

**Faculdade de Engenharia da Universidade do Porto**



**Impacto do Erro da Previsão Eólica nas Necessidades a  
Longo Prazo de Reserva Operacional**

João Teixeira

VERSÃO FINAL

Dissertação realizada no âmbito do  
Mestrado Integrado em Engenharia Eletrotécnica e de Computadores  
Energia

Orientador: Professor Manuel António Cerqueira da Costa Matos, *Ph.D.*  
Coorientador: Leonel de Magalhães Carvalho, *Ph.D.*

Porto, Portugal  
Outubro, 2015



A Dissertação intitulada

“Impacto do Erro da Previsão Eólica nas Necessidades a Longo Prazo de Reserva Operacional”

foi aprovada em provas realizadas em 23-10-2015

o júri



Presidente **Professora Doutora Maria Helena Osório Pestana de Vasconcelos**  
Professora Auxiliar do Departamento de Engenharia Eletrotécnica e de Computadores da Faculdade de Engenharia da Universidade do Porto



**Professor Doutor Humberto Manuel Matos Jorge**  
Professor Auxiliar do Departamento de Engenharia Electrotécnica e de Computadores da Faculdade de Ciências e Tecnologia da Universidade de Coimbra



**Professor Doutor Manuel António Cerqueira da Costa Matos**  
Professor Catedrático do Departamento de Engenharia Eletrotécnica e de Computadores da Faculdade de Engenharia da Universidade do Porto

O autor declara que a presente dissertação (ou relatório de projeto) é da sua exclusiva autoria e foi escrita sem qualquer apoio externo não explicitamente autorizado. Os resultados, ideias, parágrafos, ou outros extratos tomados de ou inspirados em trabalhos de outros autores, e demais referências bibliográficas usadas, são corretamente citados.



Autor - João Emanuel Leal Teixeira

Faculdade de Engenharia da Universidade do Porto



Earth is abundant with plentiful resources. Our practice of rationing resources through monetary control is no longer relevant and is counter-productive to our survival.

*Jacque Fresco*



# Resumo

A cada dia que passa, torna-se mais forte a evidência de que as centrais elétricas baseadas em combustíveis fósseis terão que ser substituídas por outras centrais mais sustentáveis, nomeadamente, centrais que usam fontes de energia renovável. Sendo o sistema elétrico um dos que mais afeta o meio ambiente, nomeadamente em termos de emissão de gases de efeito de estufa, tem havido um crescente incentivo por parte dos governos mundiais ao uso destas formas de energias alternativas.

A penetração de fontes de energia renovável no SEE trás benefícios e desvantagens. De todas as fontes de energia renovável existentes, é a eólica a mais popular e a que mais energia injeta na rede. No entanto, o comportamento variável do vento trás incertezas adicionais não só para operação mas também para o planeamento do sistema de produção. Para manter o equilíbrio entre a geração e a carga durante a operação do sistema, são necessárias reservas de potência no sistema para fazer face às situações onde existe excesso ou défice de geração. Estas situações resultam não só do comportamento estocástico associado à energia renovável e à carga do sistema mas também da indisponibilidade de geradores que podem sair de serviço intempestivamente por avaria. Mediante esta incerteza crescente, torna-se, portanto, necessário planear e dimensionar adequadamente não só a reserva estática mas também a reserva operacional do ponto de vista estratégico, i.e., no planeamento dos sistemas de produção.

O RESERVAS é um programa que avalia a disponibilidade a longo-prazo das reservas estática e operacional do sistema de produção. Baseando-se em Simulação Sequencial de Monte Carlo, consegue estimar os índices de fiabilidade para os dois tipos de reserva. Para se simular a incerteza associada à previsão da potência eólica durante a avaliação de reserva operacional, o programa RESERVAS utiliza o modelo Naïve que permite estimar erros de previsão usando o conceito de persistência. Este modelo é simples e amplamente usado para previsão a curto-prazo. No entanto, existem situações em que este modelo de previsão leva a estimação do erro de uma

forma grosseira e, conseqüentemente, não permite aferir a verdadeira adequação da reserva operacional que existe no sistema de produção. De forma a ultrapassar este problema, é proposto um modelo ARIMA para melhorar o erro de previsão e substituir o modelo Naïve.

O sistema teste utilizado é baseado no sistema didático *IEEE RTS 79* onde se incluiu um parque eólico e variação mensal da capacidade de produção hídrica. O resultado destes testes são os índices de fiabilidade da reserva operacional para vários níveis de integração eólica, ao nível HL1. A este nível hierárquico, todos os geradores e cargas do sistema estão ligados a um barramento. Os índices de fiabilidade analisados são o LOLP, LOLE, EPNS, EENS, LOLF e LOLD.

Com diferentes escalonamentos das unidades de produção do sistema, são avaliados vários cenários de capacidade máxima instalada de potência eólica, entre as quais: sem produção eólica, 800, 1600 e 2400 MW. Os escalonamentos das unidades produtoras são ordenados de duas formas: caso A - 1º parque eólico, 2º unidades térmicas, 3º unidades hídricas; caso B - 1º parque eólico, 2º unidades hídricas, 3º unidades térmicas. Em caso de cenário de produção eólica, utilizou-se os modelos de previsão Naïve e ARIMA. A análise destes dois modelos de previsão determinou qual é a influência dos erros de previsão a nível das necessidades de reserva operacional a longo-prazo.

No final, e para o mesmo valor de risco, as avaliações obtidas pelo modelo de previsão eólica ARIMA foram melhores do que as obtidas pelo modelo Naïve. Com o modelo Naïve, a Reserva Operacional estava a ser sobrestimada, devido aos erros de previsão, e com esta melhoria no modelo de previsão eólica, conseguiu-se introduzir mais eólica no sistema, pois o erro de previsão diminuiu. O modelo ARIMA é um bom modelo para previsão eólica a curto-prazo, mas introduz erros de sazonalidade que podem vir a influenciar na avaliação dos índices de fiabilidade do sistema. No entanto, os valores obtidos na previsão da potência eólica por este modelo e as respetivas avaliações da Reserva Operacional, são mais satisfatórias do que as obtidas pelo modelo Naïve, dentro do mesmo nível de risco, levando a crer que este é um modelo de previsão que deve substituir o Naïve no programa RESERVAS.

# Abstract

Every day becomes stronger the evidence of the fossil fuel-based power plants will have to be replaced by other more sustainable plants, namely, that who use renewable energy sources. Being the electric system one of the most that affects the environment, particularly in terms of emission of greenhouse gases, there has been a growing incentive for world governments to use these forms of alternative energy.

The penetration of renewable energy sources in the power system has benefits and also disadvantages. Of all the renewable energy sources that exist, the most popular is the wind energy and that kind of energy is injecting more energy in the network. However, the behaviour of variable wind energy gives additional uncertainties, not only for operation but also for the production system's management. To keep the balance between generation and load during system operation, power reserves are required in the system to deal with situations that have excess or deficit of generation. These situations are the result not only of the stochastic behaviour associated with the renewable energy and the load of the system, but also of the unavailability of generators that can leave the service releases for malfunction. Through this growing uncertainty, it is therefore necessary to plan and appropriately size not only static but also reserve operating reserve of the strategic point of view, i.e., in the planning of production systems.

The RESERVE is a program that evaluates the long-term availability of static and operational reserves of the production system. Based on Sequential Monte Carlo Simulation can estimate the reliability indices for both types of reservation. To simulate the uncertainty associated with the prediction of wind power during the evaluation of operating reserve, the RESERVE program uses the Naïve model which allows to estimate prediction errors using the concept of persistence. This forecasting model is simple and widely used for the short-term forecast. However, there are situations in which this forecast model leads to the estimation of the error of a crudely and consequently does not allow assessing the true operational reserve adequacy that exists on the

production system. In order to overcome this problem, an ARIMA model is proposed to improve the prediction error and replace the Naïve model.

The test system used is based on the system *IEEE RTS 79* where included a wind farm and monthly variation of water energy production capacity. The result of these tests are the operational reserve reliability indexes for various levels of wind integration, at HL1 level. This hierarchical level, all generators and loads in the system are connected to a single bus. The reliability indexes analysed are the LOLP, LOLE, EPNS, EENS, LOLF and LOLD.

With different steps of the system production units, are assessed several scenarios of maximum wind power installed capacity, including: no wind production, 800, 1600 and 2400 MW. The escalations of the producing units are ordered in two ways: case A - 1<sup>st</sup> wind farm, 2<sup>nd</sup> thermal units, 3<sup>rd</sup> hydroelectric units; case B - 1<sup>st</sup> wind farm, 2<sup>nd</sup> hydroelectric units, 3<sup>rd</sup> thermal units. In case of wind production scenario, it was used to predict the wind power prediction models Naïve and ARIMA. The analysis of two forecasting models determined what is the impact of forecast error in the needs of long-term operating reserve.

At the end, and for the same amount of risk, the ratings obtained by ARIMA wind forecasting model were better than those obtained by the Naïve model. With the Naïve model, the operating reserve was to be overestimated, due to forecasting errors, and with this improved wind forecasting model, was possible to introduce more wind power in the system, due to the decrease of prediction error. ARIMA model is a good model for short-term wind forecasting, but introduces seasonality errors that may influence the evaluation of system reliability indexes. However, the values obtained in the forecast of wind power for this model and the respective reviews of the operational reserve are more satisfactory than those obtained by the Naïve model, within the same level of risk, leading to believe that this is a prediction model that is to replace the Naïve in the RESERVE program.

# Agradecimentos

Ao longo dos últimos meses, o trabalho foi difícil e confuso, mas devido a pessoas que me ajudaram, posso agora escrever estas palavras. Um primeiro agradecimento vai para o meu coorientador, Doutor Leonel Carvalho, cuja orientação, paciência e atenção, fizera com que, mesmo em períodos de desmotivação, nunca perdesse o rumo. A ele a minha profunda admiração e gratidão, tendo sido um privilégio ter trabalhado sob o seu supervisionamento.

Ao Professor Manuel Matos que aceitou dar-me orientação, e cuja sabedoria, causou em mim uma crescente admiração e respeito. Um agradecimento pela orientação, palavras e ideias durante esta etapa, bem como a oportunidade do desenvolvimento da tese no INESC TEC.

À Sofia, pelo apoio incondicional, pela inspiração, pelo amor. Mesmo quando o tudo não fazia sentido, as suas palavras nas alturas mudaram o sentido de tudo.

Aos meus pais, arquitetos da minha formação, educação e principais engenheiros da criação dos meus alicerces. Sem eles nada disto seria possível.



# Índice

<b>Resumo</b> .....	<b>vii</b>
<b>Abstract</b> .....	<b>ix</b>
<b>Agradecimentos</b> .....	<b>xi</b>
<b>Índice</b> .....	<b>xiii</b>
<b>Lista de figuras</b> .....	<b>xv</b>
<b>Lista de tabelas</b> .....	<b>xvii</b>
<b>Abreviaturas e Símbolos</b> .....	<b>xix</b>
<b>Capítulo 1</b> .....	<b>1</b>
Introdução .....	1
1.1 Motivação e Contexto da Dissertação .....	1
1.2 Objetivos da Dissertação.....	4
1.3 Organização da Dissertação .....	5
<b>Capítulo 2</b> .....	<b>7</b>
Estado da Arte.....	7
2.1 Introdução .....	7
2.2 Métodos de Simulação.....	25
2.3 Índices de Fiabilidade .....	34
2.4 Avaliação da Reserva Operacional a Longo-Prazo.....	36
<b>Capítulo 3</b> .....	<b>41</b>
Previsão Eólica: Caso de Estudo.....	41
3.1 Introdução .....	41
3.2 Modelo de Previsão ARIMA.....	42
3.3 Modelo de Previsão Naïve .....	49
3.4 ARIMA vs Naïve .....	51
<b>Capítulo 4</b> .....	<b>55</b>
Avaliação da Reserva Operacional.....	55
4.1 Introdução .....	55
4.2 <i>IEEE RTS 79 HW</i> .....	56

4.3	Resultados das Simulações .....	59
4.4	Discussão de Resultados .....	63
<b>Capítulo 5</b>	.....	<b>69</b>
	Conclusão .....	69
5.1	Trabalhos Futuros .....	71
<b>Anexo 1.</b>	<b>Glossário</b> .....	<b>73</b>
<b>Anexo 2.</b>	<b>IEEE RTS 79 HW</b> .....	<b>75</b>
<b>Referências Bibliográficas</b>	.....	<b>77</b>

# Lista de figuras

Figura 1.1 – Diagrama de Consumo Total Portugal – 8 de agosto de 2015 [6].....	2
Figura 1.2 – Produção em Regime Especial Portugal – 8 de agosto de 2015 [6] .....	2
Figura 2.1 – Dois diferentes exemplos de modelos autorregressivos [11] .....	13
Figura 2.2 – Dois diferentes exemplos de modelo de média móvel [11] .....	13
Figura 2.3 – Autocorrelação de uma série temporal não estacionária .....	15
Figura 2.4 – Correlação parcial de uma série temporal não estacionária.....	17
Figura 2.5 – Fluxograma do algoritmo utilizado.....	21
Figura 2.6 – Exemplo de Simulação não Sequencial de Monte Carlo.....	26
Figura 2.7 – Exemplo de uma representação sequencial durante o período $T$ [45].....	28
Figura 2.8 – Modelo de Markov de dois estados [45] .....	29
Figura 2.9 – Modelo de Markov de multiestados [45].....	30
Figura 2.10 – Função de densidade de probabilidade da distribuição normal [8].....	33
Figura 2.11 – Representação hierárquica do SEE [45] .....	34
Figura 2.12 – Modelo de barramento único (HL1) [41] .....	35
Figura 2.13 – Reserva operacional [8] .....	37
Figura 2.14 – Modelo da estrutura do programa RESERVAS [8].....	39
Figura 2.15 – Resultado de uma simulação parcial [8].....	40
Figura 3.1 – Potência gerada pelo parque eólico ao longo de 3 anos .....	42
Figura 3.2 – A. Autocorrelação da série; B. Correlação parcial da série .....	42
Figura 3.3 – Série eólica diferenciada.....	44
Figura 3.4 – A. Autocorrelação da série diferenciada; B. Correlação parcial da série diferenciada .....	44
Figura 3.5 – Resultado do ciclo com o critério de minimização do BIC .....	46
Figura 3.6 – Resíduos do modelo de previsão ARIMA(4,1,3) .....	47
Figura 3.7 – A. Autocorrelação dos resíduos; B. Correlação parcial dos resíduos .....	47
Figura 3.8 – Resíduos do modelo de previsão Naïve.....	49

Figura 3.9 – A. Autocorrelação dos resíduos; B. Correlação parcial dos resíduos.....	49
Figura 3.10 – Histograma dos resíduos ARIMA(4,1,3) (laranja) e Naïve (azul) .....	51
Figura 3.11 – Gráficos Box para os modelos Naïve (esquerda) e ARIMA (direita) .....	52
Figura 3.12 – Gráfico <i>quantile-quantile</i> dos modelos Naïve (esquerda) e ARIMA (direita) .....	52
Figura 4.1 – Carga anual do <i>IEEE RTS 79 HW</i> .....	56
Figura 4.2 – Produção hídrica mensal vs Carga média mensal.....	57
Figura 4.3 – Parte negativa dos erros de previsão .....	58
Figura 4.4 – Valores do LOLP horários para potência eólica de 1600 MW.....	64
Figura 4.5 – Reserva Operacional solicitada na simulação A-1600 MW.....	64
Figura 4.6 – Valores do LOLP horários para potência eólica de 2400 MW.....	65
Figura 4.7 – Reserva Operacional solicitada na simulação A-2400 MW.....	66
Figura A.1 – Diagrama unifilar do sistema <i>IEEE RTS 79</i> .....	76

## Lista de tabelas

Tabela 3.1 – Tabela de valores estatísticos dos dados .....	41
Tabela 3.2 – Resultados do teste KPSS para a série eólica .....	43
Tabela 3.3 – Resultados do teste KPSS para a série eólica diferenciada .....	45
Tabela 3.4 – Critérios de ordem e estimação dos parâmetros ARIMA(4,1,3).....	46
Tabela 3.5 – Valores dos parâmetros para o modelo ARIMA(4,1,3) .....	46
Tabela 3.6 – Avaliação dos resíduos para o ARIMA(4,1,3).....	47
Tabela 3.7 – Teste Ljung-Box para o modelo ARIMA(4,1,3).....	48
Tabela 3.8 – Avaliação dos resíduos para o Naïve .....	49
Tabela 3.9 – Resultado do teste Ljung-Box para o modelo Naïve .....	50
Tabela 3.10 – Comparação da avaliação de cada modelo .....	51
Tabela 3.11 – Resultado do teste WRS.....	53
Tabela 4.1 – Ordem de mérito das unidades produtoras .....	58
Tabela 4.2 – Sumário dos testes.....	59
Tabela 4.3 – Parâmetros das simulações .....	59
Tabela 4.4 – Índices de fiabilidade sem produção eólica .....	60
Tabela 4.5 – Avaliação da $R_{OPE}$ para o modelo de previsão ARIMA.....	61
Tabela 4.6 – Avaliação da $R_{OPE}$ para o modelo de previsão Naïve .....	61
Tabela 4.7 – Comparação dos índices de fiabilidade para a ordem de mérito A .....	63
Tabela 4.8 – Comparação dos índices de fiabilidade para a ordem de mérito B .....	66
Tabela A.1 – Informação geradores do sistema <i>IEEE RTS 79 HW</i> .....	75



# Abreviaturas e Símbolos

## Lista de Abreviaturas

ACF	<i>Autocorrelation Function</i>
ADF	<i>Augmented Dickey–Fuller</i>
AIC	<i>Akaike Information Criteria</i>
ARIMA	<i>Autoregressive Integrated Moving Average</i>
BIC	<i>Bayesian Information Criteria</i>
EENS	<i>Expected Energy not Supplied</i>
EPNS	<i>Expected Power not Supplied</i>
FEUP	Faculdade de Engenharia da Universidade do Porto
HL0	<i>Hierarchical Level Zero</i>
HL1	<i>Hierarchical Level One</i>
HL2	<i>Hierarchical Level Two</i>
HL3	<i>Hierarchical Level Three</i>
INESC TEC	Instituto de Engenharia de Sistemas e Computadores - Tecnologia e Ciência

KPSS	Kwiatkowski–Phillips–Schmidt–Shin
LOLD	<i>Loss of Load Duration</i>
LOLE	<i>Loss of Load Expectation</i>
LOLF	<i>Loss of Load Frequency</i>
LOLP	<i>Loss of Load Probability</i>
MAE	<i>Mean Absolute Error</i>
MAPE	<i>Mean Absolute Percentage Error</i>
MCS	<i>Monte Carlo Simulation</i>
ME	<i>Mean Error</i>
MLE	<i>Maximum Likelihood Estimation</i>
MSE	<i>Mean Square Error</i>
MTTF	<i>Mean Time to Fail</i>
MTTR	<i>Mean Time to Repair</i>
PACF	<i>Partial Autocorrelation Function</i>
PRE	Produção em Regime Especial
REE	<i>Red Eléctrica de España</i>
REN	Rede Elétrica Nacional
RMSE	<i>Root Mean Square Error</i>
SEE	Sistema Elétrico de Energia
SMAPE	<i>Symmetric Mean Absolute Percentage Error</i>
UE	União Europeia
VAR	<i>Vector Autoregression</i>

WECS	<i>Wind Energy Conversion Systems</i>
WRS	Wilcoxon <i>rank-sum</i>
WTG	<i>Wind Turbine Generator</i>

#### Lista de Símbolos

$p$	Ordem do modelo AR
$d$	Ordem de diferenciação da série temporal
$q$	Ordem do modelo MA
$c$	Constante do modelo ARIMA( $p, d, q$ )
$\phi_p$	Parâmetro do modelo AR( $p$ )
$y_t$	Valor da série temporal a prever no instante $t$
$\theta_q$	Parâmetro do modelo MA( $q$ )
$e_t$	Erro da previsão no instante $t$
$T$	Dimensão da série temporal eólica
$L$	Valor <i>likelihood</i>
$Q^*$	Valor do teste Ljung-Box
$r_k$	Valor da autocorrelação no instante $k$
$\alpha$	Nível de confiança
$p_t$	Porcentagem do erro $e_t$ no instante $t$
$\sigma$	Desvio padrão

$\sigma^2$	Variância
$\tilde{E}[H(X)]$	Valores estimados de $E[H(X)]$
$H(X)$	Função teste na simulação Monte Carlo
$N$	Número de estados do sistema
$\tilde{V}(E[H(X)])$	Variância estimada
$\beta$	Coefficiente de variação (critério de paragem no MCS)
$S_{Xf}$	Subconjuntos de estado de insucesso
$S_{Xs}$	Subconjuntos de estado de sucesso
$NY$	Número de períodos simulados
$\lambda$	Taxa de avaria
$\mu$	Taxa de reparação
$T^{Up/Down}$	Tempo de residência em cada estado ( <i>Up/Down</i> )
$C_k$	Capacidade de produção da unidade $k$
$\Delta P_{ji}$	Perda de carga do estado $i$ na hora $j$ .
$\sigma_{CP}$	Desvio <i>standard</i> distribuição gaussiana contínua de incertezas a curto-prazo
$\sigma_{LP}$	Desvio <i>standard</i> distribuição gaussiana contínua de incertezas a longo-prazo
$STU$	Incerteza de curto-prazo
$LTU$	Incerteza de longo-prazo
$P^{Máx}$	Valor horário da carga
$R_{STA}$	Reserva Estática
$R_{OPE}$	Reserva Operacional
$R_S$	Reserva Secundária

$R_T$	Reserva Terciária
$\Delta L$	Varição da carga em curto-prazo
$\Delta P_W$	Varição da produção eólica
$\Delta G$	Varição da capacidade de produção
$p\text{-value}$	Valor $p$ resultante de testes estatísticos
$\chi^2_{\alpha, h-K}$	Valor <i>Chi-square</i> com nível de confiança $\alpha$ e $h-K$ graus de liberdade
$z\text{-value}$	Valor $z$ resultante do teste Wilcoxon <i>rank-sum</i>



# Capítulo 1.

## Introdução

### 1.1 Motivação e Contexto da Dissertação

Ao longo dos últimos anos, o Sistema Elétrico de Energia (SEE) está a mudar a sua matriz energética substituindo centrais que usam combustíveis fósseis por alternativas renováveis, sendo a Alemanha um bom exemplo internacional [1].

