



**UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

MARCELLO ANDERSON FERREIRA BATISTA LIMA

**TÉCNICAS DE PREVISÃO DO RECURSO SOLAR INTEGRADAS A PARTIR DA
TEORIA DO PORTFÓLIO**

FORTALEZA

2020

MARCELLO ANDERSON FERREIRA BATISTA LIMA

TÉCNICAS DE PREVISÃO DO RECURSO SOLAR INTEGRADAS A PARTIR DA
TEORIA DO PORTFÓLIO

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Ceará, Brasil, e ao Programa de Doutorado da Universidade de Cádiz, Espanha, como requisito parcial à obtenção do título de Doutor em Engenharia Elétrica e Doutor pela Universidade de Cádiz no Programa de Doutorado em Engenharia Energética e Sustentável, respectivamente, em regime de cotutela internacional. Área de concentração: Energias Renováveis.

Orientador (Brasil): Prof. Dr. Paulo Cesar Marques de Carvalho.

Coorientador (Brasil): Prof. Dr. Arthur Plínio de Souza Braga.

Orientador (Espanha): Prof. Luis Miguel Fernández Ramírez

FORTALEZA

2020

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca Universitária
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

- L699t Lima, Marcello Anderson Ferreira Batista.
Técnicas de previsão do recurso solar integradas a partir da teoria do portfólio / Marcello Anderson Ferreira Batista Lima. – 2020.
172 f. : il. color.
- Tese (doutorado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica, Fortaleza, 2020.
Orientação: Prof. Dr. Paulo Cesar Marques de Carvalho.
Coorientação: Prof. Dr. Arthur Plínio de Souza Braga.
1. PrevTP . 2. Previsão do Recurso Solar. 3. Integração de Técnicas de Previsão Solar.
4. Teoria do Portfólio. 5. Energias Renováveis. I. Título.

CDD 621.3

MARCELLO ANDERSON FERREIRA BATISTA LIMA

TÉCNICAS DE PREVISÃO DO RECURSO SOLAR INTEGRADAS A PARTIR DA
TEORIA DO PORTFÓLIO

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Ceará, Brasil, e ao Programa de Doutorado da Universidade de Cádiz, Espanha, como requisito parcial à obtenção do título de Doutor em Engenharia Elétrica e Doutor pela Universidade de Cádiz no Programa de Doutorado em Engenharia Energética e Sustentável, respectivamente, em regime de cotutela internacional. Área de concentração: Energias Renováveis.

Aprovada em: 07/05/2020.

BANCA EXAMINADORA

Prof. Dr. Paulo Cesar Marques de Carvalho (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Arthur Plínio de Souza Braga (Coorientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. José Renato de Brito Sousa
Instituto Federal do Ceará (IFCE)

Prof. Dr. Pablo García Triviño
Universidade de Cádiz (UCA)

Prof. Dr. Carlos Andrés García Vázquez
Universidade de Cádiz (UCA)

Prof. Dr. Francisco Jurado Melguizo
Universidade de Jaén (UJA)

A minha filha, Elis Alves Ferreira, a minha esposa, Luanna Araújo Alves, a minha mãe, Rúbia Maria Ferreira Batista, aos meus familiares e a todos os amigos.

AGRADECIMENTOS

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

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq, pelo apoio financeiro com a manutenção da bolsa de doutorado sanduíche.

Ao Instituto Federal de Educação, Ciência e Tecnologia, pelo incentivo a qualificação profissional.

Ao Prof. Dr. Paulo Cesar Marques de Carvalho, pelo incentivo ao desenvolvimento das atividades e pela excelente orientação.

Ao Prof. Dr. Arthur Plínio de Souza Braga, pela excelente coorientação.

Ao Prof. Dr. Luis Miguel Fernández Ramírez, pelo acolhimento na Espanha e pela excelente orientação.

Aos professores Dr. José Renato de Brito Sousa, Dr. Pablo García Triviño, Dr. Carlos Andrés García Vázquez, Dr. Francisco Jurado Melguizo, pela participação na banca de defesa de doutorado e pelas excelentes sugestões.

Aos colegas da turma de doutorado e mestrado, pelas reflexões, críticas e sugestões recebidas.

