

Faculdade de Engenharia da Universidade do Porto



Universidade do Porto

Faculdade de Engenharia

FEUP

**Desenvolvimento de uma metodologia e
ferramentas para a previsão da produção
elétrica em parques fotovoltaicos**

Carlos Silva

Dissertação realizada no âmbito do
Mestrado Integrado em Engenharia Mecânica
Especialização em Energia Térmica

Orientador: Eng.º Álvaro Henrique Rodrigues

Co-orientador: Eng.º João Sousa

Fevereiro de 2012

Resumo

As fontes renováveis de energia são caracterizadas pela sua variabilidade e intermitência, pelo que a produção das centrais baseadas nessas fontes varia de acordo com a disponibilidade do recurso. No caso da radiação solar incidente na superfície terrestre, esta varia essencialmente devido à presença de nebulosidade, tendo enorme influência na produção de energia elétrica a partir de sistemas solares. Aumentar a taxa de penetração na rede de centros electroprodutores baseados na energia eólica e solar através do desenvolvimento de métodos de previsão, é uma das prioridades na investigação destes recursos para os próximos anos. O desenvolvimento de métodos de previsão eficazes permitirá que a energia solar reforce a sua posição, comparativamente a outras formas de produção de eletricidade despacháveis.

Nesta dissertação apresenta-se uma metodologia de previsão de produção elétrica a curto prazo, com discretização horária, para um parque fotovoltaico. Esta ferramenta será uma mais valia para a integração da tecnologia fotovoltaica no sistema electroprodutor, pois auxiliará o operador da rede elétrica nas tarefas do planeamento do despacho da energia, na contratação de serviços auxiliares e de reserva, na gestão das ações de manutenção e congestionamento da rede, e o promotor na gestão geral do parque.

O modelo proposto nesta dissertação recorre a redes neuronais para simular a evolução da produção fotovoltaica. Inicialmente apresenta-se os modelos desenvolvidos que efetuam previsões com base em dados históricos da produção e em previsões meteorológicas. De seguida recorre-se a uma rede neuronal que utiliza as previsões efetuadas pelos modelos anteriores, com o intuito de assimilar estes resultados, efetuando assim previsões mais precisas.

Finalmente, é avaliado o desempenho do modelo proposto através da análise do erro, sendo que as previsões realizadas pelo modelo construído revelaram uma melhoria bastante significativa face ao modelo de referência considerado.

Palavras-chave: Modelos de previsão da produção fotovoltaica, redes neuronais, previsão de produção fotovoltaica, modelos de previsão baseados em séries temporais.

Abstract

Renewable energy sources are characterized by their variability and intermittency, so the production of electricity from those sources varies according to the resource availability. In the case of solar radiation on Earth's surface, this varies mainly due to the presence of clouds, having great influence in the production of electrical energy from solar systems. Increasing the penetration rate in the network of solar and wind electrical energy production through the development of forecasting methods is a priority in the investigation of these resources for the years to come. The development of effective prediction methods will allow solar energy to strengthen its position comparatively to other forms of dispatchable electricity production.

This dissertation presents a methodology for short-term forecasting of electricity production, with hourly discretization, for a photovoltaic park. This tool will be an important contribution to increase renewable power stations in the electrical grid, because will assist the power network operator in the tasks of planning the dispatch of electricity, hiring auxiliary services and reserves, management of maintenance actions and network congestion and to the promoter in the general maintenance of the photovoltaic power station.

The model proposed in this dissertation uses neural networks to simulate the evolution of electrical production. Initially, some developed forecasting models perform predictions based on historical production data and weather forecasts. Then, another neural network uses the forecasts made by the previous models, assimilating their results, therefore making more accurate predictions.

Finally, the performance of the proposed model is evaluated through error analysis. The forecasting results obtained with the model proposed here revealed a highly significant improvement, with respect to the considered reference model.

Keywords: *Solar power forecasting, neural networks for forecasting, photovoltaic power forecasting, forecasting models based on time series.*

Agradecimentos

Serve o presente momento para agradecer a todas as pessoas e instituições que contribuíram, direta e indiretamente, para a elaboração desta dissertação.

Em primeiro lugar, ao meu orientador, Professor Álvaro Henrique Rodrigues, por toda a sua ajuda prestada ao longo desta dissertação, não só pela sua disponibilidade, mas também a sua presença nos momentos mais difíceis.

Pela oportunidade de realização desta dissertação, quero deixar uma nota de agradecimento ao INEGI (Instituto de Engenharia Mecânica e Gestão Industrial) e à Prewind pela disponibilidade dos meios concedidos durante a realização deste trabalho.

Aos Engenheiros João Sousa e Ricardo Bessa, uma palavra de amizade e profundo agradecimento pelo seu apoio contínuo e incansável, os seus conhecimentos, orientação e conselhos prestados que se revelaram fulcrais para o desenvolvimento deste trabalho.

Ao grupo de investigação da Faculdade de Ciências da Universidade de Lisboa pela disponibilização das previsões meteorológicas para o parque fotovoltaico em estudo.

À empresa Novenergia II e seus colaboradores pela disponibilidade dos dados relativos ao parque fotovoltaico.

A todos os colegas e amigos, pelo apoio e por todas as horas que passamos a trabalhar ao longo destes anos na Faculdade.

Por último lugar, mas não menos importante, agradeço à minha família pelo inestimável apoio familiar, nos piores e nos melhores momentos, ao longo da realização deste trabalho e ao longo destes anos de vida académica. Sem vocês nada disto seria possível.

Índice

Resumo	I
Agradecimentos	V
Índice.....	VII
Lista de figuras	X
Lista de tabelas	XIII
Abreviaturas e Símbolos	XIV
Capítulo 1	1
Introdução.....	1
1.1 - Enquadramento geral	1
1.1.1 - Diagrama de carga diária da rede nacional	5
1.2 - Motivação e objetivos da dissertação	7
1.3 - Estrutura da dissertação.....	8
Capítulo 2	9
O fotovoltaico	9
2.1 - Introdução.....	9
2.2 - Tecnologias de conversão da energia solar	9
2.3 - A tecnologia fotovoltaica.....	10
2.3.1 - Tipos e características das células.....	11
2.3.2 - Curva I-V	12
2.3.3 - Efeito da radiação e da temperatura.....	13
2.3.4 - Associação de células	14
2.3.5 - Efeito da inclinação, orientação dos módulos e uso de sistemas de seguimento	14
2.3.6 - Efeito de sombreamento na produção do módulo	15
2.3.7 - Tipos de sistemas fotovoltaicos	15
2.3.8 - Inversores	16
2.3.9 - Tecnologia solar de concentração fotovoltaica	16
2.4 - Panorama nacional	18
Capítulo 3	21
Estado da arte	21
3.1 - Introdução	21
3.2 - Modelos de previsão solar.....	21
3.2.1 - Previsão da radiação solar utilizando imagens obtidas por satélite	22

3.2.2 - Modelos de previsão numérica do tempo (NWP)	23
3.2.2.a - Modelos globais	24
3.2.2.b - Modelos regionais/locais	24
3.2.3 - Redes neurais artificiais (RNA)	25
3.2.3.a - Neurônios	26
3.2.3.b - Arquitetura das Redes Neurais	26
3.2.3.c - Processos de aprendizagem	27
3.2.3.d - Aplicação de redes neurais para previsão da radiação solar	27
3.2.4 - Support Vector Machines	28
3.2.5 - Modelos regressivos e auto-regressivos	30
3.2.5.a - Modelo auto-regressivo (AR)	30
3.2.5.b - Modelo de média móvel (MA)	31
3.2.5.c - Modelos auto-regressivo de média móvel (ARMA)	31
3.2.5.d - Modelo auto-regressivo integrado de média móvel (ARIMA)	32
3.2.6 - Metodologia para simulação da irradiância solar em dias de céu limpo	32
3.2.6.a - Distância entre o Sol e a Terra	33
3.2.6.b - Posição relativa Sol/Terra	33
3.2.6.c - Equação do tempo	34
3.2.6.d - Ângulo horário	35
3.2.6.e - Posição solar sobre uma superfície horizontal	36
3.2.6.f - Posição solar relativamente a um plano inclinado	37
3.2.6.g - Radiação solar terrestre	38
3.3 - Avaliação do desempenho dos modelos de previsão	39
3.3.1 - Modelos de referência	40
3.3.2 - Definição dos erros de previsão	40
3.3.2.a - Erro de previsão	40
3.3.2.b - Comparação de modelos	42
3.4 - Modelos de cálculo da produção de um sistema fotovoltaico a partir da radiação solar	42
Capítulo 4	47
Construção do modelo de previsão	47
4.1 - Introdução	47
4.2 - Caso de estudo	47
4.3 - Tipos de dados utilizados nos modelos de previsão	48
4.3.1 - Sincronização dos dados	49
4.3.2 - Estandarização	49
4.4 - Estrutura dos modelos de previsão da produção da central FV	50
4.5 - Modelo de referência	51
4.6 - Modelos estatísticos	54
4.6.1 - ARMA	56
4.6.2 - AR	56
4.7 - Modelos de aprendizagem automática	56
4.7.1 - Rede neuronal	57
4.7.1.a - Arquitetura do modelo RN	57
4.7.1.b - 1ª Fase	58
4.7.1.c - 2ª Fase	61
4.7.2 - Support Vector Machines	64

Capítulo 5	65
Resultados.....	65
5.1 - Introdução.....	65
5.2 - Métodos para a avaliação do desempenho dos modelos	65
5.3 - Desempenho dos modelos	66
5.3.1 - Modelos de assimilação	70
Capítulo 6	75
Conclusões e trabalhos futuros	75
6.1 - Conclusões	75
6.2 - Trabalhos futuros	76
Referências	77
Anexos	81
Anexo A	81
A.1 - Equação $ARMA_{(29,28)}$	81
A.2 - Equação $AR_{(29)}$	81
A.3 - Equação $AR_{(173)}$	82
Anexo B	83
B.1 - Previsões efetuadas pela RN1, para o mês de Agosto	84
B.2 - Previsões efetuadas pela RN2, mês de Dezembro	86
Anexo C	89
C.1 - Resultados do processo de seleção de variáveis	89

Lista de figuras

Figura 1.1 - Distribuição da irradiação solar anual para o plano inclinado ótimo orientado a Sul e produção da energia elétrica FV na Europa, estimada por cada kW de potência pico instalada [6].	3
Figura 1.2 - Evolução anual da potência FV acumulada instalada desde 2000 até 2010 [7].	3
Figura 1.3 - Potência FV acumulada instalada na Europa, e países de destaque em 2010 [7].	4
Figura 1.4 - Diagrama de cargas da rede elétrica portuguesa no dia 21 de Junho de 2011, adaptado de [8].	5
Figura 1.5 - Potência entregue à rede elétrica portuguesa pelas centrais integradas na PRE, no dia 21 de Junho de 2011 [8].	6
Figura 2.1 - Constituição de uma célula fotovoltaica típica.	10
Figura 2.2 - Célula, módulo fotovoltaico e array [13].	12
Figura 2.3 - Curva I-V e P-V para uma célula típica de silício monocristalino.	12
Figura 2.4 - Efeito da radiação e da temperatura num módulo fotovoltaico [13].	13
Figura 2.5 - Inclinação ótima para diferentes épocas do ano [13, 14].	14
Figura 2.6 - Radiação solar incidente nos diferentes sistemas analisados [12].	17
Figura 2.7 - Produção diária dos diferentes sistemas analisados [12].	17
Figura 2.8 - Evolução da potência FV instalada, a partir do ano 2003.	18
Figura 2.9 - Comparação da potência instalada proveniente das centrais FV e microprodução em 2011. Dados retirados do site renováveis na hora.	19
Figura 2.10 - Potência instalada na microprodução, por distrito em 2011. Baseado nos dados retirados do site renováveis na hora.	19
Figura 3.1 - Metodologia utilizada para a previsão do movimento das núvens [17].	23
Figura 3.2 - Ilustração de uma rede neuronal do tipo <i>feedforward</i> [24].	25
Figura 3.3 - Processamento de um neurónio de uma rede neuronal [27].	26

Figura 3.4 - Dados da radiação global utilizados em [28]. O conjunto de treino engloba 41 dias, o conjunto de validação 13 dias e o conjunto de previsão 9 dias, perfazendo um conjunto de 63 dias.	27
Figura 3.5 - Fronteira da região que contribui para a função de custo [48].	29
Figura 3.6 - Órbita em torno do Sol, adaptado [33].	33
Figura 3.7 - Posição relativa da Terra em relação ao Sol ao meio dia, num dia de declinação negativa (Inverno no Hemisfério Norte, Verão no Hemisfério Sul), adaptado de [32].	34
Figura 3.8 - Diferença entre o tempo solar médio e o tempo solar verdadeiro ao longo um ano.....	35
Figura 3.9 - Ângulos que definem a posição solar, adaptado de [33].	36
Figura 3.10 - Ângulo de incidência dos raios solares no plano inclinado, adaptado de [32]. ..	37
Figura 3.11 - Efeitos provocados pela atmosfera sobre a radiação solar.	38
Figura 3.12 - Trajetória dos raios solares ao passar pela atmosfera [35].	39
Figura 3.13 - Modelo de previsão local de um sistema fotovoltaico, adaptado de [41].	45
Figura 3.14 - Desempenho do modelo de previsão para um local específico, para 6 dias de Maio de 2007 [41].	46
Figura 4.1 - Parque FV em estudo, Villares de Saz.	48
Figura 4.2 - Estrutura dos modelos desenvolvidos.	50
Figura 4.3 - Irradiância no plano inclinado, durante o ano de 2011.	52
Figura 4.4 - Produção prevista através do modelo da persistência pura e persistência geométrica, no instante $t=12$	52
Figura 4.5 - Comparação da produção prevista e da produção medida para o dia 21 de Julho de 2010.	53
Figura 4.6 - Comparação da produção prevista e da produção medida para o dia 21 de Dezembro de 2010.	53
Figura 4.7 - Gráfico de Autocorrelação (ACF) da série da produção elétrica medida.	54
Figura 4.8 - Gráfico de Autocorrelação Parcial (PACF) da série da produção elétrica medida.	55
Figura 4.9 - Arquitetura do modelo de previsão a partir das RN.	57
Figura 4.10 - Estrutura das redes neuronais desenvolvidas.	63
Figura 5.1 - Comparação entre a potência medida e a potência prevista para todos os modelos desenvolvidos, para o caso de estudo do dia 21 de Dezembro de 2010.....	68
Figura 5.2 - Comparação entre a potência medida e a potência prevista para todos os modelos desenvolvidos, para o caso de estudo do dia 7 de Agosto de 2011.....	69

Figura 5.3 - Desempenho de RN1, para as diferentes configurações de modelos, para um horizonte de previsão de 72 horas. A previsão foi realizada dia 7 de Agosto de 2011 às 12:00h.	72
Figura 5.4 - Desempenho de RN2, para as diferentes configurações de modelos, para um horizonte de previsão de 72 horas. A previsão foi realizada dia 4 de Fevereiro de 2011 às 12:00h.	73
Figura 5.5 - Desempenho de RN1 com a configuração 2 e dos diferentes modelos que lhe deram origem, para um horizonte de previsão de 72 horas. Previsão efetuada dia 7 de Agosto de 2011 às 12:00h.	73
Figura 5.6 - Desempenho de RN2 com a configuração 2 e dos diferentes modelos que lhe deram origem, para um horizonte de previsão de 72 horas. Previsão efetuada dia 4 de Fevereiro de 2011 às 12:00h.	74
Figura C.1 - Desempenho da configuração (<i>SW</i> , <i>T2</i> , <i>U10</i> e <i>WDIR</i>) dos dados NWP 00:00 UTC.	89
Figura C.2 - Desempenho da configuração (<i>SW</i> , <i>U10</i> , <i>V10</i> e <i>WDIR</i>) dos dados NWP 00:00 UTC.	89
Figura C.3 - Desempenho da configuração (<i>SW</i> , <i>T2</i> , <i>U10</i> , <i>V10</i> e <i>WDIR</i>) dos dados NWP 00:00 UTC.	90
Figura C.4 - Desempenho da configuração (<i>SW</i> , <i>T2</i> , <i>U10</i> , <i>V10</i> e <i>WDIR</i>) dos dados NWP 00:00 UTC, dados standardizados.	90
Figura C.5 - Desempenho da configuração (<i>SW</i> , <i>T2</i> , <i>U10</i> , <i>V10</i> , <i>WDIR</i> e <i>H₇₂</i>) dos dados NWP 00:00 UTC.....	91
Figura C.6 - Desempenho da configuração (<i>SW</i> , <i>T2</i> , <i>U10</i> , <i>V10</i> e <i>WDIR</i>) dos dados NWP 12:00 UTC.	91
Figura C.7 - Desempenho da configuração (<i>SW</i> , <i>T2</i> , <i>U10</i> , <i>V10</i> , <i>WDIR</i> e <i>H₇₂</i>) dos dados NWP 12:00 UTC.....	92
Figura C.8 - Desempenho do modelo com a adição das componentes do ciclo diário, para $k=1$	92
Figura C.9 - Desempenho do modelo com a adição das componentes do ciclo diário, para $k=2$	93
Figura C.10 - Desempenho do modelo com a adição das componentes do ciclo diário, para $k=3$	93
Figura C.11 - Desempenho do modelo com a adição das componentes do ciclo diário, para $k=4$	94
Figura C.12 - Desempenho do modelo com a adição das componentes do ciclo diário, para $k=1 + k=2$	94
Figura C.13 - Desempenho do modelo após a decomposição da direção do vento.....	95

Lista de tabelas

Tabela 2.1 - Rendimento dos vários tipos de células [12].	11
Tabela 2.2 - Descrição das centrais FV analisadas.	20
Tabela 3.1 - Exemplos de modelos <i>numéricos</i> de <i>previsão</i> globais.	24
Tabela 3.2 - Exemplos de modelos numéricos de previsão locais.	24
Tabela 3.3 - Rácio (η) para diferentes condições climáticas.	43
Tabela 4.1 - Correlação das variáveis NWP.	58
Tabela 4.2 - Seleção das variáveis relacionadas com o vento.	59
Tabela 4.3 - Tabela de verdade das variáveis relevantes.	60
Tabela 4.4 - Análise da adição do horizonte temporal.	61
Tabela 4.5 - Desempenho dos diferentes índices do harmónico.	62
Tabela 4.6 - Desempenho das componentes do ciclo diário para $k=1$ vs $k=1 + k=2$	62
Tabela 4.7 - Desempenho do modelo, antes e depois da decomposição da direção do vento.	63
Tabela 4.8 - Desempenho do modelo SVR.	64
Tabela 5.1 - Comparação e análise do erro de previsão para os diversos modelos desenvolvidos.	67
Tabela 5.2 - Desempenho de RN_AR.	70
Tabela 5.3 - Desempenho de RN1 e RN2.	71

Abreviaturas e Símbolos

Lista de abreviaturas (ordenadas por ordem alfabética)

ACF	<i>Autocorrelation Function</i>
AR	<i>Autoregressive</i>
AM	<i>Air Mass</i>
ARMA	<i>Auto Regressive Moving Average</i>
ARIMA	<i>Auto Regressive Integrated Moving Average</i>
ARPS	<i>Advanced Regional and Forecasting Model</i>
CEST	<i>Central European Summer Time</i>
CET	<i>Central European Time</i>
CPV	<i>Concentrated Photovoltaic</i>
EPIA	<i>European Photovoltaic Industry Association</i>
ECMWF	<i>European Centre for Medium-Range Weather Forecasts</i>
FV	<i>Fotovoltaica</i>
GEM	<i>Global Environment Multiscale Model</i>
GFS	<i>Global Forecast System</i>
IMP	<i>Improvement</i>
LW	<i>Longwave à superfície</i>
MA	<i>Moving Average</i>
MAE	<i>Mean Absolute Error</i>
MAPE	<i>Mean Absolute Percentage Error</i>
MLP	<i>Multi-Layer Perceptron</i>
MM5	<i>Fifth Generation Penn State / NCAR Mesoscale Model MM5</i>
MOS	<i>Model Output Statistics</i>
MSC	<i>Meteorological Service of Canada</i>
MSE	<i>Mean Square Error</i>
NCAR	<i>National Center for Atmospheric Research</i>
NCEP	<i>National Centers of Environmental Prediction</i>
NMAPE	<i>Normalized Mean Absolute Percentage Error</i>
NOCT	<i>Nominal Operating Cell Temperature</i>

NRMSPÉ	<i>Normalized Root Mean Square Percentage Error</i>
NWP	<i>Numerical Weather Prediction</i>
PACF	<i>Partial Autocorrelation Function</i>
PRE	Produção em Regime Especial
PSU	<i>Penn State University</i>
RMSE	<i>Root Mean Square Error</i>
RMSPE	<i>Root Mean Square Percentage Error</i>
RN	Rede Neuronal
RNA	Rede Neuronal Artificial
SARIMA	<i>Seasonal Auto Regressive Integrated Moving Average</i>
STC	<i>Standard Test Conditions</i>
SVM	<i>Support Vector Machines</i>
SVR	<i>Support Vector Regression</i>
SW	<i>Shortwave à superfície</i>
T2	Temperatura aos 2 metros
U10	Componente U do vento aos 10 metros
UE	União Europeia
UM	<i>Unified Model</i>
UTC	<i>Coordinated Universal Time</i>
V10	Componente V do vento aos 10 metros
WDIR	Direcção do vento
WRF	<i>Weather Research and Forecasting Model</i>
WSPD	Intensidade do vento

Lista de símbolos

$\hat{P}_{(t+k)}$	Valor previsto para o instante $t+k$
$\hat{P}_{(t+k t)}$	Previsão de Potência para o instante $t+k$, efetuada no instante t
$P_{(t+k)}$	Valor real para o instante $t+k$
P_t	Potência produzida no instante t
$e_{(t+k)}$	Erro de previsão no instante $t+k$
$\epsilon_{(t+k)}$	Erro de previsão normalizado para o instante $t+k$
A	Área
AO	Ajuste horário
ET	Equação do tempo
$G_{(t t-1)}$	Irradiância solar global no instante $t-1$, sendo t o instante de previsão
G^*	Irradiância solar global nas condições STC
G_i	Irradiância solar global

$H_{cos,k}$	Componente em co-seno do horizonte, para o harmônio k
$H_{sen,k}$	Componente em seno do horizonte, para o harmônio k
I_{on}	Irradiância extraterrestre
I_{sc}	Constante solar
P	Pressão
P_{inst}	Potência instalada
P_{max}	Potência máxima
P_{trans}	Potência transformada
R^2	Coeficiente de determinação
T	Temperatura
$T_{(t-1)}$	Temperatura ambiente no instante t-1
TL	Tempo legal
TSV	Tempo solar verdadeiro
T_{amb}	Temperatura ambiente
T_c	Temperatura da célula
WD	Direção do Vento
$WD_{(t-1)}$	Direção do vento no instante t-1
WS	Velocidade do Vento
d_n	Dia do ano
f	Fração em funcionamento da central FV
r	Distância entre o Sol e a Terra
r_0	Distância média entre o Sol e a Terra
α	Elevação Solar
β	Inclinação do plano
δ	Declinação solar
ε_t	Erro aleatório
ε_0	Fator de correção de excentricidade
η	Rendimento
θ	Distância zenital
θ_s	Ângulo de incidência solar sobre o plano inclinado
λ	Fator que relaciona a longitude local e a longitude do meridiano de Greenwich
φ	Azimute da superfície inclinada
ψ	Azimute Solar
ω	Ângulo horário
ϕ	Latitude geográfica

Capítulo 1

Introdução

Face aos problemas ambientais que enfrentamos, causados em grande parte pelo consumo excessivo de combustíveis fósseis, o recurso às energias de fonte renovável é cada vez mais uma aposta global. Estas têm demonstrado possuir benefícios inegáveis e podem ser consideradas como o futuro no panorama da energia. Com o objetivo primordial de estabelecer um equilíbrio ambiental, juntamente com a necessidade de assegurar uma política de energia eficiente e sustentável, é inevitável o desenvolvimento e consequente integração das energias renováveis no sector elétrico. É esperado que a energia solar, juntamente com a energia eólica, desempenhem um papel muito importante no fornecimento de energia. A energia solar é a fonte energética primária, e é a base para quase todos os tipos de energia fóssil e renovável. Esta fonte energética está disponível gratuitamente, e pode ser facilmente aproveitada de modo a reduzir a dependência da energia produzida a partir dos hidrocarbonetos [1].