Sendo o sector energético um dos mais críticos no que toca ao impacto ambiental, esforços estão a ser feitos para que este problema tenha uma solução. O objetivo “20-20-20”, diretiva da UE (União Europeia) é um exemplo de mudança e preocupação ambiental [2]. Dentro desta diretiva estão os seguintes objetivos a serem atingidos até ao ano 2020, dentro do tema da alteração ambiental e energia sustentável:


- Reduzir 20% a emissão dos gases de efeito de estufa de 1990;
- 20% da energia ser proveniente de energias renováveis;
- Aumentar 20% a eficiência energética.

Recentemente, os líderes industriais G7 acordaram em reduzir os gases de efeito de estufa por fase, cortando o uso de combustíveis fósseis no final deste século [3], reduzindo de 40% a 70% até 2050 a emissão dos gases de efeito de estufa, tendo como referência os valores de 2010. Um dos países que tem atraído as atenções dentro deste contexto é a Dinamarca. Este país tem sido pioneiro na integração de energia proveniente de fontes renováveis, maioritariamente energia eólica. E recentemente conseguiu um valor de produção de energia proveniente de fonte renovável que atingiu os 140% do valor do pico de carga [4], mostrando que é possível efetuar a mudança do uso de combustíveis fósseis por soluções renováveis. A par deste país estão o Reino Unido e

## 2 Introdução

a Alemanha que tem batido recordes de produção de energia por via de fontes renováveis, sobretudo através da energia solar [5].

Em Portugal, cresce cada vez mais a penetração de energias renováveis na rede, sobretudo a energia eólica. A Figura 1.1 mostra o diagrama de consumo de Portugal no dia 8 de agosto de 2015, verificando que há uma alta penetração na rede de energia proveniente de fontes de Produção em Regime Especial (PRE).



**Figura 1.1** – Diagrama de Consumo Total Portugal – 8 de agosto de 2015 [6]

Na Figura 1.2 é possível observar as diversas fontes de PRE e apesar de nem todas serem provenientes de fontes renováveis, há uma maior produção de energia eólica neste dia em concreto.



**Figura 1.2** – Produção em Regime Especial Portugal – 8 de agosto de 2015 [6]

Com este exemplo [6], verifica-se que a energia eólica tem um peso considerável no sistema produtor. Por isso, o seu estudo é cada vez mais fundamental para planeamento e gestão do sistema produtor.

Na gestão de um sistema produtor é necessário planear com antecedência se a produção é, ou não, capaz de satisfazer a carga. Um dos problemas da incorporação da energia eólica no sistema é a sua variabilidade que está aliada à variação da velocidade do vento. Para se fazer face à

variação é necessário usar modelos de previsão. No entanto, a indisponibilidade da produção eólica está também depende de falhas furtivas dos aerogeradores [7].

A avaliação das necessidades a longo-prazo de Reserva Operacional tem em consideração, entre outros fatores, o erro inerente à previsão de potência eólica. No entanto, alguns erros de previsão podem levar a reservas excessivas, nomeadamente quando a previsão é superior ao observado. Assim sendo a exatidão da previsão eólica torna-se importante. Tradicionalmente utiliza-se nas avaliações de Reserva Operacional o modelo de previsão por Persistência, que pela nomenclatura anglo-saxónica, designa-se por Naïve. Este modelo considera que o comportamento do vento na hora  $t+1$  é igual ao da hora  $t$ , mas devido à crescente incorporação de energia renovável no sistema produtor, este método tornou-se desatualizado uma vez que introduz erros de persistência que podem levar ao incorreto planeamento da flexibilidade do parque de geração.

Diversos modelos de previsão que foram desenvolvidos e aplicados à produção eólica e que apresentam uma melhor performance comparativamente ao modelo Naïve. Isto leva a crer que modelos mais avançados e complexos, como modelos Autorregressivos ou até mesmo Redes Neurais Artificiais, podem ser uma solução para a redução do erro de previsão e, com isto, gerir melhor a reserva operacional evitando reservas excessivas e desnecessárias.

## 1.2 Objetivos da Dissertação

A energia eólica está cada vez mais presente no SEE, mas devido aos erros de previsão na potência eólica a curto-prazo, os índices de fiabilidade da Reserva Operacional podem ser afetados, e consequentemente levar a um mau planeamento do sistema e gestão das reservas operacionais. Quanto melhor se conhecer o comportamento do vento, melhor se saberá qual a potência eólica que estará disponível para satisfazer a carga.

O objetivo desta dissertação consiste em alterar e comparar no programa RESERVAS [8] o modelo de previsão Naïve por um outro mais completo, ARIMA, com o intuito de comparar as necessidades a longo-prazo de reserva operacional para cada modelo considerado. Sabendo que o modelo Naïve provoca erros de persistência que, por sua vez, pode levar a reservas operacionais excessivas, pretende-se com o modelo ARIMA diminuir os erros de previsão da potência eólica para evitar estes excessos de reservas operacionais, e com isto, integrar maior quantidade de potência eólica.

O programa RESERVAS, criado pelo INESC TEC (antigo INESC Porto), em projeto com a REN e a REE, usa o método de Simulação Sequencial de Monte Carlo para avaliar o risco associado às configurações específicas do sistema produtor [8]. Com a inclusão do novo modelo de previsão, pretende-se saber quanto se ganha em termos de diminuição da reserva operacional necessária para um dado nível de risco.

### 1.3 Organização da Dissertação

Esta secção destina-se à explicação da organização do trabalho, estando esta dividida em cinco capítulos.

**Capítulo 1:** neste capítulo apresentam-se os motivos para a realização desta dissertação bem como o seu objetivo, que consiste na substituição de um modelo de previsão eólica por um mais completo e analisar, através de Simulações Sequenciais de Monte Carlo, qual a influência dos erros de previsão a nível das necessidades da reserva operacional. Também é apresentada a estrutura da dissertação

**Capítulo 2:** este é o capítulo que destina à introdução teórica de Modelos de Previsão, Métodos de Simulação, Índices de Fiabilidade e Reserva Operacional. Apresenta-se aqui o estado da arte dos modelos de previsão de potência eólica e dos métodos de simulação para avaliação de fiabilidade. Também é explorada a metodologia que será usada para se obter os resultados de previsão da potência eólica como da avaliação da Reserva Operacional. Este capítulo está dividido nas seguintes secções: Introdução, onde é feita uma pequena introdução de modelos de previsão e onde está presente toda a teoria dos modelos de previsão; Métodos de Simulação, apresentando diferentes métodos de simulação, sobretudo focados no método de Simulação Monte Carlo; Índices de Fiabilidade, mostrando quais os índices a ser considerados para a dissertação; Avaliação da Reserva Operacional, onde está uma breve síntese do que é a avaliação da Reserva Operacional no contexto do planeamento, e de que forma funciona o programa RESERVAS.

**Capítulo 3:** nesta divisão serão mostrados e discutidos os resultados dos modelos de previsão ARIMA e Naïve. O capítulo está dividido em quatro secções: Introdução, onde se faz uma breve introdução ao caso de estudo; Modelo de Previsão ARIMA, secção em que é apresentado o modelo ARIMA parametrizado para o caso de estudo, e onde também são mostrados os resultados de previsão e analisados os respetivos resíduos; Modelo de Previsão Naïve, secção do capítulo onde são apresentados os resultados do modelo de previsão Naïve, e tal como no ARIMA, são analisados os respetivos resíduos; ARIMA vs Naïve última secção deste capítulo onde são analisados e discutidos por várias métricas, os resultados provenientes destes dois modelos de previsão da potência eólica.

**Capítulo 4:** capítulo mais importante da dissertação onde estão presentes os resultados da avaliação da reserva operacional, utilizando os modelos de previsão eólica ARIMA e Naïve. É neste ponto que se discute qual o melhor modelo através do impacto na reserva operacional que esses mesmos erros provocam. Os resultados são um produto da Simulação Sequencial de Monte Carlo utilizada no programa RESERVAS aplicado ao sistema teste *IEEE RTS 79 HW*. Este

## 6 Introdução

capítulo está dividido em quatro secções: Introdução, parte do capítulo onde se introduz teoricamente, o que se passará nas seguintes secções; *IEEE RTS 79 HW*, secção onde é mostrado o sistema teste usado nas simulações, informações acerca da carga, capacidade de produção hídrica, ordem de mérito e erros de previsão da produção eólica; Resultados das Simulações, parte onde estão presentes todos os resultados de simulação para diferentes ordens de mérito, capacidade de potência eólica instalada no sistema e diferente modelo de previsão, ARIMA e Naïve; Discussão de Resultados, por último, a secção onde se analisam os resultados, para um mesmo valor de risco, obtidos pelos diferentes modelos de previsão, e onde se concluiu qual o modelo de previsão da produção eólica a curto-prazo mais interessante, do ponto de vista de avaliação da reserva operacional a longo-prazo.

**Capítulo 5:** nesta última parte do trabalho são apresentadas as conclusões e trabalhos futuros que procedem ao tema desta dissertação.

## Capítulo 2.

# Estado da Arte

### 2.1 Introdução

O desenvolvimento e utilização de fontes de energias renováveis estão cada vez mais presentes no SEE, com vista a substituir as fontes de energia convencionais. Isto é, no Sistema Elétrico Nacional, existem cada vez mais fontes de energia renováveis a injetarem energia na rede e, por isso, devem ser cuidadosamente incluídas nos estudos de planeamento do sistema

Um dos inconvenientes na produção eólica é a incerteza associada à sua previsão. Sem o vento não se pode produzir qualquer quantidade de energia, portanto torna-se essencial prever a sua disponibilidade e procurar a maior disponibilidade nos vários pontos geográficos. A influência da previsão da produção eólica afeta questões como o planeamento de um SEE ao nível da Reserva Operacional. A indisponibilidade da produção eólica pode também estar associada a falhas fortuitas dos aerogeradores.

#### 2.1.1 Modelos de Previsão

Apesar do tema desta dissertação estar relacionado com a previsão eólica, é necessário conhecer os diferentes modelos de previsão criados e desenvolvidos para diversas aplicações. Dependendo do campo que se pretende estudar e do espaço horizonte temporal pretendido, existem vários modelos capazes de se adaptar às necessidades de previsão.

O mais primitivo de todos é o modelo de previsão por Persistência, ou modelo de previsão Naïve. Através de desenvolvimentos na área de previsões, surgiram vários métodos, entre os quais, modelos Autorregressivos Integrados de Média Móvel (ARIMA – *Autoregressive Integrated Moving Average*) [9]. Através deste modelo de previsão, derivaram estudos onde se

aplicaram várias vertentes do modelo ARIMA. Este trabalho centra-se na aplicação e comparação destes dois modelos, onde serão falados mais detalhadamente nas subsecções 2.1.4 e 2.1.5.

Um dos métodos de previsão são as Redes Neurais Artificiais. Inspirada na biologia dos neurónios do sistema nervoso, este modelo tem como elemento base o neurónio, a unidade de processamento elementar. Nas Redes Neurais Artificiais também existem "neurónios" e são eles que permitem complexas relações não lineares entre a variável de resposta e as suas entradas (*inputs*) [10], [11].

A arquitetura das Redes Neurais Artificiais baseia-se na organização dos neurónios por camadas, com ligações unidireccionais, em sentido progressivo, dos *inputs* para as respostas (*outputs*). As redes mais simples contêm camadas escondidas e são equivalentes a uma regressão linear, obtendo resultado através de uma combinação linear dos *inputs*. As ligações entre neurónios estão associadas a pesos que são seleccionados usando um algoritmo de aprendizagem que minimiza uma dada função de custo, por exemplo, MSE (*Mean Square Error*) [11].

Se quisermos assumir que eventos futuros influenciam as previsões, podemos usar um modelo de previsão designado modelo de regressão dinâmico. O efeito das férias, mudança de leis, a economia geral, atividade concorrente ou outra variável externa pode explicar uma variação histórica e, com isso, permitir uma previsão mais exata. Este modelo tem como base o modelo ARIMA, apesar de ter informações sazonais que influenciam as variáveis de entrada, e consequentemente, os valores de previsão [11].

O modelo de Vetores Autorregressivos (VAR) tem na sua base influências entre variáveis do vetor de regressão. Por exemplo, variáveis como as despesas de consumo pessoal e rendimento pessoal são interdependentes, e para englobar as dependências lineares entre várias séries temporais, é criado um modelo autorregressivo multivariado. As alterações de despesas de consumo pessoal com base no rendimento pessoal é um exemplo simples de aplicação deste VAR. As despesas são afetadas com o rendimento pessoal e vice-versa, portanto, uma variação numa variável influencia a outra [11].

Existem outros tipos de modelos de previsão, tal como a Suavização Exponencial (*Exponential Smoothing*) [12] e a previsão de séries temporais hierárquica ou agrupadas [13]. A primeira baseia-se, em grande parte, num modelo ARIMA mais primitivo, o que é interessante no ponto de vista de previsão para séries temporais. Já a segunda cria uma desintegração da série temporal por níveis ou hierarquias.

O modelo Hierárquico pode-se aplicar à previsão de vendas de bicicletas de uma dada loja. As bicicletas podem ser divididas em várias camadas: montanha, estrada, híbrida ou para crianças; a das crianças pode ainda ser dividida por idades. Também se podem agrupar as bicicletas por género: masculinas, femininas ou unissexo. A partir desta desintegração, é possível fazer a previsão hierárquica utilizando um modelo adequado para cada hierarquia [11].

De entre estes modelos, os mais populares e aplicados a séries temporais eólicas são o Naïve, o ARIMA e as Redes Neurais Artificiais, que serão referenciadas nos seguintes parágrafos pela sua aplicação em alguns trabalhos.

### 2.1.2 Modelos de Previsão Aplicados à Produção Eólica

Tal como dito na subsecção anterior, os modelos mais utilizados na previsão de séries temporais são o modelo ARIMA e o modelo de Redes Neurais Artificiais. Nos seguintes parágrafos, estarão alguns exemplos de aplicação divididos pelos dois modelos de previsão, e outros modelos de previsão eólica.

#### 2.1.2.1 ARIMA

Um dos trabalhos que incluía o uso do ARIMA para previsão da produção eólica, foi proposto por R. Billinton, *et al*, em [14] e depois completado pelos mesmos, em [15], onde utilizaram um modelo ARIMA para simular a velocidade do vento e analisar os índices de fiabilidade da reserva estática com os dados simulados, para estudar o efeito que os aerogeradores teriam no sistema produtor.

Outros modelos foram aplicados para previsão do vento, principalmente, a sua velocidade. Kavasseri and Seetharaman, em [16], usaram um ARIMA fracionário (f-ARIMA) para prever as velocidades do vento para o dia seguinte, que mostram bastantes melhorias na previsão, comparando com o método Naïve.

Palomares-Salas, *et al*, em [17], compararam a performance das Redes Neurais Artificiais com ARIMA e concluíram que o modelo ARIMA é melhor para intervalos de curto-prazo (10 minutos, 1 hora, 2 horas e 4 horas). Os autores Cadenas e Rivera, em [18], também compararam Redes Neurais Artificiais com ARIMA sazonal (s-ARIMA). O resultado foi que o modelo s-ARIMA é melhor para prever velocidades do vento e tem melhor resposta a mudanças estruturais do regime de vento.

Brown, Katz e Murphy, [19], apresentaram um modelo Autorregressivo com base nas propriedades dos dados da velocidade do vento: autocorrelação, distribuição não-Gaussiana e

série do vento diurna não estacionária. O seu objetivo foi tornar os dados estacionários no período diurno e aproximar a uma distribuição Gaussiana melhorando, deste modo, a previsão da velocidade do vento. Já Chen, *et al*, em [20], propuseram um modelo ARIMA tendo em conta os dados da velocidade do vento não estacionários bem como os limites estocásticos da geração eólica. O modelo introduz limites e caracteriza a geração eólica estocástica por nível, correlação temporal e condução do ruído.

Na literatura existem alguns estudos que incorporam outros parâmetros relacionados com a previsão da velocidade do vento. Um desses estudos desenvolvido por Erdem e Shi, [21], comparam vários modelos ARIMA que consideram a direção e velocidade do vento, com o objetivo de prever esses mesmos parâmetros. Erdem, Shi e Peng, em [22], voltaram a propor um novo método, desta vez usando um modelo ARMA que incorpora direção e velocidade para previsão da potência do vento. Com este modelo obtêm-se ligeiras melhorias na estimação para a velocidade do vento a curto-prazo.

### 2.1.2.2 Redes Neurais Artificiais

Em [23], Kariniotakis, *et al*, desenvolveram um modelo baseado em Redes Neurais Artificiais para a previsão da potência gerada dum parque eólico, mostrando que é melhor do que o clássico Naïve. Com base nesses resultados, foi implementado num controlo de sistema avançado para operação e gestão de um SEE real.

Li e Shi, [24], demonstraram que a performance dos três tipos de Redes Neurais Artificiais na previsão da velocidade de vento na seguinte hora pode variar consoante a métrica de avaliação. Além disso, a seleção do tipo de Redes Neurais Artificiais para melhorar desempenho na previsão depende da qualidade dos dados. Também usando Redes Neurais Artificiais, Barbounis e Theocharis, estudaram o problema de previsão a longo-prazo da velocidade e potência do vento. Comparando três tipos de Redes Neurais Artificiais: *infinite impulse response multilayer perceptron* (IIR-MLP), *local activation feedback multilayer network* (LAF-MLN), e *diagonal recurrent neural network* (RNN), chegaram a resultados que demonstram que os modelos treinados pelos métodos sugeridos exibiam melhorias face ao método de persistência [25].

### 2.1.2.3 Outros Modelos de Previsão Eólica

Monfared, *et al*, em [26], propuseram uma nova estratégia na previsão de velocidade de vento baseado na lógica *fuzzy* e redes neurais artificiais. Este método, não só fornece significativamente

menos regras de base, mas também aumenta a precisão de velocidade estimada de vento quando comparado com o tradicional.

Já Slougher, *et al*, [27], usaram a abordagem de modelagem Bayesiana para fornecer os conjuntos na abordagem de previsão probabilística para a velocidade do vento. Ao contrário da previsão da velocidade média do vento, estes desenvolveram uma metodologia para estimar a velocidade do vento máxima analisando a natureza da topologia do sítio e a época do ano. Concluíram que a velocidade pode ter diferentes propriedades, que exigem considerações adicionais.

### 2.1.3 Influência da Previsão Eólica nos Índices de Fiabilidade

Ao longo dos anos surgiram vários estudos que conjugam modelos de previsão eólica com os cálculos dos seus índices de fiabilidade nos respetivos sistemas inseridos no estudo. Billinton, *et al*, em [15], usando o método de Simulação de Monte Carlo para a velocidade do vento, desenvolveram um estudo capaz de incluir WECS (*Wind Energy Conversion Systems*) na avaliação dos índices de fiabilidade. Usando um modelo ARMA para simulação a longo-prazo da velocidade do vento, considerando a sua localização, Karki e Hu em [28], não só analisaram os índices de fiabilidade como também os custos da inclusão da energia eólica nos tradicionais sistemas de geração.

Mais tarde, e juntando-se a Billinton, [29], desenvolveram um modelo simplificado de geração eólico para avaliação dos índices de fiabilidade. À semelhança dos dois últimos, analisaram os índices de fiabilidade com a inclusão de energia eólica no sistema produtor, preocupando-se com a exatidão da previsão da velocidade do vento. Normalmente utiliza-se um método de Simulação Sequencial de Monte Carlo MCS ou uma representação multiestados do parque eólico, no entanto, o modelo apresentado simplifica o método de avaliação. O método é simplificado através da determinação da mínima representação multiestado da geração, na avaliação dos índices de fiabilidade. Este é aplicável a múltiplas localizações geográficas e adequado para avaliação dos índices de sistemas de potência com significativa penetração eólica.

Huang e Billinton [30], estudaram o efeito na probabilidade, frequência e duração média das três fases de estados de operação quando adicionados a potência eólica a um sistema, ou substituindo algumas capacidades de produção convencionais existentes por energia eólica.

Para a integração de grandes partes da geração eólica em sistemas de energia, há a necessidade do desenvolvimento de novos algoritmos e ferramentas de previsão para a tomada de decisões no domínio operacional, tendo em conta das incertezas de previsão eólica. Uma dessas decisões

considera os requisitos de reserva operacional disponíveis para atender às variações do vento e da carga. Matos e Bessa em [31], apontaram para esse risco de decisões, mostrando que é possível descrever as consequências de cada nível de reserva, através de um conjunto de índices de risco útil para tomada de decisão durante a operação do sistema.

#### 2.1.4 *Autoregressive Integrated Moving Average*

Este foi o modelo escolhido para o estudo de previsão da produção de um parque eólico, quando aplicado a sua respetiva série eólica temporal [9], [11], [32], com o objetivo de substituir o modelo Naïve no programa RESERVAS. O modelo é na realidade a junção de dois modelos de previsão, decompondo-se em : AR – *autoregressive*; MA – *moving average* <sup>1</sup>

##### 2.1.4.1 *Autoregressive Models*

O modelo Autorregressivo (AR) faz uma regressão linear dos valores passados da série temporal, com o objetivo de prever o seu valor futuro. Esta regressão é feita numa ordem  $p$ ,  $AR(p)$ , em que  $p$  é a ordem do atraso na regressão à série temporal. Este modelo pode ser descrito do seguinte modo


$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + e_t, \quad (2.1)$$

onde  $y_t$  representa o valor a prever,  $y_{t-p}$  são os valores passados da série até à ordem de atraso  $p$ , e  $\phi_p$  os seus pesos respetivos. A constante é representada por  $c$  e  $e_t$  é o erro de previsão para o instante  $t$  [9], [11], [32]. Idealmente, este erro de previsão deverá ser ruído branco.