“Em todo o espaço há energia... é uma questão de tempo até que os homens tenham êxito em associar seus mecanismos ao aproveitamento desta energia.” (Nikola Tesla.)

RESUMO

Nas últimas décadas, diversos métodos de previsão têm sido implementados com o objetivo de melhorar a antevisão de recursos energéticos intermitentes. Motivado pelo crescimento do uso de plantas Fotovoltaicas (FV), na presente tese é desenvolvida uma técnica denominada de PrevTP, baseada na integração de técnicas de previsão a partir da Teoria do Portfólio (TP). A TP é uma ferramenta utilizada no setor financeiro para que os riscos de perdas dos investimentos sejam diminuídos através da diversificação de ativos. Para a previsibilidade solar, a TP, por meio da PrevTP, é adaptada com o enfoque na diminuição dos erros de previsão. A PrevTP aproveita os ativos de previsão diversificados, ou seja, quando um dos ativos obtiver erros de previsão, o outro ativo realiza uma compensação do erro através de ponderações pré-definidas pela metodologia utilizada. Como ativos de previsão da PrevTP, a presente tese utiliza-se das estruturas das técnicas de aprendizagem: *Multilayer Perceptron (MLP) Backpropagation*; *Radial Basis Function (RBF)*; *Support Vector Regression (SVR)*; e *Deep Learning (DL)*. A técnica desenvolvida é aplicada em dois locais com diferentes condições de irradiação solar: Fortaleza, Brasil, e Algeciras, Espanha. Com o uso das 4 técnicas, é possível perceber a redução dos erros de previsão através da integração. As etapas de aplicação da PrevTP são: coleta de dados, previsão da irradiância solar por meio dos ativos de forma individual, estudo dos erros de previsão, processamento de dados de erros de previsão pela PrevTP, definição final das ponderações dos ativos pela PrevTP e, por fim, verificação dos erros de previsão com as 4 técnicas integradas pela metodologia proposta em comparação com os ativos individuais. Os resultados obtidos mostram que o *Mean Absolute Percentage Error (MAPE)* para previsões usando a PrevTP é de 4,52 % no Brasil e 5,36 % na Espanha. Nos dois casos, os resultados da PrevTP são melhores do que os encontrados nas outras técnicas utilizadas isoladamente, com valores de MAPE entre 6,08 % a 8,53 %, o que caracteriza a PrevTP como uma ferramenta com impactos positivos para a gestão da energia solar.

Palavras-chave: PrevTP, Previsão do Recurso Solar, Integração de Técnicas de Previsão Solar, Teoria do Portfólio, Energias Renováveis.

RESUMEN

En las últimas décadas, se han implementado varios métodos de predicción para mejorar la predicción el pronóstico de los recursos energéticos intermitentes. Motivada por el crecimiento del uso de plantas fotovoltaicas (FV), esta tesis desarrolla una técnica llamada PrevTP, basada en la integración de técnicas de predicción mediante la Teoría del Portfolio (TP). TP es una herramienta utilizada en el sector financiero para reducir el riesgo de pérdida de inversiones mediante la diversificación de activos. Para la predicción solar, la TP, a través de PrevTP, se adapta con un enfoque en la reducción de errores de predicción. La PrevTP aprovecha los activos de previsión diversificados, es decir, cuando uno de los activos obtiene errores, el otro activo realiza una compensación de errores mediante ponderaciones predefinidas de acuerdo con la metodología utilizada. Como activos de previsión de la PrevTP, la presente tesis utiliza las estructuras de las técnicas de aprendizaje: *Multilayer Perceptron (MLP)*, *Backpropagation*; *Radial Basis Function (RBF)*; *Support Vector Regression (SVR)*; y *Deep Learning (DL)*. La técnica desarrollada se aplica a dos lugares con diferentes condiciones de irradiación solar: Fortaleza, Brasil, y Algeciras, España. Usando las 4 técnicas, es posible ver la reducción de los errores de predicción a través de la integración. Las etapas de aplicación de PrevTP son: recolección de datos, previsión de irradiancia solar a través de los activos individualmente, estudio de errores de predicción, procesamiento de datos de errores de predicción por la PrevTP, definición final de ponderaciones de activos por PrevTP y, finalmente, verificación de errores de predicción con las 4 técnicas integradas por la metodología propuesta en comparación con los activos individuales. Los resultados obtenidos muestran que el *Mean Absolute Percentage Error (MAPE)* para las predicciones con PrevTP es del 4,52% en Brasil y del 5,36% en España. En ambos casos, los resultados de PrevTP son mejores que los encontrados en otras técnicas utilizadas solas, con valores MAPE entre 6,08% a 8,53%, lo que caracteriza a PrevTP como una herramienta con impactos positivos para el manejo de energía solar.