No entanto, o carácter intermitente da energia elétrica produzida a partir destes recursos motiva o desenvolvimento de ferramentas de previsão deste mesmo recurso, de modo a obtermos uma integração bem sucedida destas centrais na rede elétrica.

Neste capítulo, para além da exposição do problema abordado e o contexto em que se insere, são apresentados os principais objetivos e a estrutura desta dissertação.

1.1 - Enquadramento geral

A história da eletricidade foi marcada pela rápida evolução técnica e pelos muitos desenvolvimentos científicos a ela ligados, estendendo-se a variados campos da ciência e a inúmeras aplicações de ordem prática. Foi a partir do século XIX que a energia elétrica ganhou maior dimensão, vários desenvolvimentos científicos foram feitos nesse século, e a evolução tecnológica, económica e social a que o Mundo assistiu desde então não teria sido possível sem o domínio da eletricidade.

É precisamente a mesma eletricidade que está hoje no centro de uma nova revolução. Apesar da enorme evolução verificada no último século, atualmente temos que lidar com os efeitos nefastos dessa evolução, e por isso é essencial a criação de um modelo mais

sustentável e menos poluente. O efeito indesejável de maior relevo a nível ambiental é o da emissão de gases poluentes para a atmosfera, que provocou o aquecimento do planeta, levando ao aparecimento de diversos efeitos prejudiciais. Como a produção de eletricidade é uma das atividades que mais contribui para a emissão de gases poluentes, é imperativo que esta tenha de ser reconsiderada.

O impacto dos problemas ambientais causados pelo consumo excessivo de combustíveis fósseis é cada vez mais discutido. O recurso a estes combustíveis é insustentável a médio prazo, e o recurso às chamadas energias renováveis é cada vez mais uma aposta global. Ao cumprimento das metas negociadas no âmbito do protocolo de Quioto e face aos objetivos do plano 20-20-20 da União Europeia (UE), torna-se evidente que as energias renováveis assumem um papel cada vez mais preponderante na produção elétrica [2, 3].

Portugal assumiu para 2020, no quadro dos seus compromissos europeus, a meta de satisfazer 31% do seu consumo final de energia com recurso a fontes renováveis. Atualmente, a base da produção energética de origem renovável nacional está principalmente assente na combinação da energia hídrica e da energia eólica [3].

A energia hídrica é uma aposta que tem vindo a ser feita desde os anos 40, sendo que a capacidade instalada ronda atualmente os 5200 MW. Apesar de ainda existir potencial a explorar, a energia hídrica está dependente da grande variabilidade pluviométrica interanual, levando a oscilações na sua produção de ano para ano. A energia eólica tem sido a grande aposta da última década por parte de vários países para geração de eletricidade sem emissões poluentes, e seguramente continuará a sua evolução. Em Portugal, a energia eólica tem tido uma forte progressão nos últimos anos, tendo a potência instalada passado de 537 MW em 2004 para mais de 4200 MW em Outubro de 2011 [3, 4].

Após o forte investimento na energia eólica, nos últimos anos tem-se verificado um crescente interesse na energia solar fotovoltaica (FV), posicionando-se como a tecnologia com maior potencial de desenvolvimento em Portugal na próxima década. A sua complementaridade com as restantes tecnologias renováveis, pelo facto de ser gerada nas horas de maior consumo, leva à fixação de um objetivo de 1500 MW de potência instalada em 2020, através da concretização de diversos programas e concurso, sendo que o desenvolvimento desta capacidade deverá acompanhar os avanços tecnológicos, os ganhos de eficiência e a redução dos custos associados a estas tecnologias [3].

Analisando a Figura 1.1, pode-se verificar, que o recurso solar disponível na Europa varia significativamente com a latitude, de tal forma que, nos países do Sul (Portugal, Espanha e Itália), a irradiação solar anual chega a atingir em algumas ocasiões quase o dobro da média disponível nos países do Norte da Europa (Noruega, Suécia e Dinamarca). A irradiação solar em Portugal Continental varia entre 1300-1800 kWh/m². Portanto, Portugal apresenta das melhores condições a nível europeu para o aproveitamento do recurso solar e, designadamente, para a produção elétrica por via fotovoltaica [5].




Figura 1.1 - Distribuição da irradiação solar anual para o plano inclinado ótimo orientado a Sul e produção da energia elétrica FV na Europa, estimada por cada kW de potência pico instalada [6].

Na Figura 1.2, é apresentada a evolução anual da potência FV instalada nas regiões geográficas de maior destaque desde 2000 até 2010. Como se pode constatar, na última década o crescimento da potência FV instalada é praticamente exponencial. Em 2010 o seu valor era aproximadamente 40 GW, sendo que a UE contabilizava com um pouco mais de 29 GW, revelando um aumento de cerca de 13 GW face ao ano anterior.





Figura 1.2 - Evolução anual da potência FV acumulada instalada desde 2000 até 2010 [7].

Analisando a Figura 1.2 e Figura 1.3 verifica-se que de todos os países Europeus, a Alemanha com 17 GW é claramente o que possui uma maior potência instalada. Já fora da Europa, o Japão apresenta-se como o maior mercado (3,6 GW), no entanto segundo [7] é esperado que a China se torne uma grande potência nos próximos anos. Apesar de apresentar uma excelente localização para o aproveitamento do recurso solar para a produção de energia fotovoltaica, a potência instalada em Portugal é baixa e tem crescido timidamente quando comparada com a de outros países, apresentando apenas um aumento de 16 MW comparativamente a 2009.




	Market 2009 (MW)	Cumulative 2009 (MW)	Market 2010 (MW)	Cumulative 2010 (MW)	W/habitant
EU					
Austria	20	53	50	103	12.6
Belgium	285	379	424	803	73
Bulgaria	6	7	11	18	2.4
Czech Republic	398	463	1,490	1,953	191.5
France	219	306	719	1,025	15.5
Germany	3,806	9,785	7,408	17,193	211
Greece	36	56	150	206	19.3
Italy	717	1,173	2,321	3,494	60.2
Portugal	65	114	16	130	11.5
Slovakia	0	0	145	145	26.4
Spain	17	3,415	369	3,784	80.5
United Kingdom	10	21	45	66	1.1
Rest of the EU	50	235	98	333	
Japan	483	2,632	990	3,622	28.8
North America					
Canada	62	95	106	200	5.9
USA	477	1,650	878	2,528	8
APEC					
Australia	79	184	320	504	1.6
South Korea	167	524	131	655	13.4
Taiwan	12	10	12	22	1
Thailand	0	0	10	10	0.2
China	228	373	520	893	0.7
Rest of the world					
Brazil	0	0	0	0	0
India	30	102	0	102	0.1
Mexico	0	0	0	0	0
Rest of the world	100	1,325	417	1,742	

Figura 1.3 - Potência FV acumulada instalada na Europa, e países de destaque em 2010 [7].

1.1.1 - Diagrama de carga diária da rede nacional

A potência solicitada à rede elétrica nacional pelos equipamentos utilizados pelos diversos tipos de consumidores varia ao longo do dia e em função das atividades desenvolvidas, designando-se por diagrama de carga. Apresenta-se na Figura 1.4 o diagrama de carga da rede elétrica nacional no dia 21/06/2011.



Analisando o diagrama de carga verifica-se que a base da carga (correspondente às horas de vazio), com uma potência solicitada à rede de aproximadamente 5000 MW, é em geral assegurada pelas centrais térmicas, pelas centrais hidroelétricas de albufeira e por último pelas centrais integradas na PRE (Produção em Regime Especial), onde se incluem as centrais fotovoltaicas, uma vez que estas centrais não são despacháveis sendo dependentes da disponibilidade do recurso renovável utilizado [9].

Nos períodos de ponta e cheia do diagrama de carga, o excesso de potência requerido à rede, cerca de 2000 MW, é assegurado maioritariamente pela importação, pelas centrais hidroelétricas de fio de água e também pelas centrais termoeletricas.

Como se pode constatar, as fontes de energia integradas na PRE têm uma percentagem significativa no fornecimento de energia elétrica para satisfazer o consumo. É de salientar que para um dia de funcionamento normal, os períodos das centrais hidroelétricas de albufeira e de fio de água estão invertidos, ou seja, tipicamente são as centrais de fio de água que funcionam nas horas de vazio e as centrais de albufeira em períodos de ponta. Na Figura 1.5 é representada a potência produzida pelas centrais integradas na PRE, no dia 21 de Junho de 2011.




Figura 1.5 - Potência entregue à rede elétrica portuguesa pelas centrais integradas na PRE, no dia 21 de Junho de 2011 [8].

Como se pode verificar, mesmo tratando-se de um dia de Verão, a potência fornecida atualmente pelas centrais fotovoltaicas é ainda muito baixa quando comparada por exemplo, com a energia eólica; no entanto, graças à complementaridade existente entre a energia solar e eólica, é de esperar que esta potência aumente consideravelmente com o decorrer dos anos. É importante salientar que, para o período de Inverno, a produção PRE hídrica e eólica é bastante superior à verificada na Figura 1.5, sendo que a produção FV será inferior. Relativamente à figura anterior, pode-se verificar também que devido ao carácter aleatório do vento, as centrais eólicas não se adaptam, em geral, para satisfazer o pico do consumo nas horas de cheia e ponta do diagrama, apresentando no dia em análise um mínimo próximo das 12h. Pelo contrário, a produção elétrica por via FV é quase na sua totalidade entregue à rede nas horas de ponta e cheia do diagrama de carga, complementando desta forma a produção eólica.

Segundo as previsões da EPIA (*European Photovoltaic Industry Association*), num cenário favorável, a potência FV instalada em Portugal poderá chegar a 1,18 GW em 2015 [7], o que corresponderia a um valor dez vezes superior à potência instalada em 2009. No entanto, pela análise dos relatórios referentes a 2011 [4], a menos que nos próximos 3 anos a potência FV instalada cresça consideravelmente, dificilmente Portugal atingirá esse valor.

Apesar de tudo, a exploração destas fontes de energia renovável e a sua integração na rede elétrica pode ser problemática, mesmo quando o potencial para o aproveitamento do recurso solar em determinado país é bom, como é o caso de Portugal. A energia elétrica produzida por algumas tecnologias de energia renovável, como por exemplo as centrais

solares, é conhecida por ser intermitente e é fortemente afetada pela presença de nebulosidade, pelo que são necessários esforços substanciais, não só ao nível do desenvolvimento e evolução das tecnologias, mas também ao nível da disponibilidade de informações precisas relativamente a estas formas de energia. Ainda que, atualmente, a intermitência não seja um problema grave, pois as fontes de energia solar representam uma pequena parcela da produção de energia elétrica total, no futuro, o aumento da penetração de grandes centrais solares numa rede elétrica local é susceptível de introduzir novos problemas técnicos na rede, tais como flutuações de tensão, degradação da qualidade da energia elétrica e até mesmo problemas de estabilidade [10].

Portanto, para termos uma correta integração da energia de origem solar na rede elétrica, é necessário o desenvolvimento de ferramentas fiáveis e capazes de superar estes problemas, pois só assim se podem minimizar os problemas de injeção de potência FV na rede.

1.2 - Motivação e objetivos da dissertação

Normalmente, quando se fala em fontes de energias renováveis, associa-se imediatamente a fluxos de energia altamente intermitentes e variáveis, cuja produção não se consegue armazenar.

Em Portugal a utilização da energia eólica foi claramente uma aposta ganha e representa atualmente uma boa percentagem da energia elétrica fornecida à Rede. A previsão eficaz deste recurso será uma ferramenta indispensável de forma a balancear a energia fornecida à rede elétrica.

Devido ao crescimento verificado nos últimos anos, e sabendo que produção FV é considerada por muitos países como o futuro das energias renováveis, é esperado que com o desenvolvimento de ferramentas eficazes para a previsão da produção elétrica proveniente dos sistemas solares FV seja possível suplantar as barreiras técnicas que impedem a alta penetração deste tipo de energia na rede elétrica. Desta forma será possível apostar mais em fontes de energia alternativas, reduzindo assim a energia produzida a partir de combustíveis fósseis, e consequentemente a emissão de gases poluentes para a atmosfera.

A razão que despertou o interesse pela realização desta dissertação, reside exatamente na necessidade de desenvolver ferramentas de previsão da produção solar FV a curto prazo, ou seja, para horizontes temporais até 72 horas. Um dos principais objetivos é investigar se os modelos de previsão que utilizam os *Numerical Weather Prediction* (NWP) como variáveis de entrada conseguirão um desempenho superior aos modelos estatísticos de previsão que se baseiam unicamente em dados históricos da potência FV. Para além disso, são ainda apresentados estudos e modelos desenvolvidos nos últimos anos, com o objetivo de prever tanto a radiação solar como a produção de uma central solar, que permitiram obter informações importantes para a construção do modelo de previsão aqui proposto.

1.3 - Estrutura da dissertação

A presente dissertação é constituída por seis capítulos, sendo este o capítulo introdutório ao problema que se pretender resolver.

No capítulo 2 é feita a caracterização dos sistemas fotovoltaicos atuais. O objetivo é apresentar, de forma sucinta, como funciona esta tecnologia de conversão da energia solar em energia elétrica e mostrar de que forma depende da radiação solar.

O capítulo 3 é inteiramente dedicado ao estado da arte dos modelos de previsão associados ao recurso solar e às centrais solares. Este capítulo tem como objetivo dar ao leitor uma visão geral de como os problemas de previsão podem ser resolvidos.

No capítulo 4 são expostas as etapas realizadas para a construção dos modelos e efetuados estudos das variáveis de maior relevo para a realização da previsão. Além disso, serão ainda justificadas todas as decisões tomadas durante a construção da metodologia desenvolvida.

No capítulo 5 são apresentados os valores do teste e avaliação do desempenho da metodologia desenvolvida na resolução de problemas reais, através da análise do erro de previsão. Aqui serão apresentados os resultados obtidos durante o desenvolvimento deste trabalho.

No capítulo 6 são exibidas as principais conclusões obtidas. Neste capítulo são ainda discutidas as dificuldades encontradas durante a realização desta dissertação e apresentadas ideias para trabalhos futuros.

Capítulo 2

O fotovoltaico

2.1 - Introdução

O Sol pode ser considerado como a única fonte de energia na Terra, porque praticamente toda a energia disponível está direta ou indiretamente relacionada com ele; em outras palavras, as fontes de energia são, em última instância, derivadas do Sol.

Mesmo o petróleo, a fonte de energia que tanta discussão tem gerado devido à elevada poluição que produz, vem indiretamente do sol. O petróleo que é extraído do subsolo não é nada mais do que matéria orgânica que se encontra sepultada sob camadas da crosta terrestre a elevadas pressões. Esta matéria orgânica viveu e multiplicou-se devido ao processo de fotossíntese que está diretamente ligado ao Sol.

O Sol fornece energia na forma de radiação, no seu núcleo são geradas reações nucleares e durante este processo parte da massa é transformada em energia. O Sol é assim um enorme reator de fusão [5].

Este capítulo tem como principal objetivo apresentar as tecnologias atuais de conversão de energia solar em energia elétrica. Inicialmente, é feita uma descrição sumária dos sistemas fotovoltaicos, no qual o maior relevo é dado aos fatores que condicionam a produção FV. Por último é realizada uma análise da situação FV em Portugal Continental.

2.2 - Tecnologias de conversão da energia solar

A energia proveniente do sol pode ser utilizada indireta ou diretamente. No caso da utilização indireta da energia solar, consideramos a utilização das energias renováveis que têm origem nos efeitos secundários provocados pelo sol. Para a utilização da energia solar na forma direta, existe uma variedade de tecnologias que se dividem em duas categorias principais, térmica e fotovoltaica.

As tecnologias solares térmicas convertem a energia solar em calor, que pode ser diretamente utilizado para aquecimento de águas, ou convertido em energia mecânica e posteriormente em energia elétrica, através do uso de turbinas a vapor. As tecnologias

fotovoltaicas convertem a radiação solar diretamente em eletricidade, através do efeito fotovoltaico.

A tecnologia fotovoltaica é particularmente fascinante, não só para quem desenvolve as tecnologias, mas também para o público em geral [11]. Os seus pontos fortes são:

- a fonte de energia, o sol, onipresente e inesgotável;
- conversão direta da radiação solar em eletricidade;
- inexistência de partes móveis (excetuando os sistemas dotados de mecanismos de orientação), e portanto ausência de ruídos;
- não funcionam a altas temperaturas;
- não poluem (excepto na fase de fabrico);
- os módulos fotovoltaicos têm uma vida útil bastante longa;
- o fotovoltaico é uma fonte de energia bastante flexível, a sua potência varia desde microwatt até megawatt.

2.3 - A tecnologia fotovoltaica

O efeito fotovoltaico presente nas células fotovoltaicas é a forma mais direta de converter a radiação solar em eletricidade. As células são constituídas por elementos semicondutores como o silício, telúrio de cádmio ou disseleniuto de cobre e índio, sendo a célula de silício cristalina a mais comum. O silício não existe como um elemento químico, no entanto é o segundo elemento mais abundante na terra, sendo que este apenas existe associado à areia de sílica [5].

O material utilizado nas células solares deve possuir a maior pureza possível; no entanto, como o cristal de silício puro não possui eletrões livres, este tem de ser dopado com outros elementos. O processo conhecido como dopagem do silício consiste na introdução de elementos estranhos com o objetivo de alterar as suas propriedades elétricas. Da dopagem do silício com o fósforo, que possui um eletrão a mais, obtém-se um material com eletrões livres (camada tipo *n*), este eletrão pode mover-se livremente dentro do cristal transportando com ele a carga elétrica. Dopando o silício com boro obtém-se um material com falta de eletrões (camada tipo *p*), devido à ausência do eletrão temos assim uma lacuna no cristal por cada átomo de boro introduzido. Cada célula fotovoltaica é constituída por uma camada fina de material do tipo *n* que está orientada para o Sol, e uma outra de maior espessura de material do tipo *p*. Da junção das duas camadas os eletrões livres existentes na camada do tipo *n* ocupam os espaços vazios (lacunas) na camada do tipo *p* [5].




Figura 2.1 - Constituição de uma célula fotovoltaica típica.

Quando a luz solar incide na célula fotovoltaica, os fótons são absorvidos pelos elétrons, fornecendo energia suficiente para quebrar as ligações dos elétrons. Os elétrons libertados são conduzidos através do campo elétrico para a camada n . As lacunas assim criadas seguem na direção contrária, ou seja, para a camada do tipo p . Da junção da camada n à camada do tipo p com um condutor completar-se-á um circuito elétrico, permitindo desta forma que os elétrons fluam para a camada p , criando uma corrente elétrica. Este fluxo de elétrons manter-se-á enquanto a luz solar incidir na célula sendo que a intensidade da corrente elétrica variará da mesma forma que a luz solar incidente varia [5].

2.3.1 - Tipos e características das células

Como a unidade base de qualquer sistema fotovoltaico são as células, a escolha do seu tipo vai influenciar a capacidade de produção dos sistemas FV. As células fotovoltaicas mais usuais podem ser compostas por silício monocristalino, silício policristalino ou silício amorfo.

As células de silício monocristalino foram as primeiras a serem desenvolvidas para fins comerciais, fazendo parte da primeira geração. Estas células foram as primeiras a serem elaboradas a partir de um cristal único, esta tecnologia permite obter células com maiores eficiências; no entanto, o seu processo de fabrico é mais dispendioso. As células policristalinas são mais baratas uma vez que não necessitam de tanta energia no seu fabrico; no entanto, atingem eficiências mais baixas, quando comparadas com a tecnologia anterior. No caso do silício amorfo, o cristal não tem uma forma regular, sendo as células de fabrico mais barato, mas com a desvantagem de se obterem eficiências ainda mais baixas.

Tabela 2.1 - Rendimento dos vários tipos de células [12].

<i>Tipo de célula</i>	<i>Rendimento em Laboratório (%)</i>	<i>Rendimento da célula (%)</i>	<i>Rendimento do módulo (%)</i>
Si-monocristalino	24,7	18	16
Si-policristalino	20	16	13-14
Si-amorfo	12,1	10	8-9

Nos últimos anos tem-se vindo a desenvolver outros tipos de células, com o objetivo de diminuir o consumo de silício, por requerer elevadas temperaturas na sua produção e um grau de pureza elevado. As células de Disselenieto de Cobre e Índio ou as células de Telureto de Cádmio são exemplos de células mais eficientes e baratas do que as células de silício amorfo, no entanto, contêm cádmio que é um material perigoso. Muitas novas tecnologias estão ainda em fase de estudos, mas prometem grandes eficiências e custos muito baixos, no entanto o seu processo de desenvolvimento tecnológico não deverá permitir que tenham expressão significativa no mercado no próximo 10 a 15 anos. De referir por exemplo o Arsénio de Gálio, que apresenta rendimentos que podem chegar a 25% mas que têm custos de produção muito elevados [5].

Os módulos fotovoltaicos são dispositivos constituídos por várias células fotovoltaicas. Praticamente todas as células fotovoltaicas compostas por silício são capazes de gerar uma diferença de potencial entre 0,4 e 0,5 Volt em condições normais. Por este motivo, as células devem ser ligadas em série, de modo a aumentar a diferença de potencial a um nível

normalizado. Arranjos de várias células fotovoltaicas ligadas em série (normalmente 36 células), encapsuladas entre vidro e plástico, e suportadas dentro de uma estrutura metálica, são chamados de módulos ou painéis fotovoltaicos. Grupos de módulos montados juntos são chamados de *array* [13], ver Figura 2.2.




Figura 2.2 - Célula, módulo fotovoltaico e array [13].

Durante o encapsulamento, as células são seladas a alta temperatura entre camadas de plástico e vidro, de modo a que o ar ou água não possa entrar e corra as conexões elétricas entre as células.

Todos os painéis fotovoltaicos são classificados de acordo com a sua capacidade máxima ou pico de potência. Pico de potência (*watt-peak*), é definido como a potência elétrica máxima que um painel fotovoltaico deveria produzir sob *Standard Test Conditions* (STC) [13]. As condições de teste padrão, STC, referem-se a uma radiação incidente de 1000 W/m^2 para uma temperatura ambiente de 25°C .

A energia produzida por um módulo fotovoltaico depende do número de células que possui, do tipo de células e da área total das células. Além disso, a potência produzida ainda varia em função da quantidade de radiação incidente, do ângulo do painel respectivamente ao sol, da temperatura do painel e da tensão que esta a ser consumida a partir do módulo.

2.3.2 - Curva I-V

Outro aspecto muito importante que se deve ter em conta ao compararmos painéis fotovoltaicos é a curva I-V (intensidade de corrente - tensão). Esta curva é utilizada para estimar o desempenho do painel a várias temperaturas, níveis de tensão e irradiação. Cada módulo ou célula fotovoltaica, tem as suas próprias características.




Figura 2.3 - Curva I-V e P-V para uma célula típica de silício monocristalino.

Existem vários pontos de interesse relativamente à curva I-V na Figura 2.3:

- Corrente de curto-circuito (I_{cc}), é a corrente máxima que o sistema FV consegue entregar sob determinadas condições de radiação e temperatura, correspondendo a uma tensão nula e consequentemente potência nula;
- Tensão em circuito aberto (V_{cc}), é a tensão máxima que o sistema FV consegue entregar sob determinadas condições de radiação e temperatura, correspondendo à circulação de uma corrente nula e consequentemente potência nula;
- P_{max} ou P_{MP} , é o valor de potência máxima que o sistema FV consegue produzir. O ponto de potência máxima é sempre encontrado no local onde a curva começa a quebrar acentuadamente. É aconselhável que um módulo opere o mais próximo possível deste ponto.

2.3.3 - Efeito da radiação e da temperatura

A potência produzida por uma célula fotovoltaica depende quase linearmente da radiação solar incidente. Como se pode verificar na Figura 2.4, a potência de saída aumenta com o aumento da radiação incidente no módulo. A corrente de curto-circuito aumenta de forma aproximadamente linear com o aumento da radiação incidente ao passo que o valor de tensão de circuito aberto pouco varia com a variação da radiação.




Figura 2.4 - Efeito da radiação e da temperatura num módulo fotovoltaico [13].

Ao contrário dos sistemas solares térmicos, um módulo fotovoltaico vai produzindo menos à medida que vai aquecendo. Analisando a Figura 2.4 verifica-se que o valor da tensão em circuito aberto baixa com o aumento da temperatura, enquanto que o valor da corrente de curto-circuito pouco varia. A temperatura dos painéis solares fotovoltaicos varia essencialmente com a irradiância solar, a temperatura ambiente e a velocidade do vento.