O modelo é bastante flexível para lidar com uma certa gama de diferentes padrões de séries temporais, isto quer dizer que, o modelo pode ser ajustado para várias séries temporais, com a mesma ordem de regressão  $p$ , mas com pesos  $\phi_p$  diferentes.

---

<sup>1</sup> Apesar de não estar referenciado, o *Integrated* não é um modelo de previsão, mas sim a diferenciação da série a que é aplicado. Na subsecção Série Estacionária e não Estacionária será falado em maior detalhe.



**Figura 2.1** – Dois diferentes exemplos de modelos autorregressivos [11]


Na Figura 2.1 ilustram-se dois gráficos de modelos autorregressivos diferentes, tanto em ordem  $p$ , como em peso  $\phi_p$ , onde ambos apresentam erros de previsão  $e_t$  com distribuição normal, média zero e variância um (ruído branco).

#### 2.1.4.2 Moving Average Models

Ao contrário do modelo autorregressivo, o modelo de média móvel usa erros de previsão passados num modelo de regressão tipo. A ordem de regressão é representada por  $q$  e genericamente apresenta-se  $MA(q)$  da seguinte forma

$$y_t = c + e_t + \theta_1 e_{t-1} + \theta_2 e_{t-2} + \dots + \theta_q e_{t-q}, \quad (2.2)$$

onde  $c$  é a constante e  $e_t$  é o ruído branco, ou erro da previsão,  $e_{t-q}$  são erros de previsão no instante  $t-q$ , sendo  $q$  a ordem de regressão de MA [9], [11], [32]. Na realidade, não é possível observar os valores de  $e_t$ , portanto, este tipo de modelo não é um modelo regressivo.



**Figura 2.2** – Dois diferentes exemplos de modelo de média móvel [11]

Na Figura 2.2 verificam-se dois modelos de média móvel de ordem  $q$  e diferentes pesos  $\theta_q$ . A aplicação destes modelos para a mesma série temporal resulta em dois resultados distintos em valor.

### 2.1.4.3 Série Estacionária e não Estacionária

Uma série pode ser estacionária se as suas propriedades não dependerem do tempo em que a série é observada. No caso de uma série temporal, como os dados de velocidade do vento, não se pode afirmar que a série seja estacionária, visto que, a velocidade do vento não estaciona para nenhum valor.

Se a série é não estacionária, recorre-se à diferenciação na tentativa de a estabilizar. A diferenciação consiste na diferença entre dois valores consecutivos da série, tal como se pode visualizar na seguinte equação

$$y'_t = y_t - y_{t-1} . \quad (2.3)$$

Na equação (2.3), [32], a ordem de diferenciação  $d$  é primeira ( $d=1$ ). Na prática, raramente é necessário recorrer além da segunda ordem de diferenciação ( $d=2$ ), que se expressa do seguinte modo

$$y''_t = y'_t - y'_{t-1} = (y_t - y_{t-1}) - (y_{t-1} - y_{t-2}) = y_t - 2y_{t-1} + y_{t-2} . \quad (2.4)$$

Em alguns casos, existe dificuldade em perceber se uma dada série é ou não estacionária. Uma das formas para se verificar se a série é estacionária, consiste na análise das suas autocorrelações.


O valor das autocorrelações entre  $y_t$  e  $y_{t+k}$  é obtido de acordo com a expressão [9]

$$r_k = \frac{c_k}{c_0} , \quad (2.5)$$

onde  $r_k$  é o valor da autocorrelação para o atraso  $k$ , sendo que este atraso varia de 0 e o último atraso ( $K$ ). A variável  $c_0$  é o valor da variância da série temporal, e  $c_k$  é obtido por

$$c_k = \frac{1}{T-1} \sum_{t=1}^{T-k} (y_t - \mu)(y_{t-k} - \mu), \quad (2.6)$$

onde  $T$  é o número de elementos da série,  $y_t$  e  $y_{t-k}$  são respetivamente os valores da série no instante  $t$  e  $t-k$ , e  $\mu$  é a média da série.



**Figura 2.3** – Autocorrelação de uma série temporal não estacionária<sup>2</sup>

A Figura 2.3 mostra um gráfico de autocorrelação, onde se procura encontrar as seguintes características referentes as séries não estacionárias:

- O gráfico ACF (*Autocorrelation function*) da série decai lentamente para zero;
- O primeiro valor da autocorrelação  $r_1$  é normalmente alto ( $\approx 1$ ) e positivo.

Na Figura 2.3, a linha tracejada representa o valor crítico da autocorrelação dado por

$$\pm 1,96/\sqrt{T} \quad (2.7)$$

sendo  $T$  o período de observações. Pela Figura 2.3 identifica-se de que a série é não estacionária, devido a respeitar as últimas características. No entanto, existem testes mais eficazes para se determinar se uma série é ou não estacionária. Estes testes são baseados em testes de hipóteses estatísticos sendo o teste Augmented Dickey-Fuller (ADF) um dos mais populares [11].

O teste ADF baseia-se na hipótese nula de que a série é não estacionária. Se o valor de  $p$  for acima do valor crítico (normalmente 0,05), indica que a série é não estacionária sendo que a diferenciação é necessária.

Outro teste bastante popular é o de Kwiatkowski-Phillips-Schmidt-Shin (KPSS). Este assume a hipótese nula de a série ser estacionária. Neste caso para valores de  $p$  mais baixos que 0,05 sugere que a série não é estacionária, logo a sua diferenciação é necessária. Ambos os testes também admitem que as séries são não sazonais [11].

<sup>2</sup> Gráfico obtido pela autocorrelação de uma série eólica no programa *R*.

2.1.4.4 ARIMA( $p, d, q$ )

O modelo ARIMA é a junção do modelo AR e MA, com as respectivas ordens  $p$  e  $q$ , e de grau de diferenciação  $d$ , como dito anteriormente. O modelo pode ser interpretado de acordo com as seguintes características

$$\begin{array}{ll} \text{ARIMA}(0,0,0) & y_t = e_t \\ \text{White noise} & \end{array} \quad (2.8)$$

$$\begin{array}{ll} \text{ARIMA}(0,1,0) \text{ sem constante} & y_t = y_{t-1} + e_t \\ \text{Random Walk} & \end{array} \quad (2.9)$$

$$\begin{array}{ll} \text{ARIMA}(0,1,0) \text{ com constante} & y_t = c + y_{t-1} + e_t \\ \text{Random Walk with drift} & \end{array} \quad (2.10)$$

$$\begin{array}{ll} \text{ARIMA}(1,0,0) & y_t = c + \phi_1 y_{t-1} + e_t \\ \text{AR}(1) & \end{array} \quad (2.11)$$

$$\begin{array}{ll} \text{ARIMA}(0,0,1) & y_t = c + e_t + \theta_1 e_{t-1} \\ \text{MA}(1) & \end{array} \quad (2.12)$$

$$\text{ARIMA}(1,1,1) \quad y_t = c + y_{t-1} + \phi_1 y_{t-1} + e_t + \theta_1 e_{t-1} \quad (2.13)$$


Consoante a série temporal que se analisa, são ajustadas as suas respectivas ordens  $p$  e  $q$ , e os seus coeficientes  $\phi$  e  $\theta$  (a ordem  $d$  é determinada pelos testes referidos em 2.1.4.3). Para se entender melhor os modelos ARIMA temos as seguintes hipóteses:

- Se  $c = 0$  e  $d = 0$ , a previsão a longo-prazo decresce para zero;
- Se  $c = 0$  e  $d = 1$ , a previsão a longo-prazo tende uma constante diferente de zero;
- Se  $c = 0$  e  $d = 2$ , a previsão a longo-prazo segue uma linha reta;
- Se  $c \neq 0$  e  $d = 0$ , a previsão a longo-prazo tende para a média da série;
- Se  $c \neq 0$  e  $d = 1$ , a previsão a longo-prazo segue uma linha reta;
- Se  $c \neq 0$  e  $d = 2$ , a previsão a longo-prazo segue uma tendência quadrática.

Usando gráficos da autocorrelação e correlação parcial, pode-se ter uma ideia de quais os valores de  $p$  e  $q$  mais adequadas para se ajustar aos dados temporais.

A autocorrelação mede a relação entre  $y_t$  e  $y_{t-k}$  para diferentes valores de  $k$ . E segue a lógica que se  $y_t$  e  $y_{t-1}$  têm correlação, então  $y_{t-1}$  e  $y_{t-2}$  também devem ter correlação. Mas  $y_t$  e  $y_{t-2}$  podem estar correlacionados, simplesmente por estarem conectados a  $y_{t-1}$ , em vez de qualquer nova informação contida em  $y_{t-2}$  que pode influenciar a previsão de  $y_t$  [32].

Usando as correlações parciais, são retirados os efeitos dos atrasos 1 até  $k-1$  das medições das relações entre  $y_t$  e  $y_{t-k}$ .



**Figura 2.4** – Correlação parcial de uma série temporal não estacionária

A Figura 2.4, que representa a correlação parcial da mesma série temporal da Figura 2.3, que mostra uma clara diferença de correlações parciais entre os diferentes atrasos. Neste exemplo, apenas quatro atrasos são significativos, ou seja, estão fora da banda do limite crítico da série. Esta banda está representada por duas linhas azuis tracejadas, e que respeitam a equação (2.7). Devido a  $T$  ser elevado, a banda dos limites críticos fica muito próxima da linha horizontal.

Pelo gráfico das correlações parciais, pode-se estimar a ordem do modelo Autorregressivo, ou por outras palavras, ter a ideia de quais são os atrasos mais significativos. Apesar de haver algoritmos mais eficazes para deteção dos valores dos coeficientes  $\phi_p$ , pelas correlações parciais percebe-se a influência dos atrasos  $k$  no modelo Autorregressivo.

#### 2.1.4.5 Estimação e Ordem do Modelo ARIMA

Um dos meios para determinar a ordem de um modelo ARIMA é o critério da informação Akaike (AIC - *Akaike Information Criterion*), [11], [32], e é definido pela equação

$$AIC = -2 \log(L) + 2(p + q + k + 1), \quad (2.14)$$

onde  $L$  é o valor *Likelihood* dos dados temporais,  $k = 1$  se  $c \neq 0$  e  $k = 0$  se  $c = 0$ . Este valor *likelihood* é um valor probabilístico, sendo na realidade uma probabilidade para parâmetros relativos<sup>3</sup>.

Para modelos ARIMA, o AIC é corrigido de acordo com a equação

$$AIC_C = AIC + \frac{2(p + q + k + 1)(p + q + k + 2)}{T - p - q - k - 2}. \quad (2.15)$$

Para  $T \gg p + q + k$ ,  $AIC_C \cong AIC$ . Outro critério de ordem é o de *Bayesian Information Criterion* (BIC) que é determinado por

$$BIC = AIC + (\log(T) - 2)(p + q + k + 1). \quad (2.16)$$

O processo de obtenção da ordem do modelo vai depender da minimização destes critérios [11].

Depois de determinadas quais as ordens  $p$ ,  $d$  e  $q$  do modelo ARIMA, é fundamental saber que influência estas ordens  $p$  e  $q$  têm na previsão. Como tal, existe um conjunto de testes para serem estimados os respetivos coeficientes  $\phi_p$  e  $\theta_q$ . Um deles é o *Maximum Likelihood Estimation* (MLE), técnica que encontra os valores dos coeficientes que têm maior probabilidade de se ajustar à série. Este modelo é muito similar ao método dos mínimos quadrados, cujo objetivo é minimizar

$$\sum_{t=1}^T e_t^2, \quad (2.17)$$

sendo  $e_t$  o erro de previsão para a hora  $t$ . Idealmente, este erro de previsão deverá ser ruído branco.

---

<sup>3</sup> Uma probabilidade tem um resultado fixo ou esperado: qual a probabilidade de sair cara ou coroa numa moeda justa após 5 tentativas. No caso do *Likelihood*: qual a probabilidade da moeda ser justa ao fim de 5 tentativas (definição em Anexo 1).

#### 2.1.4.6 Diagnóstico dos Resíduos

Um bom modelo de previsão terá resíduos com as seguintes propriedades:

- Os resíduos não correlacionados. Se existir correlação entre os resíduos, então ainda existe informação nos resíduos que deve ser usada na previsão;
- Os resíduos têm média zero. Caso não se verifique, os resultados de previsão são tendenciosos.

Se nenhuma destas propriedades forem satisfeitas, então deve-se modificar o modelo até que as seguintes se verifiquem: se os resíduos tiverem média diferente de zero, basta adicionar esse valor a todos os dados de previsão; se houver correlação então deve-se recorrer ao algoritmo apresentado na subsecção 2.1.4.7.

Em seguida da análise do gráfico da autocorrelação dos resíduos, recorre-se a um teste que considera os valores da autocorrelação  $r_k$  como um todo, em vez de individualmente. Este teste é usado para verificar se existe efetivamente autocorrelação entre os resíduos, sem hipótese para dúvidas, tal como pode acontecer na observação do gráfico. Testam-se as primeiras autocorrelações dos atrasos  $h$  para verificar se são significativamente diferentes do que seria de esperar de um ruído branco. A este tipo de teste designa-se de *portmaunteau test* [11].

Dois desses testes são o *Box-Pierce* [33] e o Ljung-Box [34], sendo este último o mais exato e completo. As expressões (2.18) e (2.19) mostram o teste Ljung-Box.

$$Q^* = T(T + 2) \sum_{k=1}^h (T - k)^{-1} r_k^2, \quad (2.18)$$

$$Q^* > \chi_{1-\alpha, (h-K)}^2, \quad (2.19)$$

sendo  $\chi_{1-\alpha, (h-K)}^2$  o teste de chi-quadrado, com nível de confiança  $\alpha$  (normalmente 0,05),  $h - K$  graus de liberdade, em que  $K = p + q$  (ordens do modelo  $ARIMA(p, d, q)$ );  $r_k$  são os valores da autocorrelação dos erros. Se a condição (2.19) for satisfeita, então rejeita-se a hipótese de que os resíduos não são correlacionados.

#### 2.1.4.7 Algoritmo

O algoritmo proposto foi baseado no de Hyndman-Khandakar [11], [32], com a finalidade de encontrar as ordens  $p$ ,  $d$ , e  $q$ , de modo a ser ajustável à série. Por definição,  $d=0$ .

1. Analisar os gráficos de autocorrelação e correlação parcial, e verificar se a série é estacionária recorrendo ao teste KPSS. Se a série for estacionária, avança-se para o ponto 2, senão aumenta-se a ordem de diferenciação ( $d=d+1$ ), e volta-se aos mesmos procedimentos deste ponto;
2. As ordens  $p$  e  $q$  são escolhidas através da minimização do critério BIC. Combina-se todos os modelos  $p$  e  $q$ , fazendo variar as respetivas ordens entre 1 e o último atraso cujo valor da correlação esteja fora da banda do limite crítico, estando os restantes dentro da banda;
3. O modelo escolhido é aquele que tem o valor mínimo de BIC;
4. Estimar os parâmetros do modelo  $ARIMA(p,d,q)$ , através do MLE;
5. Verificar os resíduos do modelo escolhido pelo gráfico ACF dos resíduos e efetuar um *portmanteau test*. Se não se parecerem a um ruído branco, então repetir o ponto 2;
6. Uma vez que os resíduos se assemelhem a ruído branco, verificar a precisão dos resíduos e calcular as previsões.

A Figura 2.5 mostra todo este procedimento.

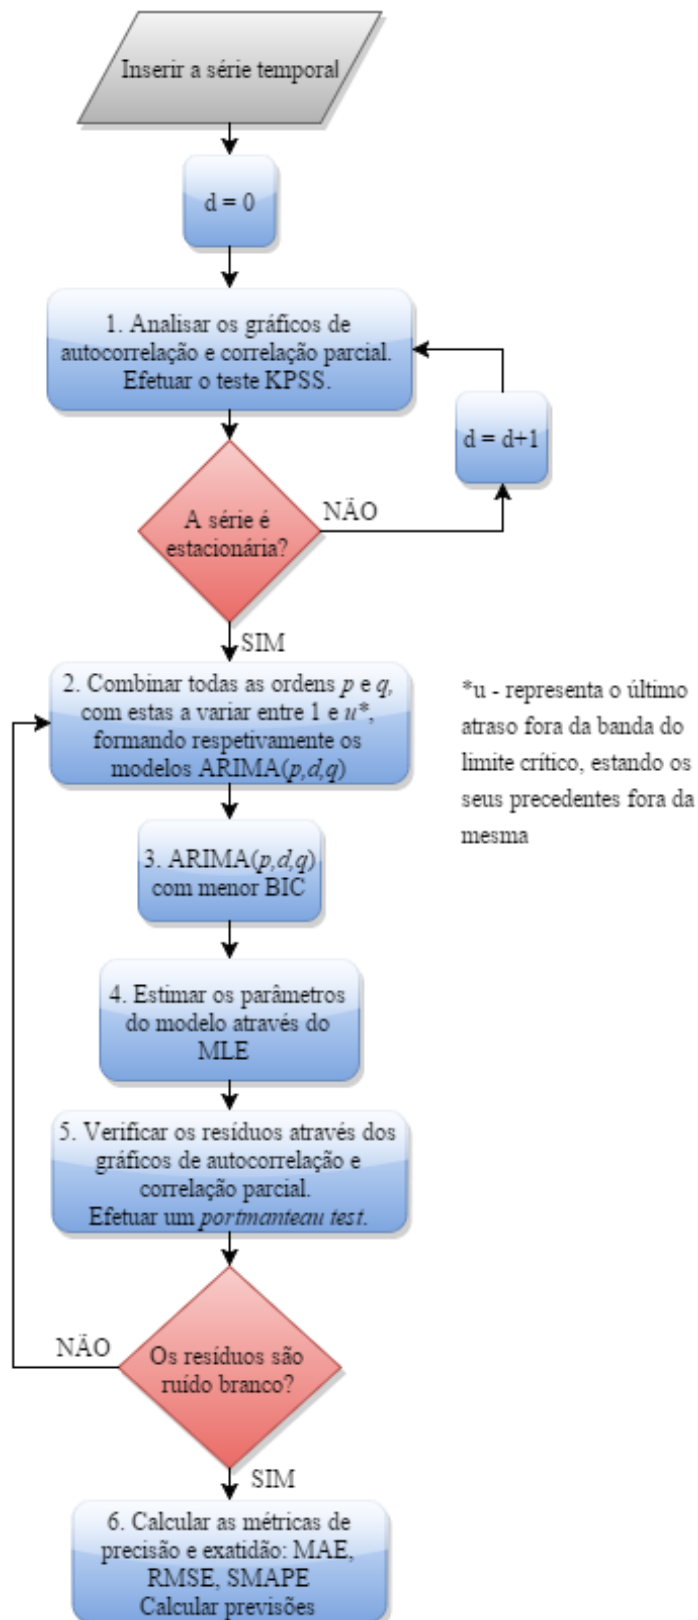


Figura 2.5 – Fluxograma do algoritmo utilizado

### 2.1.5 Naïve

O modelo de previsão Naïve, [9] [11], também chamado de modelo de previsão por Persistência, assume que um instante  $t$  irá ter o mesmo comportamento no instante  $t+1$ . É o método de previsão mais simples e representa-se por

$$\hat{y}_t = y_{t-1}. \quad (2.20)$$

sendo  $\hat{y}_t$  o valor previsto. O erro associado a este tipo de previsão é expresso por

$$e_t = y_t - \hat{y}_t = y_t - y_{t-1}. \quad (2.21)$$

Tal como na equação (2.9), há uma semelhança entre o modelo ARIMA(0,1,0) sem constante (*Random Walk model*), que na prática, tem como base o modelo Naïve.

### 2.1.6 Precisão da Previsão

Para avaliar a performance dos modelos de previsão, são utilizados os seguintes critérios

$$\text{Mean Absolute Error: } MAE = \frac{1}{T} \sum_{t=1}^T |e_t|, \quad (2.22)$$

$$\text{Root Mean Squared Error: } RMSE = \sqrt{\frac{\sum_{t=1}^T e_t^2}{T}}, \quad (2.23)$$

em que  $e_t$  é o erro no instante  $t$  e  $T$  é o número total de erros. Relacionando o valor do erro  $e_t$  com o valor observado  $y_t$  no instante  $t$ , define-se uma proporção com o erro em causa. Deste modo, teremos outro modo de avaliar o erro.

$$p_t(\%) = e_t/y_t \cdot 100\%, \quad (2.24)$$

$$\text{Mean Absolute Percentage Error: } MAPE(\%) = \frac{1}{T} \sum_{t=1}^T |p_t|. \quad (2.25)$$

Uma das desvantagem dos erros percentuais é o seu uso para valores de  $y_t \approx 0$ . Isto leva a valores percentuais muito elevados, chegando mesmo a infinito quando  $y_t = 0$ . Outra desvantagem é o maior peso que é dado aos erros negativos face aos erros positivos. Para ultrapassar estas desvantagens, é usada uma avaliação dos erros proposta por Armstrong, e alterada por Flores [35], SMAPE (*Symmetric Mean Absolute Percentage Error*), definida como

$$SMAPE(\%) = \frac{1}{T} \sum_{t=1}^T \frac{|y_t - \hat{y}_t|}{(y_t + \hat{y}_t)} \cdot 100\%, \quad (2.26)$$

sendo  $y_t$  o valor observado no instante  $t$ ,  $\hat{y}_t$  o valor previsto para o instante  $t$ . No entanto, esta versão tem alguns inconvenientes:

- Valor previsto maior que o observado:  $y_t = 100$  e  $\hat{y}_t = 110$  resulta num  $SMAPE = 4.76\%$ ;
- Valor previsto menor que o observado:  $y_t = 100$  e  $\hat{y}_t = 90$  resulta num  $SMAPE = 5.26\%$ ;
- Se o valor previsto e o observado forem zero, o valor de  $SMAPE$  passando o valor limite (100%);
- A gama de resultados pode variar entre  $\{-\infty; +\infty\}$ .

