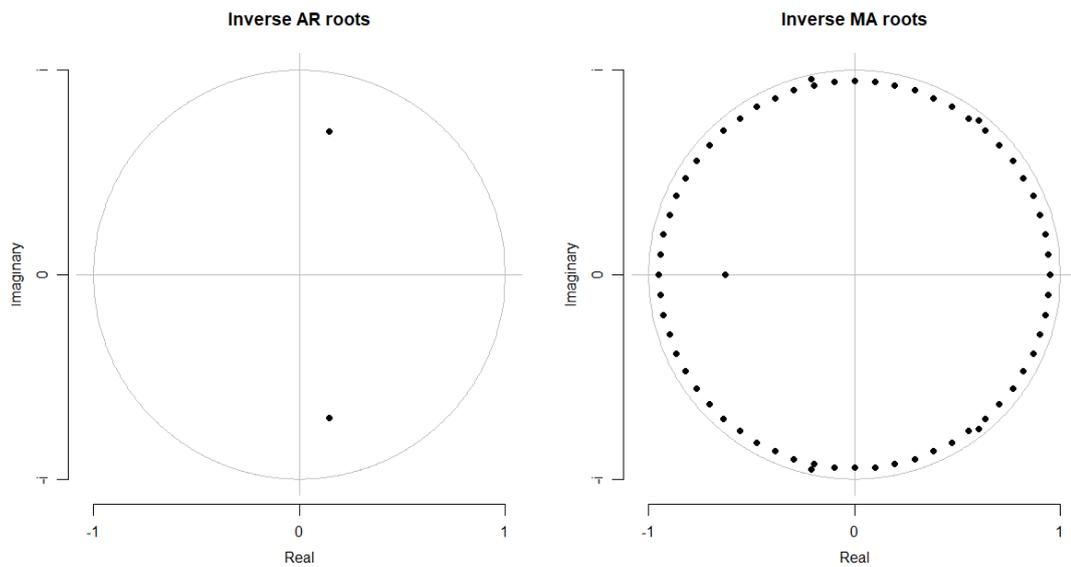
A seguir simulação para previsão com redes neurais utilizando a função NNETAR (33,1,17).

Figura 25 - Redes neurais utilizando a função NNETAR (33,1,17).



O modelo função NNETAR (33,1,17) demonstrou-se adequado para as previsões, visto que está em conformidade com as restrições do método.

Figura 26- Raízes inversas do polinômio característico AR e MA.



Se o processo ARMA estimado for (covariância) estacionário, então todas as raízes AR devem estar dentro do círculo unitário. Se o processo ARMA estimado for invertível, todas as raízes MA devem estar dentro do círculo unitário.

Para análise da precisão foi utilizada função *accuracy*, assim foram calculadas as medidas de desempenho para cada modelo como pode ser observado na Tabela 1.

Onde:

ME: erro médio;

RMSE: erro quadrático médio da raiz;

MAE: erro absoluto médio;

MPE: erro de porcentagem média;

MAPE: erro de porcentagem absoluta média;

MASE: erro escalonado absoluto médio;

ACF: coeficiente de autocorrelação.

Tabela 1 – Resultado das medidas de desempenho para cada modelo

Modelo	ME	RMSE	MAE	MPE	MAPE	MASE	ACF1
ARIMA (2,0,5) (2,2,0) [24]	0.001074743	1.021.133	0.788756	5,39E-01	2.069.277	0.2394877	0.06635264
ARIMA (5,1,3)	-3,86E+01	0.6620694	0.509526	0.002444642	1.337.176	0.1396354	-0.009915964
ARIMA (1,1,12)	0.0004236059	0.5443749	0.4108816	0.006442624	1.077.502	0.1126019	0.001457442
ARIMA (1,1,1)	-9,37E+00	0.7277055	0.5477016	0.00875272	1.438.827	0.1500974	-0.003807087
ARIMA NNETAR (33,1,17) [30].	0.0009423634	0.4985138	0.3828945	0.01758842	1.005.115	0.104932	-0.01415711

É esperado que os valores da estatística variem, como indicação de modelos de previsão adequados, os melhores modelos são os que se aproximam de 0. Assim, observa-se que os modelos são aceitáveis e capazes de calcular valores de previsões.

Pode-se dividir as métricas de precisão em dois grupos: os baseados em escala e os baseados em percentuais. As duas métricas de erro baseadas em escala são o MAE e o RMSE. Como o objetivo desta análise é avaliar a qualidade de ajuste e a precisão de diferentes modelos para uma mesma série, as métricas baseadas em escala não são um problema. Entre as duas métricas, a MAE é mais fácil e simples de explicar. Contudo, o *output* da RMSE representa o que vários algoritmos de previsão são escritos para minimizar, podendo ser compreendida como uma medida análoga ao desvio padrão do modelo.