Um módulo constituído por células monocristalinas tem um decréscimo na sua produção na ordem dos 0,5% por cada grau centígrado. Geralmente, a temperatura dos módulos fotovoltaicos é 20 °C superior à temperatura registada num termómetro, isto porque uma parte da radiação solar absorvida não é convertida em energia elétrica, mas sim dissipada sob a forma de calor. Este aspeto é muito importante, porque em alguns locais a temperatura ao nível do solo pode ser superior a 60 °C reduzindo a potência em aproximadamente 20% ou mais. Por esse motivo, os módulos devem ser instalados em estruturas a uma altura superior à do local e de preferência em locais onde são arrefecidos por correntes de ar [13].

2.3.4 - Associação de células

Num agrupamento ligado em série, as células são atravessadas pela mesma corrente e a característica resultante deste agrupamento é obtida pela adição das tensões aos terminais das células, para um mesmo valor de corrente. Por outro lado, num agrupamento ligado em paralelo, as células estão submetidas à mesma tensão e as intensidades de corrente adicionam-se. A característica resultante obtém-se por adição de correntes, para um mesmo valor de tensão.

A grande maioria dos módulos são construídos associando em primeiro lugar as células em série até se obter um nível de tensão considerável, e depois associando-as em paralelo até alcançar o nível de corrente desejado.

2.3.5 - Efeito da inclinação, orientação dos módulos e uso de sistemas de seguimento

A quantidade de energia produzida por um sistema fotovoltaico é influenciada pela orientação do painel e pelo ângulo de inclinação deste relativamente ao plano horizontal. Se estes parâmetros proporcionarem um aumento da energia captada pelos módulos, a energia produzida também irá aumentar. Como se pode ver pela Figura 2.5, a quantidade de radiação solar captada numa superfície é máxima quando esta se encontra posicionada perpendicular à radiação, por esta razão, é essencial que a inclinação dos sistemas solares seja otimizada, sendo que esta varia de acordo com a latitude

No hemisfério norte, a orientação que maximiza a quantidade de radiação aproveitável coincide com o sul geográfico, sendo que para o hemisfério sul, a orientação ótima coincide com o norte geográfico [13].




Figura 2.5 - Inclinação ótima para diferentes épocas do ano [13, 14].

Normalmente, os sistemas solares fixos são montados de forma a aproveitar o máximo de radiação para o mês de menor insolação. Seguindo esta regra, um modo de descobrir facilmente a inclinação ótima é somando 10° à latitude do local.

Se o objetivo é maximizar o aproveitamento da energia solar ao longo do dia, capta-se mais energia se os sistemas solares estiverem constantemente virados na direção do Sol. O processo de direcionar os sistemas solares em relação ao Sol, à medida que este se move no céu, é chamado de seguimento. Este processo pode aumentar a potência produzida em 30%.

Existem dois grupos de sistemas mecânicos de seguimento, os de dois eixos e os de um eixo. Os mecanismos com dois eixos colocam a superfície de captação na posição ideal relativamente ao Sol. No entanto, estes são muito mais complexos do ponto de vista técnico do que os sistemas de um eixo. As instalações com sistemas de um eixo são mais simples e podem apresentar várias configurações.

Apesar de maximizarem a energia captada, os sistemas mecânicos de seguimento solar são mais complexos, mais caros e apresentam maiores custos de operação e manutenção. Uma vez que são dotados de partes móveis estes também são mais susceptíveis a avarias [13].

2.3.6 - Efeito de sombreamento na produção do módulo

Se uma sombra bloquear a radiação incidente numa parte do módulo fotovoltaico, a potência produzida será inferior. De facto, bloquear simplesmente uma única célula pode reduzir consideravelmente a potência gerada, e até mesmo danificar o módulo, porque as células nos módulos são ligadas em série e todas elas devem ter a mesma corrente. Se uma célula é bloqueada, passa a estar inversamente polarizada, consumindo energia elétrica, convertendo-a em calor. Se a célula estiver bloqueada por um longo período de tempo poderá provocar a falha completa do módulo [13].

2.3.7 - Tipos de sistemas fotovoltaicos

As aplicações tipológicas dos sistemas fotovoltaicos terrestres podem ser divididas em duas categorias principais:

- sistemas autónomos/híbridos;
- sistemas ligados à rede

Os sistemas autónomos podem ter potências que variam desde os miliwatt até aos kilowatt. A fim de garantir o abastecimento de eletricidade em dias com fraca ou nenhuma radiação solar, a maioria dos sistemas autónomos tem um sistema de armazenamento integrado (baterias). Existe uma enorme variedade de sistemas autónomos, as suas aplicações variam desde máquinas calculadoras e relógios, até sistemas de controlo de tráfego ou até mesmo sistemas capazes de alimentar habitações situadas em locais remotos, onde não existe uma rede elétrica. Estes sistemas podem ser implementados apenas com o módulo fotovoltaico como gerador de eletricidade ou com fontes de energia auxiliares, sendo conhecidos como sistemas híbridos. Os geradores adicionais podem ser alimentados a combustíveis fósseis (por exemplo fuel ou gás) ou a energias renováveis (por exemplo eólica, hídrica ou biomassa), complementado assim a produção fotovoltaica [11].

Os sistemas FV ligados à rede são sempre ligados à rede elétrica através de um inversor, porque os módulos fotovoltaicos apenas geram corrente contínua. Habitualmente estes sistemas não produzem grandes efeitos na rede elétrica no que diz respeito à qualidade da onda, carga nas linhas e transformadores, etc.. No entanto, se sistemas FV de maior capacidade forem implementados numa rede elétrica de baixa tensão, estes aspetos já devem ser considerados [11].

Por norma estes sistemas utilizam um elevado número de módulos FV, embora com a promoção da microgeração comecem a aparecer também sistemas de dimensões reduzidas, sem necessidade de recurso a baterias. No entanto, o inversor tem que possuir características adequadas à satisfação dos requisitos que a ligação impõe, de modo a não afetar a qualidade da energia. Nestes sistemas fotovoltaicos ligados à rede o critério de dimensionamento é a maximização de energia produzida.

2.3.8 - Inversores

Tal como referido anteriormente, os módulos fotovoltaicos podem ser ligados em série, em paralelo ou em associações série-paralelo. O tamanho e número das filas são determinados com base na escolha do inversor, tendo em conta a potência de saída do módulo.

Em sistemas ligados à rede os módulos fotovoltaicos são habitualmente ligados em série, formando fileiras, pelo que o valor máximo da tensão da fila deve ser inferior ao valor máximo da tensão nominal do inversor. No entanto, pode haver necessidade de ligar módulos fotovoltaicos em paralelo em caso de sombreamentos de partes do painel fotovoltaico do sistema, no caso de o painel ser constituído por módulos com diferentes características elétricas ou ainda quando é necessário cumprir com um determinado valor da tensão de saída das filas.

2.3.9 - Tecnologia solar de concentração fotovoltaica

As centrais solares fotovoltaicas de concentração (CPV) geram energia elétrica da mesma forma que a tecnologia fotovoltaica convencional. A diferença entre as tecnologias reside na adição de um sistema óptico que concentra uma grande quantidade de luz solar numa célula fotovoltaica. Embora o CPV tenha uma maior eficiência quando comparado com os sistemas fotovoltaicos tradicionais, os sistemas de concentração utilizam apenas a componente direta da radiação solar. Por este motivo, estes sistemas devem possuir um sistema de posicionamento de forma a que estejam sempre orientados na direção do sol.

Uma vez que os sistemas fotovoltaicos tradicionais utilizam tanto a componente direta como a difusa da radiação solar, ainda continuam a ser uma boa opção para ser instalado em zonas onde existem frequentemente condições de céu nublado. Ao contrário dos sistemas de concentração, o FV tradicional não necessita de um sistema de seguimento solar embora possa tê-lo [13].

Na apresentação realizada por Collares Pereira [12], é efetuado um estudo comparativo da produção proveniente de diferentes tecnologias FV. As tecnologias comparadas são:

- Painéis FV monocristalinos fixos;
- Painéis FV monocristalinos dotados de um sistema de seguimento de 2 eixos;
- CPV dotado com o mesmo sistema de seguimento.

A produção diária dos sistemas estudados foi monitorizada para os primeiros seis dias do mês de Agosto com diferentes condições climáticas:




Figura 2.6 - Radiação solar incidente nos diferentes sistemas analisados [12].

Da análise do gráfico da Figura 2.6 pode-se constatar que a radiação solar incidente em todos os sistemas é muito irregular, o que sugere que o dia 1 de Agosto foi claramente afetado pela presença de nebulosidade. Neste caso, os sistemas FV convencionais têm uma produção de energia superior à dos sistemas CPV (ver Figura 2.7). Tal deve-se ao facto de que, como já foi referido anteriormente, estes sistemas aproveitam a componente direta e difusa da radiação solar, que é maior em dias nublados do que em dias de céu limpo.




Figura 2.7 - Produção diária dos diferentes sistemas analisados [12].

Para os dias em que se verificam condições de céu limpo, como por exemplo no dia 3 de Agosto, o sistema CPV, como seria de se esperar, consegue produzir mais energia elétrica quando comparado com os sistemas tradicionais.

Este estudo comparativo traduz a alta dependência das tecnologias fotovoltaicas de concentração da componente direta da radiação incidente no painel do sistema. Os sistemas CPV demonstram ser uma ótima alternativa aos sistemas tradicionais para o aproveitamento do recurso solar em regiões onde se verifique uma elevada incidência da radiação direta e registos de baixa nebulosidade.

2.4 - Panorama nacional

Nesta secção, será efetuada uma análise da situação FV em Portugal Continental. Como ponto de partida foi feito um levantamento no site da Direcção Geral de Energia e Geologia (DGEG) da evolução anual da potência FV instalada. De seguida, através do site da e2p [15] e renováveis na hora [16] foi possível efetuar o levantamento de uma grande parte das instalações licenciadas em Portugal Continental (excluindo miniprodução).

É possível verificar pela análise da Figura 2.8, um crescimento da potência instalada a nível nacional principalmente a partir do ano de 2006 até à atualidade. Em 2007 grande parte da potência FV instalada devia-se à central FV de Hércules em Serpa (11 MW) e à central FV de Corte Pão e Água (0,6 MW). Entre 2007 e 2008 o crescimento da potência instalada, deveu-se à entrada em funcionamento de grandes centrais FV, tais como a de Amareleja (46,41 MW), Olva (2,2 MW) e do Interior Alentejano (2,2 MW). Entre 2008 e 2009 o crescimento esteve relacionado com a entrada em funcionamento de três centrais FV em Ferreira do Alentejo das empresas; Generg (12 MW), Tecneira (10 MW) e Netplan (1,8 MW) e da central em meio urbano Mercado Abastecedor da Região de Lisboa - MARL (6 MW). Entre 2009 e 2010 o crescimento esteve relacionado com a entrada em funcionamento da central FV de Porteirinhos (6 MW), Malhada a Velha (1 MW) e Castanhos (1,3 MW).




Figura 2.8 - Evolução da potência FV instalada, a partir do ano 2003.

Na Figura 2.9 pode-se ver a comparação entre a potência instalada a partir das centrais fotovoltaicas e dos sistemas de microprodução em 2011, para Portugal Continental. Como se pode ver, dos 149 MW de potência FV instalada no final de Outubro, grande parte dessa energia (68,1%) provem das centrais FV em funcionamento, sendo que a microprodução fica-se pelos (27,6%) não deixando no entanto, de ser um valor assinalável. Uma vez que não foi possível aceder aos dados relativos à potência instalada da miniprodução, estes não são contabilizados.




Figura 2.9 - Comparação da potência instalada proveniente das centrais FV e microprodução em 2011. Dados retirados do site renováveis na hora.

Na Figura 2.10 é ilustrado o somatório da potência instalada relativamente à microprodução, por distrito em Portugal Continental, até ao fim do ano de 2011.




Figura 2.10 - Potência instalada na microprodução, por distrito em 2011. Baseado nos dados retirados do site renováveis na hora.

Como se pode verificar, Lisboa apresenta-se como o distrito com maior potência instalada (5140 kWp). Inversamente, e apesar de possuir melhores condições para aproveitamento do recurso solar comparativamente com Lisboa, Portalegre afigura-se como o distrito com menor potência instalada (460 kWp). Isto poderá estar relacionado com a sua menor densidade populacional e poder de compra.

Outra análise que se efetuou foi perceber quais são os tipos de materiais mais utilizados nas centrais fotovoltaicas a nível nacional e o tipo de seguimento que estas utilizam. Para este estudo apenas foram contabilizadas as centrais FV presentes no site da e2p, uma vez que seria impossível analisar todos os sistemas FV pertencentes à microprodução.

Tendo em conta as diferentes alternativas existentes no mercado, para os materiais utilizados na construção dos módulos FV, verificou-se que a escolha do material utilizado nas centrais varia consoante a central. Isto poderá estar relacionado com os objetivos a que a mesma se propõe, disponibilidade financeira/orçamento do projeto, localização e níveis de eficiência pretendidos. Relativamente à escolha do sistema de seguimento este prende-se essencialmente com questões financeiras. O aumento verificado na captação de radiação solar pelos painéis deve compensar significativamente o custo associado ao investimento, manutenção e operação do ou dos sistema de seguimento.

Os sistemas mecânicos de seguimento foram divididos em três categorias:

- instalações fixas (sem sistemas de seguimento);
- instalações com sistema de seguimento de 1 eixo;
- instalações com sistemas de seguimento de 2 eixos.

Na Tabela 2.2 é apresentado o tipo de tecnologia e sistema de seguimento utilizado pelas centrais FV analisadas, sendo que se desconhece algumas características das centrais de Castanhos, Ferreira do Alentejo (Tecneira) e Malhada Velha.

Tabela 2.2 - Descrição das centrais FV analisadas.

<i>Central FV</i>	<i>Potência Instalada [MW]</i>	<i>Tecnologia dos módulos</i>	<i>Tipo de seguimento</i>
Amareleja	46,41	Si-m	1 eixo
Castanhos	1,3	----	fixo
Corte de Pão e Água	0,6	a-Si	fixo
Ferreira do Alentejo (Generg)	12	Si-p	fixo
Ferreira do Alentejo (Netplan)	1,8	a-Si	fixo
Ferreira do Alentejo (Tecneira)	10	Si-p	----
Hércules	11	Si-m	fixo
Interior Alentejano	2,2	Si-m / Si-p	2 eixos
Malhada Velha	1	----	-----
MARL	6	Si-p	fixo
Olva	2,2	Si-p	fixo
Porteirinhos	6	Si-p / CIGS	fixo

Pela Tabela 2.2 pode-se concluir que os sistemas fixos são os mais utilizados entre as centrais FV analisadas, independentemente do tipo de sistema utilizado pelas centrais desconhecidas. Relativamente ao tipo de tecnologia utilizada nos módulos FV, conclui-se que há uma predominância das células de silício policristalino (Si-p) comparativamente às células monocristalinas (Si-m) e amorfas (a-Si).

Capítulo 3

Estado da arte

3.1 - Introdução

A intensidade da radiação solar incidente não é constante, é maior no Verão do que no Inverno e apenas uma parte dela atinge a superfície terrestre, sendo que esta é fortemente afetada pela presença de nebulosidade, pelo que o conhecimento da evolução das núvens é muito importante [17]. Devido à intermitência da radiação solar incidente fica claro que a sua previsão assume um papel de enorme importância para a gestão das centrais solares e consequentemente da rede elétrica.

A potência produzida a partir de uma central fotovoltaica está intimamente relacionada com a radiação global incidente no local, pelo que as incertezas dos valores previstos da radiação solar se refletem diretamente no valor previsto da produção solar. Este é de longe o efeito mais influente sobre a qualidade das previsões da energia solar. Portanto, as dificuldades encontradas para a previsão da produção das centrais fotovoltaicas são praticamente as mesmas da previsão da radiação solar [18].

Este capítulo tem como principal objetivo apresentar algumas metodologias desenvolvidas para a previsão da radiação solar, que permitem antever a produção de energia elétrica nas centrais solares para diferentes horizontes temporais.

3.2 - Modelos de previsão solar

Segundo *Makridakis* [19], é frequente existir um desfasamento temporal entre a consciência de um evento iminente e a ocorrência desse evento. Assim, esse período de tempo revela-se como a principal razão para o planejar e prever. A necessidade de prever alia-se ao facto de tentar diminuir a dependência face ao acaso. Assim, em diversas situações, a previsão é imprescindível para determinar quando um evento ou uma necessidade irá ocorrer, de forma a que seja possível desencadear ações pertinentes e apropriadas.

Como já foi referido anteriormente, a produção elétrica a partir de fontes de energia renovável tem surgido no mercado devido a razões económicas e ambientais. Contudo, existem limitações técnicas que impedem a penetração deste tipo de centrais na rede

elétrica. A variabilidade da produção elétrica é o principal desafio que tem de ser ultrapassado, isto porque a produção deste tipo de centrais depende bastante das condições meteorológicas.

Existem diversos modelos matemáticos que permitem simular a radiação solar incidente na superfície terrestre. No entanto, para se realizar previsões, deve-se ter em conta todos os processos que ocorrem quando a radiação solar interage com a atmosfera. Dependendo do horizonte de previsão, são utilizadas várias metodologias na previsão da radiação solar. Um grande passo na direção de melhorar a previsão solar é a combinação de vários modelos, com o objetivo de explorar os pontos fortes de cada um, preenchendo assim as lacunas existentes nos mesmos. Com uma boa previsão da radiação solar pode-se obter uma boa estimativa da produção de uma central solar.

3.2.1 - Previsão da radiação solar utilizando imagens obtidas por satélite

Para previsões com um horizonte temporal de 30 minutos até 6 horas, os dados obtidos a partir dos satélites são uma fonte de informação com grande qualidade devido à sua boa resolução temporal e espacial. Como já foi referido anteriormente, a presença de nebulosidade tem forte impacto na radiação solar incidente na superfície, portanto, uma descrição aproximada relativamente ao desenvolvimento temporal da situação da nuvem é essencial para a previsão da radiação incidente [17].

No artigo escrito por Lorenz et al. [20], pode-se observar um método de previsão da radiação solar, baseando-se no cálculo dos vetores de deslocamento das nuvens. O algoritmo desenvolvido neste artigo consiste nos seguintes passos:

- Como medida da nebulosidade, imagens com o índice de nebulosidade de acordo com o método descrito por Hammer et al. [21], são calculadas a partir dos dados de satélite;
- Vetores de deslocamento que fornecem informação relativamente à direção e velocidade com que as nuvens se deslocam, são calculados a partir de duas imagens consecutivas do índice de nebulosidade;
- A previsão do comportamento das nuvens é determinada aplicando os vetores previamente calculados à imagem mais recente extrapolando assim o movimento das nuvens;
- É aplicado um filtro de suavização com o objetivo de eliminar variáveis aleatórias pouco relevantes ou que não são previsíveis;
- A radiação solar incidente é então calculada a partir das imagens com o índice de nebulosidade previsto, utilizando o método Heliosat;
- Informações da precisão para a irradiância são então fornecidas.




Figura 3.1 - Metodologia utilizada para a previsão do movimento das núvens [17].

Apesar de fornecerem boas previsões, os satélites apresentam algumas limitações, o seu elevado custo e a elevada duração de tempo na aquisição de duas imagens consecutivas não permite a previsão para horizontes temporais inferiores a 30 minutos.

3.2.2 - Modelos de previsão numérica do tempo (NWP)

A primeira utilização com sucesso dos NWP para a previsão das condições meteorológicas remonta a 1950, após um trabalho desenvolvido por *Charney* [22].

Uma vez que as previsões da radiação solar a muito curto prazo, até 6h, não são suficientes para um planeamento eficiente dos sistemas FV, especialmente para a integração na rede elétrica da energia solar, sendo por isso necessário ter previsões para um horizonte temporal de alguns dias. Para estes casos, os modelos de previsão numérica afiguram-se como sendo a melhor alternativa. Um modelo meteorológico é qualquer modelo que permite calcular variáveis meteorológicas, como por exemplo a radiação solar. Os modelos NWP fazem a previsão das condições climáticas utilizando as condições meteorológicas atuais como entradas de modelos matemáticos que simulam o comportamento da atmosfera. Estes modelos variam desde globais até locais, sendo que os primeiros têm geralmente uma baixa resolução e não permitem um mapeamento detalhado das características em pequena escala. Portanto, é necessário o uso de modelos de mesoescala regionais juntamente com modelos NWP para prever os efeitos locais [17].

Model Output Statistics (MOS) é uma técnica de pós-processamento utilizada para interpretar os dados provenientes dos modelos NWP, produzindo dessa forma previsões da

radiação solar em locais específicos. Os MOS relacionam os elementos meteorológicos observados com as variáveis apropriadas através de uma abordagem estatística.

Sendo assim, os NWP podem ser divididos em duas categorias:

- Global - Efetuam previsões para todo o planeta;
- Regional/local - Efetuam previsões para zonas continentais.

3.2.2.a - Modelos globais

Os modelos globais oferecem previsões meteorológicas de maior alcance (escala mundial, mas normalmente apenas um hemisfério). Estes modelos possuem uma resolução da ordem de 200 km e têm como objetivo identificar o comportamento geral da atmosfera sobre uma determinada zona. São modelos que apresentam capacidade de identificar fenómenos meteorológicos de larga escala. A Tabela 3.1 apresenta alguns exemplos de NWP globais.

Tabela 3.1 - Exemplos de modelos numéricos de previsão globais.

<i>Designação</i>	<i>Desenvolvido por:</i>
<i>GFS - Global Forecast System</i>	<i>National Centre of Environmental Prediction</i> <i>MSC - Meteorological Service of Canada</i> <i>UK Met Office</i>
<i>GEM - Global Environment Multiscale Model</i>	
<i>UM - Unified Model</i>	

Uma vez que os NWP são modelos matemáticos complexos, são normalmente corridos em supercomputadores, o que de certa forma limita a sua utilidade para a previsão a muito curto prazo. Por este motivo são mais utilizados para realizar previsões para um horizonte temporal maior que 6 horas [23].

3.2.2.b - Modelos regionais/locais

Os modelos atmosféricos locais concentram-se em grandes áreas (países), e apresentam uma resolução espacial de 2 km até cerca de 50 km. O seu objetivo é analisar e identificar em detalhe o comportamento da atmosfera sobre uma região específica, reconhecendo desta forma fenómenos meteorológicos de pequena escala. A Tabela 3.2 apresenta alguns exemplos de modelo NWP locais.

Tabela 3.2 - Exemplos de modelos numéricos de previsão locais.

<i>Designação</i>	<i>Desenvolvido por:</i>
<i>MM5 - Fifth Generation Penn State / NCAR Meso-scale Model MM5</i>	<i>Penn State University (PSU) / National Center for Atmospheric Research (NCAR)</i> <i>NCEP (National Centers of Environmental Prediction)</i> <i>University of Oklahoma</i>
<i>WRF - Weather Research and Forecasting Model</i>	
<i>ARPS - Advanced Regional and Forecasting Model</i>	

Estes modelos são de extrema importância para a previsão de produção de parques fotovoltaicos e eólicos, uma vez que permitem estudar uma determinada zona geográfica com grande resolução espacial. No entanto, como possuem uma resolução espacial superior aos NWP globais, o tempo de processamento é superior.

3.2.3 - Redes neurais artificiais (RNA)

O interesse na utilização de redes neurais para a realização da previsão tem aumentado nos últimos anos. Este interesse deve-se essencialmente à sua capacidade de emular a inteligência natural, aprendendo a partir da experiência, isto é, aprendendo uma relação entre as variáveis de entrada e de saída estudando a informação guardada. As redes neurais artificiais (RNA) são ferramentas que determinam os dados de forma semelhante àquela realizada pelas redes de neurónios biológicos. Por este motivo oferecem uma alternativa na resolução de problemas complexos, são capazes de aprender a partir de exemplos e de lidar com dados incompletos, lidam com problemas não lineares e uma vez treinadas podem realizar previsões e generalizações quase instantaneamente [24].

Outra vantagem da utilização das redes neurais é a sua habilidade de lidar com uma elevada quantidade de dados contendo diversos parâmetros relacionados. São capazes de simplesmente ignorar o excesso de dados com pouca relevância, concentrando-se desta forma nos dados mais importantes [24].