Porém, Chen e Yang, em [36], alteraram a equação de forma a controlar a variação dos resultados para  $\{0,1\}$ , exceto se  $y_t + \hat{y}_t = 0$ .

$$SMAPE(\%) = \frac{1}{T} \sum_{t=1}^T \frac{|y_t - \hat{y}_t|}{|y_t| + |\hat{y}_t|} \cdot 100\%. \quad (2.27)$$

Originalmente a equação (2.27) não tem percentagem, mas por uma questão de simplicidade, usar-se-á os valores em percentagem.

### 2.1.7 Comparação de Modelos de Previsão

Para avaliar se os resíduos obtidos por ambos os modelos de previsão seguem a mesma distribuição, é realizado um teste de comparação individual. Um desses testes que compara individualmente duas populações independentes por métodos de *ranking* é o Wilcoxon *rank-sum test* (WRS) (ou também designado de teste Wilcoxon-Mann-Whitney) proposto inicialmente por Frank Wilcoxon [37], para amostras de tamanhos iguais. Mais tarde foi modificado por Henry Mann e Whitney para tamanhos diferentes entre populações [38]. Teste não paramétrico para duas populações independentes, pode ser utilizado em análise de métodos de confiança, tal como em [39]. Este teste não necessita de assumir que nenhuma série segue qualquer distribuição.

A abordagem inicial deste teste baseia-se em:

- As observações de ambas as populações são independentes;
- As observações são variáveis contínuas;

- $H_0$ : a distribuição de ambas as populações é igual;
- $H_A$ : os valores das duas populações tendem a exceder os outros:  $P(X > Y) + 0.05 \cdot P(X = Y) > 0.05$ .

Para construir o *ranking*, todas as amostras são juntas e ordenadas por valor. Ao serem ordenadas, é atribuído a cada uma, uma posição (*rank*). São então separadas e cada valor terá a sua posição no *rank*. Calcula-se estatisticamente  $U$  para cada valor das populações.

$$U_m = m \cdot n + \frac{m(m+1)}{2} - r_m, \quad (2.28)$$

$$U_n = m \cdot n + \frac{n(n+1)}{2} - r_n, \quad (2.29)$$

em que  $m$  e  $n$  são os respetivos tamanhos das populações,  $r_{m,n}$  é o somatório do respetivo *ranking*. Este teste segue uma distribuição  $Z$ , quando a quantidade das amostras é superior a 20. Depois de calculados os  $U$ , escolhe-se qual o que teve menor resultado de acordo com

$$U = \min(U_m, U_n). \quad (2.30)$$

O valor de  $z$  pode ser calculado por

$$z = \frac{U - \mu_m}{\sigma_m}, \quad (2.31)$$

em que

$$\mu_m = \frac{m(m+n+1)}{2}, \quad (2.32)$$

$$\sigma_m = \sqrt{\frac{m \cdot n(m+n+1)}{12}}, \quad (2.33)$$

ou seja,  $\mu_m$  e  $\sigma_m$  são respetivamente a média e o desvio padrão da população  $m$  (caso seja a população com menor  $U$ ).

Quando determinado o valor  $z$  e para um nível de confiança de 95%, o teste indica a possibilidade de rejeição, ou não, da hipótese nula de relação entre os resíduos de cada modelo, se aplicado para dois modelos de previsão, como no caso do modelo de previsão ARIMA e Naive.

## 2.2 Métodos de Simulação

O método de Simulação de Monte Carlo (MCS – *Monte Carlo Simulation*) pode ser uma ferramenta para resolver tanto problemas estocásticos como determinísticos e as técnicas deste método são aplicados em diversos campos, tais como: cálculos matemáticos complexos, processo de simulação estocásticos, estatísticas médicas e análise de sistemas de engenharia [40]. O interesse ampliou-se devido a fatores como o incremento do poder computacional ao dispor dos utilizadores a preço acessível e, com o desenvolvimento de técnicas de aceleração de convergência, que em algumas centenas de simulações, se pode atingir resultados com a mesma precisão teórica que sem essas mesmas técnicas [41].

O método MCS pode ser visto como uma agregação de estados, incluindo o estado de carga e, por este motivo, é vantajoso face à dificuldade de encontrar um modelo analítico que englobe todas as dependências de funcionamento entre os diferentes elementos do sistema. Devido à sua flexibilidade, têm sido amplamente utilizados em estudos de sistemas.

Dependendo das diferentes representações do método de Simulação de Monte Carlo, o mesmo é classificado por: sequencial, quando os estados do sistema são amostrados tendo em conta a cronologia dos acontecimentos; não-sequencial, se o sistema tiver uma representação espacial, ou seja, ser tirada uma “fotografia” ao estado do sistema; sistemas híbridos, tais como o pseudo sequencial [42], pseudo-cronológico [43] e quasi-sequencial [44], sendo que estes não adotam uma representação espacial pura do estado do sistema, nem uma representação cronológica pura [45].

No método de Simulação não Sequencial de Monte Carlo, estima-se  $E[H(X)]$  a partir de um sorteio aleatório de  $N$  estados do sistema.

$$\tilde{E}[H(X)] = \frac{1}{N} \sum_{i=1}^N H(x_i), \quad (2.34)$$

em que  $\tilde{E}[H(X)]$  são valores estimados de  $E[H(X)]$ ;  $H(X)$  é a função teste, por exemplo, um índice de fiabilidade (LOLP – *Loss of Load Probability*);  $N$  é o número de amostras;  $x_i$  o  $i$ -ésimo estado de sistema sorteado [41].

Como em qualquer processo de amostragem, o seu valor médio distribui-se à volta do valor “verdadeiro”, de tal forma que se pode representar a incerteza na estimativa de acordo com a variância do estimador

$$V(\tilde{E}[H(X)]) = \frac{V(H(X))}{N}. \quad (2.35)$$


No entanto, a verdadeira variância  $V(H(X))$  não é conhecida, pelo que deverá também ser estimada através de

$$\tilde{V}(E[H(X)]) = \frac{1}{N-1} \sum_{i=1}^N (H(x_i) - \tilde{E}[H(X)]), \quad (2.36)$$

sendo  $\tilde{V}(E[H(X)])$  a variância estimada, e onde  $x_i$  é um estado do sistema de  $N$  exemplos.

A convergência ou critério de paragem no método de Simulação de Monte Carlo é baseada num coeficiente de variação  $\beta$ , definido matematicamente por

$$\beta = \frac{\sqrt{V(\tilde{E}[H(X)])}}{\tilde{E}[H(X)]}. \quad (2.37)$$



**Figura 2.6** – Exemplo de Simulação não Sequencial de Monte Carlo

A Figura 2.6 mostra um exemplo de Simulação não Sequencial de Monte Carlo com o objetivo de estimar o valor de  $\pi$ , onde os pontos azuis são as variáveis de sucesso, e as vermelhadas de insucesso. Neste exemplo, foram simulados pontos com coordenadas compreendidas entre zero e um, onde se pretendia descobrir quais os que se encontravam dentro (sucesso) ou fora (insucesso) de um quarto de área de uma circunferência de raio 1.

### 2.2.1 Método de Simulação não Sequencial de Monte Carlo

O método MCS não sequencial, também conhecido por não cronológico, é caracterizado por retirar amostras aos estados do sistema através de “fotografias” do seu comportamento estocástico. Ou seja, as amostras analisadas não têm qualquer dependência temporal dos estados anteriores do sistema. Tal como na Figura 2.6, cada estado está localizada no espaço de estados, não sendo o tempo um fator a ser considerado.

O índice de confiança será dado matematicamente pela equação (2.34), sendo  $H(x_i)$  é o resultado da função de teste  $H$  do estado do sistema  $x_i$ . Um exemplo desta função aplicada ao índice LOLP (*Loss Of Load Probability*) [46]

$$H_{LOLP}(x_i) = \begin{cases} 1 & \text{se } x_i \in S_{Xf} \\ 0 & \text{se } x_i \in S_{Xs} \end{cases} \quad (2.38)$$

em que  $S_X = S_{Xf} \cup S_{Xs}$  é o conjunto de todos os estados do sistema, dividido em dois subconjuntos de estado de sucesso,  $S_{Xs}$ , e de insucesso,  $S_{Xf}$  [45].

Devido à sua dificuldade de modelização temporal, a Simulação não Sequencial de Monte Carlo tem dificuldades em modelizar sistemas como os de carga ou variações eólicas. Mesmo assim, estão a ser feitos esforços para ultrapassar esta limitação.

### 2.2.2 Método de Simulação Sequencial de Monte Carlo

O MCS sequencial, ou cronológico, é baseado em modelos estocásticos dos componentes e carga do sistema. Neste método são simulados os estados dos diferentes componentes, num dado período de tempo [47]. É “traçada” a história de vida de um só componente do sistema, garantindo que dois estados consecutivos diferem entre si [45]. Como a sua representação cronológica pode reproduzir a operação do sistema torna-se, por isso, um método muito adequado para avaliação de processos cronológicos, tais como energias renováveis e incertezas naturais (hidrológicas e eólicas), bem como variação de cargas.




Figura 2.7 – Exemplo de uma representação sequencial durante o período  $T$  [45]

Na Figura 2.7 observa-se uma ilustração do MCS sequencial para a avaliação da capacidade de produção disponível. O estado da carga altera-se entre dois estados consecutivos, estando estes separados por intervalos de tempo. A área sombreada representa os estados onde a capacidade de produção disponível é inferior à carga, ou seja, estados onde existe corte de energia devido a falhas de geradores.

Adequando a equação (2.34) ao MCS sequencial, a estimação dos índices de confiança é obtida de acordo com

$$\tilde{E}[H(X)] = \frac{1}{NY} \sum_{i=1}^{NY} H(y_i), \quad (2.39)$$

sendo neste caso  $NY$  o número de períodos simulados,  $y_i$  a sequência de estados simulados para o período  $i$  definido por

$$y_i = \{x_n\}_{n=1}^{S_i} = \{x_1, \dots, x_{S_i}\}, S_i \in \mathbb{N}. \quad (2.40)$$

Aplicando a função de teste ao índice LOLP, define-se como

$$H_{LOLP}(y_i) = \frac{1}{T} \sum_{n=1}^{S_i} [d(x_n) \times H_{LOLP}(x_n)]. \quad (2.41)$$

À semelhança do que foi definido anteriormente,  $x_n$  é o estado  $n$  da sequência,  $T$  a duração do período simulado (normalmente um ano – 8760h),  $d(x_n)$  é a duração em cada estado e  $H_{LOLP}(x_n)$  é o resultado da função de teste para o estado  $x_n$ , tal como definido na equação (2.38) em [8], [45], [48].


### 2.2.3 Modelização dos Componentes do Sistema

A capacidade dos componentes do sistema depende de dois modelos distintos:

- O modelo do ciclo estocástico falha/restauro;
- O modelo de dependência temporal da capacidade do componente.

O primeiro modelo está relacionado com o comportamento estocástico das falhas furtivas dos componentes. O modelo define a disponibilidade do componente, isto é, a transição entre o estado de funcionamento (*up state*) e de não funcionamento (*down state*). A disponibilidade do componente pode ser vista como a capacidade máxima que este tem num determinado estado. O modelo do ciclo estocásticos falha/restauro são modelos de Markov de dois estados e de multiestados [7].

Um modelo de Markov de dois estados é utilizado para modelizar os estados dos componentes do sistema. Estes estados variam entre o estado de funcionamento de não funcionamento, onde as taxas de avaria  $\lambda$  e de reparação  $\mu = \frac{1}{r}$ , são as transições entre os estados *up/down* e *down/up* respetivamente, em que  $r$  é o tempo médio de reparação, em horas.




**Figura 2.8** – Modelo de Markov de dois estados [45]

A Figura 2.9 mostra um ciclo estocástico falha/restauro (modelo de Markov de dois estados) tem a sua disponibilidade máxima quando está no estado de funcionamento (*up state*). No estado em de não funcionamento (*down state*), a capacidade do componente é zero. Assumindo que a duração em cada estado segue uma distribuição exponencial, o tempo de residência em cada estado é dado de acordo com

$$T^{Up} = -\frac{1}{\lambda} \ln U_1, \quad (2.42)$$

$$T^{Down} = -\frac{1}{\mu} \ln U_2, \quad (2.43)$$

sendo  $T^{Up/Down}$  o tempo residência em cada estado de funcionamento;  $U_1$  e  $U_2$  são amostras uniformemente distribuídas entre um intervalo  $\{0,1\}$ .



**Figura 2.9** – Modelo de Markov de multiestados [45]

A Figura 2.9 exemplifica um modelo de Markov de multiestados, que pode ser interpretado como a agregação do ciclo falha/restauro de  $N$  componentes. Nesta situação, a capacidade máxima de cada estado,  $C_k$  é obtida de acordo com

$$C_k = (N - k) \times C, \quad (2.44)$$

sendo  $k=0, 1, \dots, N$  e  $C$  a capacidade de cada componente. Se a duração em cada estado é exponencialmente distribuída, o tempo de residência em cada estado  $C_0$  e  $C_N$  é

$$T^{C_0} = -\frac{1}{N\lambda} \ln U_1, \quad (2.45)$$

$$T^{C_N} = -\frac{1}{(k+1)\mu} \ln U_2, \quad (2.46)$$

onde  $T^{C_0}$  é o tempo de residência no estado  $C_0$ ;  $T^{C_N}$  é o tempo de residência no estado  $C_N$ ;  $\lambda$  e  $\mu$  são respetivamente taxas de avaria e de reparação de cada componente agregado. O tempo de residência em cada estado é calculo por [7]

$$T^{C_k} = \min \left\{ -\frac{1}{(N-k)\lambda} \ln U_1, -\frac{1}{k\mu} \ln U_2 \right\}. \quad (2.47)$$

Normalmente são definidos parâmetro dos componentes MTTF (*Mean Time To Fail*) e MTTR (*Mean Time To Repair*). Estes podem ser obtidos por

$$MTTF = \frac{1}{\lambda}, \quad (2.48)$$

$$MTTR = \frac{1}{\mu}. \quad (2.49).$$

Por outro lado, o segundo modelo enunciado preocupa-se com a representação da dependência temporal da capacidade de cada componente. Sendo isto de extrema importância devido à capacidade de alguns componentes seguirem uma variação horária, mensal e até mesmo anual

[45], [47], [48]. Esta característica de dependência temporal é dada por séries horárias e/ou mensais com probabilidades associadas. Estas séries são obtidas através de anos de observações.

#### 2.2.3.1 Unidades Térmicas

As unidades térmicas são as que convertem energia térmica contida nos combustíveis fósseis ou nos núcleos atômicos por via de um ciclo térmico-dinâmico. O modelo de Markov de dois estados é usado para representar o ciclo de falha/restauro deste tipo de unidade de geração. As transições entre estados seguem uma distribuição probabilística exponencial.

Quando a central é capaz de produzir à sua capacidade máxima, então está no estado de funcionamento (*up state*). Caso contrário está no estado de não funcionamento (*down state*). A capacidade de produção deste tipo de unidade são pré-especificadas e fixas a longo-prazo.

#### 2.2.3.2 Unidades Hídricas

Estas unidades de produção convertem a energia potencial da água em eletricidade. E tal como as unidades térmicas, o ciclo de falha/restauro é representado por um modelo de Markov de dois estados, em que as transições entre estados seguem uma distribuição probabilística exponencial.

O modelo da dependência temporal da capacidade da unidade hídrica é complexo devido à dependência nos níveis de água disponíveis, tanto em albufeira como em fio de água. Com uma simples e robusta aproximação, é comum usar-se algumas séries temporais hidrológicas. Baseadas em eventos históricos, estabelece-se uma relação proporcional entre o total de água armazenada e a produção de energia através das unidades hídricas, em cada mês do ano [45], [47], [48].

O uso deste modelo simples é justificado devido à elevada complexidade em estabelecer condições de despacho a longo-prazo [48]. A capacidade disponível em cada mês é calculada através da multiplicação da capacidade máxima, que é obtida pelo modelo estocástico falha/restauro, com o correspondente valor mensal da série temporal hidrológica. As séries temporais hidrológicas são construídas baseadas em registos de vários anos. Apesar da natureza probabilística das séries hidrológicas, estas são um parâmetro determinístico do método de Simulação Sequencial de Monte Carlo. [47].

#### 2.2.3.3 Parques Eólicos

Os aerogeradores (WTG – *Wind Turbine Generator*) são os responsáveis por converter energia do vento em eletricidade. Tradicionalmente, os aerogeradores de um parque eólico são

iguais. Para tal, é usado um modelo de Markov multiestado para representar o ciclo de falha/restauro de um parque eólico. Neste tipo de modelo, as transições entre estados seguem uma distribuição probabilística exponencial.


Tal como o modelo de dependência temporal da capacidade hídrica, a capacidade máxima dos estados dos aerogeradores é multiplicada pelo correspondente valor horário da série temporal eólica. Estas séries são compostas por valores horários das produções dos parques eólicos, em percentagem da capacidade total.

Apesar de haver uma natureza probabilística, e tal como acontece nas unidades hídricas, também nos parques eólicos são usados os mesmos parâmetros no método de Simulação Sequencial de Monte Carlo. A vantagem do uso deste método é a ausência de um modelo para correlações espaço-temporais para parques eólicos de diferentes pontos geográficos, desde que, estas correlações sejam implicitamente incluídas nas séries e, naturalmente, contabilizadas para a simulação sequencial através do tempo. As incertezas da previsão eólica a curto-prazo são também incluídas no processo de simulação.

#### 2.2.3.4 Carga

A carga é modelada através do uso de uma representação sequencial que contém o nível da carga para cada hora do ano. O modelo de Simulação Sequencial de Monte Carlo segue cronologicamente estes passos da carga com o progresso da simulação. Cada barramento que suporta a carga tem o seu próprio perfil de carga, em valores percentuais em relação ao respetivo valor de pico. Cada percentagem é obtida dividindo o pico de carga da respetiva hora pelo valor de pico anual.

Devido à flexibilidade do método de Simulação Sequencial de Monte Carlo, não há necessidade do uso discreto de representações de distribuições gaussianas. A inclusão de incertezas a curto-prazo nas simulações sequenciais consistem em adicionar ao valor horário de carga, um valor aleatório da distribuição gaussiana contínua de média zero e desvio *standard*,  $\sigma_{CP}$  (Figura 2.10). De igual forma, às incertezas a longo-prazo são contabilizadas através da adição ao valor de pico anual da carga, um valor aleatório de uma distribuição gaussiana contínua de média zero e desvio *standard*,  $\sigma_{LP}$  (Figura 2.10). Estes desvios controlam a amplitude da incerteza e são pré-especificados no início das simulações [45].



**Figura 2.10** – Função de densidade de probabilidade da distribuição normal [8]

A incerteza a curto-prazo da carga horária pode ser obtida através do uso da seguinte expressão [8]

$$P(t) = P(t) \times (1 + \sigma_{CP} \times STU), \quad (2.50)$$

onde  $P(t)$  é o valor da carga para a hora  $t$ ;  $\sigma_{CP}$  é o desvio *standard* distribuição gaussiana contínua de média zero para as incertezas a curto-prazo; e  $STU$  é a incerteza de curto-prazo, em valor percentual.

A incerteza a longo-prazo é obtida de forma semelhante, mas neste caso, o valor de pico de carga é alterado para o valor de pico de carga anual

$$P^{Máx} = P^{Máx} \times (1 + \sigma_{LP} \times LTU), \quad (2.51)$$

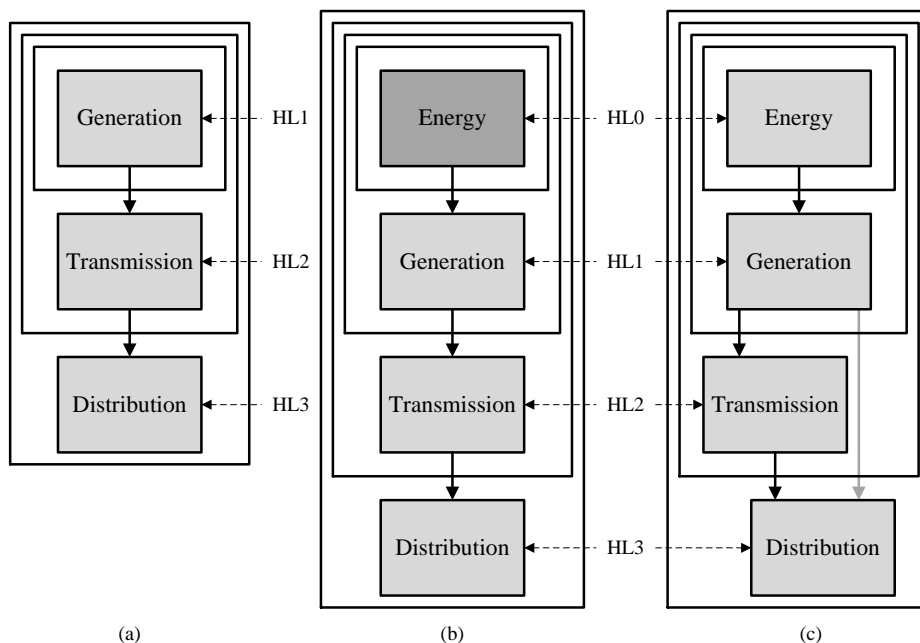
onde  $P^{Máx}$  é o valor horário da carga;  $\sigma_{LP}$  é o desvio *standard* distribuição gaussiana contínua de média zero para as incertezas a longo-prazo; e  $LTU$  é a incerteza de longo-prazo, em valor percentual [8].

## 2.3 Índices de Fiabilidade

Existem muitos índices dos quais podem ser usados para medir a fiabilidade de um SEE, no entanto estes índices estão ordenados por hierarquias, e cada um é usado no seu campo de aplicação.

### 2.3.1 Hierarquia dos Índices de Fiabilidade

Os estudos de fiabilidade do sistema eléctricos são analisados em níveis de hierarquia (HL – *Hierarchical Level*) dependendo do seu enquadramento no SEE. Tradicionalmente são considerados três níveis – HL1, HL2 e HL3 – respectivamente correspondendo à produção, transporte e distribuição de energia eléctrica.