5 CONSIDERAÇÕES FINAIS

Neste trabalho, por meio dos modelos ARIMA, analisou-se a qualidade e a precisão dos modelos de previsão dos preços da eletricidade de uma VPP. A escolha do modelo foi motivada pela sua capacidade capturar medições das séries temporais na presença de correlações.

Foi apresentado o conceito de VPP, analisados os tipos de VPP e os modelos com as técnicas e estratégias de implantação existentes no mercado.

Realizou-se um estudo de caso estruturado para simulação dos modelos de previsão ARIMA com dados reais coletados dos preços *spot* do dia seguinte da Grã-Bretanha em GBP.

Após ajustes nos modelos de previsão apropriados para os preços de eletricidade do dia seguinte comparou-se os modelos ARIMA por meio de medidas de desempenho. A análise da precisão foi utilizada com função *accuracy* e os melhores modelos foram os que se aproximam de 0, onde se observou que os modelos são aceitáveis e capazes de traçar previsões. O resultado da previsão com redes neurais apresentou as melhores medidas de desempenho com o modelo ARIMA NNETAR.

Os modelos estimados permitiram uma previsão de 100 períodos com sazonalidade e com as médias moveis. Assim, com o estudo conclui-se que a utilização da metodologia de séries temporais constitui um importante suporte e apoio nas previsões das VPP já que possibilita a melhor tomada de decisões.

REFERÊNCIAS

BOX, G, JENKINS, G.; **Time series analysis: forecasting and control**. revised ed. San Francisco: Holden-Day; 1976.

CONEJO A.J.; CONTRERAS J.; ARROYO J.M.; S. de la Torre. “Optimal response of an oligopolistic generating company to a competitive pool-based electric power Market”, in **IEEE Transactions on Power Systems**, Vvo. 17, no. 2, p. 424-43, May 2002. Doi: 10.1109/TPWRS.2002.1007913. Disponível em <https://ieeexplore.ieee.org/document/1007913>, acesso em 01 de maio de 2022.

WEISS E., “Forecasting commodity prices using ARIMA,” **Technical Analysis of Stocks & Commodities**, vol. 18, no. 1, pp. 18–19, 2000.

HOOSHMAND, R. A.; NOSRATABADI, S. M.; GHOLIPOUR, E. Event-based scheduling of industrial technical virtual power plant considering wind and market prices stochastic behaviors - A case study in Iran. **Journal of Cleaner Production**, v. 172, p. 1748–1764, 2018.

ARROYO J. M. and CONEJO A.J, "Optimal response of a thermal unit to an electricity spot market," in **IEEE Transactions on Power Systems**, vol. 15, no. 3, pp. 1098-1104, Aug. 2000, doi: 10.1109/59.871739. Disponível em <https://ieeexplore.ieee.org/document/871739>, acesso em 01 de maio de 2022.

JU, L. et al. Multi-objective stochastic scheduling optimization model for connecting a virtual power plant to wind-photovoltaic-electric vehicles considering uncertainties and demand response. **Energy Conversion and Management**, v. 128, p. 160–177, 2016a.

JU, L. et al. A bi-level stochastic scheduling optimization model for a virtual power plant connected to a wind-photovoltaic-energy storage system considering the uncertainty and demand response. **Applied Energy**, v. 171, p. 184–199, 2016b.

KOW, K. W. et al. A review on performance of artificial intelligence and conventional method in mitigating PV grid-tied related power quality events. **Renewable and Sustainable Energy Reviews**, v. 56, p. 334–346, 2016.

LAW, R. (2000). Back-propagation learning in improving the accuracy of neural network-based tourism demand forecasting. *Tourism Management*, 21(4), 331-340.

NOSRATABADI, S. M.; HOOSHMAND, R. A.; GHOLIPOUR, E. Stochastic profit-based scheduling of industrial virtual power plant using the best demand response strategy. **Applied Energy**, v. 164, p. 590–606, 2016.

NOSRATABADI, S. M.; HOOSHMAND, R. A.; GHOLIPOUR, E. A comprehensive review on microgrid and virtual power plant concepts employed for distributed energy resources scheduling in power systems. **Renewable and Sustainable Energy Reviews**, v. 67, p. 341–363, 2017.

VENABLES, W.N. ; RIPLEY, B.D. **Modern Applied Statistics with S**. Springer, New York, 271-300., 2002