Uma RNA é constituída por um grupo de neurónios artificiais ligados por caminhos unidireccionais, interagindo uns com os outros de uma forma adequada. Nestes sistemas, a excitação é efetuada à entrada da rede e, com a aplicação de algumas operações adequadas, obtém-se a variável de saída desejada. Nas sinapses há um acumular de potencial, que no caso dos neurónios artificiais é modelado como sendo um peso da conexão. Estes pesos são constantemente modificados com base em regras de aprendizagem. Como podemos ver na Figura 3.2, normalmente as RNA são constituídas por uma camada de entrada, uma ou várias camadas escondidas e uma camada de saída [25].




Figura 3.2 - Ilustração de uma rede neuronal do tipo *feedforward* [24].

3.2.3.a - Neurónios

Uma rede neuronal é constituída por várias unidades de processamento, denominadas de neurónios. Como podemos ver na Figura 3.2 o neurónio é um elemento básico que funciona em paralelo e em série, sendo que o seu modelo é inspirado no sistema nervoso biológico.




Figura 3.3 - Processamento de um neurónio de uma rede neuronal [27].

O neurónio artificial recebe os valores de entrada (x_i) que são ponderados por valores associados com cada sinapse (w_{ki}), chamados pesos sinápticos. Inicialmente todos os valores ponderados são somados e o resultado obtido é o nível de atividade do neurónio (u_k). A saída do neurónio é então processada pela função de ativação ($f(u_k)$). Existem muitos tipos de funções de ativação, mas os três tipos mais utilizados são: em degrau, linear e sigmóide. O uso de uma função não linear, como a função sigmóide, permite à RNA aprender comportamentos não lineares e complexos [26, 27].

3.2.3.b - Arquitetura das Redes Neurais

As RNA podem ser classificadas quanto à sua arquitetura como sendo unidirecionais (*feedforward*) ou recorrentes (*feedback*).

A arquitetura *feedforward* é a que mais frequentemente é utilizada para efetuar previsões. Funciona de forma progressiva sem informação adicional dos processos a jusante, isto é, a informação é projetada diretamente desde a camada de entrada até à camada de saída. Este tipo de redes só funciona num único sentido, não sendo possível a inversão da orientação do processo [27].

Uma rede neuronal do tipo recorrente distingue-se de uma *feedforward* na medida em que possui pelo menos um ciclo de *feedback*, isto é, pelo menos num ciclo ela conhece a informação dos neurónios a jusante. A presença de ciclos de *feedback* tem um impacto acentuado sobre a capacidade de aprendizagem da rede, bem como sobre o seu desempenho; no entanto, estas redes exigem um elevado poder de processamento [27].

3.2.3.c - Processos de aprendizagem

O método de treino ou aprendizagem de uma rede neuronal pode ser efetuado de duas formas distintas, supervisionado ou não supervisionado. No treino supervisionado, muitos dados históricos são fornecidos à rede, e a partir deste conjunto de dados a rede neuronal aprende a correspondência entre a entrada e a saída. Desta forma, quando a rede for submetida a um conjunto de teste onde apenas são fornecidas as entradas, ela irá ser capaz de processar a saída. De uma forma geral, os pesos que conectam cada neurónio na rede são ajustados com o objetivo de minimizar o erro entre a saída desejada e a saída obtida na rede [25].

Na aprendizagem não supervisionada não são fornecidos exemplos para que a rede aprenda a relação entre a entrada e a saída. Uma vez que não são conhecidos os dados de saída, ela atualiza os seus pesos sem utilizar pares entra-saída [25].

3.2.3.d - Aplicação de redes neurais para previsão da radiação solar

O artigo desenvolvido por Sfetsos et al. [28], explora técnicas de aprendizagem automática para realizar previsões da radiação global incidente na horizontal. São utilizados valores horários da irradiação global, e o método desenvolvido neste artigo distingue-se dos demais, na medida em que a irradiação não necessita de nenhuma transformação. Além disso, ainda são utilizadas observações da temperatura (T), pressão (P), velocidade do vento (WS) e direção do vento (WD) com intuito de verificar se há melhoria na performance do modelo.




Figura 3.4 - Dados da radiação global utilizados em [28]. O conjunto de treino engloba 41 dias, o conjunto de validação 13 dias e o conjunto de previsão 9 dias, perfazendo um conjunto de 63 dias.

Foram encontrados e avaliados modelos com e sem as variáveis climáticas. As técnicas de aprendizagem automática utilizadas foram as redes neurais e sistemas de inferência *neurofuzzy* adaptativos. O modelo convencional analisado é um $ARIMA(1,0,1)(0,1,1)_{24}$ (modelo auto-regressivo integrado de média móvel) e também um modelo de regressão linear (LR):

$$G_{(t|t-1)} = a_1 \cdot G_{(t-1)} + a_2 \cdot G_{(t-2)} + a_3 \cdot G_{(t-3)} + b_1 \cdot G_{(t-24)} + c_1 \cdot T_{(t-1)} + c_2 \cdot T_{(t-6)} + d_1 \cdot WD_{(t-1)} + e_t \quad (3.1)$$

De salientar que o modelo ARIMA é aplicado com apenas uma diferenciação sazonal, pelo que o resultado é um processo não estacionário. O resultado da previsão realizada no instante t para $t+1$ é avaliado pelo *improvement* calculado através da raiz do erro médio quadrático (*RMSE%*) em relação ao modelo de persistência. Para o modelo ARIMA obteve-se uma melhoria de 62,89% e para o melhor modelo IA sem variáveis adicionais 71,94%. Incluindo as variáveis adicionais, obteve-se uma melhoria de 60,91% para o modelo LR e 74,04% para o melhor modelo IA que foi a rede neuronal.

Este estudo comprova que, mesmo para um conjunto de dados relativamente pequeno, a rede neuronal demonstra ser uma ferramenta melhor que os restantes métodos de previsão.

3.2.4 - Support Vector Machines

Support Vector Machines (SVM), são métodos baseados em estatística e ciência da computação, que através do método da aprendizagem supervisionada são capazes de analisar os dados de entrada e encontrar determinados padrões [48]. Os resultados da aplicação desta técnica são comparáveis e muitas vezes superiores aos obtidos por outros algoritmos de aprendizagem, como as RNA.

A *Support Vector Regression* (SVR) é uma técnica de regressão não-linear baseada em *Support Vector Machines*. Esta técnica é muitas vezes utilizada nas áreas de reconhecimento de padrões e classificação de texto. Em vez de minimizar o erro de treino observado, SVR tenta minimizar a fronteira do erro, de forma a obter um desempenho generalizado. O conceito de SVR é baseado no cálculo computacional de uma função de regressão linear num espaço de elevada característica dimensional, onde os dados de entrada são mapeados através de uma função não linear. SVR tem sido aplicado em diversas áreas, tais como: previsões de séries temporais, aproximação de análises de engenharia de elevada complexidade, e escolha de funções de perda, etc.. [48].

O funcionamento do algoritmo em SVR é baseado na metodologia de aprendizagem supervisionada. Esta metodologia faz com que um sistema aprenda uma função, a partir de uma amostra de dados de treino $S = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\} \subseteq (X \times Y)^n$, onde X denomina o espaço de entrada e Y o espaço de saída. Nesse contexto, o objetivo do SVR é encontrar uma função $f(x)$ que apresente no máximo um desvio ε em relação aos valores alvo y_i . Por outras palavras, procura-se uma função com margem de erros caracterizada pelo intervalo $[y_i - \varepsilon, y_i + \varepsilon]$ [49].

Assumindo funções na forma:

$$f(x) = \langle w \cdot x \rangle + b \quad (3.2)$$

Onde: $w \in \mathbb{R}^n, b \in \mathbb{R}$

Diz-se que procurar uma função mais paralela ao domínio possível, significa determinar valores pequenos para o vetor dos pesos w , o que corresponde a minimizar a medida $\|w\|^2$ [49]. Desta forma, modela-se o problema de otimização original do SVR com sendo:

$$\text{minimizar } \frac{1}{2} \|w\|^2 \quad (3.3)$$

$$\text{sujeito a: } \begin{cases} y_i - \langle w \cdot x_i \rangle - b \leq \varepsilon \\ \langle w \cdot x_i \rangle + b - y_i \leq \varepsilon \end{cases} \quad (3.4)$$

Onde: $w \in \mathbb{R}^n$ e $b \in \mathbb{R}$ são as incógnitas do problema.

Nem sempre é possível garantir a viabilidade do problema descrito a cima, isto porque existem pontos que violam as suas restrições. Por este motivo, estuda-se uma função de perda, que introduz variáveis de folgas não negativas ξ_i, ξ_i^* cuja finalidade é penalizar dados que se situem fora da margem $|f(x_i) - y_i| \leq \varepsilon$ [48]. A formulação do problema fica então:

$$\begin{aligned} &\text{minimizar } \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) \\ &\text{sujeito a: } \begin{cases} y_i - \langle w \cdot x_i \rangle - b \leq \varepsilon + \xi_i \\ \langle w \cdot x_i \rangle + b - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases} \end{aligned} \quad (3.5)$$

Onde C é a constante de regularização. A função de perda, denominada ε -Intensive, é descrita por:

$$|\xi|_\varepsilon = f(x) = \begin{cases} 0, & \text{se } |\xi| < \varepsilon \\ |\xi| - \varepsilon, & \text{caso contrário} \end{cases} \quad (3.6)$$

Na Figura 3.5 podemos ver que apenas os pontos localizados fora da fronteira contribuem para o valor custo da função.




Figura 3.5 - Fronteira da região que contribui para a função de custo [48].

Para finalizar, é de salientar que os resultados obtidos pelo SVR dependem significativamente dos valores da constante de regularização C , margem ε , do tipo de função *kernel* e seus respectivos parâmetros. Desta forma, verifica-se que conforme é realizada a seleção dessas variáveis, obtêm-se funções que melhor ou pior se ajustam aos dados do problema analisado.

3.2.5 - Modelos regressivos e auto-regressivos

A previsão da potência elétrica utilizando métodos quantitativos pode ser feita através de vários modelos de regressão. A utilização de cada modelo depende basicamente do comportamento da série temporal que se deseja analisar [29].

Os métodos de séries temporais são baseados na suposição de que os dados possuem uma estrutura interna, como a autocorrelação, tendência ou variação sazonal. Portanto, os métodos de previsão baseados em séries temporais são capazes de detetar e explorar essa estrutura. Os métodos mais frequentemente utilizados são, ARMA (modelo auto-regressivo de médias móveis), ARIMA (modelo auto-regressivo integrado de média móvel), ARMAX (modelo auto-regressivo de médias móveis com variáveis exógenas) e o ARIMAX (modelo auto-regressivo integrado de média móvel com variáveis exógenas). Os modelos ARMA são normalmente utilizados para processos estacionários, enquanto que os modelos ARIMA são uma extensão dos ARMA a processos não estacionários [30].

3.2.5.a - Modelo auto-regressivo (AR)

Um modelo AR expressa uma série temporal, como se esta fosse uma função linear dos seus valores passados. Ou seja, uma variável dependente x_t segue um processo auto-regressivo de primeira ordem, quando o seu valor em um dado momento t apenas depende do seu próprio valor no período anterior ($t-1$) e de um termo aleatório (ruído branco), ε_t , não correlacionado com x_t , com média zero e variância constante [31]. A ordem de um modelo AR diz-nos quantos valores passados são incluídos.

Se a observação x_t é gerada pela média ponderada das p primeiras observações anteriores da variável, acrescida de um erro aleatório ε_t , então ela pode ser modelada por um processo AR(p) [31].

$$x_t = \phi_1 \cdot x_{t-1} + \phi_2 \cdot x_{t-2} + \dots + \phi_p \cdot x_{t-p} + \xi + \varepsilon_t \quad (3.7)$$

Onde:

- $\varepsilon_t = x_t - \hat{x}_t$ corresponde ao erro aleatório ou ruído branco;
- $\hat{x}_t$ é a estimativa de x_t ;
- ξ é um valor constante;
- ϕ_p são os coeficientes constantes auto-regressivos que descrevem como um valor corrente x_t que se relaciona com valores passados $x_{t-1}, x_{t-2}, \dots, x_{t-p}$.

A versão mais simples de um modelo AR é aquela em que x_t depende somente de x_{t-1} , de ε_t e de uma constante ξ . Neste caso diz-se que estamos perante um modelo auto-regressivo de primeira ordem, indicado por AR(1) [25].

$$x_t = \phi_1 \cdot x_{t-1} + \xi + \varepsilon_t \quad (3.8)$$

3.2.5.b - Modelo de média móvel (MA)

O método de média móvel é aquele onde o valor atual de uma série temporal x_t pode ser explicado através da soma ponderada dos ruídos anteriores, bem como de um ruído atual [31].

Se uma observação x_t é gerada pela média ponderada do valor presente e dos q primeiros valores passados, de um processo de ruído branco ε_t mais a média μ , então ela pode ser modelada por um processo MA(q) [31].

$$x_t = \mu + \varepsilon_t - \theta_1 \cdot \varepsilon_{t-1} - \theta_2 \cdot \varepsilon_{t-2} - \dots - \theta_q \cdot \varepsilon_{t-q} \quad (3.9)$$

Onde:

- $\varepsilon_t = x_t - \hat{x}_t$ é o erro aleatório ou ruído branco;
- $\hat{x}_t$ é a estimativa de x_t ;
- θ_q são os coeficientes de média móvel que descrevem como um valor x_t que se relaciona com valores passados $x_{t-1}, x_{t-2}, \dots, x_{t-q}$.

Em geral, a média móvel MA(q) usa dados passados estimados de um número q predeterminado de períodos, normalmente os mais recentes, para gerar a previsão. As médias móveis são indicadores denominados de seguidores de tendências. Estes indicadores possuem uma inércia natural, ou seja, não foram projetados para apontar reversões rapidamente [25].

3.2.5.c - Modelos auto-regressivo de média móvel (ARMA)

Se o processo estacionário apresentar características simultaneamente de um processo AR e de um processo MA, então pode ser modelado por um processo combinado ARMA. A ordem do modelo ARMA é representada dentro de parêntesis como sendo ARMA(p, q), onde p é a ordem do modelo auto-regressivo e q é a ordem do modelo de média móvel. Portanto, este modelo é caracterizado pelos seus p valores passados e pelos q erros aleatórios correntes e passados [25].

$$x_t = \phi_1 \cdot x_{t-1} + \dots + \phi_p \cdot x_{t-p} + \xi + \varepsilon_t - \theta_1 \cdot \varepsilon_{t-1} - \dots - \theta_q \cdot \varepsilon_{t-q} \quad (3.10)$$

Tanto a média como as condições de estacionariedade são dadas pela parcela do processo AR.

O ARMA(1,1) é o modelo mais simples que um processo desta natureza pode apresentar.

$$x_t = \phi_1 \cdot x_{t-1} + \xi + \varepsilon_t - \theta_1 \cdot \varepsilon_{t-1} \quad (3.11)$$

Na prática, os valores de p e q são geralmente menores que 2 para séries temporais estacionárias [31].

3.2.5.d - Modelo auto-regressivo integrado de média móvel (ARIMA)

São conhecidos também como Modelos Box-Jenkins univariados, em homenagem aos dois investigadores que mais contribuições fizeram ao nível das suas construções e aplicações [31].

Os modelos ARIMA compreendem:

- modelo auto-regressivo de ordem p , AR(p), usado quando há autocorrelação entre as observações;
- modelo de média móvel de ordem q , MA(q), usado quando há autocorrelação entre os resíduos;
- modelo auto-regressivo de média móvel, ARMA(p,q), usado quando há autocorrelação entre as observações e entre os resíduos;
- modelo auto-regressivo integrado e de média móvel, ARIMA(p,d,q), usado em séries não estacionárias.

O modelo ARIMA é um caso geral dos modelos propostos por Box e Jenkins, o qual é apropriado para descrever séries não estacionárias, ou seja, séries que não possuem média constante durante o período de análise, nas quais os parâmetros são quase sempre pequenos.

Os modelos ARIMA podem possuir termos auto-regressivos e podem ser integrados quando os seus dados não são estacionários. De modo a obter-se uma série estacionária, é necessário diferenciar d vezes a série original de dados. Para a série ser estacionária é necessário que a sua média e variância sejam constantes no tempo [31].

Estes modelos são muito importantes devido à sua natureza extrapolativa ou de carácter preditivo. A vantagem no caso de previsões, em relação aos modelos estruturais, é que nos modelos ARIMA as extrapolações não acumulam os erros de outras variáveis explicativas ao longo do processo. Para um bom ajuste do modelo ARIMA é necessário utilizar técnicas em que a estrutura residual seja um ruído branco, isto é, que o resíduo seja uma variável aleatória independente e identicamente distribuída [25].

3.2.6 - Metodologia para simulação da irradiância solar em dias de céu limpo

A intensidade da radiação solar que atinge a superfície terrestre depende de vários fatores como a posição solar, a distância entre o Sol e a Terra, a inclinação da superfície recetora, hora do dia e até mesmo da atenuação provocada pela atmosfera.

Nesta subsecção pode-se ver um método analítico, que através dos fatores mencionados acima nos permite calcular a radiação solar incidente e consequentemente o valor da produção.

3.2.6.a - Distância entre o Sol e a Terra

A quantidade e a intensidade de radiação solar que atinge a atmosfera da Terra depende da distância entre esta e o Sol. Como podemos verificar na Figura 3.6, a Terra gira em torno do Sol numa órbita elíptica [32]:




Figura 3.6 - Órbita em torno do Sol, adaptado [33].

Durante o decorrer do ano, a distância entre o Sol e a Terra pode variar entre $1,47 \times 10^8$ km e os $1,52 \times 10^8$ km. Esta distância, r , pode ser calculada através da equação (3.12),

$$r = r_0 \left[1 + 0,0017 \sin \left(\frac{360(d_n - 93)}{365} \right) \right] \quad (3.12)$$

onde d_n é o número de dias contados a partir do início do ano e r_0 é igual a $1,496 \times 10^8$ km, e representa a distância média do Sol à Terra. A constante r_0 é também normalmente designada como sendo uma unidade astronómica, 1 UA [32].

De forma a simplificar os cálculos matemáticos, é útil obtermos a distância e a excentricidade da órbita da Terra numa forma simples. Por esse motivo é utilizada uma expressão simplificada denominada de fator de correção de excentricidade.

$$\varepsilon_0 = \left(\frac{r_0}{r} \right)^2 = 1 + 0,033 \cos \left(\frac{360d_n}{365} \right) \quad (3.13)$$

3.2.6.b - Posição relativa Sol/Terra

A Terra gira uma vez por dia em torno do seu próprio eixo, o eixo polar, a uma velocidade praticamente constante. O eixo polar orbita em torno do sol, mantendo uma inclinação

constante de $23,45^\circ$ relativamente ao plano da elíptica. Essa inclinação é o que faz com que o Sol esteja mais alto no Verão e, por consequência, mais baixo no Inverno. É também a causa de haver mais horas de luz solar no Verão do que no Inverno. Na Figura 3.6 pode-se observar a órbita da Terra em torno do Sol, bem como o eixo polar inclinado [32].

É importante salientar que o ângulo entre o plano equatorial e uma linha reta traçada entre o centro da Terra e do Sol está em constante alteração. Este ângulo é conhecido como declinação solar δ , ver Figura 3.7. Apesar de ela ser diferente ao longo do dia, para os nossos propósitos ela é considerada constante, isto porque a diferença máxima da declinação ao longo de 24 horas é de apenas $0,5^\circ$ [32].




Figura 3.7 - Posição relativa da Terra em relação ao Sol ao meio dia, num dia de declinação negativa (Inverno no Hemisfério Norte, Verão no Hemisfério Sul), adaptado de [32].

A declinação solar δ pode ser calculada a partir da equação (3.14).

$$\delta = 23,45 \sin \left[\frac{360(d_n + 284)}{365} \right] \quad (3.14)$$

Os ângulos a norte do equador são considerados positivos, e a sul do equador negativos. Para o *equinócio de primavera* (21 de Março) e para o *equinócio de outono* (21 de Setembro), a linha entre o Sol e a Terra passa pelo equador, pelo que $\delta=0$ [32].

3.2.6.c - Equação do tempo

Devido à excentricidade da órbita terrestre, com a inclinação do eixo de rotação da Terra em relação à eclíptica, a velocidade orbital da Terra varia ao longo do ano. De modo a superar esta dificuldade foi preciso imaginar um “Sol fictício”, que produzia dias iguais durante todo o ano. Esse corpo, também chamado Sol médio, percorre sobre o equador celeste espaços iguais em tempos iguais, dando origem ao tempo solar médio, 24 horas.

A equação do tempo (equação (3.15)) descreve a diferença entre este tempo solar médio e o tempo solar verdadeiro (TSV) que varia consoante o lugar e o dia do ano [33].

$$ET_{minutos} = 229,18(0,000075 + 0,001868 \cos(\gamma) - 0,032077 \sin(\gamma) - 0,014615 \cos(2\gamma) - 0,040849 \sin(2\gamma)) \quad (3.15)$$

onde,

$$\gamma = \frac{2\pi}{365}(d - 1) \quad (3.16)$$

$$ET_{horas} = \frac{ET_{minutos}}{60} \quad (3.17)$$




Figura 3.8 - Diferença entre o tempo solar médio e o tempo solar verdadeiro ao longo um ano.

3.2.6.d - Ângulo horário

Como se sabe o planeta Terra está dividido em 24 meridianos, com origem no meridiano Greenwich, que está na longitude 0°. Estes meridianos dão origem aos fusos horários. Uma vez que o Sol demora 1 hora a percorrer 15° de longitude, é necessário aplicar um fator de correção da longitude em que este deverá ser somado ou subtraído ao tempo local.

A equação que nos permite calcular o tempo solar verdadeiro, é a equação (3.18).

$$TSV = TL + \frac{\lambda}{15} + ET_{horas} - AO \quad (3.18)$$

Onde:

- TL corresponde à hora local;
- ET corresponde à equação do tempo;

- AO é a hora de adianto ou atraso, caso aconteça, em função do fuso horário. Em Portugal estes valores são de 0 horas para o horário de Inverno e 1 hora para o horário de Verão; em Espanha é de 1 hora e 2 horas, para horário de Inverno e de Verão, respetivamente. A mudança de hora efetua-se adiantando os relógios de 60 minutos à 1 hora UTC (*Coordinated Universal Time*) do último domingo de Março e atrasando-os em 60 minutos à 1 hora UTC do último domingo de Outubro seguinte;
- $(\lambda/15)$ é o fator que relaciona a longitude local e a longitude do meridiano de Greenwich. De fazer notar que este valor é positivo para este de Greenwich e negativo para oeste e é múltiplo de 15.

Uma vez calculado o tempo solar verdadeiro pode-se prosseguir para o cálculo do ângulo solar. O ângulo horário solar varia de 15° por cada hora e será nulo ao meio-dia (12 horas) de cada dia e é considerado negativo no período da manhã e positivo no período da tarde, como podemos ver na equação (3.19).

$$w = 15 * (TSV - 12) \quad (3.19)$$

3.2.6.e - Posição solar sobre uma superfície horizontal

Para descrever a posição do Sol em relação a uma superfície horizontal na Terra, são necessários outros ângulos como a elevação solar α , o azimute solar ψ e a distância zenital θ [33].

Estes ângulos são mostrados na Figura 3.9.




Figura 3.9 - Ângulos que definem a posição solar, adaptado de [33].

O zénite é a direção vertical sobre o plano horizontal. A distância zenital é o ângulo entre o zénite e a direção dos raios provenientes do Sol. Esta ainda pode ser relacionada com a elevação solar através da equação (3.20).

$$90 - \alpha = \theta \quad (3.20)$$

A elevação solar é o ângulo entre o plano horizontal e a direção dos raios provenientes do Sol. O azimute solar é o ângulo formado entre a direção Sul e a projeção da linha Sol-Terra

sobre o plano horizontal. A elevação solar e o azimute solar podem ser calculados, respetivamente, através das equações (3.21), (3.22) e (3.23),

$$\alpha = \sin^{-1}[\sin \phi \sin \delta + \cos \phi \cos \delta \cos w] \quad (3.21)$$

$$\psi = \cos^{-1} \left[\frac{\sin \alpha \sin \phi - \sin \delta}{\cos \alpha \cos \phi} \right] \text{ para } w \geq 0 \quad (3.22)$$

$$\psi = -\cos^{-1} \left[\frac{\sin \alpha \sin \phi - \sin \delta}{\cos \alpha \cos \phi} \right] \text{ para } w < 0 \quad (3.23)$$

onde ϕ é a latitude geográfica do local.