**Figura 2.11** – Representação hierárquica do SEE [45]

Como se pode ver na Figura 2.11 (a), é representado a hierarquia tradicional do SEE. No entanto, A. Leite da Silva, *et al*, em [49], criaram uma nova hierarquia, propondo o nível da Energia, Figura 2.11 (b) e (c). O novo nível inclui a variação do recurso primário da energia, mais especificamente as energias renováveis, tornando mais exato a representação da capacidade disponível de geração para cada período de tempo.

### 2.3.2 HL1

A este nível de análise designa-se por HL 1 (do inglês *Hierarchical Level One*), referindo-se à avaliação da geração e a sua capacidade de suportar as cargas do sistema.



**Figura 2.12** – Modelo de barramento único (HL1) [41]

No nível HL1 ignora-se a rede de transporte e o modelo do sistema é de barramento único, onde toda a carga e unidades de produção estão ligados a um único barramento, tal como representado na Figura 2.12.

## 2.4 Avaliação da Reserva Operacional a Longo-Prazo

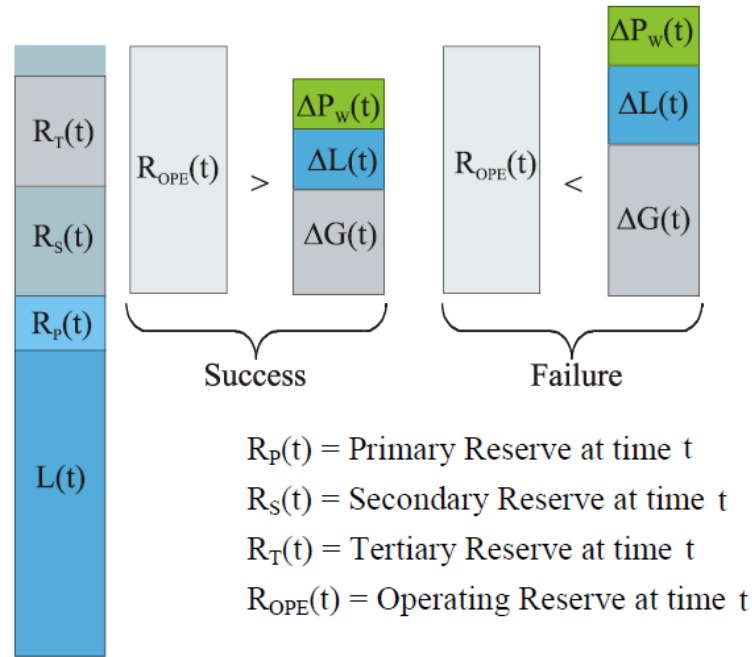
De forma a manter o sistema em funcionamento, são criadas reservas no sistema, para que, com variações de geração e de carga, o sistema consiga ultrapassar estas oscilações. A consideração básica a ser feita é juntar todas as unidades de produção e de carga num único barramento. Se a reserva estática deve servir para assegurar o abastecimento de energia a longo-prazo, a reserva operacional deve servir como apoio para decisões a curto-prazo.

A avaliação a longo-prazo das capacidades de produção podem ser vistas de duas perspetivas: estática<sup>4</sup> e reserva operacional, [45], [47], [48]. Os estudos de reserva operacional concentram-se com a análise a longo-prazo da flexibilidade do sistema de produção para cobrir as variações a curto-prazo que correm durante a operação do sistema, [47], [48]. A capacidade de produção disponível em cada período de operação é afetada por falhas furtivas planeadas, e por flutuações do recurso de energia primário. Esta capacidade deve ser capaz não só de fazer face às variações da carga, mas também de acomodar as diferenças entre previsões eólicas de curto-prazo e realizações atuais de variações estocásticas. Essas variáveis são visíveis na Figura 2.13. Tudo isto deve ter em consideração as regras de reserva operacional estabilizadas pelas necessidades, tais como, reservas mínimas primária e secundária e prioridades nos escalonamentos.

As unidades produtoras, que caracterizam este tipo de reserva, são unidades capazes de sincronizarem rapidamente com a rede e estarem preparadas para entrar em funcionamento (reserva girante). O tipo de unidades produtoras desta reserva são unidades de entrada rápida, tais como: turbinas a gás e turbinas hídricas.

---

<sup>4</sup> Como a dissertação apenas avalia as necessidades de Reserva Operacional, as definições de Reserva Estática estão descritas em Anexo I



**Figura 2.13** – Reserva operacional [8]

A Figura 2.13 mostra a estrutura da reserva operacional, mostrando o que pode acontecer em caso de falha. Para este caso existe um risco associado e é definido pela equação (2.52), onde se pode ser as variáveis definidas [8]

$$R_{OPE} = R_S + R_T < \Delta L + \Delta P_W + \Delta G, \quad (2.52)$$

em que  $\Delta L$  representa a variação da carga para a hora  $t$ ,  $\Delta P_W$  é a variação da produção eólica para a hora  $t$ ;  $\Delta G$  variação da capacidade de produção para a hora  $t$ . Pode-se ainda acrescentar que a reserva operacional é composta pelo somatório da reserva secundária (reserva girante) e reserva terciária (não girante). A última diz respeito aos geradores que podem ser sincronizados à rede numa hora.

Analisando a Figura 2.13, pode ser observado que existe um extra de capacidade produtora por cima da reserva terciária. Este extra representa o efeito discreto das unidades de produção. A equação (2.52) descreve o risco da carga, capacidade de geração eólica não serem totalmente cobertos pela reserva girante, bem como pela reserva terciária. Então, a partir deste risco é possível avaliar os seus índices de fiabilidade.

No contexto desta dissertação, é na equação (2.52) que reside o ponto fulcral – o erro de previsão eólica  $\Delta P_W$ . Sendo esta variável a previsão a curto-prazo da potência eólica gerada, há um risco associado ao erro da sua previsão, e com isso haver um excesso ou déficit de reserva

operacional desnecessário. Este risco pode levar a índices de fiabilidade que não correspondem à realidade, tudo porque o modelo de previsão pode não ser o melhor na previsão.

No programa RESERVAS [8], usando o modelo de previsão Naïve, introduz-se erros de previsão das variações horárias da potência eólica, que podem levar a uma avaliação errada da reserva operacional. Estes erros são simplesmente calculados como a diferença de variação do vento de uma hora  $t-1$  e  $t$ . Para este caso a variável  $\Delta P_{W_t}$  pode ser escrita como

$$\Delta P_{W_t} = P_{W_t} - \hat{P}_{W_t} = P_{W_t} - P_{W_{t-1}}, \quad (2.53)$$

sendo  $P_{W_t}$  o valor da potência eólica observada para a hora  $t$ ;  $\hat{P}_{W_t}$  o valor de potência eólica previsto para a hora  $t$ , neste caso é igual ao valor da hora  $t-1$ ,  $P_{W_{t-1}}$ . Quanto melhor for o erro de previsão, menor será esta variação. Assim, e pela Figura 2.13, percebe-se que a reserva operacional pode ser melhor ajustada às suas necessidades, sem que haja um excesso ou défice de reserva.

O escalonamento das unidades produtoras disponíveis no sistema deve de ser feito de modo a calcular a reserva operacional. A ordem das unidades segue um processo iterativo que por sua vez, segue prioridades pré-definidas. Estas prioridades podem variar de acordo com a disponibilidade do recurso primário, isto é, com cenários anuais de operação. Este processo pára quando a seguinte expressão é satisfeita

$$P_{Committed} \geq L + R_P + R_S, \quad (2.54)$$

sendo  $P_{Committed}$  é a capacidade de produção escalonada e  $R_P$  é a reserva primária. Estas últimas variáveis são determinadas e podem fazer a diferença de acordo com o cenário de operação. Na equação (2.52), a variável  $R_T$  pode ser vista como a capacidade total disponível que não foi escalonada e pode ser mobilizada até ao final do período de operação. Com isto assumindo que as unidades mobilizadas que não falham durante o arranque. Então, a reserva operacional pode ser reescrita do seguinte modo

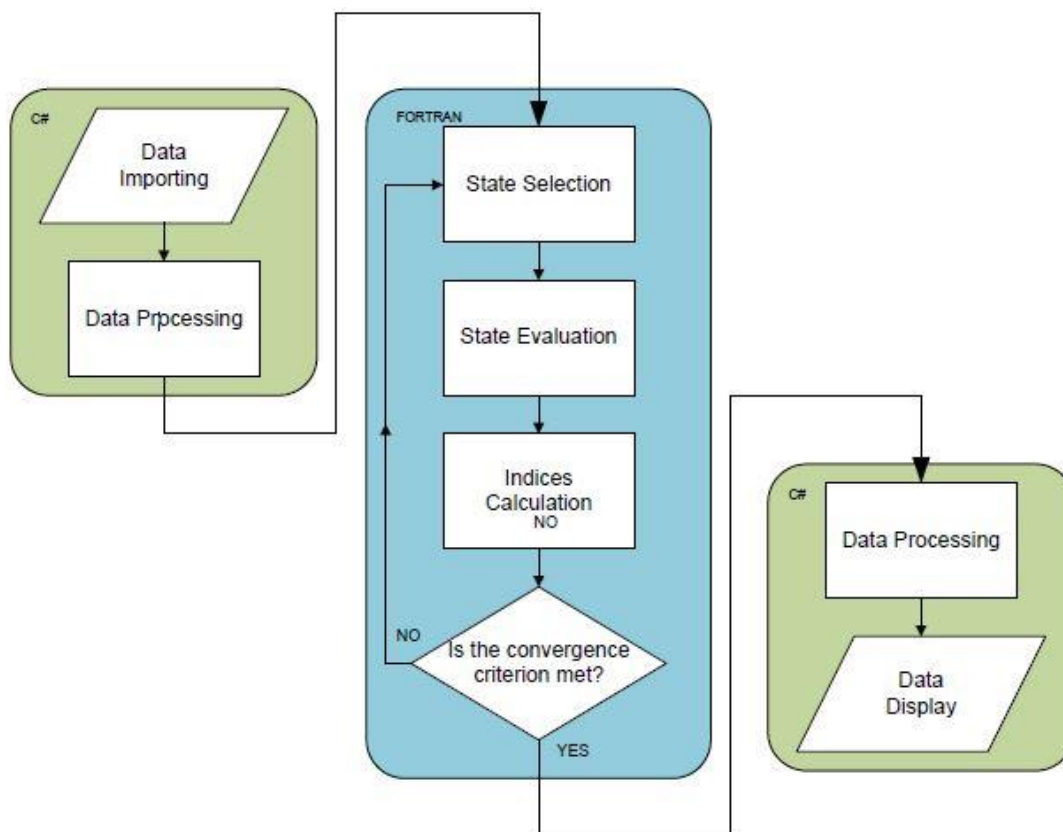
$$R_{OPE} = P_{Committed} + R_T - (L + R_P). \quad (2.55)$$

### 2.4.1 Programa RESERVAS

Criado e desenvolvido pelo INESC TEC (antigo INESC Porto), em projeto com a REN e a REE, este programa chamado RESERVAS usa o método de Simulação Sequencial de Monte Carlo para avaliar o risco associado às configurações específicas do sistema produtor [8].

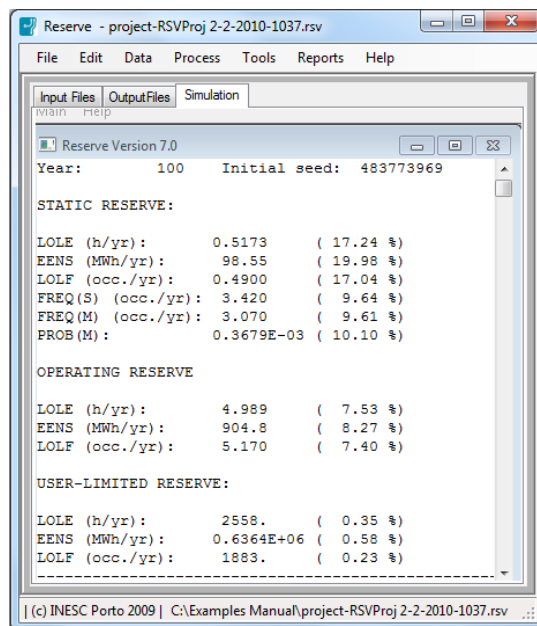
O seu desenvolvimento possibilitou a este programa ser uma ótima ferramenta para a avaliação da performance de geração do sistema em duas vias: Reserva Estática e Operacional. São nestas reservas onde é considerado o problema da integração das energias renováveis, tal como a variação da produção eólica, e impactos das interconexões.

Sendo o RESERVAS [8] o programa de objeto de estudo, é de todo o interesse perceber o seu processo de simulação. Seguindo um método de Simulação Sequencial de Monte Carlo, este permite aceder à performance da geração de um sistema em termos de reserva estática e operacional.



**Figura 2.14** – Modelo da estrutura do programa RESERVAS [8]

Verifica-se na Figura 2.14 de que o processo em azul é referente à simulação. Nesta fase, a linguagem usada é o FORTRAN, por forma a criar rapidez no cálculo, que depois é usada a linguagem C# para tratamento e amostra dos resultados.



**Figura 2.15** – Resultado de uma simulação parcial [8]

A Figura 2.15 mostra um exemplo do resultado de uma simulação parcial, em que se pode ver os índices de fiabilidade para cada tipo de reserva: LOLE, EENS, LOLF. Os restantes índices são de bem-estar (*well-being*) e não serão considerados neste trabalho: FREQ(S), FREQ(M), PROB(M).

Este programa oferece uma panóplia de análise de resultados que se poderia introduzir aqui. Todo o seu conteúdo informativo está disposto em [8].

## Capítulo 3.

# Previsão Eólica: Caso de Estudo

### 3.1 Introdução

Neste Capítulo 3 é analisada uma série de 3 anos da produção de um parque eólico, adaptado de um concurso de previsão eólica [50]. Esta série eólica é a agregação de três anos de sete parques eólicos. Com estes dados, parametrizou-se um modelo ARIMA que melhor se ajusta à série, de forma a obter-se melhores resultados de previsão do que os obtidos pelo modelo Naïve.

**Tabela 3.1** – Tabela de valores estatísticos dos dados


	Ano 1	Ano 2	Ano 3	Total
<b>Média</b>	0.2632	0.3048	0.3017	0.2899
<b>Mediana</b>	0.1973	0.2277	0.2201	0.2151
<b><math>\sigma</math></b>	0.2175	0.2467	0.2467	0.2381
<b>Mínimo</b>	0.0000	0.0000	0.0000	0.0000
<b>Máximo</b>	0.9354	0.9519	0.9349	0.9519

Como todo o conjunto de valores torna-se de pesada visualização, pela Tabela 3.1 consegue-se ter uma ideia estatística de como variam os valores, em que todos os valores estão em relativos à capacidade máxima instalada.


## 3.2 Modelo de Previsão ARIMA

### 3.2.1 Estudo da Série

Cada ano representa a medição horária da potência gerada pelo parque eólico, ou seja, 8760 elementos de cada ano. O objetivo da análise destes dados é a modelização de um  $ARIMA(p, d, q)$ , para futuras previsões e comparar com os resultados de previsão do modelo Naïve.



**Figura 3.1** – Potência gerada pelo parque eólico ao longo de 3 anos



**Figura 3.2** – A. Autocorrelação da série; B. Correlação parcial da série

A Figura 3.1 mostra o gráfico da agregação da produção dos sete parques ao longo dos três anos, verificando que a potência produzida nunca atinge a potência nominal. Existe uma periodicidade na produção, isto é, existem alturas do ano em que a produção eólica é maior comparativamente a outras épocas do ano. Facilmente se observam três períodos de maior produção, intercalados com “vales”. Poder-se-á dizer que existe uma sazonalidade, no entanto, a

modelização do ARIMA é para muito curto-prazo, e não é de todo interessante saber os padrões mensais ou anuais, mas sim saber o que se passou nas horas anteriores mais próximas.


Na Figura 3.2.A está representado o gráfico da autocorrelação da série, observa-se uma descida lenta dos valores para zero, mostrando de que a série é não estacionária. A linha vermelha tracejada representa o valor crítico da autocorrelação da série, dada pela equação (2.7), em que neste caso  $T = 3 \times 8760 h$ . Já na Figura 3.2.B, gráfico das correlações parciais, o caso muda de figura e percebe-se claramente que os atrasos 1, 2, 3 e 4 estão acima do valor crítico, concluindo que estes atrasos influenciam significativamente o valor  $y_t$ , sobretudo os atrasos 1 e 2. Pela correlação parcial percebe-se qual será, possivelmente, a ordem de regressão  $p$ .

Apesar de ser evidente que a série é não estacionária, é necessário efetuar o teste KPSS para o confirmar. Este teste é feito até 20 atrasos, sob o critério do  $p$ -value ser maior que 0,05, rejeitando a hipótese nula da série ser não estacionária.


**Tabela 3.2** – Resultados do teste KPSS para a série eólica

Atraso	Resultado	$p$ -value
0	Verdadeiro	0.01
1	Verdadeiro	0.01
2	Verdadeiro	0.01
3	Verdadeiro	0.01
4	Verdadeiro	0.01
5	Verdadeiro	0.01
6	Verdadeiro	0.01
7	Verdadeiro	0.01
8	Verdadeiro	0.01
9	Verdadeiro	0.01
10	Verdadeiro	0.01
11	Verdadeiro	0.01
12	Verdadeiro	0.01
13	Verdadeiro	0.01
14	Verdadeiro	0.01
15	Verdadeiro	0.01
16	Verdadeiro	0.01
17	Verdadeiro	0.01
18	Verdadeiro	0.01
19	Verdadeiro	0.01
20	Verdadeiro	0.01

A Tabela 3.2 dos resultados do teste KPSS mostra que a hipótese de que a série ser estacionária é rejeitada. Desta forma, a série necessita de ser diferenciada, atribuindo  $d=1$ .



**Figura 3.3** – Série eólica diferenciada



**Figura 3.4** – A. Autocorrelação da série diferenciada; B. Correlação parcial da série diferenciada

A Figura 3.3 mostra o gráfico da série eólica diferenciada, o que na prática representam as variações da produção de uma hora para a outra. Existe uma concentração dos valores em torno de zero, mas pode-se ver picos de variações. Na Figura 3.4, os primeiros valores dos gráficos foram retirados devido a serem mais elevados que os restantes ( $\approx 1$ ), sendo possível assim, uma melhor interpretação dos valores correlacionais, bem como uma melhor visualização da banda de limite crítico.

A Figura 3.4.A, onde é representado o gráfico das autocorrelações, mostra que os valores têm um comportamento diferente dos valores da Figura 3.2.A, pois aproximam-se bastante de zero, o que leva a crer que esta série diferenciada pode ser estacionária. Pode-se ver que os atrasos de 2 a 4 estão fora da banda do limite crítico, especialmente o segundo e o terceiro que têm valores mais elevados. Também outros valores estão fora da banda, no entanto, não são significativos em

comparação com os três primeiros. Na Figura 3.4.B, também estes atrasos estão fora da banda do limite crítico, estando os restantes em torno da banda do limite crítico. Com estes resultados estima-se que a ordem  $p$  de autorregressão não será maior que 4, pois a partir deste atraso, os valores já quase ou nada se correlacionam com o valor em  $y_t$ .

Para confirmar se esta série diferenciada também é estacionária, realizou-se novamente um teste KPSS.

**Tabela 3.3** – Resultados do teste KPSS para a série eólica diferenciada

Atraso	h	<i>p-value</i>
0	Falso	0.1
1	Falso	0.1
2	Falso	0.1
3	Falso	0.1
4	Falso	0.1
5	Falso	0.1
6	Falso	0.1
7	Falso	0.1
8	Falso	0.1
9	Falso	0.1
10	Falso	0.1
11	Falso	0.1
12	Falso	0.1
13	Falso	0.1
14	Falso	0.1
15	Falso	0.1
16	Falso	0.1
17	Falso	0.1
18	Falso	0.1
19	Falso	0.1
20	Falso	0.1

A Tabela 3.1 mostra pelo teste KPSS que a série diferenciada é estacionária. Caso contrário, dever-se-ia proceder novamente à diferenciação da série.

### 3.2.2 Parametrização do Modelo ARIMA

Depois de efetuado o teste estacionário e tendo sido diferenciada, introduz-se a série num ciclo para que seja possível determinar todas as combinações possíveis das ordens  $p$  e  $q$  entre 1 e o último atraso fora da banda do limite crítico, que para o caso seria 4. Para cada combinação, é calculado o seu respetivo AIC e BIC e a seleção do modelo baseia-se na minimização do critério BIC.

ARIMA(4,1,3) Model:			
-----			
Conditional Probability Distribution: Gaussian			
Parameter	Value	Standard Error	t
-----			
Constant	6.64339e-08	2.67258e-07	0.248576
AR{1}	1.83667	0.0597231	30.7531
AR{2}	-1.06216	0.106127	-10.0084
AR{3}	0.269581	0.0662263	4.0706
AR{4}	-0.0601435	0.0159104	-3.78015
MA{1}	-1.39982	0.0599956	-23.332
MA{2}	0.352219	0.0823601	4.27657
MA{3}	0.0486112	0.0333211	1.45887
Variance	0.00149055	8.17978e-06	182.223

Figura 3.5 – Resultado do ciclo com o critério de minimização do BIC

A Figura 3.5 mostra um ARIMA(4,1,3), resultado do critério de seleção pela minimização do BIC. Como seria de esperar, a ordem de autorregressão afirmou-se ser efetivamente 4.

Tabela 3.4 – Critérios de ordem e estimação dos parâmetros ARIMA(4,1,3)

AIC	BIC
-96451	-96430

A Tabela 3.4 mostra qual o resultado do AIC e BIC do modelo ARIMA(4,1,3). Segundo o critério de seleção, este é o modelo que melhor se ajusta aos dados da série. Para chegar a este resultado e estimar os valores dos parâmetros do modelo, foi utilizada a função automática *estimate*, do programa *MatLab* [51]. Esta função utiliza como critério o MLE.