Palabras clave: PrevTP, Predicción de Recursos Solares, Integración de Técnicas de Previsión Solar, Teoría del Portfolio, Energía Renovable.

ABSTRACT

In the last decades, several forecasting methods have been implemented in order to improve the forecast of intermittent energy resources. Motivated by the growth in the use of Photovoltaic (PV) plants, this thesis develops a technique called PrevTP, based on the integration of forecasting techniques using the Portfolio Theory (TP). TP is a tool used in the financial sector so that the risk of loss of investments is reduced through the diversification of assets. For solar predictability, TP, through PrevTP, is adapted with a focus on reducing forecasting errors. PrevTP takes advantage of diversified forecast assets, that is, when one of the assets obtains forecast errors, the other asset compensates for the error through pre-defined weightings based on the methodology used. As PrevTP predictive assets, this thesis uses the structures of the learning techniques: Multilayer Perceptron (MLP) Backpropagation; Radial Basis Function (RBF); Support Vector Regression (SVR); and Deep Learning (DL). The technique developed is applied to two sites with different solar irradiation conditions: Fortaleza, Brazil, and Algeciras, Spain. Using the 4 techniques, it is possible to perceive the reduction of forecasting errors through integration. The stages of application of PrevTP are: data collection, prediction of solar irradiance through the assets individually, study of forecast errors, data processing of forecast errors by PrevTP, final definition of asset weightings by PrevTP and, finally, verification of forecasting errors with the 4 techniques integrated by the proposed methodology in comparison with the individual assets. The results obtained show that Mean Absolute Percentage Error (MAPE) for predictions using PrevTP is 4.52% in Brazil and 5.36% in Spain. In both cases, PrevTP results are better than other techniques used alone, with MAPE values between 6.08% to 8.53%, which characterizes PrevTP as a tool with positive impacts for the management of solar energy.

Keywords: PrevTP, Solar Resource Forecast, Integration of Solar Forecasting Techniques, Portfolio Theory, Renewable Energy.

LISTA DE FIGURAS

Figura 2.1	– AOD no mundo (2015).....	28
Figura 2.2	– Sensores utilizados.....	29
Figura 2.3	– Irradiância solar prevista e observada	31
Figura 2.4	– Comparativo da previsão e valor de potência observada	32
Figura 2.5	– Comparativos de previsões.....	33
Figura 2.6	– Estação radiométrica	35
Figura 2.7	– Comparativo da previsão e valor observado.....	36
Figura 2.8	– Comparativo de previsões e medição de irradiância	38
Figura 2.9	– Distribuição das estações meteorológicas.....	39
Figura 2.10	– Comparativo de previsões e medição de irradiância	40
Figura 4.1	– Sensor de irradiância solar	63
Figura 4.2	– Sensor de temperatura	63
Figura 4.3	– Localização das medições, Fortaleza, Ceará, Brasil	64
Figura 4.4	– Tela do PVGIS	65
Figura 4.5	– Localização das medições, Algeciras, Cádiz, Espanha	66
Figura 4.6	– Estrutura MLP	68
Figura 4.7	– Propagação da saída e retropropagação dos erros.....	69
Figura 4.8	– Procedimento MLP Backpropagation.....	71
Figura 4.9	– Estrutura RBF	72
Figura 4.10	– Separação de dados MLP e RBF	73
Figura 4.11	– Procedimento RBF Utilizada.....	76
Figura 4.12	– Estrutura SVR.....	77
Figura 4.13	– Separação de dados SVR	77
Figura 4.14	– Separação de dados SVM com relaxamento.....	79
Figura 4.15	– Separação de dados SVM com Kernel.....	79
Figura 4.16	– Hiperplano de separação SVR	80
Figura 4.17	– Procedimento SVR Utilizada.....	82
Figura 4.18	– Modelo da LSTM utilizada	83
Figura 4.19	– Estrutura da DL LSTM	85
Figura 4.20	– Procedimento LSTM <i>Backpropagation</i> utilizado	87
Figura 4.21	– Curva de efeito da diversificação.....	89
Figura 4.22	– Correlação perfeita positiva	91