3.2.6.f - Posição solar relativamente a um plano inclinado

Na maior parte das aplicações em engenharia é exigida a posição do Sol relativamente a um plano inclinado. A posição de uma superfície pode em geral ser descrita pela sua inclinação β , que representa o ângulo formado com a horizontal, e o azimute φ da superfície inclinada, que é dado pelo ângulo entre o Sul geográfico e a projeção da normal do plano inclinado no plano horizontal [32].




Figura 3.10 - Ângulo de incidência dos raios solares no plano inclinado, adaptado de [32].

O ângulo de incidência solar entre os raios do sol e a normal à superfície pode ser calculada pela equação (3.24).

$$\theta_s = \cos^{-1}[\sin(\delta) \sin(\varphi) \cos(\beta) - \sin(\delta) \cos(\varphi) \sin(\beta) \cos(w) + \cos(\delta) \cos(\varphi) \cos(\beta) \cos(w) + \cos(\delta) \sin(\varphi) \sin(\beta) \cos(\alpha) \cos(w) + \cos(\delta) \sin(\alpha) \sin(w) \sin(\beta)] \quad (3.24)$$

No caso da superfície inclinada estar orientada a Sul geográfico, $\alpha=0$, simplifica-se a equação (3.25), para:

$$\theta_s = \cos^{-1}[\sin(\delta) \sin(\phi - \beta) + \cos(\delta) \cos(\phi - \beta) \cos(w)] \quad (3.25)$$

3.2.6.g - Radiação solar terrestre

A radiação solar na superfície da atmosfera é designada de radiação extraterrestre. A variação da radiação extraterrestre deve-se essencialmente à variação da distância entre o Sol e a Terra e da atividade solar. O valor da radiação solar extraterrestre durante o ano varia entre 1307 (W/m^2) e 1393 (W/m^2), e é calculada a partir da equação (3.26) [34].

$$I_{on} = I_{sc} \left[1 + 0,033 \cos\left(\frac{360 \cdot d_n}{365}\right) \right] \quad (3.26)$$

I_{sc} é a constante solar, e tem um valor de 1367 W/m^2 .

Quando a radiação solar passa através da atmosfera terrestre é modificada pela sua interação com alguns componentes lá presentes. Alguns destes, como as nuvens, refletem a radiação, os gases existentes na atmosfera têm uma absorção significativa em várias bandas espectrais e, por fim, as gotículas de água e a poeira suspensa ainda causam a dispersão da radiação [32].

O resultado de todos estes processos é a decomposição da radiação solar incidente em duas componentes:

- radiação direta;
- radiação difusa.

A radiação direta é constituída por raios solares que não são refletidos nem dispersos, atingem a superfície numa linha reta direta desde o Sol. A radiação difusa é proveniente de todo o céu excepto do disco solar, ou seja, radiação refletida e dispersa. Aparte das duas categorias principais da radiação ainda temos a radiação albedo, que é a radiação refletida pelo solo [32].

Em dias de céu limpo, ao atravessar a atmosfera terrestre, a intensidade da radiação solar é reduzida devido à dispersão e absorção provocada pelos gases e poeira ali existentes. A radiação solar que chega à superfície da Terra é designada por radiação terrestre.




Figura 3.11 - Efeitos provocados pela atmosfera sobre a radiação solar.




Figura 3.12 - Trajetória dos raios solares ao passar pela atmosfera [35].

Como é perceptível na Figura 3.12, o máximo de radiação que atinge a superfície terrestre ocorre quando o sol está sobre a posição de zênite. É nesta posição que um raio solar percorre um menor caminho até atingir a superfície.

A massa de ar (AM) representa a proporção da atmosfera que um raio solar tem de atravessar até atingir a superfície da Terra. Esta extensão de caminho pode ser calculada através da equação (3.27) [32].

$$AM = \frac{1}{\cos(\theta)} \quad (3.27)$$

Para dias em que se verifique céu limpo, a radiação global no plano horizontal pode ser obtida pela equação (3.28) [32]:

$$G = I_{on} \times 0,7^{AM^{0,678}} \times \cos(\theta) \quad (3.28)$$

Concluída a análise da simulação da irradiância para dias de céu limpo, será necessário convertê-la para potência.

3.3 - Avaliação do desempenho dos modelos de previsão

Aumentar o valor da produção da energia eólica e solar através da melhoria do desempenho dos métodos de previsão é uma das prioridades na investigação destes recursos para os próximos anos. Os métodos de previsão ajudam a energia eólica, e mais recentemente a energia solar, a reforçar a sua posição em comparação com outras formas de produção de energia despacháveis.

Nos últimos anos têm surgido bastantes métodos de previsão. Por este motivo, existe a necessidade de utilizar uma metodologia padrão para a apresentação dos resultados relativamente à precisão de um método de previsão, a fim de ter uma ideia das vantagens e desvantagens do modelo analisado. A avaliação do desempenho do modelo de previsão pode

ser realizada por intermédio de indicadores estatísticos, e existem várias vertentes de análise do erro, porém não há consenso acerca dos critérios de erro a utilizar [40].

3.3.1 - Modelos de referência

Só vale a pena desenvolver uma ferramenta de previsão se esta for capaz de superar os modelos de referência, que são o resultado de considerações e não de esforços de modelação. Provavelmente, o método de referência mais utilizado na previsão da produção a partir da energia solar e eólica, bem como no campo meteorológico é a persistência. Este método afirma que, no futuro próximo, a produção elétrica será muito provavelmente igual à última medição registada [40].

$$\hat{P}_{(t+k|t)} = P_t \quad (3.29)$$

Apesar da sua simplicidade, este modelo é difícil de superar pelo menos nos primeiros instantes do horizonte temporal (e. g. 4 a 6 horas). Uma generalização do modelo da persistência consiste em substituir o último valor medido pela média dos n últimos valores medidos.

$$\hat{P}_{MA,n}(t+k|t) = \frac{1}{n} \sum_{i=0}^{n-1} P(t-i) \quad (3.30)$$

3.3.2 - Definição dos erros de previsão

3.3.2.a - Erro de previsão

Geralmente, dentro do campo da previsão de séries temporais, o erro de previsão é definido como sendo a diferença entre o valor real ($P_{(t+k)}$) e a prevista ($\hat{P}_{(t+k)}$). Uma vez que já se considera separadamente cada instante da previsão, o erro de previsão para o instante k é dado por [40]:

$$e_{(t+k|t)} = P_{(t+k)} - \hat{P}_{(t+k)} \quad (3.31)$$

Muitas vezes, é vantajoso introduzir o erro de previsão normalizado,

$$\epsilon_{(t+k|t)} = \frac{(P_{(t+k)} - \hat{P}_{(t+k)})}{P_{inst}} \quad (3.32)$$

onde P_{inst} corresponde à potência instalada.

É de salientar que, durante a explicação dos erros, N corresponde ao número total dos erros de previsão.

Todos os erros de previsão podem ser decompostos num erro sistemático μ_e e num erro aleatório ξ_e .

$$e = \mu_e + \xi_e \quad (3.33)$$

A avaliação do erro sistemático pode ser feita pela análise do *BIAS*; este é estimado como sendo o erro médio durante todo o período de avaliação, e é calculado para cada horizonte.

$$BIAS_k = \hat{\mu}_e(k) = \overline{e(k)} = \frac{1}{N} \sum_{t=1}^N e_{(t+k|t)} \quad (3.34)$$

Existem dois critérios para ilustrar o desempenho de uma previsão [40]:

- *MAE (Mean Absolute Error)*, em português o erro médio absoluto. Sendo que a expressão geral é dada pela equação (3.35):

$$MAE_k = \frac{1}{N} \sum_{t=1}^N |e_{(t+k|t)}| \quad (3.35)$$

- *RMSE (Root Mean Square Error)*, em português raiz do erro médio quadrático. Antes de apresentar o RMSE é conveniente introduzir o erro médio quadrático (MSE):

$$MSE_k = \frac{\sum_{t=1}^n (e_{(t+k|t)})^2}{N - p} \quad (3.36)$$

Sendo assim, a raiz do erro médio quadrático é dada pela equação (3.37):

$$RMSE_k = \sqrt{MSE} \quad (3.37)$$

$$RMSE_k = \sqrt{\frac{\sum_{t=1}^n (e_{(t+k|t)})^2}{N - p}} \quad (3.38)$$

É de salientar que tanto os erros sistemáticos como os erros aleatórios contribuem para o valor de RMSE.

Estatisticamente, os valores de $BIAS_k$ e do MAE_k estão associados a um primeiro momento do erro de previsão, enquanto que o valor de $RMSE_k$ está associado ao momento de segunda ordem e, portanto, à variância do erro de previsão.

Todos os erros de medição apresentados acima, podem ser calculados a partir do erro de previsão $e_{(t+k|t)}$ ou pelo seu valor normalizado $\epsilon_{(t+k|t)}$. É interessante utilizarmos as medidas de erro normalizadas, uma vez que produzem resultados independentemente da capacidade da central fotovoltaica ou do parque eólico.

Assim define-se os erros NMAPE (equação (3.39)) e NRMSPE (equação (3.40)):

- NMAE (*Normalize Mean Absolute Error*)

$$NMAE_k = \frac{\frac{1}{N} \sum_{t=1}^N |e_{(t+k|t)}|}{P_{inst}} \quad (3.39)$$

- NRMSPE (*Normalize Root Mean Square Error*):

$$NRMSE_k = \frac{\sqrt{\frac{\sum_{t=1}^n (e(t+k|t))^2}{N-p}}}{P_{inst}} \quad (3.40)$$

3.3.2.b - Comparação de modelos

A comparação de modelos pode ser interessante para destacar e quantificar o ganho da utilização de um modelo de previsão avançada, em detrimento do modelo de referência. Este ganho é representado como sendo uma melhoria em relação ao modelo de referência considerado [40],

$$Imp_{EC\ k}^{ref} = \frac{EC_k^{ref} - EC_k}{EC_k^{ref}} \quad (3.41)$$

onde o EC é o critério de validação considerado, que pode ser NMAE ou NRMSE.

Uma outra maneira de demonstrar a capacidade dos métodos de previsão, é calcular o coeficiente de determinação R^2 para cada instante no horizonte de previsão,

$$R^2(k) = \frac{MSE_k^{ref} - MSE_k}{MSE_k^{ref}} \quad (3.42)$$

onde MSE_k^{ref} representa o erro médio quadrático para modelo global, sendo que a média é estimada para os dados disponíveis.

3.4 - Modelos de cálculo da produção de um sistema fotovoltaico a partir da radiação solar

Durante a realização desta dissertação foram encontrados diversos métodos que permitem calcular a produção de um sistema fotovoltaico. Embora estes métodos tenham diferentes níveis de complexidade, muitos apresentam similaridades em termos de suposições feitas para calcular a produção de um sistema fotovoltaico. O objetivo desta secção não é apresentar uma análise exaustiva de todos métodos encontrados, mas sim descrever diferentes abordagens utilizadas.

O desempenho de um sistema FV conectado à rede elétrica resulta da performance dos diferentes componentes que o constituem que, por sua vez, são afetados por fatores climáticos. Sem considerar as limitações físicas de alguns dos componentes de uma central FV, uma das metodologias de cálculo mais simplistas apenas tem em conta a irradiância global incidente no painel. Neste modelo, a potência debitada pela central pode ser calculada através da equação (3.43) [36].

$$P = A \times f \times G \times \eta \times \eta_{inv} \quad (3.43)$$

Onde:

- P é a potência elétrica;
- A corresponde à área total do sistema PV;
- f é a fração em funcionamento da central PV;
- G é radiação solar;
- η é o valor da eficiência dos módulos utilizados;
- η_{inv} é o valor da eficiência do inversor utilizado.

A principal e única vantagem deste modelo é a sua simplicidade. Este modelo, em junção com o modelo de previsão da radiação solar em dias de céu limpo, permite ter de uma forma rápida uma estimativa preliminar do potencial de um sistema fotovoltaico a ser construído num dado local.

No artigo desenvolvido por Rahman et. al. [37], pode-se ver outro modelo que permite calcular a produção elétrica em dias de céu limpo. O modelo proposto é igual ao anterior, sendo que considera que a fração da central FV em funcionamento é sempre $f=1$.

No entanto, de modo a que este modelo seja capaz de realizar previsões mais eficazes para dias com nuvens e de chuva, foi estudada a performance do painel fotovoltaico perante diferentes condições climáticas. Durante vários dias foi registada a previsão do estado do tempo através do modelo 1-day-ahead, como também se procedeu à medição da produção produzida pelo painel fotovoltaico. De seguida calculou-se o rácio (η) entre o valor medido de produção do painel fotovoltaico para diferentes condições climáticas e a produção do painel fotovoltaico estimada para dia de céu limpo.

Na Tabela 3.3 apresentam-se os valores médios do rácio, o que permite estimar a produção solar FV em qualquer condição climática, pela multiplicação da produção estimada para dia de céu limpo pelo rácio respetivo calculado previamente.

Tabela 3.3 - Rácio (η) para diferentes condições climáticas.

Previsão do estado do tempo	<i>Sol</i>	<i>Núvens</i>	<i>Chuva</i>	<i>Neve</i>
Valor médio do η (%)	80	35	13	18

É de salientar que os rácios calculados apenas podem ser utilizados para realizar previsões para o local onde estes foram estimados.

No modelo desenvolvido por Yona et. al. [38], a previsão de produção de potência de sistemas fotovoltaicos para um horizonte temporal de 24 horas é efetuada através de redes neurais. Neste artigo os autores tiveram em conta a radiação de cada mês e confirmaram a validade do uso de RN para prever radiação através de simulações por computador. O método proposto utilizou dados meteorológicos e não requereu cálculos complicados nem modelos matemáticos.

Após uma análise comparativa entre os valores medidos e os previstos, foi possível encontrar um método de cálculo da produção de energia do sistema FV. O método proposto pode ser visto na equação (3.44),

$$P = \eta \times A \times G \times [1 - 0,005 \times (t_0 + 25)] \quad (3.44)$$

onde:

- P é a potência elétrica;
- η é a eficiência da célula FV;
- A corresponde à área da instalação;
- G corresponde à radiação solar;
- t_0 é a temperatura ambiente.

Neste modelo assume-se que o total da radiação solar incidirá sobre célula FV e instalação solar, não tendo em consideração o ângulo de incidência solar nem o ângulo de inclinação da instalação solar. Como a área da instalação solar é constante, a potência é função da temperatura do ar, da insolação e da eficiência do painel.

No artigo desenvolvido por Fuentes et. al. [39], são apresentados alguns modelos, para o cálculo da potência gerada por um painel FV. O modelo mais simples apenas tem como entrada a irradiação global no plano do painel, e o valor da produção FV é calculada através da equação (3.45).

$$P_M = \frac{G_i}{G_i^*} \times P_M^* \quad (3.45)$$

Onde:

- P_M é a potência elétrica do módulo FV;
- G_i corresponde à irradiância global;
- G_i^* corresponde à irradiância global nas condições STC (1000 W/m²);
- P_M^* é a potência do painel para as condições STC.

Para uma central fotovoltaica constituída por n módulos, a produção é calculada multiplicando a equação (3.45) por n .

Ainda neste artigo é proposto um modelo ligeiramente mais complexo, mas que é baseado no modelo anterior. Esse modelo é apresentado na equação (3.46),

$$P_M = P_M^* \times \frac{G_i}{G_i^*} \times [1 - \gamma(T_C - 25)] \quad (3.46)$$

onde:

- γ corresponde a um parâmetro que traduz a variação da potência devido à variação da temperatura da célula. Embora este valor varie entre uma determinada gama, foram atingidos bons resultados utilizando $\gamma = (-0,0035 \text{ } ^\circ\text{C})^{-1}$;
- T_c é a temperatura da célula.

A temperatura da célula pode ser obtida através da equação (3.47),

$$T_c = T_{amb} + G_i \times \frac{NOCT - 20}{800} \quad (3.47)$$

onde:

- T_{amb} corresponde à temperatura ambiente;
- NOCT representa a temperatura que a célula atinge em condições de circuito aberto, a uma temperatura ambiente de 20°C , coeficiente AM de 1,5, condições de irradiância de 800 W/m^2 e velocidades de vento inferiores a 1 m/s .

O modelo de previsão desenvolvido por Lorenz et. al. [41] utiliza modelos NWP com previsões da radiação solar fornecidos pelo *European Centre for Medium-Range Weather Forecasts (ECMWF)*. O modelo executado pela *ECMWF* fornece previsões da radiação solar e parâmetros das nuvens para um horizonte de até 3 dias. Estas previsões têm uma resolução temporal de 3 horas e uma resolução espacial de $25 \text{ km} \times 25 \text{ km}$.




Figura 3.13 - Modelo de previsão local de um sistema fotovoltaico, adaptado de [41].

A Figura 3.13 exemplifica o modelo utilizado para a previsão da produção fotovoltaica a partir de previsões fornecidas pela *ECMWF*, em cada etapa, são especificadas informações adicionais relativamente aos sistemas FV.

Num primeiro instante, as previsões dos modelos NWP fornecidos pelo *ECMWF* são refinadas através de um modelo *MOS (Model Output Statistics)*. Desta forma, as previsões, que até então tinham uma resolução temporal de 3 horas, são transformada em previsões para uma escala horária a nível local. Após este processo, as previsões da irradiância no plano horizontal são convertidas para o plano dos painéis, através do conhecimento da sua localização e orientação. Finalmente, a partir das previsões da irradiância no plano inclinado, das características do parque fotovoltaico e da aplicação de um modelo de simulação FV, é possível prever a produção elétrica. Os resultados obtidos por este modelo para um período de seis dias são ilustrados na Figura 3.14.




Figura 3.14 - Desempenho do modelo de previsão para um local específico, para 6 dias de Maio de 2007 [41].

Neste artigo é realizada uma análise detalhada da precisão das previsões da produção FV para um conjunto de 11 sistemas FV.

Para sistemas individuais, a análise do desempenho resultou num $rRMSE=49\%$ (valor relativo da raiz do erro médio quadrático) para o mês de Abril, onde a maior parte dos dias foram nublados. Para Julho, para os dias com céu limpo, obteve-se um erro inferior, $rRMSE=30\%$.

Esta análise foi ainda complementada com a avaliação das previsões da irradiância no plano inclinado para local do sistema FV, e uma análise das previsões da irradiância no plano horizontal para as estações meteorológicas localizadas na mesma região. Os erros de previsão da produção FV estão intimamente relacionados com os erros da previsão da irradiância inclinada, pelo que os seus valores são semelhantes. A qualidade das previsões da irradiação horizontal com um $rRMSE=44\%$ para Abril e um $rRMSE=28\%$ para Julho, é ligeiramente melhor que a qualidade das previsões realizadas da irradiância no plano inclinado. Os erros de previsão são amplificados pela conversão da irradiância para o plano inclinado.

Pela análise conjunta dos 11 sistemas FV o erro foi reduzido para $rRMSE=39\%$ em Abril e para $rRMSE=22\%$ em Julho.

Capítulo 4

Construção do modelo de previsão

4.1 - Introdução

Vários modelos utilizados na previsão do recurso solar foram propostos no capítulo anterior. Uns recorrem às previsões dos modelos de previsão numéricos das variáveis meteorológicas como dados de entrada, de modo a preverem a produção solar, outros simplesmente utilizam métodos de regressão para a previsão do mesmo. A presente dissertação tem como objetivo o desenvolvimento de um modelo de previsão que permita antever a produção solar para um curto prazo de tempo.

Este capítulo explica, os processos utilizados na construção dos modelos de previsão da produção de uma central fotovoltaica. Para além da descrição do modelo, serão estudadas e justificadas a importância das diferentes variáveis utilizadas para alimentar as várias etapas desta metodologia.

Quando avaliamos o desempenho dos modelos de previsão a utilização de um modelo de referência é bastante útil, especialmente quando se comparam resultados de diferentes estudos. Um modelo de previsão é desenvolvido e utilizado como modelo de referência. A avaliação do desempenho dos modelos é inspirada na estrutura sugerida em [40]. Estes métodos de avaliação podem ser aplicados diretamente às previsões da energia solar.

4.2 - Caso de estudo

A central FV utilizada como caso de estudo, fica situada em Villares del Saz (Cuenca), Espanha. É constituída por 19440 módulos FV monocristalinos de 175 W, perfazendo uma potência instalada de 3406 kW. Os módulos estão montados sobre uma estrutura fixa, orientados para Sul com um ângulo de 34° de inclinação.



Figura 4.1 - Parque FV em estudo, Villares de Saz.

4.3 - Tipos de dados utilizados nos modelos de previsão

Os sistemas de previsão desenvolvidos são baseados em modelos físicos e no desenvolvimento de modelos estatísticos (regressivos). Na construção dos modelos utilizaram-se dois tipos de dados:

- dados NWP (previsões meteorológicas para a localização do parque FV);
- dados históricos da produção horária do parque FV.

Os dados NWP foram fornecidos pelo grupo de investigação da Faculdade de Ciências da Universidade de Lisboa e foram obtidos a partir do modelo de mesoscala WRF para um período desde 01-01-2008 até 30-09-2011. As previsões foram efetuadas duas vezes por dia (00:00 horas UTC e 12:00 horas UTC) para um horizonte temporal de 72 horas. As variáveis meteorológicas previstas pelo modelo são as seguintes:

- *Shortwave* (radiação no comprimento de onda curta) à superfície (SW);
- *Longwave* (radiação no comprimento de onda longa) à superfície (LW);
- Temperatura ambiente aos 2 metros (T2);
- Componente U do vento aos 10 metros (U10);
- Componente V do vento aos 10 metros (V10);
- Intensidade do vento (WSPD);
- Direção do vento (WDIR).

Os dados históricos da produção horária medida foram fornecidos pela Novenergia II, empresa proprietária pela central FV analisada, para um período desde 08-06-2010 até 02-11-2011. Infelizmente não foram fornecidos dados relativamente ao mês de Janeiro de 2011.

É importante salientar que, o software utilizado para o desenvolvimento e teste dos modelos de previsão foi, excetuando raras exceções, o MATLAB R2009b.

4.3.1 - Sincronização dos dados

A fim de utilizar dados na mesma referência de tempo, todos foram transferidos para o tempo UTC (*Coordinated Universal Time*). Os dados NWP já se encontram em UTC, pelo que não é necessário fazer qualquer alteração. Nos dados históricos da produção, como foram registados à hora espanhola, é necessário fazer 2 alterações para transferir a hora para UTC:

- CEST (*Central European Summer Time*) para CET (*Central European Time*). No período de Verão o relógio é adiantado 1 hora e por isso nessa ocasião é utilizada a hora em CEST. Para sincronizar a hora neste período, é subtraída 1 hora à hora local entre 28-03-2010 01:00 UTC e 31-10-2010 01:00 UTC, e entre 27-03-2011 01:00 UTC e 30-10-2011 01:00 UTC.
- CET para UTC. É subtraída 1 hora à hora local.

4.3.2 - Estandarização

Os dados de entrada dos modelos de aprendizagem automática foram estandarizados, ou seja, as variáveis com escalas diferentes são expressas numa determinada gama de valores, neste caso entre $[-1;1]$. Concretamente, neste trabalho adotou-se como método de estandarização de dados o Método Min-Max, pois segundo [42] este é um dos melhores métodos para esse efeito. O método utilizado para a estandarização dos valores denomina-se Min-Máx. Esta técnica é aplicada uma vez que são conhecidos os valores máximos e mínimos das variáveis. Sendo min_a e max_a os valores mínimos e máximos do conjunto de dados x , os valores estandarizados x' na escala $[min_A ; max_A]$ são obtidos através da seguinte expressão.

$$x' = \frac{x - min_a}{max_a - min_a} \times (max_A - min_A) + min_A \quad (4.1)$$

O processo inverso, que transforma a escala das variáveis estandarizadas na escala real é designado por destandarização, sendo expresso pela seguinte equação:

$$x = \frac{x' - min_A}{max_A - min_A} \times (max_a - min_a) + min_a \quad (4.2)$$

Nos dados históricos da produção horária medida, de modo a assegurar que todas as previsões da produção são positivas, foi aplicada uma transformação à série de dados. Como podemos ver no artigo escrito por Bremnes [43], é utilizada uma transformação nos dados da produção que coloca os seus valores entre $[0 e P_{max}]$. A transformação utilizada pode ser vista na equação (4.3).

$$P_{trans} = \text{sen} \left(\sqrt{\frac{P}{P_{max}}} \right) \quad (4.3)$$

Depois de obtidas as previsões, é necessário voltar a aplicar uma nova transformação à série de valores previstos, de forma a obtermos a produção na mesma escala em que foi fornecida. Para tal utiliza-se a equação (4.4):

$$\hat{P} = \text{sen}^{-1}(\hat{P}_{trans})^2 \times P_{max} \quad (4.4)$$

4.4 - Estrutura dos modelos de previsão da produção da central FV

O modelo global de previsão da produção da central FV, como já foi dito na secção anterior, é baseado na utilização de modelos físicos e no desenvolvimento de modelos estatísticos (ver Figura 4.2), onde as várias colorações (vermelho, verde e laranja) representam os sistemas de previsão desenvolvidos.