Tabela 3.5 – Valores dos parâmetros para o modelo ARIMA(4,1,3)

$d$	$\phi_1$	$\phi_2$	$\phi_3$	$\phi_4$	$\theta_1$	$\theta_2$	$\theta_3$	$\sigma^2$	$c$
1	1.8367	-1.0622	0.2696	-0.0601	-1.3998	0.3522	0.0486	0.0015	0.0000

Matematicamente, o modelo é escrito do seguinte modo

$$y_t = y_{t-1} + 1.8367 \cdot y_{t-1} - 1.0622 \cdot y_{t-2} + 0.2696 \cdot y_{t-3} - 0.0601 \cdot y_{t-4} + e_t - 1.3998 \cdot e_{t-1} + 0.3522 \cdot e_{t-2} + 0.0486 \cdot e_{t-3} \quad (3.1)$$

### 3.2.3 Diagnóstico dos Resíduos

As previsões foram realizadas através da função *forecast* do *MatLab* [52], que inserindo o modelo ARIMA correspondente, determinava as previsões para a hora  $t+1$ , para um intervalo de confiança de 95%. Através da expressão dos erros de previsão facilmente se determinavam os resíduos


$$e_t = y_t - \hat{y}_t, \quad (3.2)$$

sendo  $y_t$  o valor observado e  $\hat{y}_t$  o valor previsto. No entanto, através função *infer* do *MatLab* [53] e fornecendo o modelo  $ARIMA(p,d,q)$  bem como a série, determinaram-se os resíduos do respectivo modelo. Com os resíduos avalia-se o modelo usando MAE, RMSE e MAPE.

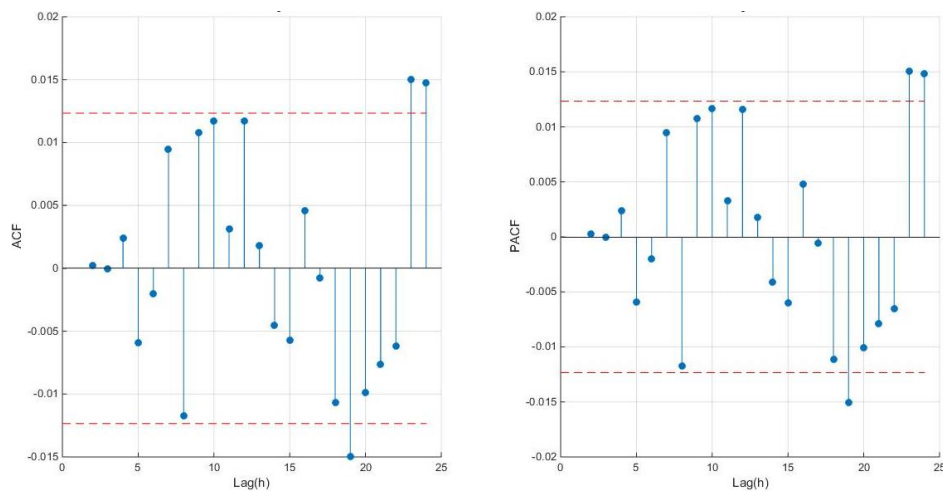
**Tabela 3.6** – Avaliação dos resíduos para o ARIMA(4,1,3)

ME	MAE	RMSE	SMAPE
0.00%	2.73%	3.86%	7.92%

A Tabela 3.6 mostra os diferentes tipos de avaliação dos resíduos. Posteriormente neste documento, estas avaliações serão comparadas com as do Naïve em 3.4. Um dos requisitos destes resíduos seria a sua média (ME) ser zero, o que se confirma na Tabela 3.6. Outra passava pela análise da sua autocorrelação (Figura 3.7).



**Figura 3.6** – Resíduos do modelo de previsão ARIMA(4,1,3)



**Figura 3.7** – A. Autocorrelação dos resíduos; B. Correlação parcial dos resíduos

Para melhor visualização, foi retirado o primeiro valor de correlação, tal como nos gráficos da Figura 3.4, devido a ser muito maior que os restantes. Por isso, facilmente se visualiza nas Figura 3.7.A e Figura 3.7.B de que os resíduos são não correlacionados. Em ambos, vê-se que todos os valores se encontram dentro dos limites críticos, com a exceção dos atrasos 18, 23 e 24 que saem ligeiramente dos limites. Contudo, esta banda é muito estreita,  $\{-0.0123, 0.0123\}$ , e de valores muito baixos em comparação ao primeiro valor de autocorrelação ( $\approx 1$ ), desprezando-se assim estes atrasos que saem dos limites.

**Tabela 3.7** – Teste Ljung-Box para o modelo ARIMA(4,1,3)

<b>h</b>	<b>h-K</b>	$\chi^2_{\alpha, h-K}$	<b>Q*</b>	<b>p-value</b>	<b>Resultado</b>
10	3	7.81	14.07	0.0028	Verdadeiro
11	4	9.49	17.67	0.0014	Verdadeiro
12	5	11.07	17.76	0.0033	Verdadeiro
13	6	12.59	18.29	0.0055	Verdadeiro
14	7	14.07	19.14	0.0078	Verdadeiro
15	8	15.51	19.70	0.0115	Verdadeiro
16	9	16.92	19.71	0.0198	Verdadeiro
17	10	18.31	22.72	0.0118	Verdadeiro
18	11	19.68	28.63	0.0026	Verdadeiro
19	12	21.03	31.20	0.0018	Verdadeiro
20	13	22.36	32.73	0.0019	Verdadeiro

Aplicando o teste Ljung-Box no *MatLab*, sendo nível de confiança 95%, o resultado “Verdadeiro” indica rejeição da hipótese nula da não autocorrelação residual, para o respetivo atraso  $h$  e grau de liberdade  $h-K$ . Verifica-se que, em todos eles, a hipótese é rejeitada.

Entra-se aqui numa discordância: pela média zero, visualização dos gráficos de autocorrelação e correlação parcial, estes resíduos identificam-se como ruído branco. No entanto, o teste Ljung-Box afirma que a hipótese de não autocorrelação residual é rejeitada. Esta contradição torna os resultados confusos e suspeitos.

Existem algumas suposições que podem justificar estes resultados:

- O teste pode não estar a ser bem aplicado e/ou não adequado para o modelo ARIMA, uma vez que nas referências [9], [11] e [34], apenas é apontado como recomendado para modelos ARMA;
- O conjunto de dados pode não ser adequado para ser aplicado a este tipo de teste. Devido ao tamanho elevado da série, o teste pode perder força com esta dimensão, [11].

### 3.3 Modelo de Previsão Naïve

Sendo este o modelo de previsão aplicado no programa RESERVAS, é o mais básico de todos os modelos de previsão. Como não há qualquer métrica de cálculo e/ou determinação de qualquer tipo de ajustamento do modelo à série onde é aplicado, rapidamente se obtém resultados.




Figura 3.8 – Resíduos do modelo de previsão Naïve

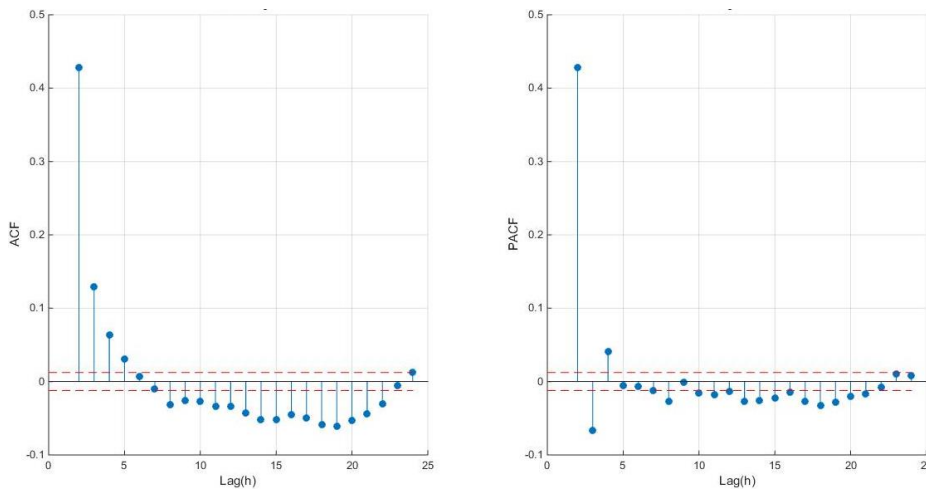


Figura 3.9 – A. Autocorrelação dos resíduos; B. Correlação parcial dos resíduos

Quando aplicando este modelo à série em estudo, verifica-se que não existe diferença entre os resíduos do modelo de previsão Naïve (Figura 3.8) e a série diferenciada (Figura 3.3), tal como seria de esperar.

Tabela 3.8 – Avaliação dos resíduos para o Naïve

ME	MAE	RMSE	SMAPE
0.00%	3.08%	4.34%	8.72%

Tal como a análise feita para os gráficos nas respetivas Figura 3.3 e Figura 3.4, estes resíduos aparentemente são considerados ruído branco. O seu ME é igual a zero e os gráficos correlacionais mostram que os resíduos não são correlacionados entre si, pois os seus valores rapidamente se aproximam de zero.

**Tabela 3.9** – Resultado do teste Ljung-Box para o modelo Naïve

<b>h</b>	$\chi^2_{\alpha,h}$	Q*	<i>p-value</i>	<b>Resultado</b>
10	18.31	5486	0.0000	Verdadeiro
11	19.68	5516	0.0000	Verdadeiro
12	21.03	5565	0.0000	Verdadeiro
13	22.36	5636	0.0000	Verdadeiro
14	23.68	5708	0.0000	Verdadeiro
15	25.00	5762	0.0000	Verdadeiro
16	26.30	5826	0.0000	Verdadeiro
17	27.59	5916	0.0000	Verdadeiro
18	28.87	6013	0.0000	Verdadeiro
19	30.14	6087	0.0000	Verdadeiro
20	31.41	6138	0.0000	Verdadeiro

Tal como para o método ARIMA(4,1,3), a hipótese de não autocorrelação residual é rejeitada para este modelo, entre os respetivos atrasos e graus de liberdade  $h$ . O nível de confiança usado neste teste é de 95%.

Este teste Ljung-Box mostra que os resíduos são correlacionados, no entanto, o *p-value* é pior neste modelo de previsão que no ARIMA, sendo que este último tem o resultado “menos mau” entre os dois. Pela Figura 3.7 e pela média zero, pode-se afirmar que estes resíduos não estão correlacionados, apesar do teste ter outro resultado.


### 3.4 ARIMA vs Naïve

Um dos objetivos do trabalho é comparar estes modelos ARIMA e Naïve e perceber qual dos dois oferece uma melhor previsão. Para servir de comparação foram utilizadas várias avaliações, entre as quais MAE, RMSE, SMAPE, histograma dos resíduos, gráficos Box e gráficos *quantile-quantile*. Foi também efetuado um teste Wilcoxon *rank-sum* (WRS) para verificar se existe algum relacionamento entre ambos os resíduos dos respectivos modelos

**Tabela 3.10** – Comparação da avaliação de cada modelo


Modelo	MAE	RMSE	SMAPE
ARIMA(4,1,3)	2.73%	3.86%	7.92%
Naïve	3.08%	4.34%	8.72%

Pela Tabela 3.10 verifica-se que o ARIMA tem resíduos inferiores aos do modelo Naïve. Comparando o parâmetro MAE, há uma melhoria de 3,08% para 2,73%. De igual forma se verifica que o RMSE e o SMAPE do ARIMA são inferiores ao Naïve, confirmando que o modelo ARIMA(4,1,3) tem uma melhor previsão do que o Naïve.



**Figura 3.10** – Histograma dos resíduos ARIMA(4,1,3) (laranja) e Naïve (azul)

A Figura 3.10 mostra a distribuição dos resíduos segundo a sua probabilidade. Olhando ao resultado, existe uma clara tendência gaussiana com médias zero em ambos os modelos. No entanto, é possível verificar que os resíduos do modelo ARIMA têm uma menor variância quando comparados aos do Naïve. Os resíduos do modelo ARIMA tendem a concentrar-se em torno de zero, enquanto os segundos estão ligeiramente mais dispersos.




**Figura 3.11** – Gráficos Box para os modelos Naïve (esquerda) e ARIMA (direita)

A Figura 3.11 mostra outra maneira de analisar os resíduos através dos gráficos Box. Nestes gráficos, a linha vermelha dentro do retângulo azul representa a mediana dos resíduos, que em ambos é zero. Isto indica que 50% dos valores se encontram abaixo de zero e 50% acima.

A primeira linha a preto abaixo do retângulo representa 25% (1ºquartil) dos resultados e a que está acima do retângulo representa 75% (3ºquartil) dos valores. No gráfico do Naïve (esquerda), estes limites aproximam-se bastante do valor de -0,1 e 0,1 respetivamente, enquanto que no ARIMA (direita) visualiza-se que estas margens são mais estreitas. Existe então uma maior concentração de valores em torno de zero no ARIMA em comparação com o Naïve, sendo isso bastante positivo.

Os *outliers* (valores que estão fora dos 25 e 75% e representados por cruces vermelhas) são mais dispersos no Naïve, apesar que no ARIMA existem cerca de quatro resíduos que saem bastante da zona de concentração.



**Figura 3.12** – Gráfico *quantile-quantile* dos modelos Naïve (esquerda) e ARIMA (direita)

A Figura 3.12 mostra se os resíduos seguem uma distribuição normal. No gráfico da esquerda pode-se concluir que os resíduos do modelo Naïve são lineares entre os intervalos  $\{-1, 1\}$ , o que quer dizer que seguem uma função normal, no entanto as suas caudas tendem em dispersar da linha a tracejado, fora do intervalo referido. Em caso semelhante, o gráfico da direita mostra se os resíduos do modelo ARIMA seguem ou não uma função normal. Isso verifica-se para os intervalos  $\{-2, 2\}$ , mas as suas caudas tendem também em se afastar da linha a tracejado. Nos dois gráficos, a linha a tracejado representa a regressão linear dos respetivos resíduos de cada modelo. É visível que a cauda do modelo ARIMA é mais extensa que a do Naïve.

**Tabela 3.11** – Resultado do teste WRS

<i>z-value</i>	<i>ranksum</i>	<i>p-value</i>	<b>Resultado</b>
4.530	157122829	0.0000	Verdadeiro

A Tabela 3.11 mostra o resultado do teste WRS que rejeita a hipótese de que os resíduos dos dois modelos seguem a mesma distribuição, para um nível de confiança de 95% ( $\alpha=5\%$ ), concluindo, que são independentes.



## **Capítulo 4.**

# **Avaliação da Reserva Operacional**

### **4.1 Introdução**


Devido à crescente utilização de energias renováveis na produção de energia elétrica, nomeadamente, a utilização de energia eólica, torna-se necessário saber qual o seu impacto no planeamento do sistema produtor. Sabendo que este tipo de energia sofre conseqüentemente variações de geração que não se podem controlar, tornou-se necessário prever o comportamento do vento.

O programa RESERVAS usa o modelo tradicional de previsão, Naïve. E tal como dito anteriormente, o nível de exatidão da previsão eólica tem cada vez mais influência no planeamento do sistema, e sabendo que o Naïve tem uma pior performance do que o ARIMA, pretende-se comparar as avaliações da Reserva Operacional utilizando o modelo de previsão ARIMA e o modelo de previsão Naïve.

A avaliação da Reserva Operacional, no contexto desta dissertação, apenas tem interesse quando esta está a subir, isto é, avaliar e comparar se os modelos de previsão estão a provocar reservas operacionais excessivas. Por outras palavras, pretende-se saber se há unidades de geração a entrar em funcionamento ou a variar a sua geração para satisfazer a carga, para um determinado erro de previsão, quando este é superior ao valor de potência eólica observado.


## 4.2 *IEEE RTS 79 HW*

O sistema usado nas simulações foi o *IEEE RTS 79 HW*, como referido anteriormente, é uma versão alterada do original *IEEE RTS 79* [54] (Anexos, Tabela A.1) que inclui unidades hídricas e eólicas no sistema produtor. O perfil da carga varia entre uma potência mínima de 965.25 MW, e 2850 MW de pico de carga. A capacidade de produção hídrica é a média mensal de uma série de cinco anos da referência [48].



**Figura 4.1** – Carga anual do *IEEE RTS 79 HW*

A Figura 4.1 mostra o perfil da carga do sistema, sendo que o valor de pico é atingido no final da série, ou mais precisamente, no final da série os valores são os mais elevados. Este é um ponto bastante importante a ter em conta, pois é nesta altura do ano que a carga exige mais do sistema produtor.



**Figura 4.2** – Produção hídrica mensal vs Carga média mensal

O sistema produtor tem seis geradores hídricos com 50 MW cada um. Na Figura 4.2, está a comparação da capacidade de produção hídrica mensal (azul), em porcentagem da capacidade máxima instalada hídrica, e da carga mensal (laranja), estando esta em relação ao valor de pico de carga. Apesar dos valores estarem em valores percentuais dos respectivos valores máximos (capacidade máxima de produção e respetivo pico de carga) existem alturas do ano em que a carga é maior que a capacidade de produção hídrica, em termos de valores relativos. Tanto para as primeiras 744 horas, bem como para os últimos dois meses, onde a carga atinge valores de pico, a produção hídrica atinge os valores mais baixos da sua produção.

As unidades térmicas representam a grande maioria da capacidade de produção do sistema, com uma capacidade de geração de 3105MW, entre as 26 unidades térmicas. Quando se agrega a potência eólica, todas as unidades eólicas agregam-se num único parque eólico, aumentando o número de geradores do sistema de 32 para 33. Como o trabalho incide na busca do impacto do erro de previsão eólica, a capacidade de geração eólica varia de 800, 1600 e 2400 MW de capacidade instalada. É também avaliada a reserva operacional sem produção eólica.

No planeamento a curto-prazo, neste sistema teste didático, definiram-se duas ordens de mérito, apresentadas na Tabela 4.1, de forma a simular diferentes casos.

Tabela 4.1 – Ordem de mérito das unidades produtoras

Prioridade de Escalonamento	Ordem de Mérito	
	A	B
1ª	Eólica	Eólica
2ª	Térmica	Hídrica
3ª	Hídrica	Térmica

Tal como dito anteriormente, pretende-se fazer o estudo da reserva operacional quando esta está a subir, pretendendo-se com isso, evitar que a reserva operacional entre em nível excessivo por uma má previsão. Neste caso, só é interessante retirar os valores negativos dos erros de previsão, isto quer dizer que

$$\Delta P_{W_t} < 0 \Leftrightarrow P_{W_t} - \hat{P}_{W_t} < 0 \Leftrightarrow P_{W_t} < \hat{P}_{W_t}, \quad (4.1)$$

sendo  $P_{W_t}$  o valor observado e  $\hat{P}_{W_t}$  o valor previsto. Por esta razão, a equação de risco da reserva operacional (2.52) terá de ser reescrita da seguinte forma

$$R_{OPE} < \Delta L - \Delta P_W + \Delta G. \quad (4.2)$$

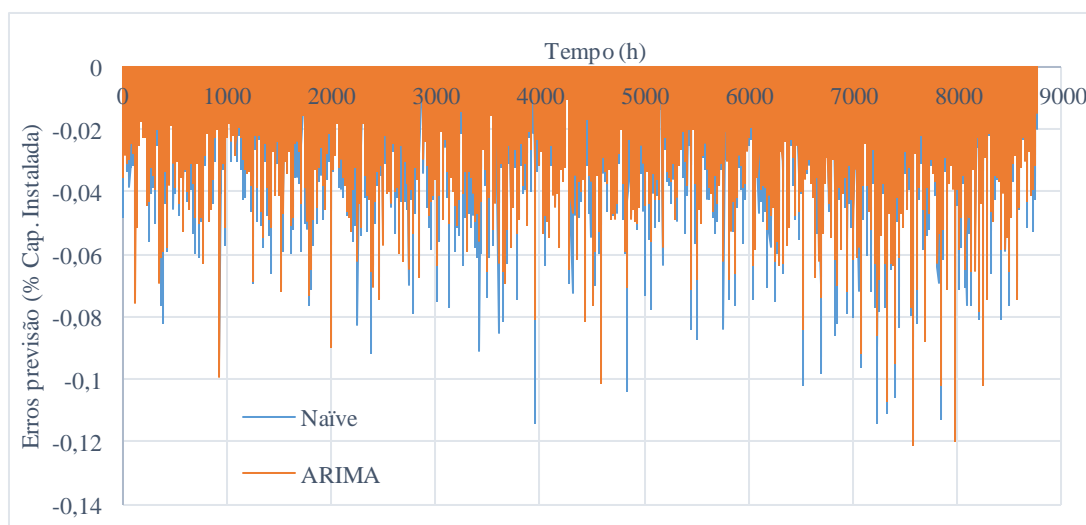


Figura 4.3 – Parte negativa dos erros de previsão

Na Figura 4.3 estão representados os erros médios horários da previsão de três anos, obtidos pelos dois modelos de previsão eólica. Apesar do modelo ARIMA ser melhor do que o Naïve em termos de valores médios, como visto na secção ARIMA vs Naïve, existem alturas da série onde isso não se verifica. Entre a hora 7296 e o final da série, os erros de previsão são superiores, em valores absolutos.

### 4.3 Resultados das Simulações

As simulações realizadas diferem nas ordens de mérito dos geradores, produção eólica e respetivo modelo de previsão. A Tabela 4.2 mostra o sumário dos testes realizados.

**Tabela 4.2** – Sumário dos testes

Número aerogeradores	Cap. unitária eólica	Cap. instalada eólica	Cap. Máx. Produtora		
	MW	MW	MW		
0		0	3405		
400	2	800	4205		
800		1600	5005		
1200		2400	5805		
Pico Carga MW	Valley Load MW	Número Unidades Térmicas	Número Unidades Hídricas	Número Parques Eólicos	
2850	965.62	26	6	1	

Com diferentes quantidades de aerogeradores, existem diferentes capacidades máximas do sistema produtor. Considera-se que cada gerador eólico tem capacidade de 2MW, como pode ser visualizado nos Anexos, Tabela A.1.