Figura 4.23	– Correlação positiva	91
Figura 4.24	– Correlação nula	92
Figura 4.25	– Correlação perfeita negativa.....	92
Figura 4.26	– Correlação negativa.....	92
Figura 4.27	– Gráfico de fronteiras eficientes	95
Figura 4.28	– Exemplo de curva de análise.....	95
Figura 4.29	– Comparativo entre erros modular e não modular	98
Figura 4.30	– Desenvolvimento do gráfico de fronteiras eficientes.....	101
Figura 4.31	– Estrutura PrevTP	102
Figura 4.32	– Estrutura simplificada PrevTP.....	103
Figura 4.33	– Fluxograma PrevTP	104
Figura 5.1	– Irradiação média diária	106
Figura 5.2	– Dia característico solar (setembro de 2003)	107
Figura 5.3	– Dia característico solar (fevereiro de 2004)	107
Figura 5.4	– Comportamento da irradiância solar em Abril de 2003	108
Figura 5.5	– Comparativo entre a irradiância solar prevista e medida (MLP)	112
Figura 5.6	– Distribuição dos erros de previsão (MLP)	113
Figura 5.7	– <i>Boxplot</i> (MLP)	113
Figura 5.8	– Comparativo entre a irradiância solar prevista e medida (RBF).....	117
Figura 5.9	– Distribuição dos erros de previsão (RBF)	118
Figura 5.10	– <i>Boxplot</i> (RBF)	118
Figura 5.11	– Comparativo entre a irradiância solar prevista e medida (SVR)	121
Figura 5.12	– Distribuição dos erros de previsão (SVR).....	122
Figura 5.13	– <i>Boxplot</i> (SVR)	122
Figura 5.14	– Comparativo entre a irradiância solar prevista e medida (DL)	126
Figura 5.15	– Distribuição dos erros de previsão (DL).....	127
Figura 5.16	– <i>Boxplot</i> (DL).....	127
Figura 5.17	– <i>Boxplot</i> dos dados observados e previstos em Fortaleza, Brasil....	128
Figura 5.18	– Desenvolvimento das Fronteiras Eficientes (primeira camada)	129
Figura 5.19	– Desenvolvimento das Fronteiras Eficientes (segunda camada)	129
Figura 5.20	– Desenvolvimento das Fronteiras Eficientes (saída).....	130
Figura 5.21	– Pesos e estrutura final da PrevTP no Brasil	131
Figura 5.22	– Distribuição dos erros de previsão no Brasil.....	132
Figura 5.23	– <i>Boxplot</i> para o período de chuvas e sem chuvas no Brasil	134

Figura 5.24	– Irradiação média diária	134
Figura 5.25	– Dia característico solar (junho de 2013)	135
Figura 5.26	– Dia característico solar (dezembro de 2016)	135
Figura 5.27	– Comparativo entre a irradiância solar prevista e medida (MLP)	139
Figura 5.28	– Distribuição dos erros de previsão (MLP)	140
Figura 5.29	– <i>Boxplot</i> (MLP)	140
Figura 5.30	– Comparativo entre a irradiância solar prevista e medida (RBF)	144
Figura 5.31	– Distribuição dos erros de previsão (RBF)	145
Figura 5.32	– <i>Boxplot</i> (RBF)	145
Figura 5.33	– Comparativo entre a irradiância solar prevista e medida (SVR)	148
Figura 5.34	– Distribuição dos erros de previsão (SVR)	149
Figura 5.35	– <i>Boxplot</i> (SVR)	149
Figura 5.36	– Comparativo entre a irradiância solar prevista e medida (DL)	153
Figura 5.37	– Distribuição dos erros de previsão (DL)	154
Figura 5.38	– <i>Boxplot</i> (RBF)	154
Figura 5.39	– <i>Boxplot</i> dos dados observados e previstos em Algeciras, Espanha	155
Figura 5.40	– Desenvolvimento das Fronteiras Eficientes (primeira camada)	156
Figura 5.41	– Desenvolvimento das Fronteiras Eficientes (segunda camada)	156
Figura 5.42	– Desenvolvimento das Fronteiras Eficientes (saída)	157
Figura 5.43	– Pesos e estrutura final da PrevTP na Espanha	158
Figura 5.44	– Distribuição dos erros de previsão na Espanha	159
Figura 5.45	– <i>Boxplot</i> para as quatro estações do ano na Espanha	161