Na Figura 4.2 pode-se ver a estrutura de cada modelo desenvolvido. Cada um destes modelos será comparado com um modelo de referência, de forma a analisar a sua performance. Na implementação da previsão da produção global utilizam-se modelos de aprendizagem computacional (Redes Neurais e *Support Vector Machines*) bem como modelos estatísticos. Os modelos de previsão desenvolvidos apresentam previsões horárias para um horizonte temporal de 72 horas.




Figura 4.2 - Estrutura dos modelos desenvolvidos.

4.5 - Modelo de referência

Para comparar o desempenho dos modelos de previsão desenvolvidos é necessário um modelo que sirva de referência. Um modelo de referência também pode ser utilizado para comparar o desempenho de modelos desenvolvidos em diferentes estudos. Inicialmente o modelo utilizado na presente dissertação é a persistência pura, que apesar da sua simplicidade, este modelo é difícil de superar pelo menos nos primeiros instantes do horizonte temporal (2 a 4 horas).

Como foi descrito na secção 3.4.1, a previsão a partir do modelo da persistência pura consiste em assumir que a produção FV não sofre alterações nos instantes futuros, ou seja, o valor da produção prevista toma o mesmo valor que no instante anterior à previsão como pode ser visto na equação 3.29.

Embora este modelo seja muito utilizado como referência na previsão da produção eólica, não pode ser diretamente aplicado à previsão solar. Neste tipo de previsões a persistência pura apresenta uma forte limitação: durante o período da noite não existe radiação solar, logo não haverá produção elétrica a partir dos sistemas FV. Portanto, se efetuarmos uma previsão em $\hat{P}_{(t=12)}$ (12:00 horas UTC) através do modelo da persistência, este lançará previsões da produção iguais à produção do instante anterior, ou seja, assume que nas próximas 72 horas a potência elétrica será igual a $P_{(t=11)}$. É fácil de entender que esta suposição está completamente errada pois sabe-se que não pode haver produção elétrica FV durante a noite.

Foi necessário adotar outro modelo de referência, tendo-se optado pelo modelo paramétrico de estimativa da radiação solar para condições céu limpo descrito no capítulo 3, ao qual se denominou de “persistência geométrica”.

Considerando a localização geográfica e as características técnicas do parque fotovoltaico em estudo, o modelo da persistência geométrica é desenvolvido recorrendo às equações do modelo de previsão da radiação solar em condições de céu limpo descritas na secção 3.2.5, permitindo desta forma estimar a radiação solar no plano inclinado. Esta metodologia consiste na determinação das seguintes variáveis:

- Declinação solar (δ);
- Ângulo solar (ω);
- Elevação solar (α);
- Distância zenital (θ);
- Azimute solar (ψ);
- Inclinação do painel (β);
- Azimute da superfície inclinada (φ);
- Ângulo de incidência solar (θ_s);
- Radiação solar extraterrestre (I_{on});
- Massa de ar (AM);
- Radiação global no plano inclinado (G).

A Figura 4.3, ilustra a evolução diária da irradiação solar no plano inclinado dos módulos da central FV, ao longo do ano 2011.




Figura 4.3 - Irradiância no plano inclinado, durante o ano de 2011.

Concluídos os cálculos referentes à irradiação solar, esta pode então ser convertida em potência elétrica. A função utilizada para a conversão, foi a seguinte.

$$P_M = \frac{G_i}{G_i^*} \times P_M^*$$

Onde:

- P_M é a potência elétrica do módulo FV;
- G_i corresponde à irradiância global;
- G_i^* corresponde à irradiância global nas condições STC (1000 W/m²);
- P_M^* é a potência do painel para as condições STC.




Figura 4.4 - Produção prevista através do modelo da persistência pura e persistência geométrica, no instante $t=12$.

Como podemos ver pela Figura 4.4 e Figura 4.3, o modelo da persistência geométrica afirma que apenas haverá produção elétrica nas horas em que existe radiação solar. Por outro lado, o modelo da persistência pura assume que a produção elétrica será igual a 2533,8 kW durante as próximas 72 horas. Sendo assim, daqui para a frente o modelo de referência utilizado será o modelo da persistência geométrica, pois é este que melhor se ajusta às condições reais.

Na Figura 4.5 e Figura 4.6, podemos ver dois exemplos da aplicabilidade do modelo persistência geométrica.




Figura 4.5 - Comparação da produção prevista e da produção medida para o dia 21 de Julho de 2010.




Figura 4.6 - Comparação da produção prevista e da produção medida para o dia 21 de Dezembro de 2010.

Como se pode verificar através da Figura 4.5 e Figura 4.6, para um típico dia de Verão, em que se verificam condições de céu limpo, o modelo da persistência geométrica apresenta uma boa aproximação entre a produção prevista e a produção real. No entanto, para um dia típico de Inverno, claramente afetado pela presença de nebulosidade, a aproximação do modelo da persistência geométrica é bastante deficiente.

4.6 - Modelos estatísticos

Como foi referido no capítulo 3, a previsão da produção a injetar na rede utilizando métodos quantitativos pode ser efetuada através de vários modelos de regressão. A utilização de cada modelo depende basicamente do comportamento da série temporal que se deseja analisar. Os métodos de séries temporais são baseados na suposição de que os dados possuem uma estrutura interna, como a autocorrelação, tendência ou variação sazonal. Estes métodos são capazes de detetar e explorar essa estrutura.

De forma a analisar corretamente uma série de dados, a sua visualização gráfica é muito importante.

O primeiro passo reside na seleção do modelo. A seleção consiste em especificar a estrutura adequada (AR, MA, ARMA ou ARIMA), bem como a ordem do modelo. Por vezes a identificação do modelo é feita através dos gráficos da autocorrelação (ACF) e autocorrelação parcial (PACF). Outras vezes a identificação é efetuada através de um processo iterativo, que consiste em experimentar diversas estruturas e ordens até se encontrar a melhor configuração.

A função de autocorrelação (ACF) é definida como a correlação entre uma série x_t e ela mesma, atrasada de k passos ou *lags*.

A Figura 4.7 e a Figura 4.8 mostram a série de produção medida do parque fotovoltaico em estudo. As retas horizontais azuis identificadas no gráfico da Figura 4.7 e da Figura 4.8 representam limites de um intervalo de confiança de 95%.




Figura 4.7 - Gráfico de Autocorrelação (ACF) da série da produção elétrica medida.




Figura 4.8 - Gráfico de Autocorrelação Parcial (PACF) da série da produção elétrica medida.

As análises da autocorrelação (Figura 4.7) e autocorrelação parcial (Figura 4.8) mostram uma predominância da sazonalidade diária sobre as demais. Nota-se uma maior correlação com os termos atrasados (*lags*) de até 24 horas (diária), um pouco em torno dos de 48, das 72 e 168 horas (semanal). Devido à presença de sazonalidade, esta componente necessita de ser modelada para se obter um modelo mais fidedigno. Para tal, recorre-se a um ARIMA sazonal, também conhecidos como $SARIMA_{(p,d,q) \times (P,D,Q)_s}$, sendo s o período correspondente à sazonalidade. Para o caso estudado s é igual a 24 horas.

Tendo em conta todos estes aspetos, pode-se iniciar o processo de estimativa das ordens do SARIMA. Para tal recorreu-se ao software *R*, que estima automaticamente qual é o melhor modelo para a série em análise. O $SARIMA_{(4,1,4) \times (8,0,5)_{24}}$ foi o modelo selecionado.

Uma vez que o MATLAB R2009b não está devidamente otimizado para operar com modelos SARIMA, foi necessário transformar o modelo SARIMA num ARMA. A função utilizada para a conversão é descrita na equação (4.5):

$$SARIMA_{(p,d,q) \times (P,D,Q)_s} = ARMA_{(p+P \times s + d + s \times D, q + s \times Q)} \quad (4.5)$$

O modelo resultante foi um $ARMA_{(197,124)}$. No entanto, como este modelo ainda apresenta um elevado grau de complexidade, foi necessário recorrer a modelos mais simples. Foram selecionados três novos modelos:

- $SARIMA_{(4,1,4) \times (1,0,1)_{24}}$, correspondente a um $ARMA_{(29,28)}$;
- $SARIMA_{(4,1,0) \times (7,0,0)_{24}}$, correspondente a um $ARMA_{(173,0)}$, ou seja, um $AR_{(173)}$;
- $SARIMA_{(4,1,0) \times (1,0,0)_{24}}$, correspondente a um $ARMA_{(29,0)}$, ou seja, um $AR_{(29)}$;

4.6.1 - ARMA

Um modelo ARMA, apresenta características simultaneamente de um processo AR e de um processo MA. Este modelo é caracterizado pelos seus p valores passados e pelos q erros aleatórios correntes e passados. Conforme mostrado no capítulo 3, um modelo ARMA pode ser representado pela equação (3.10).

Uma vez selecionada a estrutura do modelo, bem como as suas ordens, o próximo passo consiste em estimar os respetivos coeficientes deste modelo. Os coeficientes do processo AR podem ser estimados através do método dos mínimos quadrados. A estimação dos parâmetros do processo MA necessita normalmente de um método de iteração mais complexo.

Na prática, estimar os coeficientes é bastante mais simples, já que estes podem ser calculados através de um programa computacional. Utilizando a função ARMAX disponível no MATLAB R2009b, é possível calcular os coeficientes ϕ_p (coeficientes do AR) e θ_q (coeficientes do MA) do modelo ARMA. Estes coeficientes, e a respetiva função do modelo ARMA, podem ser vistos no Anexo A.1.

É importante salientar, que para este modelo os coeficientes foram estimados para a série de dados da produção não transformada, ou seja, não foi aplicada a transformação descrita pela equação (4.3). Por este motivo, as previsões da potência por vezes apresentavam valores negativos, pelo que, sempre que tal se verificou a potência foi alterada para zero.

Se os coeficientes fossem estimados para a série transformada, na prática, estes pouco ou nada se diferenciariam dos calculados. A desvantagem de se utilizar a série não transformada prende-se ao facto de o modelo ARMA desenvolvido não ser aplicável a outras centrais solares, sendo exclusivo da central em estudo.

4.6.2 - AR

Como foi descrito no capítulo 3, se a observação x_t é gerada pela média ponderada das p primeiras observações anteriores da variável, acrescida de um erro aleatório ε_t , então ela pode ser modelada por um processo AR(p). Este tipo de modelo pode ser representado pela equação (3.7).

Uma vez mais, com o auxílio da função ARMAX existente no MATLAB R2009b, é possível calcular os coeficientes ϕ_p dos modelos AR. Os coeficientes, e a respetiva função dos modelos AR podem ser vistos no Anexo A.2 e A.3.

Ao contrário do modelo ARMA, os coeficientes do modelo AR₍₂₉₎ e AR₍₁₇₃₎, foram estimados para a série de dados da produção transformada.

4.7 - Modelos de aprendizagem automática

A RN é uma vertente da inteligência artificial e apresenta-se, na atualidade, como uma ferramenta muito poderosa e frequentemente utilizada em aplicações que requerem inteligência artificial.

A grande desvantagem deste tipo de modelos consiste na necessidade de se dispor de um grande conjunto de dados para efetuar o processo de aprendizagem. Outra desvantagem está

relacionada com o esforço computacional necessário no processo de treino, caso estes modelos sejam compostos por um elevado número de entradas. No entanto, apesar do processo de treino ser lento, o processo de previsão é muito rápido, constituindo esta uma condição primordial num sistema de previsão.

4.7.1 - Rede neuronal

As RN são constituídas por uma camada de entrada, uma ou mais camadas escondidas e uma camada de saída. Estas podem apresentar na sua constituição vários neurónios que se encontram distribuídos na ou nas camadas escondidas.

Nesta dissertação as RN serão desenvolvidas em duas fases:

- 1ª fase, as RN utilizam apenas as variáveis meteorológicas previstas pelo modelo NWP como conjunto de entrada. Esta fase tem como objetivo encontrar as variáveis explicativas, ou seja, as que mais influência têm no valor da produção FV;
- 2ª fase, serão adicionadas outras variáveis ao conjunto de entrada, na expectativa de melhorar a performance da rede neuronal.

4.7.1.a - Arquitetura do modelo RN

A Figura 4.9 apresenta, de uma forma geral, a arquitetura dos modelos de previsão a partir das RN. Este modelo é caracterizado por realizar previsões da potência elétrica através de dados de previsões meteorológicas previstas pelo modelo NWP, juntamente com a possível adição de variáveis que possam ser relevantes.




Figura 4.9 - Arquitetura do modelo de previsão a partir das RN.

As RN desenvolvidas são do tipo *feedforward*, isto é, funcionam de forma progressiva e sem realimentação (sem informação adicional acerca dos processos posteriores). As RN são treinadas por retropropagação (*backpropagation*), que é o método de aprendizagem supervisionada mais utilizado. Este método de treino consiste em apresentar-se à rede um determinado exemplo, verificando-se a saída da rede. Esta saída é então comparada à saída esperada, obtendo-se assim um erro. Calcula-se o gradiente desse erro em relação aos valores

sinápticos da camada de saída, obtendo-se assim o erro da saída da penúltima camada, propagando para trás o erro (origem do nome *backpropagation*) por todas as camadas de conexões. A seguir apresenta-se mais um exemplo (pode ser o mesmo repetido) e continua-se o processo até que o erro seja menor que uma tolerância predefinida. Este tipo de treino baseia-se num algoritmo que generaliza a aplicação do método dos mínimos quadrados à RN. O algoritmo utilizado é o de Levenberg-Marquardt (LM) que é uma aproximação ao método de Newton; este algoritmo é caracterizado por ser mais eficiente que o último, no entanto também exige maior poder computacional [44, 45].

Configurar a estrutura das RN consiste em definir o número de camadas escondidas, assim como o número de neurónios dessas camadas. Segundo o teorema de *Kolmogorovs Superposition* [46], a utilização de uma só camada escondida é suficiente. As camadas de entrada e de saída vão apresentar um número de neurónios igual ao número de variáveis de entrada e de saída, respetivamente. Para a camada escondida não existe uma metodologia que defina um número ideal, embora um número excessivo possa provocar *overfitting*, *Kolmogorov* [46] defende que, se a camada intermédia for constituída por $2n+1$ neurónios, onde n é o número de variáveis de entrada, então a RN pode aproximar qualquer função contínua do tipo $f: [0,1]^n \rightarrow \mathcal{R}$.

A função de ativação dos neurónios utilizada é *Tan-Sigmoid Transfer Function*, e é dada pela expressão:

$$f(x) = \frac{2}{1 + \exp(-2x)} - 1 \quad (4.6)$$

4.7.1.b - 1ª Fase

Nesta primeira fase foi necessário escolher dentro das variáveis meteorológicas previstas pelo modelo NWP quais as variáveis explicativas. Para isso, cada uma das variáveis foi inserida individualmente na camada de entrada da RN, com o objetivo de verificar quais as que tinham um maior coeficiente de correlação (R). Como nesta fase apenas se queria selecionar as variáveis mais relevantes, apenas se utilizou os dados NWP com previsões efetuadas às 00:00 UTC.

O conjunto de dados inserido na RN foi de 1 ano (10-06-2010 até 10-06-2011), dividido internamente em 70% para treino, 15% para validação e 15% para teste.

Tabela 4.1 - Correlação das variáveis NWP.

	<i>SW</i>	<i>LW</i>	<i>T2</i>	<i>U10</i>	<i>V10</i>	<i>WSPD</i>	<i>WDIR</i>
<i>R</i>	0,574	0,014	0,150	0,135	0,232	0,109	0,255

Como podemos verificar na Tabela 4.1, de todas as variáveis NWP a que apresenta menor correlação é *LW*, ou seja, é a variável menos influente no valor da produção elétrica. Como seria de esperar, *SW* (radiação no comprimento de onda curta à superfície) que é de facto a radiação global incidente, é a variável com maior coeficiente de correlação.

De seguida, e uma vez que U10 e V10 não são nada mais do que a decomposição do vetor WSPD nas componente x e y , foram criados dois arranjos distintos em que a camada de entrada era constituída por apenas variáveis relacionadas com o vento, com o objetivo de verificar qual dos dois seria o melhor.

No primeiro arranjo as variáveis utilizadas no conjunto de entrada foram U10, V10 e WDIR, sendo que no outro arranjo o conjunto de entrada era constituído por WSPD e WDIR. Em ambos os casos a produção elétrica é a saída desejada. Mais uma vez, recorreu-se ao coeficiente de correlação, para encontrar a melhor combinação.

Tabela 4.2 - Seleção das variáveis relacionadas com o vento.

	<i>U10, V10 e WDIR</i>	<i>WSPD e WDIR</i>
<i>R</i>	0,354	0,337

Analisando a Tabela 4.2 conclui-se que o arranjo das variáveis U10, V10 e WDIR apresenta um desempenho superior ao arranjo constituído por WSPD e WDIR. Sendo assim, WSPD, à imagem de LW, também será descartada.

Finalizada a seleção das variáveis explicativas, foi criada uma tabela de verdade com o intuito de encontrar o conjunto de entrada ideal. Para a construção da tabela de verdade, numa primeira instância, as variáveis começam por ser testadas duas a duas, de seguida são testadas três a três, etc., até obtermos a combinação perfeita. Como nesta etapa apenas se pretende encontrar o melhor arranjo de variáveis, mais uma vez só foram utilizados os dados NWP com as previsões efetuadas às 00:00 UTC. O conjunto de dados inserido é o já considerado anteriormente (10-06-2010 até 10-06-2011).

Tabela 4.3 - Tabela de verdade das variáveis relevantes.

<i>SW</i>	<i>T2</i>	<i>U10</i>	<i>V10</i>	<i>WDIR</i>	<i>R</i>	<i>MSE</i>
1	1	0	0	0	0,599	4,73x10 ⁷
1	0	1	0	0	0,622	4,96x10 ⁷
1	0	0	1	0	0,611	4,75x10 ⁷
1	0	0	0	1	0,627	4,88x10 ⁷
0	1	1	0	0	0,164	7,51x10 ⁷
0	1	0	1	0	0,275	7,02x10 ⁷
0	1	0	0	1	0,324	6,91x10 ⁷
0	0	1	1	0	0,352	6,68x10 ⁷
0	0	1	0	1	0,340	6,75x10 ⁷
0	0	0	1	1	0,302	6,97x10 ⁷
1	1	1	0	0	0,605	4,82x10 ⁷
1	1	0	1	0	0,627	4,69x10 ⁷
1	1	0	0	1	0,619	4,63x10 ⁷
1	0	1	1	0	0,608	4,72x10 ⁷
1	0	1	0	1	0,637	4,71x10 ⁷
1	0	0	1	1	0,630	4,54x10 ⁷
0	1	1	1	0	0,342	6,76x10 ⁷
0	1	1	0	1	0,327	6,85x10 ⁷
0	1	0	1	1	0,365	6,62x10 ⁷
0	0	1	1	1	0,349	6,64x10 ⁷
1	1	1	1	0	0,628	4,47x10 ⁷
1	1	1	0	1	0,638	4,77x10 ⁷
1	1	0	1	1	0,624	4,73x10 ⁷
1	0	1	1	1	0,638	4,58x10 ⁷
0	1	1	1	1	0,372	6,77x10 ⁷
1	1	1	1	1	0,636	4,54x10 ⁷

Como podemos constatar através da Tabela 4.3, existem dois arranjos de variáveis que obtiveram o mesmo valor de *R* (*SW*, *T2*, *U10* e *WDIR*) e (*SW*, *U10*, *V10* e *WDIR*). No entanto, como o segundo arranjo tem um *MSE* (erro médio quadrático) inferior, este seria a melhor escolha.

Contudo, esperava-se que o arranjo que inclui todas as variáveis (*SW*, *T2*, *U10*, *V10* e *WDIR*) tivesse um desempenho melhor que os restantes, mas como se pode verificar na Tabela 4.3 este obteve um *R* ligeiramente inferior ao arranjo descrito no parágrafo anterior. No

entanto, como o seu MSE é inferior ao MSE do melhor arranjo, optou-se por utilizar o conjunto que engloba todas as variáveis.

É de salientar que os valores de MSE são muito elevados, devido ao facto de, nesta etapa, os dados do conjunto de entrada ainda não se encontrarem estandardizados. No Anexo C.1 apresentam-se as imagens do valor de R correspondentes aos três melhores arranjos, e os respetivos MSE .

4.7.1.c - 2ª Fase

Concluída a seleção das variáveis explicativas presentes nos dados NWP, nesta fase serão adicionadas ao conjunto de entrada novas variáveis consideradas relevantes, com o intuito de melhorar a performance da RN.

Inicialmente adicionou-se o horizonte temporal das previsões, ou seja, de 1 a 72 horas. O valor de R pode ser visto na Tabela 4.4. Nesta etapa também serão comparados os conjuntos de dados NWP com as previsões efetuadas às 00:00 UTC e 12:00 UTC.

Tabela 4.4 - Análise da adição do horizonte temporal.

						<i>Previsões NWP às 00:00 UTC</i>		<i>Previsões NWP às 12:00 UTC</i>	
SW	T2	U10	V10	WDIR	H ₇₂	R	MSE	R	MSE
1	1	1	1	1	0	0,927	0,0112	0,930	0,0114
1	1	1	1	1	1	0,932	0,0122	0,936	0,0110

Como se pode verificar através da análise do primeiro arranjo de variáveis da Tabela 4.4, e do último arranjo da Tabela 4.3, a estandardização das variáveis de entrada melhora e muito a performance da RN, obtendo-se um aumento de sensivelmente 30% do valor do R em relação ao conjunto de entrada não estandardizado. A adição do horizonte temporal também melhora, embora muito pouco, o desempenho da RN, obtendo um aumento na performance de aproximadamente 0,5% em R comparativamente ao conjunto de entrada anterior. Também se pode constatar, que os dados NWP com as previsões às 12:00 UTC permitem um desempenho superior comparativamente às previsões 00:00 UTC. Por este motivo, todas as alterações que possam vir a ser efetuadas à estrutura das RN, serão apenas comparadas com os dados NWP às 12:00 UTC. No entanto, na avaliação dos modelos finais os dados NWP às 00:00 UTC também são considerados.

Para o desenvolvimento da próxima etapa é necessário compreender que a produção horária é modelada como sendo a soma de duas componentes. A primeira componente é determinística, representando a tendência, ciclo anual e os efeitos de diferentes ciclos de dias. A segunda componente é estocástica.

Como se pode ver, por exemplo na Figura 4.4, a produção elétrica diária é extremamente dependente do ciclo diário. Este ciclo repete-se ao longo do ano dando assim origem a uma evolução harmónica. Sendo assim, o ciclo anual pode ser modelado como uma soma de senos e co-senos, à semelhança de uma série de Fourier [47].

$$f(x) = \sum_k A_k \cdot \cos(k \cdot w_0 \cdot x) + B_k \cdot \sin(k \cdot w_0 \cdot x) \quad (4.7)$$

Onde:

- A_k e B_k são os coeficientes do harmónico que, no caso dos modelos de aprendizagem automática, são estimados internamente;
- k corresponde ao índice do harmónico;
- w_0 representa a frequência. Como a radiação solar, e consequentemente a produção elétrica, se repete de 24 em 24 horas, $w_0 = \frac{2\pi}{T} = \frac{2\pi}{24}$.

De forma a eliminar o ciclo diurno, o horizonte temporal H_{72} foi então decomposto com base numa série de Fourier. De modo a encontrar-se os índices dos harmónicos mais relevantes, foram adicionadas ao conjunto de entrada da RN as componentes em seno e co-seno de H_{72} para os diversos índices testados. Portanto, o conjunto de entrada será constituído por SW , $T2$, $U10$, $V10$, $WDIR$, $H_{\cos_k}$ e $H_{\sin_k}$, onde k é o índice do harmónico utilizado.

O desempenho de cada índice pode ser visto na Tabela 4.5.