O perfil da carga pode ser visualizado na Figura 4.1. Com pico de carga de 2850 MW e o mínimo de 965,62 MW, verifica-se que a capacidade máxima produtora sem produção eólica é superior ao pico de carga (3405MW sem produção eólica). Um reforço de capacidade eólica no sistema aumenta esta diferença entre o pico de carga e a capacidade máxima instalada de geração. Foi admitido que todos os aerogeradores foram aglomerados no mesmo parque eólico. Com isto, admite-se que todos os aerogeradores são afetados pelo mesmo comportamento de vento, ou seja, as previsões de produção eólica em cada gerador seguirão a mesma série, bem como os respetivos valores observados.

Em todas as simulações, foram mantidos os seguintes parâmetros

**Tabela 4.3** – Parâmetros das simulações

Parâmetro		
Convergência	$\beta$	2.50%
Incerteza de carga a curto-prazo	$STU$	2.50%
Reserva Primária	$R_P$	50 MW
Reserva Secundária	$R_S$	200 MW

### 4.3.1 Caso sem Produção Eólica

As simulações do sistema sem unidades eólicas incorporadas no sistema resultam numa avaliação da reserva operacional quando não há reforço de geração por via eólica.

**Tabela 4.4** – Índices de fiabilidade sem produção eólica

	<b>LOLP prob.</b>	<b>LOLE h/ano</b>	<b>EPNS MW</b>	<b>EENS MWh/ano</b>	<b>LOLF oc./ano</b>	<b>LOLD h/oc.</b>
Ordem de mérito A	0.00056	4.90	0.0299	262.04	4.89	1.002
Ordem de mérito B	0.00277	24.28	0.2372	2078.17	24.23	1.002

Claramente que quando as unidades hídricas são as últimas a entrar em funcionamento, há uma maior flexibilidade da reserva terciária em satisfazer as variações da carga e de geração. Já no caso da ordem de mérito B, em que as unidades hídricas entram antes das unidades térmicas, os índices de Reserva Operacional pioram, devido à pouca flexibilidade de produção das unidades térmicas de fazer face a estas variações. Para algumas destas unidades térmicas, uma variação na produção, ou entrada em funcionamento, leva mais do que uma hora, não sendo as ideais para atuarem a curto-prazo. Claramente que as unidades hídricas são bem mais flexíveis e melhores para serem usadas na reserva terciária.

### 4.3.2 Caso com Produção Eólica

Nesta subsecção introduz-se produção eólica no sistema, aumentando a capacidade máxima de geração do sistema produtor. De forma a simular vários cenários de eólica, foram considerados três valores de potência: 800, 1600 e 2400 MW. E foram testados os dois modelos de previsão, ARIMA e Naïve.

#### 4.3.2.1 ARIMA

Tal como se observou no Capítulo 3, este é o melhor modelo de previsão comparativamente ao Naïve, que quando aplicado no programa RESERVAS, obtiveram-se os seguintes resultados da avaliação da reserva operacional.

Tabela 4.5 – Avaliação da ROPE para o modelo de previsão ARIMA

	Nº geradores eólicos	Cap. unitária eólica	Cap. instalada eólica	LOLP	LOLE	EPNS	EENS	LOLF	LOLD
		MW	MW	prob.	h/ano	MW	MWh/ano	oc./ano	h/oc.
Ordem de Mérito A	400		800	0.00043	3.76	0.0240	210.11	3.76	1.001
	800	2	1600	0.00055	4.81	0.0349	305.98	4.80	1.002
	1200		2400	0.00186	16.28	0.1443	1263.92	16.20	1.005
Ordem de Mérito B	400		800	0.00305	26.75	0.2119	1856.13	26.65	1.004
	800	2	1600	0.00936	82.00	0.4819	4221.03	80.00	1.025
	1200		2400	0.02409	211.00	1.6141	14139.23	202.50	1.042

À semelhança da Tabela 4.4, também neste caso se pode concluir que a ordem de mérito influencia bastante os índices de fiabilidade da reserva operacional. A Tabela 4.5 mostra que quando maior é a potência eólica instalada, piores são os seus índices. Devido aos erros de previsão eólica, quanto maior for a potência instalada no parque, maior irá ser o  $\Delta P_W$  em MW.

Para um  $\Delta P_W$  (% Cap. Instalada) = 0,01, e um  $P_{W_{Máx}}$  (MW) = 1600 MW (para quando não se consideram as saídas por falhas furtivas dos aerogeradores), o  $\Delta P_W$  (MW) = 16 MW. Mas se a potência eólica máxima aumentar para 2400 MW, então o erro de previsão leva a um erro de 24 MW. Isto leva a uma maior probabilidade de insucesso de reserva, devido a limitações das unidades hídricas em termos de potência disponível, e de unidades térmicas, em termos de resposta às variações a curto-prazo. Com o aumento da potência eólica, os erros atingem magnitudes que a potência hídrica tem dificuldade de compensar.

#### 4.3.2.2 Naïve

Usando o modelo Naïve para a previsão da produção eólica, realizou-se a avaliação dos índices de fiabilidade da reserva operacional com os seguintes resultados.

Tabela 4.6 – Avaliação da ROPE para o modelo de previsão Naïve

	Nº geradores eólicos	Cap. unitária eólica	Cap. instalada eólica	LOLP	LOLE	EPNS	EENS	LOLF	LOLD
		MW	MW	prob.	h/ano	MW	MWh/ano	oc./ano	h/oc.
Ordem de Mérito A	400		800	0.00043	3.74	0.0241	211.04	3.74	1.001
	800	2	1600	0.00053	4.67	0.0300	262.91	4.66	1.002
	1200		2400	0.00263	23.04	0.1853	1623.15	21.45	1.074
Ordem de Mérito B	400		800	0.00325	28.46	0.2166	1897.58	28.24	1.008
	800	2	1600	0.01373	120.28	0.7112	6230.37	107.22	1.122
	1200		2400	0.03288	288.00	2.2237	19479.35	238.50	1.208

Tal como aconteceu com o modelo de previsão ARIMA, o efeito da ordem de mérito é igual: quando a produção hídrica está fora da base, melhores são os seus índices. Neste caso, as unidades hídricas fazem a parte da reserva terciária, atendendo assim, às eventuais variação de carga, erro de previsão eólica e variação na produção. A Tabela 4.6 mostra esses resultados. Quanto maior a potência instalada eólica, maior é o índice LOLP, bem como o índice EENS, pelas mesmas razões dadas no modelo ARIMA.

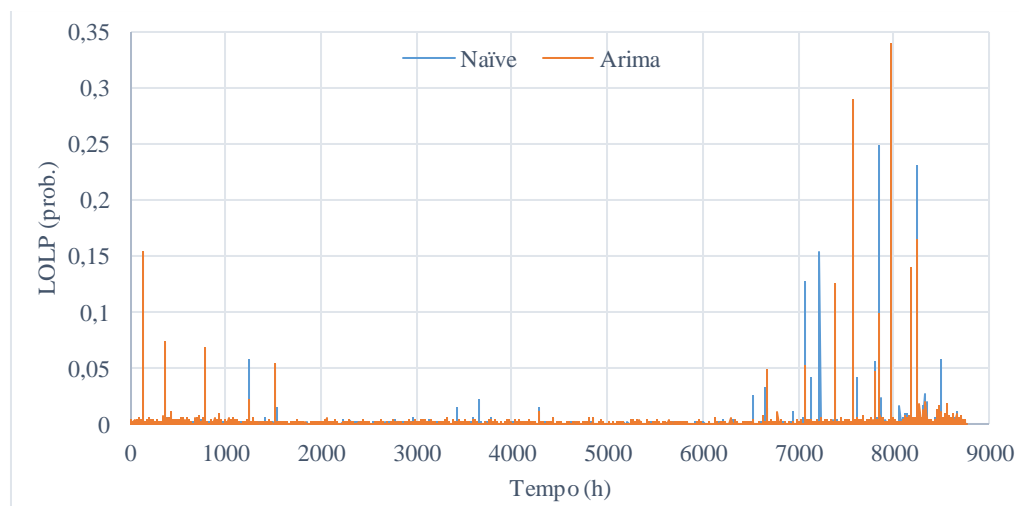
#### 4.4 Discussão de Resultados

Nas subsecções anteriores analisaram-se os resultados obtidos da avaliação do sistema produtor do *IEEE RTS 79 HW*, tendo esta capacidade máxima produtora, sem produção eólica, de 3405 MW. Apesar de haver capacidade produtora para a carga, devido ao erro de previsão eólica e variação da carga, há um risco associado de não existir flexibilidade para atender às variações de curto-prazo.

**Tabela 4.7** – Comparação dos índices de fiabilidade para a ordem de mérito A

	Cap. instalada eólica MW	Modelo previsão	LOLP prob.	LOLE h/ano	EPNS MW	EENS MWh/ano	LOLF oc./ano	LOLD h/oc.
	-	-	0.00056	4.90	0.0299	262.04	4.89	1.002
Ordem de Mérito A	800	ARIMA	0.00043	3.76	0.0240	210.11	3.76	1.001
		Naïve	0.00043	3.74	0.0241	211.04	3.74	1.001
	1600	ARIMA	0.00055	4.81	0.0349	305.98	4.80	1.002
		Naïve	0.00053	4.67	0.0300	262.91	4.66	1.002
	2400	ARIMA	0.00186	16.28	0.1443	1263.92	16.20	1.005
		Naïve	0.00263	23.04	0.1853	1623.15	21.45	1.074

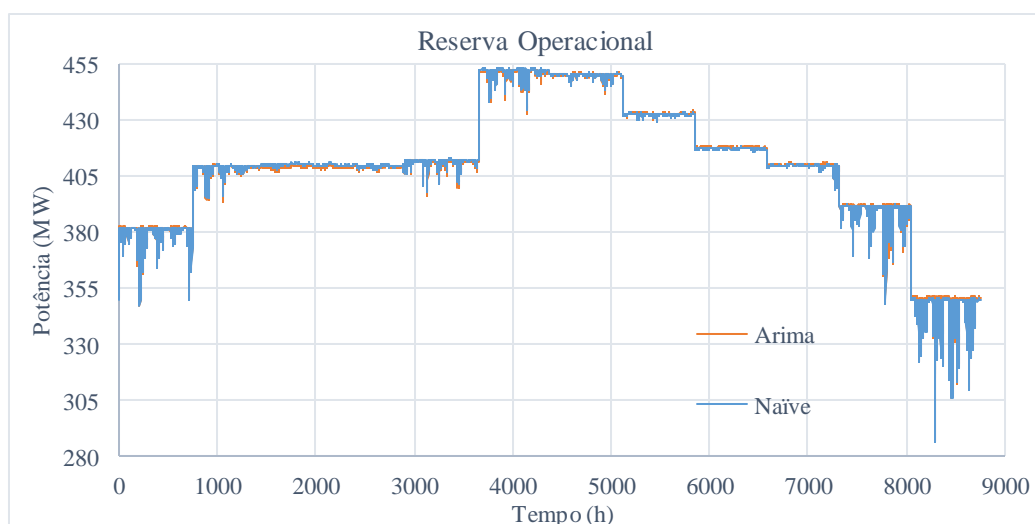
A Tabela 4.7 mostra a comparação da avaliação da reserva operacional, quando utilizados os dois modelos de previsão, bem como, quando não se consideram unidades eólicas na geração. Como visto no Capítulo 3 e dito na secção 4.2, o modelo ARIMA é um melhor modelo de previsão, em termos de valores médios, do que o Naïve. Por isso, esperava-se que a avaliação da reserva fosse melhor do que o Naïve. Analisando as simulações de 800 e 1600 MW, verifica-se de que os índices são bastante semelhantes, tendo o Naïve melhores índices. Mas isso é diferente para a simulação de 2400 MW.



**Figura 4.4** – Valores do LOLP horários para potência eólica de 1600 MW

Como visualizado na Figura 4.4, os erros maiores do modelo de previsão ARIMA acontecem entre {7296, 8760}. Nesse mesmo intervalo de tempo, a carga atinge o seu pico bem como os valores das cargas médias mensais dos últimos dois meses são as maiores. E nesses mesmos últimos meses, a capacidade de geração por fontes hídricas é a menor (Figura 4.2).

Visualizando a Figura 4.4 verifica-se que há maior perda de carga nos instantes referidos. Uma vez que os erros do ARIMA são maiores do que os do Naïve, em valores absolutos, entre 7296 e 8760h há uma afirmação maior da perda de carga deste modelo. Para este caso de simulação, os erros do Naïve não estão tão afirmados ao longo da série, fazendo com que o ARIMA se torne um mau modelo apenas porque está a errar mais nos últimos instantes.




**Figura 4.5** – Reserva Operacional solicitada na simulação A-1600 MW

A Figura 4.5 representa a reserva operacional solicitada para uma potência eólica de 1600 MW, e ordem de mérito A. Apesar de não ser muito perceptível, estão representados graficamente

os resultados das simulações de reserva operacional dos dois modelos, que se apresentam resultados muito semelhantes.

Pelo desenho do gráfico, poder-se-á dizer que as unidades hídricas estão a assegurar a reserva terciária do sistema produtor. As variações de reserva são provocadas pela variação de carga. Estas são maiores nos últimos dois meses, meses onde a carga atinge os valores mais altos.

Comparativamente à avaliação entre os sistemas com e sem produção eólica, chega-se à conclusão de que para uma capacidade instalada inferior a 1600 MW, há um menor LOLE, ou seja, o risco é menor. O facto de haver muita produção eólica, faz aumentar a incerteza das unidades de reserva operacional satisfazerem os erros de previsão. Isto quer dizer que a probabilidade da reserva operacional causar falha no sistema é maior.



**Figura 4.6** – Valores do LOLP horários para potência eólica de 2400 MW

Quando a potência instalada eólica é de 2400 MW, a avaliação torna-se melhor usando o modelo ARIMA do que o Naïve. A Figura 4.6 mostra que os erros do Naïve provocam maior impacto na reserva operacional, isto devido à variação  $\Delta P_W$  ser maior em valores de MW neste caso, do que no caso de 1600 MW. Aqui, o fator da ponta dos erros ARIMA não é tão significativo comparativamente aos erros do Naïve, e os erros deste modelo sobressaem-se mais ao longo da série.



**Figura 4.7** – Reserva Operacional solicitada na simulação A-2400 MW

Importante de referir que quanto maior a capacidade instalada de eólica, maior será a dificuldade de unidades hídricas e unidades térmicas de suportarem os erros de previsão da produção eólica. A Figura 4.7 da reserva operacional solicitada para a simulação de 2400 MW mostra que os valores de reserva aproximam-se da geração eólica, sem que ocorram muitas variações, reforçando a ideia que existe menor capacidade de reserva operacional para suportar os erros de previsão da produção eólica, bem como variações de carga a curto-prazo.

**Tabela 4.8** – Comparação dos índices de fiabilidade para a ordem de mérito B

	Nº geradores eólicos	Cap. unitária eólica MW	Cap. instalada eólica MW	Modelo previsão	LOLP prob.	LOLE h/ano	EPNS MW	EENS MWh/ano	LOLF oc./ano	LOLD h/oc.
	-	-	-	-	0.00277	24.28	0.2372	2078.17	24.23	1.002
Ordem de Mérito B	400	2	800	ARIMA	0.00305	26.75	0.2119	1856.13	26.65	1.004
				Naïve	0.00325	28.46	0.2166	1897.58	28.24	1.008
	800	2	1600	ARIMA	0.00936	82.00	0.4819	4221.03	80.00	1.025
				Naïve	0.01373	120.28	0.7112	6230.37	107.22	1.122
	1200	2	2400	ARIMA	0.02409	211.00	1.6141	14139.23	202.50	1.042
				Naïve	0.03288	288.00	2.2237	19479.35	238.50	1.208

A análise feita para a simulação sem produção eólica repete-se aqui, que pela Tabela 4.8, se verifica um aumento dos índices de fiabilidade. Ora isto traduz-se na falta de flexibilidade que as unidades térmicas têm para variações a curto-prazo. Com as unidades hídricas na reserva secundária, as unidades térmicas ficam a assegurar a reserva terciária. Isto provoca uma menor reserva disponível. No entanto, o efeito dos erros de previsão enunciado nos parágrafos anteriores não se repete neste caso.

Neste caso de escalonamento, claramente que o modelo ARIMA dá uma melhor avaliação, pondo em evidência de que o modelo Naïve sobrestima os índices de fiabilidade. Quando se adiciona eólica, há um aumento dos índices de fiabilidade devido ao facto de se estar a adicionar mais incerteza ao sistema produtor.

O impacto do erro de previsão nas necessidades a longo-prazo da reserva operacional varia com o modelo de previsão usado. Quanto melhor for o modelo e melhor se ajustar à série eólica, melhor irá ser o planeamento da reserva operacional a curto-prazo. No entanto, para pequenas potências eólicas instaladas no sistema, a importância dos modelos de previsão não influencia muito a avaliação da reserva. Mas para potências elevadas, quanto melhor for o modelo de previsão melhor será o planeamento da reserva operacional. Quando existe um maior reforço de capacidade eólica no sistema, este não se torna tão fiável em termos de Reserva Operacional. O que acontece quando se utiliza um modelo de previsão como o Naïve é a sobrestimação dos índices de fiabilidade da Reserva Operacional, que são melhorados através do modelo ARIMA.



## Capítulo 5.

### Conclusão

Com o crescimento da integração da energia eólica na rede, torna-se necessário saber o seu impacto no sistema produtor. O trabalho desenvolvido permitiu saber que influência pode ter as previsões do vento na Reserva Operacional de um sistema, e qual o impacto do erro de previsão nas necessidades de reserva operacional. Este estudo permitiu saber se é ou não viável substituir o modelo de previsão Naïve, usado no programa RESERVAS, por um mais completo e com melhores previsões, como o modelo de previsão ARIMA.

Pelos testes realizados, com a utilização do modelo ARIMA para previsão eólica de uma série temporal de 3 anos, obtiveram-se melhores resultados em termos de valores médios, quando comparados com os obtidos pelo modelo Naïve. O modelo ARIMA caracteriza-se por ajustar as ordens de regressão e os seus respetivos parâmetros à série em análise, que desta forma, consegue obter uma melhor previsão. O Naïve assume que o que se passará na hora  $t+1$ , será igual ao que ocorre em  $t$  levando a erros de previsão por persistência. Em termos médios, o modelo ARIMA obteve um erro médio absoluto de 2,73%, enquanto o Naïve obteve 3.08% da capacidade máxima instalada eólica.

Para avaliar a reserva operacional utilizando dois modelos de previsão, foi utilizado o sistema *IEEE RTS 79 HW* e com recurso ao programa RESERVAS obtiveram-se os índices de fiabilidade da Reserva Operacional. O programa RESERVAS utiliza o método de Simulação Sequencial de Monte Carlo para simular os estados do sistema, e para prever a potência eólica para a hora seguinte, utiliza o modelo de previsão Naïve.

Os testes realizados tiveram diferentes cenários de eólica e diferentes ordens de mérito das unidades geradoras. Para o caso em a ordem de mérito utiliza as hídricas em último lugar, os índices de fiabilidade tiveram os melhores valores. No entanto, para níveis de potência eólica

mais baixos, com o modelo ARIMA, a avaliação da Reserva Operacional foi pior do que com o Naïve. Apesar do ARIMA ser melhor que o Naïve, este obteve os maiores erros no final da série (entre os instantes 7296 e os 8760). Na mesma altura, a potência média disponível hídrica atinge os valores mais baixos, e a carga atinge os valores mais elevados.

Com esta indisponibilidade da produção em relação à carga, os erros obtidos pelo ARIMA são mais significativos para pequenas capacidades de produção eólica quando comparado com o modelo Naïve. Apesar do modelo Naïve ser pior no ponto de vista de valor médio dos erros de previsão, não implica que a sua previsão seja sempre pior do que as do modelo ARIMA. Isto quer dizer que, em certas alturas do ano e para baixas capacidades de produção eólica, os índices de fiabilidade da Reserva Operacional não são sobrestimados. No entanto, quando a potência aumenta, aí estes erros de previsão obtidos pelo Naïve causam uma sobrestimação nos índices de fiabilidade da Reserva Operacional. Para casos em que a capacidade de produção eólica é mais elevada, os erros do modelo ARIMA não são tão significativos em comparação ao Naïve. Para este caso, as unidades hídricas funcionam, praticamente, como reserva terciária.

Quando as unidades térmicas entram em último lugar no escalonamento das unidades geradoras, a avaliação da Reserva Operacional. Porém, aqui verifica-se que o modelo ARIMA obtém muito melhores resultados do que o Naïve. Há uma clara diferença entre os dois modelos, sendo que com o ARIMA se consegue atingir uma avaliação da reserva operacional de uma forma mais precisa, diferente dos índices de fiabilidade sobrestimados pelo modelo de previsão Naïve. Mas os melhores índices são atingidos quando não há unidades eólicas no sistema. Isto devido ao facto da falta de flexibilidade das unidades térmicas em não conseguirem acompanhar, a curto-prazo, as variações de carga e os erros de previsão da potência eólica. Neste caso, ao ser inserido mais capacidade eólica no sistema, aumenta-se os valores de risco. Devido ao facto de haver menos reserva operacional disponível. Pois pelas unidades hídricas estarem como reserva secundária, e dificuldade da disponibilidade das unidades térmicas em fazer reserva terciária, faz com que a disponibilidade a curto-prazo da reserva não seja atendida.

Através deste estudo pode-se concluir que o modelo ARIMA é melhor que o modelo Naïve, em termos de valores médios dos erros de previsão, confirmando-se assim a influência do modelo de previsão nas necessidades de Reserva Operacional a longo-prazo. Com a mesma reserva, os índices de fiabilidade são melhores quando se usa o modelo de previsão eólica ARIMA, especialmente quando existe elevada penetração de eólica no sistema. Isto permite reduzir a Reserva Operacional sem aumentar o risco.

No entanto, o modelo ARIMA contém erros de sazonalidade, e a avaliação da Reserva Operacional pode piorar em alguns casos, quando comparada com a avaliação da Reserva

Operacional usando o modelo Naïve. Tal como aconteceu neste trabalho, os erros maiores de previsão ARIMA aconteceram nos mesmos intervalos em que a carga atingia os valores mais elevados, e as unidades hídricas atingiam os valores mínimos das suas capacidades de geração.