LISTA DE TABELAS

Tabela 2.1	– Comparativo entre diversas técnicas de previsão.....	41
Tabela 2.2	– Comparativo entre diversas integrações de técnicas de previsão ...	47
Tabela 4.1	– Evolução do risco mediante a diversificação	89
Tabela 4.2	– Integração das técnicas de previsão	100
Tabela 4.3	– Elaboração de Gráfico de fronteiras eficientes.....	101
Tabela 5.1	– Coeficiente de correlação entre as grandezas.....	109
Tabela 5.2	– Impacto das entradas nas previsões da RNA MLP	109
Tabela 5.3	– Definição da quantidade de entradas da MLP	110
Tabela 5.4	– Definição da quantidade de neurônios da camada oculta MLP	111
Tabela 5.5	– Impacto das entradas nas previsões da RNA RBF	114
Tabela 5.6	– Definição da quantidade de entradas da RBF.....	115
Tabela 5.7	– Definição da quantidade de neurônios da camada oculta da RBF.	116
Tabela 5.8	– Impacto das entradas nas previsões da SVR	119
Tabela 5.9	– Definição da quantidade de entradas da SVR	120
Tabela 5.10	– Impacto das entradas nas previsões da DL.....	123
Tabela 5.11	– Definição da quantidade de entradas da DL	124
Tabela 5.12	– Definição da quantidade de unidades ocultas da DL.....	125
Tabela 5.13	– Comparação entre as técnicas de previsão solar	133
Tabela 5.14	– MAPE para as sessões chuvosas e sem chuva no Brasil	133
Tabela 5.15	– Coeficiente de correlação entre as grandezas.....	136
Tabela 5.16	– Impacto das entradas nas previsões da RNA MLP.....	136
Tabela 5.17	– Definição de entradas MLP.....	137
Tabela 5.18	– Definição de neurônios da camada oculta MLP	138
Tabela 5.19	– Impacto das entradas nas previsões da RNA RBF	141
Tabela 5.20	– Definição da quantidade de entradas da RBF	142
Tabela 5.21	– Definição da quantidade de neurônios da camada oculta da RBF	143
Tabela 5.22	– Impacto das entradas nas previsões da SVR	146
Tabela 5.23	– Definição da quantidade de entradas da SVR	147
Tabela 5.24	– Impacto das entradas nas previsões da DL.....	150
Tabela 5.25	– Definição da quantidade de entradas da DL	151
Tabela 5.26	– Definição da quantidade de neurônios da camada oculta da RBF	152
Tabela 5.27	– Comparação entre as técnicas de previsão solar	160