Tabela 4.5 - Desempenho dos diferentes índices do harmónico.

k	R	MSE
1	0,949	0,0085
2	0,946	0,0095
3	0,933	0,0112
4	0,931	0,0105

Constata-se que apenas houve melhoria do modelo para os dois primeiros valores de k , tendo para $k=1$ o modelo com melhor desempenho. Também se pode verificar que, à medida que aumentamos o índice do harmónico, há um declínio na performance do modelo, sendo que não faria muito sentido continuar a testar mais índices.

Como se obteve uma melhoria no desempenho para dois índices diferentes, optou-se por testar se o modelo teria melhor desempenho com apenas as componentes seno e co-seno para $k=1$, ou com a junção das componentes para $k=1$ e $k=2$.

Tabela 4.6 - Desempenho das componentes do ciclo diário para $k=1$ vs $k=1 + k=2$.

SW	$T2$	$U10$	$V10$	$WDIR$	$H_{\sin_1}$	$H_{\cos_1}$	$H_{\sin_2}$	$H_{\cos_2}$	R	MSE
1	1	1	1	1	1	1	0	0	0,949	0,0085
1	1	1	1	1	1	1	1	1	0,953	0,0080

Através da Tabela 4.6 pode-se verificar que a junção das componentes seno e co-seno dos dois harmónicos conduz a um desempenho ligeiramente superior comparativamente ao modelo com a utilização de apenas o harmónico para $k = 1$.

Um pouco à semelhança da etapa anterior, a variável *WDIR* também será decomposta. Como esta variável é fornecida em graus, variando de 0 a 360, a RN não é capaz de assimilar que a direção do vento aos 0° é igual à direção 360°. Por isso, sentiu-se a necessidade de testar o desempenho da RN, caso se efetuasse a sua decomposição em coordenadas cartesianas. Para tal multiplica-se *WDIR* por: $\cos(2\pi/360)$ e $\sin(2\pi/360)$.

Tabela 4.7 - Desempenho do modelo, antes e depois da decomposição da direção do vento.

<i>SW</i>	<i>T2</i>	<i>U10</i>	<i>V10</i>	<i>WDIR</i>	<i>WDIR_{cos}</i>	<i>WDIR_{sen}</i>	<i>H_{cos_1}</i>	<i>H_{sen_1}</i>	<i>H_{cos_2}</i>	<i>H_{sen_2}</i>	<i>R</i>	<i>MSE</i>
1	1	1	1	1	0	0	1	1	1	1	0,953	0,0080
1	1	1	1	0	1	1	1	1	1	1	0,956	0,0088

Como se pode verificar pela análise da Tabela 4.7, apesar de não ser uma diferença muito significativa, há um aumento no desempenho do novo modelo. No Anexo C.1 apresentam-se as imagens dos testes efetuados nesta fase.

A Figura 4.10 dá uma imagem da estrutura final do modelo de previsão RN.




Figura 4.10 - Estrutura das redes neuronais desenvolvidas.

Importa salientar que foram utilizadas duas redes neuronais, com as mesmas características, uma para a previsão da potência elétrica a partir dos dados NWP às 12:00 UTC (RN12) e outra para os dados NWP às 00:00 UTC (RN00). Cada rede é constituída por uma camada de entrada, uma camada intermédia e uma camada de saída. As redes têm 10 entradas e 1 saída cada. A camada intermédia é constituída por 21 neurónios e a função de ativação utilizada é a tangente sigmóide.

4.7.2 - Support Vector Machines

Uma vez que o MATLAB R2009a não possui funções nativas para desenvolver modelos SVR, recorreu-se a uma biblioteca externa (LIBSVM - *A Library for Support Vector Machines*) bastante capaz e com provas dadas a este nível. Os parâmetros utilizados no modelo com melhor desempenho foram os seguintes:

- O tipo de função *kernel* utilizada foi a *radial basis*, $\exp(-\gamma * |u - v|^2)$;
- $\gamma = 0,0001$;
- $C=10000$, este parâmetro representa a perda (*cost*);
- $\epsilon = 0,001$, que corresponde à tolerância do critério de paragem;

Dentro dos parâmetros descritos anteriormente, os que afetam mais o desempenho do modelo são C e γ . De forma a avaliar quais serão os valores ideais, foi necessário a implementação de um ciclo que percorre alternadamente uma determinada gama de valores para C e γ . A gama utilizada para ambos os parâmetros foi:

- $\gamma = C = 10^n$, onde $-4 \leq n \leq 4$

Para o mesmo conjunto de treino das RN, e com a mesma distribuição dos dados com 70% para treino, 15% para validação e os outros 15% para teste, obtiveram-se os seguintes resultados:

Tabela 4.8 - Desempenho do modelo SVR.

	<i>R</i>	<i>MSE</i>
SVR	0,91	0,0092

À semelhança do que foi feito nas RN, também foram desenvolvidos dois SVM com as mesmas características, um para a previsão da produção elétrica a partir dos dados NWP às 12:00 UTC (SVM12) e outro para os dados NWP às 00:00 UTC (SVM00).

Capítulo 5

Resultados

5.1 - Introdução

Uma vez desenvolvidos os vários modelos, neste capítulo são apresentados os resultados relativamente à aplicação dos mesmos na resolução de problemas reais.

Como se pôde ler na secção 4.5, a persistência geométrica apresenta-se como o modelo de referência com melhor desempenho. A essência deste capítulo será avaliar o desempenho dos modelos desenvolvidos, sendo que, além de comparados com o modelo de referência, também serão comparados entre si. Para efetuar o diagnóstico do desempenho dos modelos de previsão pode-se recorrer a diversos indicadores estatísticos, vulgarmente apelidados de indicadores de erro.

Neste capítulo são ainda apresentadas e analisadas as previsões efetuadas através de um modelo final que tem como entradas os resultados das previsões dos modelos que apresentaram um melhor desempenho.

5.2 - Métodos para a avaliação do desempenho dos modelos

Como se pode ver na secção 3.4.2, existem várias vertentes de análise de erro, não havendo um consenso generalizado acerca dos critérios de erro a utilizar. No entanto, de uma forma genérica, o erro que um sistema de previsão pode cometer na previsão para um determinado instante é dado pela diferença entre o valor previsto e o valor medido.

O método utilizado para avaliação do erro dos modelos propostos foi o *NMAPE*. Neste método, o erro sofre uma transformação relativamente ao erro proposto na sub-secção 3.3.2.a, a qual consiste simplesmente em passar o erro para a forma percentual. O *NMAPE* (*Normalize Mean Absolute Percentage Error*) é caracterizado pela seguinte equação (5.1):

$$NMAPE_k = \frac{\frac{1}{N} \sum_{t=1}^N |\hat{P}_t - P_t|}{P_{m\acute{a}x}} \times 100 \quad (5.1)$$

Onde:

- P_t corresponde ao valor da potência elétrica medida num determinado instante;
- $\hat{P}_t$ corresponde ao valor da potência prevista para o mesmo instante;
- N é o comprimento da série prevista;
- $P_{m\acute{a}x}$ é o valor máximo da produção para o conjunto de dados em análise. Este valor é, geralmente, próximo da potência instalada no parque FV.

Além do $NMAPE$ será utilizado também um método adicional de comparação dos modelos analisados. Este método foi descrito na sub-seção 3.3.2.b, e tem como objetivo quantificar o ganho na utilização de um determinado modelo, em detrimento do modelo de referência.

$$Imp_{NMAPE_k}^{ref} = \frac{NMAPE_k^{ref} - NMAPE_k}{NMAPE_k^{ref}} \quad (5.2)$$

Onde:

- $NMAPE_k^{ref}$ corresponde ao $NMAPE$ do modelo de referência;
- $NMAPE_k$ corresponde ao $NMAPE$ do modelo que se pretende avaliar.

5.3 - Desempenho dos modelos

Por forma a obter uma boa avaliação do desempenho dos modelos desenvolvidos anteriormente, estes serão testados para dois períodos distintos: Inverno e Verão.

Como se viu no capítulo 3, existem modelos que necessitam de treino prévio (RN e SVM). Por este motivo foi necessário dividir o conjunto de dados em dois sub-conjuntos distintos:

- O subconjunto de treino contem os dados das previsões efetuadas pelo modelo NWP e as variáveis consideradas relevantes como conjunto de entrada, e os dados históricos da produção como alvo. Uma vez que se pretende analisar dois períodos diferentes, também é necessário criar dois conjuntos de treino distintos. Para o período de Verão o intervalo de treino é compreendido entre 13-06-2010 e 13-06-2011, enquanto que para o período de Inverno o intervalo de treino será de 13-06-2010 até 31-10-2010 e de 01-02-2011 até 13-06-2011;
- O conjunto de teste é constituído apenas pelas previsões dos modelos NWP e as variáveis consideradas relevantes, pois o que se pretende é que estes modelos simulem a previsão da potência elétrica apenas com base nos primeiros. Para o período de Verão o conjunto de teste será de três meses (21-06-2011 até 21-09-2011). Para o período de Inverno, uma vez que não foram fornecidos dados relativamente ao mês de Janeiro, optou-se por considerar como período de teste de Inverno de 01-11-2010 até 28-02-2011.

Para os modelos que não necessitam de ser treinados previamente, os períodos de teste serão os mesmo que os anteriores. Sendo assim, o período de avaliação do erro corresponde

sempre a um horizonte de três meses com discretização horária. Na Tabela 5.1, apresenta-se a análise do *NMAPE* e do *Improvement* para todos os modelos desenvolvidos.

Tabela 5.1 - Comparação e análise do erro de previsão para os diversos modelos desenvolvidos.

Modelos	Teste para o período de Inverno [Novembro, Dezembro e Fevereiro]		Teste para o período de Verão [21 de Junho até 21 de Setembro]	
	NMAPE [%]	Imp. [%]	NMAPE [%]	Imp. [%]
Persistência	8,85	----	7,05	----
Geométrica				
AR ₍₂₉₎	7,44	15,92	5,14	27,09
AR ₍₁₇₃₎	7,61	14,02	3,84	45,55
ARMA _(29,28)	8,76	1,00	4,47	36,58
RN12	6,75	23,73	5,38	23,64
RN00	7,01	20,78	5,82	17,35
SVM12	8,46	4,35	5,04	28,47
SVM00	8,65	2,22	6,94	1,49

Verifica-se, da análise da Tabela 5.1, que para o período de Inverno os modelos que apresentam melhor desempenho são as RN. Era expectável que fossem estas, uma vez que, devido à sua capacidade de aprendizagem e pelo facto de serem auxiliadas pelas previsões meteorológicas, as RN são mais eficazes a prever a possível presença de nuvens, efetuando assim previsões mais precisas. Também é de salientar o melhor desempenho da RN12 comparativamente à RN00, demonstrando que as previsões do modelo NWP para as 12:00 UTC são efetivamente mais precisas que as previsões efetuadas para as 00:00 UTC. Quando interrogado relativamente a esta conclusão, o grupo de investigação da Universidade de Lisboa disse que na prática, não deveria haver diferenças entre as previsões dos dois modelos. No entanto, também afirmaram que quando se efetuam as previsões meteorológicas às 12:00 UTC, normalmente existe uma maior quantidade de observações processadas pelo modelo mesoescala, pelo que é possível que estas previsões sejam mais precisas.

Devido à sua capacidade de aprendizagem, era esperado que os modelos SVM apresentassem um desempenho idêntico às RN, no entanto isso não se verificou. De facto, para o período de Inverno, estes modelos, a par do ARMA_(29,28), são de todos os modelos desenvolvidos os que apresentam pior desempenho. A fraca performance poderá ser explicada pelo facto de que os parâmetros encontrados no seu desenvolvimento, talvez não fossem os mais adequados, ou estes modelos simplesmente não possuam um método de treino tão eficaz como os das RN.

Como é do conhecimento geral, no período de Inverno as condições meteorológicas são mais instáveis, podendo variar bastante entre dois dias consecutivos. Uma vez que os modelos regressivos apenas se baseiam em dados do passado, revelam uma performance inferior comparativamente aos modelos das RN. Na Figura 5.1, pode-se ver a representação gráfica da comparação da potência medida e prevista para todos os modelos desenvolvidos para um dia típico de Inverno.




Figura 5.1 - Comparação entre a potência medida e a potência prevista para todos os modelos desenvolvidos, para o caso de estudo do dia 21 de Dezembro de 2010.

Para o período de Verão, verifica-se que todos os modelos obtiveram um desempenho superior comparativamente ao de Inverno. Como neste período as variações meteorológicas são menos acentuadas, os modelos $AR_{(173)}$ e $ARMA_{(29,28)}$ demonstraram ser as melhores alternativas para efetuar previsões da potência.

No caso do modelo SVM, o SVM00 obteve mais uma vez um desempenho insatisfatório. Por outro lado, o SVM12 conseguiu obter um bom desempenho chegando a ser superior aos modelos RN. Apesar das RN apresentarem um desempenho inferior ao dos modelos estatísticos para o período de Verão, ao considerar ambos os períodos analisados, as RN são os modelos que menores oscilações apresentam.




Figura 5.2 - Comparação entre a potência medida e a potência prevista para todos os modelos desenvolvidos, para o caso de estudo do dia 7 de Agosto de 2011.

Na Figura 5.2 pode ver-se a comparação da potência medida com a prevista, para todos os modelos desenvolvidos, para um dia típico de Verão. Todos os modelos conseguem, de certa forma, seguir os valores reais da potência. Existem, naturalmente, desvios relativamente aos valores reais; no entanto, os valores previstos estão relativamente próximos dos mesmos. Apesar de haver dias em que os valores previstos são mais próximos dos reais, optou-se por representar este dia pelo seguinte motivo: como se pode ver no primeiro gráfico da Figura 5.2, o modelo RN12 consegue, de certa forma, prever que existirá uma queda na potência elétrica. Este aspeto é muito importante, pois o operador da rede elétrica, sabendo de antemão que existirá uma quebra, pode compensar a potência injetada através da ativação de outras fontes de energia, evitando assim a introdução de flutuações na mesma. Portanto, independentemente da altura do ano analisada, as redes neuronais demonstram que são ferramentas poderosas, revelando-se, dentro dos modelos desenvolvidos, como a melhor alternativa para a previsão da potência elétrica.

5.3.1 - Modelos de assimilação

Concluída a análise do desempenho dos modelos desenvolvidos, procedeu-se à criação de uma rede neuronal, RN_AR, que tem como objetivo verificar se a junção dos modelos RN12 e de um modelo baseado num $AR_{(173)}$, conduz a uma melhoria do desempenho. Para tal, a RN_AR utiliza como conjunto de entrada os dados utilizados na construção do modelo RN12 e os 173 valores anteriores da produção medida. Os coeficientes do modelo $AR_{(173)}$ são modelizados pela RN que durante o processo de treino obtém intrinsecamente os valores dos coeficientes autorregressivos. O período de teste considerado para a avaliação deste modelo foi o de Verão, coincidindo com o utilizado na secção anterior.

Tabela 5.2 - Desempenho de RN_AR.

	<i>Teste para o período de Inverno [Novembro, Dezembro e Janeiro]</i>		<i>Teste para o período de Verão [21 de Junho até 21 de Setembro]</i>	
Modelos	NMAPE [%]	Imp. [%]	NMAPE [%]	Imp. [%]
Persistência Geométrica	8,85	----	7,05	----
$AR_{(173)}$	7,61	14,02	3,84	45,55
RN12	6,75	23,73	5,38	23,64
RN_AR	6,52	26,27	5,14	27,09

Pela análise da Tabela 5.2 verifica-se que, apesar do desempenho de RN_AR ainda ser inferior ao modelo $AR_{(173)}$ para o período de Verão, no Inverno houve de facto uma melhoria comparativamente ao modelo RN12 e $AR_{(173)}$, pelo que a junção de modelos se apresenta como uma melhoria de desempenho.

Sendo assim, procedeu-se à criação de duas redes neuronais, RN1 e RN2, que têm como objetivo assimilar os resultados obtidos através dos modelos anteriores. O conjunto de entrada é constituído pelas previsões efetuadas através dos modelos anteriores e o mês de cada previsão. Uma vez que tanto as RN como os SVM apresentaram melhor desempenho com

as previsões meteorológicas do modelo NWP para as 12:00 UTC, optou-se por não considerar nesta etapa os modelos RN00 e SVM00.

Para a criação da RN1 foi necessário, numa primeira fase, efetuar a previsão da potência através dos diferentes modelos desenvolvidos para um período de 1 ano (13-06-2010 até 13-06-2011). Estas previsões, juntamente com o mês de cada uma delas, foram utilizadas no treino da RN1 como conjunto de entrada, e utilizou como alvo os dados históricos da potência medida para o mesmo período. A RN2 foi criada e treinada de forma idêntica à RN1, com os períodos de treino de 13-06-2010 até 31-10-2010 e de 01-02-2011 até 13-06-2011.

Após a criação de RN1 e RN2 foi necessário testar a performance das mesmas. Para RN1 o período de teste utilizado foi de três meses (21-06-2011 até 21-09-2011), sendo que o conjunto de entrada foi, uma vez mais, o mês de cada previsão e as previsões efetuadas pelos modelos anteriores para o mesmo período. Para RN2 o período de teste considerado foi de 01-11-2010 até 28-02-2011, o conjunto de entrada foi novamente o mês de cada previsão e as previsões efetuadas para este mesmo período.

O desempenho da redes é novamente dado pelo *NMAPE* em relação à persistência geométrica, pois desta forma é possível compará-lo com o dos modelos desenvolvidos anteriormente. Para além disso, também será avaliado o *improvement* de RN1 e RN2 em relação aos modelos utilizados na sua criação.

Na Tabela 5.3 pode ver-se o desempenho de RN1 e RN2 para diferentes configurações dos modelos utilizados.

Tabela 5.3 - Desempenho de RN1 e RN2.

	RN1 (Verão)		RN2 (Inverno)	
Modelos utilizados	NMAPE [%]	Imp. [%]	NMAPE [%]	Imp. [%]
RN12		26,39		5,48
AR ₍₂₉₎	3,96	22,95	6,38	14,52
AR ₍₁₇₃₎		-3,12		16,43
ARMA _(29,28)		11,41		27,40
Persistência geométrica		42,84		29,83
RN12	4,03	25,09	6,21	8,00
AR ₍₂₉₎		21,60		16,53
AR ₍₁₇₃₎		-4,95		18,40
ARMA _(29,28)		9,84		29,11
SVM12		15,67		24,94
RN12	4,25	21,00	6,35	5,93
AR ₍₂₉₎		17,32		14,85
AR ₍₁₇₃₎		-10,68		16,56
ARMA _(29,28)		4,92		27,51
Persistência geométrica		42,84		29,38
SVM12	4,03	20,04	6,25	26,12
RN12		25,09		7,41
AR ₍₂₉₎		21,60		15,99
AR ₍₁₇₃₎		-4,95		17,87
ARMA _(29,28)		9,84		28,65

Constata-se que, para o período de Verão, a primeira configuração de modelos (RN12, AR₍₂₉₎, AR₍₁₇₃₎ e ARMA_(29,28)) foi a que obteve o melhor desempenho, apresentado um *NMAPE*

de 3,96%. Nesta configuração, a RN1 apresenta um *improvement* bastante significativo em relação a praticamente todos os modelos, com exceção do $AR_{(173)}$, para o qual se obteve um *improvement* negativo. No entanto a RN1 apresenta uma melhoria bastante significativa de desempenho comparativamente aos modelos anteriores.

Para o período de Inverno verifica-se que a segunda configuração de modelos (Persistência geométrica, RN12, $AR_{(29)}$, $AR_{(173)}$ e $ARMA_{(29,28)}$) foi a que obteve melhor desempenho, resultando num *NMAPE* de 6,21%. Ao contrário do período de Verão, onde o *improvement* em relação ao $AR_{(173)}$ é negativo, para o período de Inverno todas as configurações testadas apresentam um *improvement* positivo.

Como se pode verificar pela Figura 5.3, os valores da potência previstos pela RN1, independentemente da configuração de modelos que utiliza, conseguem aproximar-se bastante dos valores reais. Sendo assim, o ponto crítico para escolha da melhor configuração de modelos reside, sem dúvida alguma, no desempenho da RN2 para o período de Inverno.




Figura 5.3 - Desempenho de RN1, para as diferentes configurações de modelos, para um horizonte de previsão de 72 horas. A previsão foi realizada dia 7 de Agosto de 2011 às 12:00h.

Pela análise da Figura 5.4 verifica-se que, para um dia típico de Inverno, existe uma maior discrepância entre os valores das previsões e os valores medidos da potência. Como se viu anteriormente, a configuração 2 foi a que obteve melhor desempenho para o período de Inverno e, se analisarmos com atenção a Figura 5.4, pode-se constatar que esta parece ser a única que passadas 48 horas consegue aproximar-se do ponto de produção máximo medido.

Assim sendo, pode-se concluir que a segunda configuração de modelos (Persistência geométrica, RN12, $AR_{(29)}$, $AR_{(173)}$ e $ARMA_{(29,28)}$), tendo em conta ambos os períodos analisados, é de facto a melhor escolha para efetuar previsões da potência elétrica.




Figura 5.4 - Desempenho de RN2, para as diferentes configurações de modelos, para um horizonte de previsão de 72 horas. A previsão foi realizada dia 4 de Fevereiro de 2011 às 12:00h.

Na Figura 5.5 e na Figura 5.6, pode-se ver a comparação dos valores da potência previstos pela RN1 e RN2 com os valores medidos. Nestas figuras também se pode observar a evolução das previsões efetuadas através dos modelos que deram origem a RN1 e RN2. Desta forma, tem-se uma visualização do ganho que RN1 e RN2 apresentam em relação aos modelos anteriores.




Figura 5.5 - Desempenho de RN1 com a configuração 2 e dos diferentes modelos que lhe deram origem, para um horizonte de previsão de 72 horas. Previsão efetuada dia 7 de Agosto de 2011 às 12:00h.




Figura 5.6 - Desempenho de RN2 com a configuração 2 e dos diferentes modelos que lhe deram origem, para um horizonte de previsão de 72 horas. Previsão efetuada dia 4 de Fevereiro de 2011 às 12:00h.

Numa análise geral, é perceptível que através do modelo de previsão da produção a curto prazo (RN1 e RN2), os valores das previsões seguem a evolução da potência do parque FV. Como era esperado, as previsões efetuadas são bastante mais precisas em dias de céu limpo, apresentando um bom desempenho para estes dias. Para dias nublados o modelo revela alguma dificuldade em efetuar previsões precisas, pelo que o seu desempenho é inferior. Apesar de tudo, para os dias fortemente afetados por nebulosidade sempre é melhor ter alguma previsão do que não ter nenhuma.

Capítulo 6

Conclusões e trabalhos futuros

6.1 - Conclusões

Apesar de, atualmente, a produção de energia elétrica a partir de sistemas FV representar uma pequena parte da energia total produzida, o recurso a este tipo de sistemas está em claro crescimento, impulsionado pelas medidas energéticas impostas pela Comunidade Europeia e pelas diversas vantagens que estes sistemas apresentam. Portanto, se até agora a variabilidade destes recursos, e consequentemente, a produção elétrica, tinha pouco ou praticamente nenhum impacto na rede elétrica, no futuro, com o aumento da penetração dos sistemas FV, a natureza intermitente da geração de energia poderá ser problemática, sendo susceptível de introduzir flutuações na rede elétrica. A previsão da sua produção assume, pois, importância crescente.

Relativamente ao objetivo desta dissertação, foi construída e apresentada uma metodologia para a previsão a curto prazo da produção elétrica de parques fotovoltaicos. De seguida, enumeram-se as principais conclusões obtidas.

Numa primeira fase foram desenvolvidos e analisados os vários modelos individuais. No que diz respeito aos modelos estatísticos, foi possível concluir que, para o período de Verão, foram estes que apresentaram os melhores resultados, com especial destaque para o $AR_{(173)}$, o melhor de entre todos. Para o período de Inverno, estes modelos revelam maiores dificuldades em efetuar previsões precisas, uma vez que são claramente influenciados pelas fortes alterações do tempo que se fazem sentir nessa época do ano. Ainda assim, as previsões efetuadas apresentam um erro médio absoluto menor comparativamente à persistência geométrica.