## 5.1 Trabalhos Futuros

Para ultrapassar este problema, um dos trabalhos futuros seria melhorar o modelo ARIMA, considerando mais variáveis na previsão eólica, nomeadamente, sazonalidade (estações do ano), bem como dados geográficos dos parques eólicos. Ou utilizando outros métodos de previsão, seria interessante comparar o desempenho do modelo de previsão por vetores autorregressivos com o utilizado ARIMA.

Uma outra abordagem seria analisar a reserva operacional quando esta está a descer, ou seja, quando há insuficiência de reserva. Também se poderia realizar este estudo num sistema maior, como na Rede Elétrica Nacional (REN), onde se consideraria outras ordens de mérito das unidades geradoras.



## Anexo 1. Glossário

Falhas furtivas (*forced outage*) [7] – Uma interrupção que resulta de condições de emergência diretamente associadas a um componente que deve ser retirado de serviço imediatamente, automaticamente ou com comutação de operações que podem ser executadas, ou uma interrupção causada por operação indevida de equipamentos ou erro humano.

*Likelihood* [55] – em estatística, é uma função de parâmetros de um modelo estatístico que permite inferir sobre o seu valor a partir de um conjunto de observações. Este desempenha um papel fundamental na inferência estatística, especialmente em métodos de estimação de parâmetros.

Reserva Estática [45] – os estudos de reserva estática pontam definir para um certo nível de risco, a capacidade necessária para encontrar a carga esperada. A incerteza associada a este tipo de reserva, que é uma variável estocástica, é causada pela intermitência dos recursos energéticos primários, as saídas planeadas e furtivas, e a incerteza das cargas. Os eventos de reserva estática insuficiente acontecem quando

$$R_{STA} = G - L < 0, \quad (\text{A.1})$$

onde  $G$  representa a capacidade de produção e  $L$  a carga do sistema.



## Anexo 2. *IEEE RTS 79 HW*

Tabela A.1 – Informação geradores do sistema *IEEE RTS 79 HW*

ID	Número de geradores	Nome	Nome tecnologia	Potência	Potência	MTIF	MTR	Tipo Modelo Markov	Estado	Mobilizável
				Mínima MW	Máxima MW					
1	1	U20	<i>Oil/CT</i>	0	20	450	50	Dois estados	0	false
2	1	U20	<i>Oil/CT</i>	0	20	450	50	Dois estados	0	false
3	1	U76	<i>Coal/Steam</i>	0	76	1960	40	Dois estados	0	false
4	1	U76	<i>Coal/Steam</i>	0	76	1960	40	Dois estados	0	false
5	1	U20	<i>Oil/CT</i>	0	20	450	50	Dois estados	0	false
6	1	U20	<i>Oil/CT</i>	0	20	450	50	Dois estados	0	false
7	1	U76	<i>Coal/Steam</i>	0	76	1960	40	Dois estados	0	false
8	1	U76	<i>Coal/Steam</i>	0	76	1960	40	Dois estados	0	false
9	1	U100	<i>Oil/Steam</i>	0	100	1200	50	Dois estados	0	false
10	1	U100	<i>Oil/Steam</i>	0	100	1200	50	Dois estados	0	false
11	1	U100	<i>Oil/Steam</i>	0	100	1200	50	Dois estados	0	false
12	1	U197	<i>Oil/Steam</i>	0	197	950	50	Dois estados	0	false
13	1	U197	<i>Oil/Steam</i>	0	197	950	50	Dois estados	0	false
14	1	U197	<i>Oil/Steam</i>	0	197	950	50	Dois estados	0	false
15	1	U12	<i>Oil/Steam</i>	0	12	2940	60	Dois estados	0	false
16	1	U12	<i>Oil/Steam</i>	0	12	2940	60	Dois estados	0	false
17	1	U12	<i>Oil/Steam</i>	0	12	2940	60	Dois estados	0	false
18	1	U12	<i>Oil/Steam</i>	0	12	2940	60	Dois estados	0	false
19	1	U12	<i>Oil/Steam</i>	0	12	2940	60	Dois estados	0	false
20	1	U155	<i>Coal/Steam</i>	0	155	960	40	Dois estados	0	false
21	1	U155	<i>Coal/Steam</i>	0	155	960	40	Dois estados	0	false
22	1	U400	<i>Nuclear</i>	0	400	1100	150	Dois estados	0	false
23	1	U400	<i>Nuclear</i>	0	400	1100	150	Dois estados	0	false
24	1	U155	<i>Coal/Steam</i>	0	155	960	40	Dois estados	0	false
25	1	U155	<i>Coal/Steam</i>	0	155	960	40	Dois estados	0	false
26	1	U350	<i>Coal/Steam</i>	0	350	1150	100	Dois estados	0	false
27	1	U50	<i>Hydro</i>	0	50	1980	20	Dois estados	0	true
28	1	U50	<i>Hydro</i>	0	50	1980	20	Dois estados	0	true
29	1	U50	<i>Hydro</i>	0	50	1980	20	Dois estados	0	true
30	1	U50	<i>Hydro</i>	0	50	1980	20	Dois estados	0	true
31	1	U50	<i>Hydro</i>	0	50	1980	20	Dois estados	0	true
32	1	U50	<i>Hydro</i>	0	50	1980	20	Dois estados	0	true
33	100	W1	<i>Wind</i>	0	2	1914.74	80	Multiestado	0	false

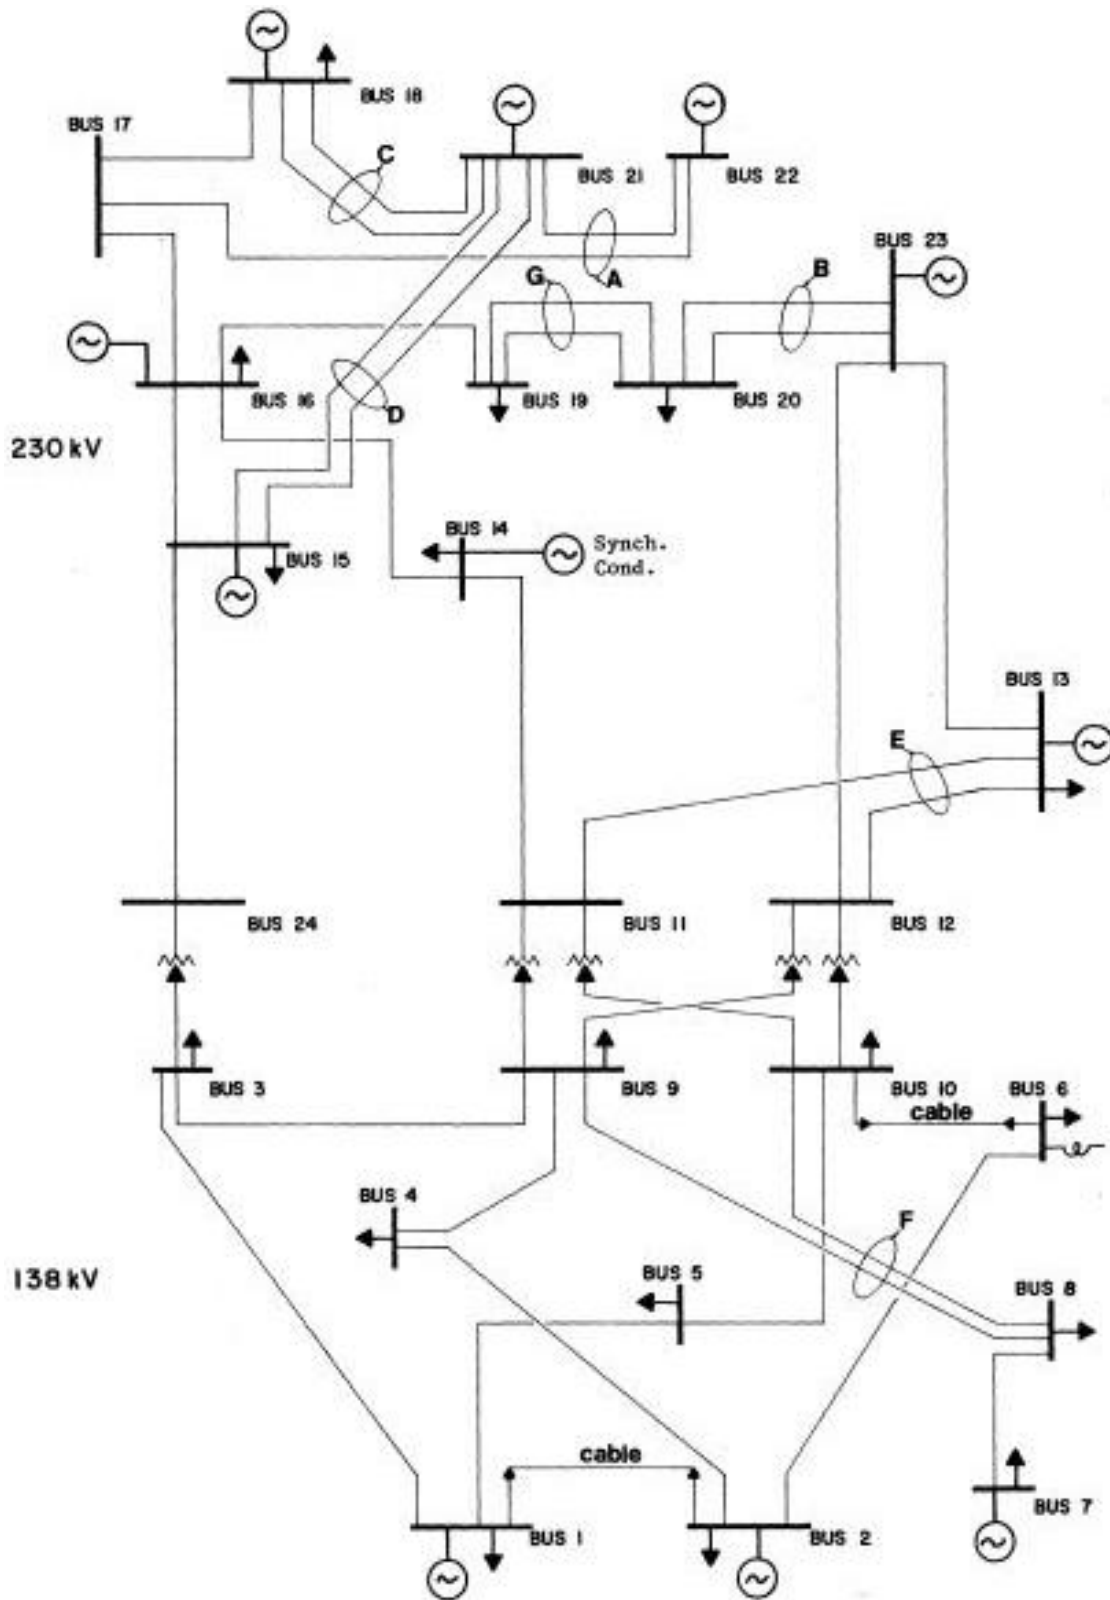


Figura A.1 – Diagrama unifilar do sistema IEEE RTS 79

## Referências Bibliográficas

- [1] Tim Smedley. "Goodbye nuclear power: Germany's renewable energy revolution," 18 August 2015; <http://www.theguardian.com/sustainable-business/nuclear-power-germany-renewable-energy>.
- [2] "Europe 2020 targets," 07 August 2015; [http://ec.europa.eu/europe2020/europe-2020-in-a-nutshell/targets/index\\_en.htm](http://ec.europa.eu/europe2020/europe-2020-in-a-nutshell/targets/index_en.htm).
- [3] Kate Connolly. "G7 leaders agree to phase out fossil fuel use by end of century," 8 June 2015; <http://www.theguardian.com/world/2015/jun/08/g7-leaders-agree-phase-out-fossil-fuel-use-end-of-century>.
- [4] Arthur Neslen. "Wind power generates 140% of Denmark's electricity demand," 07 Agosto 2015; <http://www.theguardian.com/environment/2015/jul/10/denmark-wind-windfarm-power-exceed-electricity-demand>.
- [5] John Vidal. "UK and Germany break solar power records," 18 August 2015; <http://www.theguardian.com/environment/2014/jun/23/uk-and-germany-break-solar-power-records>.
- [6] REN. "Estatística Diária - SEN," 8 Agosto 2015 2015; <http://www.centrodeinformacao.ren.pt/PT/InformacaoExploracao/Paginas/EstatisticaDiaria.aspx>.
- [7] R. Billinton, and R. N. Allan, *Reliability Evaluation of Power Systems*, 2nd ed.: Plenum Press, 1994.
- [8] M. A.da Rosa, L. M. Carvalho, and R. Ferreira, *RESERVE - Program Manual*, 1.0 ed., Porto: INESC, 2011.
- [9] George E. P. Box, Gwilym M. Jenkins, and Gregory C. Reinsel, *Time Series Analysis: Forecasting and Control* 3rd ed., Englewood Cliffs, New Jersey, 1994.
- [10] Vladimiro Miranda, "Redes Neurais – treino por retropropagação," Faculdade de Engenharia da Universidade do Porto, 2007, p. 10.

- [11] R. J. Hyndman, and G. Athanasopoulos. "Forecasting: principles and practice," 25 June 2015.
- [12] Everette S. Gardner, "Exponential Smoothing: The State of the Art," *Journal of Forecasting*, vol. 4, pp. 1-28, 1985.
- [13] R. J. Hyndman, R. A. Ahmed, G. Athanasopoulos, and H. L. Shang, "Optimal combination forecasts for hierarchical time series," 2010, p. 24.
- [14] R. Billinton, H. Chen, and R. Ghajar, "Time-series models for Reliability Evaluation of Power Systems Including Wind Energy," *Microelectron. Reliab.*, 36, 1996.
- [15] R. Billinton, H. Chen, and R. Ghajar, "A Sequential Simulation Technique for Adequacy Evaluation of Generating Systems Including Wind Energy," *IEEE Transactions on Energy Conversion*, 11, 1996.
- [16] R. G. Kavasseri, and K. Seetharaman, "Day-ahead wind speed forecasting using f-ARIMA models," 34, 2009.
- [17] J.C. Palomares-Salas, J.J. G. de la Rosa, J.G. Ramiro, J. Melgar, A. Agüera, and A. Moreno, "ARIMA vs. Neural Networks for Wind Speed Forecasting," 2009.
- [18] E. Cadenas, and W. Rivera, "Wind speed forecasting in the south coast of Oaxaca, Mexico," *Renewable Energy* 32, 2007.
- [19] B. G. Brown, R. W. Katz, and A. H. Murphy, "Time Series Models to Simulate and Forecast Wind Speed and Wind Power," *Journal of Climate and Applied Meteorology*, vol. 23, pp. 1184-1195, 1984.
- [20] P. Chen, T. Pedersen, B. Bak-Jensen, and Z. Chen, "ARIMA-Based Time Series Model of Stochastic Wind Power Generation," *IEEE Transactions on Power Systems*, 25, 2010.
- [21] E. Erdem, and J. Shi, "ARMA based approaches for forecasting the tuple of wind speed and direction," *Applied Energy*, 88, 2011.
- [22] E. Erdem, J. Shi, and Y. Peng, "Short-Term Forecasting of Wind Speed and Power - A Clustering Approach," *Industrial and Systems Engineering Research Conference*, 2014.
- [23] G. N. Kariniotakis, G. S. Stavrakakis, and E. F. Nogaret, "Wind Power Forecasting Using Advanced Neural Networks Models," *IEEE Transactions on Energy Conversion*, 11, 1996.
- [24] G. Li, and J. Shi, "On comparing three artificial neural networks for wind speed forecasting," *Applied Energy*, 87, 2010.
- [25] T. G. Barbounis, J. B. Theocharis, M. C. Alexiadis, and P. S. Dokopoulos, "Long-Term Wind Speed and Power Forecasting Using Local Recurrent Neural Network Models," *IEEE Transactions on Energy Conversion*, 21, 2006.
- [26] M. Monfared, H. Rastegar, and H. Madadi Kojabadi, "A new strategy for wind speed forecasting using artificial intelligent methods," *Renewable Energy*, 34, 2009.

- [27] J. M. Sloughther, T. Gneiting, and A. Raftery, "Probabilistic Wind Speed Forecasting Using Ensembles and Bayesian Model Averaging," *American Statistical Association*, vol. 105, pp. 25-35, 2010.
- [28] R. Karki, and P. Hu, "Wind Power Simulation Model For Reliability Evaluation," 2005.
- [29] R. Karki, P. Hu, and R. Billinton, "A Simplified Wind Power Generation Model for Reliability Evaluation," *IEEE Transactions on Energy Conversion*, 21, 2006.
- [30] D. Huang, and R. Billinton, "Effects of Wind Power on Bulk System Adequacy Evaluation Using the Well-Being Analysis Framework," *IEEE Transactions on Power Systems*, 24, 2009.
- [31] M. A. Matos, and R. Bessa, "Operating Reserve Adequacy Evaluation using Uncertainties of Wind Power Forecast," in IEEE Bucharest Power Tech Conference, Bucharest, Romania, 2009, pp. 1 - 8.
- [32] Rob J. Hyndman, *Forecasting: Principles & practice*: University of Western Australia, 2014.
- [33] G. E. P. Box, and D. A. Pierce, "Distribution of Residual Autocorrelations in Autoregressive-Integrated Moving Average Time Series Models," *Journal of the American Statistical Association*, vol. 65, pp. 1509–1526, 1970.
- [34] G. M. Ljung, and G. E. P. Box, "On a Measure of a Lack of Fit in Time Series Models," *Biometrika*, vol. 65, pp. 297-303, 1978.
- [35] Benito E. Flores, "A Pragmatic View of Accuracy Measurement in Forecasting," *Journal of Mgmt Sci.*, vol. 14, pp. 93-98, 1986.
- [36] Z. Chen, and Y. Yang, "Assessing Forecast Accuracy Measures," Department of Economics, Iowa State University, 2004, pp. 1-26.
- [37] Frank Wilcoxon, "Individual Comparisons by Ranking Methods," *Biometrics Bulletin*, 6, International Biometric Society, 1945, pp. 80-83.
- [38] H. B. Mann, and D. R. Whitney, "On a test of whether one of two random variables is stochastically larger than the other," pp. 1-11, 1947.
- [39] V. S. Srinivasan, and K.V. Ramachandra, "Decision Making in Reliability," *IEEE Transactions on Reliability*, vol. R-26, pp. 261-265, October 1977.
- [40] Roy Billinton, and Wenyuan Li, *Reliability Assessment of Electrical Power Systems Using Monte Carlo Methods*, New York: Plenum Press, 1994.
- [41] Vladimiro Miranda, *Fiabilidade em Sistemas de Potência – Uma Introdução*, 2.0 ed., Porto: INESC, 2006.
- [42] J. C. O. Mello, M. V. F. Pereira, and A. M. Leite da Silva, "Evaluation of reliability worth in composite systems based on pseudo-sequential monte carlo simulation," *IEEE Transactions on Power Systems*, 9, 1994.

- [43] A. M. Leite da Silva, L. A. F. Manso, J. C. O. Mello, and R. Billinton, "Pseudo-Chronological Simulation for Composite Reliability Analysis with Time Varying Loads," *IEEE Transactions on Power Systems*, 15, 2000.
- [44] A. M. Leite da Silva, R. A. González-Fernández, W. S. Sales, and L. A. F. Manso, "Reliability Assessment of Time-Dependent Systems via Quasi-Sequential Monte Carlo Simulation," 2010.
- [45] Leonel M. Carvalho, "Advances on the Sequential Monte Carlo Reliability Assessment of Generation-Transmission Systems using Cross-Entropy and Population-based Methods," PhD, Universidade do Porto, Porto, 2013.
- [46] A. C. G. Melo, M. V. F. Pereira, and A. M. Leite da Silva, "Frequency and duration calculations in composite generation and transmission reliability evaluation," *IEEE Transactions on Power Systems*, 7, 1992.
- [47] M. A. Matos, J. P. Lopes, M. A. da Rosa, R. Ferreira, A. Leite da Silva, W. Sales, L. Resende, L. Manso, P. Cabral, M. Ferreira, N. Martins, C. Artaiz, F. Soto, and R. López, "Probabilistic evaluation of reserve requirements of generating systems with renewable power sources: The Portuguese and Spanish cases," *Electrical Power and Energy Systems*, 31, 2009.
- [48] A. M. Leite da Silva, W. S. Sales, L. A. F. Manso, and R. Billinton, "Long-Term Probabilistic Evaluation of Operating Reserve Requirements With Renewable Sources," *IEEE Transactions on Power Systems*, vol. 25, no. 1, pp. 106-116 February 2010.
- [49] A. M. Leite da Silva, A. M. Cassula, R. Billinton, and L. A. F. Manso, "Integrated reliability evaluation of generation, transmission and distribution systems," *IEE Proc.-Gener. Transm. Distrib.*, 149, 2002.
- [50] T. Hong, P. Pinson, and S. Fan, "Global Energy Forecasting Competition 2012," *International Journal of Forecasting*, vol. 30, pp. 357-363, April - June 2014.
- [51] The MathWorks. "estimate," 29 July 2015; <http://www.mathworks.com/help/econ/arima.estimate.html>.
- [52] The MathWorks. "Forecast," 29 July 2015; <http://www.mathworks.com/help/econ/arima.forecast.html>.
- [53] The MathWorks. "Infer," 29 July 2015; [http://www.mathworks.com/help/econ/arima.infer.html#outputarg\\_E](http://www.mathworks.com/help/econ/arima.infer.html#outputarg_E).
- [54] Probability Methods Subcommittee, "IEEE Reliability Test System," *IEEE Transactions on Power Apparatus and Systems*, PAS-98, 1979.
- [55] A. Raue, C. Kreutz, T. Maiwald, J. Bachmann, M. Schilling, U. Klingmüller, and J. Timmer, "Structural and practical identifiability analysis of partially observed dynamical models by exploiting the profile likelihood," *BIOINFORMATICS*, vol. 25, pp. 1923-1929, June 2009.