Tabela 5.28 – MAPE para as sessões chuvosas e sem chuva no Brasil160

LISTA DE ABREVIATURAS E SIGLAS

AE	Avaliações Estatísticas
AG	Algoritmo Genético
ANFISs	<i>Adaptive Neurofuzzy Inference Systems</i>
AOD	<i>Aerosol Optical Depth</i>
AR	aprendizagem por reforço
ARMA	média móvel autorregressiva
ARIMA	média móvel integrada autorregressiva
BMA	<i>Bayesian Model Averaging</i>
CAPES	Coordenação de Aperfeiçoamento de Pessoal de Nível Superior
DEE	Departamento de Engenharia Elétrica
DL	<i>Deep Learning</i>
EEMD	<i>Enhanced Empirical Model Decomposition</i>
ELM	<i>Elman backpropagation network</i>
EMD	<i>Empirical Mode Decomposition</i>
EUA	Estados Unidos da América
FNN	<i>Feedforward</i>
FV	Fotovoltaica
IA	Inteligência Artificial
IET	<i>European Commission/Institute for Energy and Transport</i>
INMET	Instituto Nacional de Meteorologia
LEA	Laboratório de Energias Alternativas
LMS	<i>Least Median Square</i>
LSTM	<i>Long Short Term Memory</i>
LWL	<i>Locally Weighted Learning</i>
MAE	<i>Mean Absolute Error</i>
MAPE	<i>Mean absolute percentage error</i>
MLP	<i>Multilayer Perceptron</i>
MPE	<i>Mean Percentage Error</i>
NewCF	<i>cascade-forward backpropagation</i>
NRMSE	<i>Normalized Root Mean Square Error</i>
NWP	<i>Numerical Weather Prediction</i>

PPGEE	Programa de Pós-Graduação em Engenharia Elétrica
PVGIS	<i>Photovoltaic Geographical Information System</i>
RBF	<i>Radial Basis Function</i>
RF	<i>Random Forest</i>
RFT	<i>Random Forests Technique</i>
RMSE	<i>Root Mean Square Error</i>
RNAs	Redes Neurais Artificiais
RNN	<i>Recurrent Neural Network</i>
SLT	<i>Statistical Theory of Learning</i>
SRM	<i>Structural Minimization of Risk</i>
SVM	<i>Support Vector Machine</i>
SVR	<i>Support Vector Regression</i>
TESYR	<i>Grupo de Investigación en Tecnologías Eléctricas Sostenibles y Renovables</i>
TP	Teoria do Portfólio
UCA	Universidade de Cádiz
UFC	Universidade Federal do Ceará
UTSA	Universidade do Texas em Santo Antônio
WD	<i>Wavelet Decomposition</i>

LISTA DE SÍMBOLOS

%	Porcentagem
°C	Grau Celsius
m ²	Metros Quadrados
ρ	Coefficiente de Correlação
Cov	Covariância
σ	Desvio padrão do ativo
ω	Portfólio eficiente do ativo
€	Euro
y_j	Saída de neurônio
e_j	Erro
δ	Sensibilidade
w	Peso
b	Bias
φ	saída de cada neurônio da camada oculta
C_k	Centro do neurônio
E	erro de previsão integrado
R	Risco
r	diferença entre a entrada x e o centro t
α	taxa de aprendizagem arbitrada pelo programador
ξ_i	distância entre o dado de classe errônea em relação ao hiperplano de separação
C	limite de relaxamento atribuído pelo programador
$K_{(x, x')}$	núcleos do produto interno
ε	variável de folga
f_t	porta de esquecimento
i_t	porta de entrada
g_t	porta de atualização
o_t	porta de saída
c_t	célula de memória
h_t	saída da rede

D_p	dados previstos
D_o	dados observados
$\rho_{x,y}$	Coefficiente de Correlação
\bar{x}	média dos valores do ativo
x_i	valores do ativo
E_p	erro de previsão
D_m	dados medidos
D_p	dados previstos
E_{pon}	erro de previsão ponderado
FI	fator de impacto
Mr	maior valor encontrado do recurso