Os modelos de aprendizagem automática efetuam as previsões recorrendo aos dados históricos da produção do parque FV e a previsões meteorológicas efetuadas por um modelo NWP. Numa primeira instância, e recorrendo à análise dos modelos RN e SVM desenvolvidos, verificou-se que os que utilizam os dados das previsões meteorológicas efetuadas pelo modelo NWP ao meio dia revelaram um desempenho superior comparativamente aos modelos equivalentes que utilizam os dados NWP da meia-noite. No que concerne ao modelo RN, verificou-se que este é, em termos globais de todos os modelos desenvolvidos na primeira fase o que apresenta melhor desempenho, ou seja, independentemente da época analisada,

este modelo apresentou sempre bons resultados, não havendo grande discrepância entre o desempenho para o período de Verão e Inverno.

Relativamente aos modelos SVM, concluiu-se que, para o caso analisado nesta dissertação não são uma ferramenta tão poderosa como as RN. Analisando o seu desempenho, ficou patente que, principalmente para o período de Inverno, o processo de aprendizagem não é tão eficaz como processo das RN.

Na segunda fase da metodologia, foram modelizadas duas redes neuronais com o objetivo de assimilar o resultado obtido através dos modelos desenvolvidos na fase anterior. Foram testadas diferentes configurações de modelos como conjunto de entrada, com o intuito de encontrar o melhor desempenho possível, para diferentes épocas do ano. Da análise conjunta das diferentes épocas, a configuração com melhor desempenho é a que utiliza como conjunto de entrada os modelos da persistência geométrica, RN12, $AR_{(29)}$, $AR_{(173)}$ e $ARMA_{(29,28)}$. Este modelo revelou um *improvement* bastante considerável em relação a praticamente todos os modelos que lhe dão origem, sendo capaz de efetuar previsões com maior exatidão, pelo que, a decisão de culminar vários modelos em um só revelou-se acertada.

Em suma, a metodologia final para a previsão da potência FV pode ser dividida em três etapas distintas. A primeira etapa consiste na previsão da irradiação solar para dias de céu limpo e a sua transformação em potência elétrica. Na segunda etapa, através dos dados históricos da produção do parque FV e com base nas previsões meteorológicas efetuadas pelo modelo NWP, é possível prever a potência através dos modelos RN12, $AR_{(29)}$, $AR_{(173)}$ e $ARMA_{(29,28)}$. Por fim, na terceira etapa, as previsões efetuadas na etapa 1 e 2 juntamente com a indicação do mês correspondente a cada previsão, são utilizadas como conjunto de entrada numa RN final que simula as “verdadeiras” previsões da potência.

Tendo em conta os objetivos definidos para a dissertação, pode considerar-se que estes foram cumpridos. Foi desenvolvido um modelo de previsão, pronto a ser implementado reduzindo o impacto da intermitência da produção FV nos sistemas elétricos onde são integrados.

6.2 - Trabalhos futuros

Como trabalhos futuros apresentam-se algumas sugestões:

- Na disponibilidade de uma maior quantidade de dados históricos da produção, seria interessante averiguar se é possível melhorar ainda mais o desempenho dos modelos de aprendizagem automática, nomeadamente das redes neuronais;
- Estudar a possível implementação de outros modelos inteligentes, como por exemplo o ANFIS (*Adaptive Neural Fuzzy Inference Systems*);
- Avaliar se a desagregação das previsões em horizontes de 24 horas, melhorará a performance do modelo final;
- Analisar a eventual influência de diferentes períodos de treino;
- Estudar a aplicação de um filtro de Kalman;
- Efetuar previsões em eventos extremos;
- Incorporar nos modelos a informação registado no local.

Referências

1. Azadeh, A., A. Maghsoudi, and S. Sohrabkhani, *An integrated artificial neural networks approach for predicting global radiation*. Energy Conversion and Management, 2009. 50(6): p. 1497-1505.
2. Walker, S., K.W. Hipel, and T. Inohara. *Strategic analysis of the Kyoto Protocol*. in *Systems, Man and Cybernetics*, 2007. ISIC. IEEE International Conference on. 2007.
3. MEID, *RE.NEW.ABLE a inspirar Portugal, Plano Nova Energias ENE2020*, 2010.
4. DGEG - Estatísticas rápidas - Outubro de 2011 - <http://www.dgge.pt/>.
5. GREENPRO, *ENERGIA FOTOVOLTAICA manual sobre tecnologias, projecto e instalação* 2004.
6. Šúri, M., et al., *Potential of solar electricity generation in the European Union member states and candidate countries*. Solar Energy, 2007. 81(10): p. 1295-1305.
7. EPIA, *Global market outlook for photovoltaics until 2015*, 2011.
8. REN (Rede Eléctrica Nacional), Estatísticas diárias 2011, data de entrada (21/06/2011) - <http://www.centrodeinformacao.ren.pt/PT/InformacaoExploracao/Paginas/EstatisticaDiariaDiagrama.aspx>.
9. Rodrigues, C.N., *Centrais solares fotovoltaicas ligadas à rede elétrica*, 2008: Lisboa.
10. Woyte, A., et al., *Voltage fluctuations on distribution level introduced by photovoltaic systems*. Energy Conversion, IEEE Transactions on, 2006. 21(1): p. 202-209.
11. Goetzberger, A. and V.U. Hoffmann, *Photovoltaic Solar Energy Generation* 2005: Springer.
12. Collares Pereira, M., *Fotovoltaico de Alta Concentração, uma nova tecnologia solar com excelente potencial em Portugal*, 2010.
13. Hankins, M., *Stand-Alone Solar Electric Systems*. The Earthscan Expert Handbook for Planning, Design and Instalation, ed. F. JACKSON 2010, London, Washington DC: Earthscan.
14. Himalaya, C.S.P. *Guia da Energia Solar*. [cited 2011 12-01-2012]; Available from: <http://www.cienciaviva.pt/rede/energia/himalaya2005/home/indice.asp>.
15. e2p. *Energias endógenas de Portugal*. 2011; Available from: <http://e2p.inegi.up.pt/>.
16. Renováveis na hora, *Informações, microprodução*. 2011; Available from: <http://www.renovaveisnahora.pt/web/srm>.
17. Girodo, M., E. Lorenz, and D. Heinemann, *Solar irradiance forecasting for the management of solar energy systems*. 2006.
18. Bacher, P., *Short-term Solar Power Forecasting*, in *Informatics and Mathematical Modeling* 2008, Technical University of Denmark: Denmark.
19. Makridakis, S., S.C. Wheelwright, and R.J. Hyndman, *Forecasting: methods and applications*, ed. J.W. Sons 1998 New York.

20. Lorenz, E., et al., *Short-term forecasting of solar radiation: a statistical approach using satellite data*. Solar Energy, 1999. 67(1-3): p. 139-150.
21. Hammer, A., et al., *Solar energy assessment using remote sensing technologies*. 2002.
22. Charney, J.G., *Numerical integration of the barotropic vorticity equation*. 1950. 2.
23. Yuan-Kang, W. and H. Jing-Shan. *A literature review of wind forecasting technology in the world*. in *Power Tech, 2007 IEEE Lausanne*. 2007.
24. Soteris A, K., *Applications of artificial neural-networks for energy systems*. Applied Energy, 2000. 67(1-2): p. 17-35.
25. Cardoso, M.M., *SIMULAÇÃO DE MODELOS GARCH PARA SERIES TEMPORAIS UNIVARIADAS DE DEMANDA DE ENERGIA ELÉTRICA PARA CONSUMIDORES LIVRES EM REGIME DE CURTO PRAZO*, in *Engenharia de Produção*2005, Uiversidade Federal de Itajubá: Itajubá.
26. Guarnieri, R.A., et al., *Previsões de Radiação Solar Utilizando Modelo de Mesoescala - Refinamento com Redes Neurais*, in *1 CBENS - 1 Congresso Brasileiro de Energia Solar*2007.
27. Aggarwal, R. and Y. Song, *Artificial neural networks in power systems. I. General introduction to neural computing*. Power Engineering Journal, 1997. 11(3): p. 129-134.
28. Sfetsos, A. and A.H. Coonick, *Univariate and multivariate forecasting of hourly solar radiation with artificial intelligence techniques*. Solar Energy, 2000. 68(2): p. 169-178.
29. Pellegrini, F.R. and F.S. Fogliatto, *Passos para Implementação de Sistemas de Previsão de Demanda - Técnicas e Estudo de Caso*. Revista PRODUÇÃO, 2001. 11.
30. Moreno-Munoz, A., et al. *Short term forecasting of solar radiation*. in *Industrial Electronics, 2008. ISIE 2008. IEEE International Symposium on*. 2008.
31. BOX, G.E.P. and G.M. JENKINS, *Time Series Analysis: Forecasting and Control*1976.
32. Hegedus, S. and A. Luque, *Handbook of Photovoltaic Science and Engineering*2003: John Wiley & Sons, Ltd.
33. Kalogirou, S., *Solar energy engineering: processes and systems*, ed. 12009: Elsevier.
34. Radosavljević, J. and A. Đorđević, *DEFINING OF THE INTENSITY OF SOLAR RADIATION ON HORIZONTAL AND OBLIQUE SURFACES ON EARTH*. 2001. 2: p. 77-86.
35. Honsberg, C. and S. Bowden. *PVCDROM*. 2011; Available from: <http://pveducation.org/pvcdrom/properties-of-sunlight/air-mass>.
36. PVPS, *Performance Prediction of Grid-Connected Photovoltaic Systems Using Remote Sensing*, in *International Energy Agency*2008.
37. Rahman, M.H. and S. Yamashiro, *Novel Distributed Power Generating System of PV-ECaSS Using Solar Energy Estimation*. Energy Conversion, IEEE Transactions on, 2007. 22(2): p. 358-367.
38. Yona, A., et al. *Application of Neural Network to One-Day-Ahead 24 hours Generating Power Forecasting for Photovoltaic System*. in *Intelligent Systems Applications to Power Systems, 2007. ISAP 2007. International Conference on*. 2007.
39. Fuentes, M., et al., *Application and validation of algebraic methods to predict the behaviour of crystalline silicon PV modules in Mediterranean climates*. Solar Energy, 2007. 81(11): p. 1396-1408.
40. Madsen, H., et al., *A Protocol For Standardizing The Performance Evaluation Of Short-Term Wind Power Prediction Models*. Wind Engineering, 2006. 29.

41. Lorenz, E., et al., *Irradiance Forecasting for the Power Prediction of Grid-Connected Photovoltaic Systems*. Selected Topics in Applied Earth Observations and Remote Sensing, IEEE Journal of, 2009. 2(1): p. 2-10.
42. Shalabi, L.A., Z. Shaaban, and B. Kasasbeh, *Data Mining: A Preprocessing Engine*. Journal of Computer Science, 2006. 2.
43. Bremnes, J.B., *Probabilistic Wind Power Forecasts Using Local Quantile Regression*. Wind Energy, 2004. 7: p. 47-54.
44. Hagan, M.T. and M.B. Menhaj, *Training feedforward networks with the Marquardt algorithm*. Neural Networks, IEEE Transactions on, 1994. 5(6): p. 989-993.
45. Barreto, J.M., *Introdução às Redes Neurais Artificiais*, in *Departamento de Informática e Estatística 2002*, Laboratório de Conexão e Ciências Cognitivas'UFSC.
46. de Figueiredo, R., *Implications and applications of Kolmogorov's superposition theorem*. Automatic Control, IEEE Transactions on, 1980. 25(6): p. 1227-1231.
47. Soares, L.J. and M.C. Medeiros, *Modeling and forecasting short-term electricity load: A comparison of methods with an application to Brazilian data*. International Journal of Forecasting, 2008. 24(4): p. 630-644.
48. Basak, D., S. Pal, and D.C. Patranabis, *Support Vector Regression*. Neural Information Processing - Letters and Reviews, 2007. 11.
49. Beltrami, M., G.V. Loch, and A.C.L. Silva, *COMPARAÇÃO DAS TÉCNICAS DE SUPPORT VECTOR REGRESSION E REDES NEURAS NA PRECIFICAÇÃO DE OPÇÕES*. 2009.

Anexos

Anexo A

A.1 - Equação ARMA_(29,28)

$$\begin{aligned}x_t = & 1,273343258 \cdot x_{t-1} + 0,112747534 \cdot x_{t-2} - 0,435432884 \cdot x_{t-3} + \\& + 0,047983414 \cdot x_{t-4} + 0,001358678 \cdot x_{t-5} - 1,259317311 \cdot x_{t-25} - \\& - 0,111505614 \cdot x_{t-26} + 0,430636567 \cdot x_{t-27} - 0,047454875 \cdot x_{t-28} - \\& - 0,001343172 \cdot x_{t-29} - 0,56828125 \cdot \varepsilon_{t-1} - 0,37181288 \cdot \varepsilon_{t-2} + \\& + 0,06307402 \cdot \varepsilon_{t-3} - 0,12250962 \cdot \varepsilon_{t-4} - 0,83890641 \cdot \varepsilon_{t-24} + \\& + 0,47673478 \cdot \varepsilon_{t-25} + 0,31191621 \cdot \varepsilon_{t-26} - 0,05291320 \cdot \varepsilon_{t-27} + \\& + 0,10277410 \cdot \varepsilon_{t-28}\end{aligned}\tag{A.1}$$

A.2 - Equação AR₍₂₉₎


$$\begin{aligned}x_t = & 0,6882 \cdot x_{t-1} + 0,1156 \cdot x_{t-2} - 0,00645 \cdot x_{t-3} - 0,04401 \cdot x_{t-4} - \\& - 0,009896 \cdot x_{t-5} - 0,002185 \cdot x_{t-6} - 0,02934 \cdot x_{t-7} - 0,008848 \cdot x_{t-8} + \\& + 0,004206 \cdot x_{t-9} + 0,0165 \cdot x_{t-10} + 0,02342 \cdot x_{t-11} + 0,01352 \cdot x_{t-12} - \\& - 0,003859 \cdot x_{t-13} - 0,02034 \cdot x_{t-14} - 0,0262 \cdot x_{t-15} - 0,007688 \cdot x_{t-16} + \\& + 0,0116 \cdot x_{t-17} + 0,01497 \cdot x_{t-18} + 0,00468 \cdot x_{t-19} - 0,01718 \cdot x_{t-20} + \\& + 0,05562 \cdot x_{t-21} + 0,06352 \cdot x_{t-22} + 0,1279 \cdot x_{t-23} + 0,1546 \cdot x_{t-24} - \\& - 0,002999 \cdot x_{t-25} - 0,1059 \cdot x_{t-26} - 0,02239 \cdot x_{t-27} - 0,03117 \cdot x_{t-28} + \\& + 0,02801 \cdot x_{t-29}\end{aligned}\tag{A.2}$$



A.3 - Equação AR₍₁₇₃₎

$$\begin{aligned}
 x_t = & 0,6379 \cdot x_{t-1} + 0,1271 \cdot x_{t-2} + 0,0142 \cdot x_{t-3} - 0,03765 \cdot x_{t-4} - 0,01569 \cdot x_{t-5} - \\
 & - 0,006976 \cdot x_{t-6} - 0,02445 \cdot x_{t-7} - 0,002171 \cdot x_{t-8} + 0,005431 \cdot x_{t-9} + \\
 & + 0,007422 \cdot x_{t-10} + 0,006763 \cdot x_{t-11} + 0,00379 \cdot x_{t-12} + 0,00003312 \cdot x_{t-13} - \\
 & - 0,007668 \cdot x_{t-14} - 0,01254 \cdot x_{t-15} - 0,004073 \cdot x_{t-16} + 0,007719 \cdot x_{t-17} + \\
 & + 0,009737 \cdot x_{t-18} + 0,00917 \cdot x_{t-19} - 0,01588 \cdot x_{t-20} + 0,04529 \cdot x_{t-21} + \\
 & + 0,02281 \cdot x_{t-22} + 0,06713 \cdot x_{t-23} + 0,118 \cdot x_{t-24} - 0,01243 \cdot x_{t-25} - 0,08079 \cdot \\
 & \cdot x_{t-26} + 0,00347 \cdot x_{t-27} - 0,02862 \cdot x_{t-28} + 0,01702 \cdot x_{t-29} + 0,000838 \cdot x_{t-30} - \\
 & - 0,0002597 \cdot x_{t-31} + 0,001862 \cdot x_{t-32} + 0,0006759 \cdot x_{t-33} + 0,005008 \cdot x_{t-34} + \\
 & + 0,0008788 \cdot x_{t-35} + 0,0001904 \cdot x_{t-36} + 0,00184 \cdot x_{t-37} - 0,0006122 \cdot x_{t-38} - \\
 & - 0,006922 \cdot x_{t-39} - 0,01034 \cdot x_{t-40} - 0,002211 \cdot x_{t-41} - 0,000633 \cdot x_{t-42} + \\
 & + 0,005042 \cdot x_{t-43} - 0,008136 \cdot x_{t-44} + 0,02076 \cdot x_{t-45} + 0,008938 \cdot x_{t-46} + \\
 & + 0,02494 \cdot x_{t-47} + 0,04301 \cdot x_{t-48} + 0,00005211 \cdot x_{t-49} + 0,01556 \cdot x_{t-50} - \\
 & - 0,04698 \cdot x_{t-51} + 0,0003949 \cdot x_{t-52} + 0,01574 \cdot x_{t-53} - 0,02074 \cdot x_{t-54} + \\
 & + 0,006433 \cdot x_{t-55} + 0,006194 \cdot x_{t-56} + 0,0009651 \cdot x_{t-57} - 0,0002013 \cdot x_{t-58} + \\
 & + 0,0001012 \cdot x_{t-59} + 0,001307 \cdot x_{t-60} + 0,000783 \cdot x_{t-61} + 0,000721 \cdot x_{t-62} + \\
 & + 0,0001362 \cdot x_{t-63} - 0,003899 \cdot x_{t-64} - 0,0123 \cdot x_{t-65} - 0,004536 \cdot x_{t-66} + \\
 & + 0,01846 \cdot x_{t-67} - 0,01228 \cdot x_{t-68} - 0,03971 \cdot x_{t-69} - 0,01941 \cdot x_{t-70} + \\
 & + 0,06699 \cdot x_{t-71} + 0,03156 \cdot x_{t-72} - 0,0008595 \cdot x_{t-73} - 0,005822 \cdot x_{t-74} - \\
 & - 0,02142 \cdot x_{t-75} - 0,02734 \cdot x_{t-76} + 0,01922 \cdot x_{t-77} + 0,006258 \cdot x_{t-78} + \\
 & + 0,01308 \cdot x_{t-79} - 0,007714 \cdot x_{t-80} - 0,006898 \cdot x_{t-81} + 0,002758 \cdot x_{t-82} + \\
 & + 0,0005779 \cdot x_{t-83} - 0,0004376 \cdot x_{t-84} - 0,0005375 \cdot x_{t-85} - 0,001011 \cdot x_{t-86} - \\
 & - 0,002327 \cdot x_{t-87} + 0,002926 \cdot x_{t-88} + 0,012 \cdot x_{t-89} - 0,005355 \cdot x_{t-90} - \quad (A.3) \\
 & - 0,001117 \cdot x_{t-91} + 0,01068 \cdot x_{t-92} + 0,01045 \cdot x_{t-93} - 0,02079 \cdot x_{t-94} + \\
 & + 0,006016 \cdot x_{t-95} + 0,03519 \cdot x_{t-96} - 0,03002 \cdot x_{t-97} - 0,02859 \cdot x_{t-98} + \\
 & + 0,01031 \cdot x_{t-99} + 0,004782 \cdot x_{t-100} + 0,01133 \cdot x_{t-101} + 0,007096 \cdot x_{t-102} - \\
 & - 0,005066 \cdot x_{t-103} + 0,001428 \cdot x_{t-104} - 0,008013 \cdot x_{t-105} - 0,001004 \cdot x_{t-106} + \\
 & + 0,003617 \cdot x_{t-107} + 0,001322 \cdot x_{t-108} + 0,005724 \cdot x_{t-109} - 0,003152 \cdot x_{t-110} - \\
 & - 0,00322 \cdot x_{t-111} + 0,002443 \cdot x_{t-112} + 0,003626 \cdot x_{t-113} - 0,005348 \cdot x_{t-114} + \\
 & + 0,02181 \cdot x_{t-115} - 0,01406 \cdot x_{t-116} - 0,007527 \cdot x_{t-117} + 0,008814 \cdot x_{t-118} + \\
 & + 0,01271 \cdot x_{t-119} + 0,008187 \cdot x_{t-120} - 0,009239 \cdot x_{t-121} + 0,004257 \cdot x_{t-122} - \\
 & - 0,04069 \cdot x_{t-123} + 0,03138 \cdot x_{t-124} - 0,002885 \cdot x_{t-125} + 0,0001774 \cdot x_{t-126} + \\
 & + 0,003751 \cdot x_{t-127} - 0,003931 \cdot x_{t-128} + 0,001224 \cdot x_{t-129} - 0,001824 \cdot x_{t-130} + \\
 & + 0,002645 \cdot x_{t-131} + 0,0008527 \cdot x_{t-132} - 0,0007822 \cdot x_{t-133} - 0,003493 \cdot \\
 & \cdot x_{t-134} - 0,002101 \cdot x_{t-135} + 0,009166 \cdot x_{t-136} + 0,005333 \cdot x_{t-137} - 0,006582 \cdot \\
 & \cdot x_{t-138} - 0,01345 \cdot x_{t-139} - 0,01348 \cdot x_{t-140} + 0,0174 \cdot x_{t-141} + 0,01574 \cdot \\
 & \cdot x_{t-142} - 0,008968 \cdot x_{t-143} + 0,02379 \cdot x_{t-144} - 0,01596 \cdot x_{t-145} - 0,04786 \cdot \\
 & \cdot x_{t-146} + 0,04388 \cdot x_{t-147} - 0,01909 \cdot x_{t-148} + 0,006106 \cdot x_{t-149} + 0,0155 \cdot \\
 & \cdot x_{t-150} - 0,007864 \cdot x_{t-151} - 0,01085 \cdot x_{t-152} + 0,003821 \cdot x_{t-153} + 0,001813 \cdot \\
 & \cdot x_{t-154} + 0,003187 \cdot x_{t-155} - 0,001704 \cdot x_{t-156} + 0,001401 \cdot x_{t-157} + \\
 & + 0,0009299 \cdot x_{t-158} - 0,00258 \cdot x_{t-159} + 0,004242 \cdot x_{t-160} + 0,0107 \cdot x_{t-161} + \\
 & + 0,001051 \cdot x_{t-162} - 0,002417 \cdot x_{t-163} - 0,02759 \cdot x_{t-164} + 0,01817 \cdot x_{t-165} - \\
 & - 0,02805 \cdot x_{t-166} + 0,08555 \cdot x_{t-167} + 0,006555 \cdot x_{t-168} + 0,03136 \cdot x_{t-169} - \\
 & - 0,06896 \cdot x_{t-170} - 0,02407 \cdot x_{t-171} + 0,00681 \cdot x_{t-172} - 0,008553 \cdot x_{t-173}
 \end{aligned}$$


Anexo B


B.1 - Previsões efetuadas pela RN1, para o mês de Agosto





B.2 - Previsões efetuadas pela RN2, mês de Dezembro





Anexo C

C.1 - Resultados do processo de seleção de variáveis




Figura C.1 - Desempenho da configuração (SW, T2, U10 e WDIR) dos dados NWP 00:00 UTC.




Figura C.2 - Desempenho da configuração (SW, U10, V10 e WDIR) dos dados NWP 00:00 UTC.




Figura C.3 - Desempenho da configuração (SW, T2, U10, V10 e WDIR) dos dados NWP 00:00 UTC.




Figura C.4 - Desempenho da configuração (SW, T2, U10, V10 e WDIR) dos dados NWP 00:00 UTC, dados estandardizados.




Figura C.5 - Desempenho da configuração (SW, T2, U10, V10, WDIR e H72) dos dados NWP 00:00 UTC.




Figura C.6 - Desempenho da configuração (SW, T2, U10, V10 e WDIR) dos dados NWP 12:00 UTC.




Figura C.7 - Desempenho da configuração (SW, T2, U10, V10, WDIR e H_{72}) dos dados NWP 12:00 UTC.




Figura C.8 - Desempenho do modelo com a adição das componentes do ciclo diário, para $k=1$.




Figura C.9 - Desempenho do modelo com a adição das componentes do ciclo diário, para $k=2$.




Figura C.10 - Desempenho do modelo com a adição das componentes do ciclo diário, para $k=3$.




Figura C.11 - Desempenho do modelo com a adição das componentes do ciclo diário, para $k=4$.




Figura C.12 - Desempenho do modelo com a adição das componentes do ciclo diário, para $k=1 + k=2$.




Figura C.13 - Desempenho do modelo após a decomposição da direção do vento.