SUMÁRIO

1	INTRODUÇÃO	20
1.1	Motivação	21
1.2	Objetivos	24
1.3	Metodologia	24
1.4	Organização dos capítulos	25
2	PREVISIBILIDADE SOLAR	26
2.1	Técnicas de aprendizagem aplicadas à previsibilidade solar	27
2.1.1	<i>Alfadda, Rahman e Pipattanasomporn (2018)</i>	27
2.1.2	<i>Chu, Li e Coimbra (2016)</i>	28
2.1.3	<i>Mellit e Pavan (2010)</i>	30
2.1.4	<i>Awad e Qasrawi (2016)</i>	31
2.1.5	<i>Jiang et al. (2015)</i>	32
2.1.6	<i>Meenal e Selvakumar (2018)</i>	34
2.1.7	<i>Belaid e Mellit (2016)</i>	34
2.1.8	<i>Zeng e Qiao (2013)</i>	35
2.1.9	<i>Husein e Chung (2019)</i>	37
2.1.10	<i>Kaba et al. (2018)</i>	38
2.1.11	<i>Moncada, Richardson e Vega-Avila (2018)</i>	39
2.1.12	<i>Comparativos entre técnicas de aprendizagem aplicadas a previsibilidade solar</i>	40
2.2	<i>Integração de técnicas de previsibilidade solar</i>	41
2.2.1	<i>Raza, Mithulananthan e Summerfield (2018)</i>	42
2.2.2	<i>Monjoly, et al. (2017)</i>	43
2.2.3	<i>Abuella e Chowdhury (2017)</i>	44
2.2.4	<i>Wang e Wu (2016)</i>	45
2.2.5	<i>Wu, Chen e Abdul Rahman</i>	45
2.2.6	<i>Hossain, Oo e Ali (2013)</i>	46
2.2.7	<i>Comparativos entre integrações de técnicas de previsão</i>	47
2.3	Conclusões parciais	47
3	TEORIA DO PORTFÓLIO E SUA UTILIZAÇÃO NO SETOR ELÉTRICO	48

3.1	Breve histórico	48
3.2	TP no setor de energia elétrica	49
3.2.1	<i>Shahriari e Blumsack (2018)</i>	50
3.2.2	<i>Santos-Alamillos et al. (2017)</i>	50
3.2.3	<i>Narayan e Ponnambalam (2017)</i>	51
3.2.4	<i>Lima (2016)</i>	52
3.2.5	<i>Tola (2015)</i>	53
3.2.6	<i>Cucchiella, Gastaldi e Trosini (2015)</i>	54
3.2.7	<i>Nazari et al. (2015)</i>	54
3.2.8	<i>Cunha e Ferreira (2014)</i>	56
3.2.9	<i>Speth (2013)</i>	57
3.2.10	<i>Roques, Hiroux e Saguan (2010)</i>	58
3.2.11	<i>Jansen, Beurskens e Tilburg (2006)</i>	59
3.2.12	<i>Krey e Zweifel (2006)</i>	59
3.2.13	<i>Awerbuch e Berger (2003)</i>	60
3.3	Conclusões parciais	61
4	MATERIAIS E MÉTODOS	62
4.1	Obtenção de dados	62
4.1.1	<i>Dados coletados no Brasil</i>	62
4.1.2	<i>Coleta de dados na Espanha</i>	64
4.2	Tratamento dos dados	66
4.3	Técnicas de aprendizagem e seu uso na previsibilidade	67
4.3.1	<i>MLP</i>	67
4.3.2	<i>RBF</i>	71
4.3.3	<i>SVR</i>	76
4.3.4	<i>Deep Learning</i>	82
4.4	<i>Ajustes finos nas técnicas de previsão</i>	87
4.5	PrevTP	88
4.5.1	<i>Diversificação dos ativos</i>	88
4.5.2	<i>Fronteiras Eficientes</i>	94
4.5.3	<i>Erros de previsão</i>	96
4.5.4	<i>Gráfico de Fronteiras Eficientes</i>	98
4.5.5	<i>Estrutura adaptativa PrevTP</i>	102

4.5.6	<i>Étapas para funcionamento da PrevTP</i>	103
4.6	Conclusões parciais	105
5	RESULTADOS	106
5.1	Resultado para dados do Brasil	106
5.1.1	<i>Dados coletados</i>	106
5.1.2	<i>Resultados MLP</i>	108
5.1.3	<i>Resultados RBF</i>	114
5.1.4	<i>Resultados SVR</i>	119
5.1.5	<i>Resultados DL</i>	123
5.1.6	<i>Integração das técnicas de previsão no Brasil</i>	128
5.2	Resultado para dados da Espanha	134
5.2.1	<i>Dados coletados</i>	134
5.2.2	<i>Resultados MLP</i>	136
5.2.3	<i>Resultados RBF</i>	141
5.2.4	<i>Resultados SVR</i>	146
5.2.5	<i>Resultados DL</i>	150
5.2.6	<i>Integração das técnicas de previsão na Espanha</i>	155
5.3	Conclusões parciais	161
6	CONCLUSÃO	162
	REFERÊNCIAS	166

1 INTRODUÇÃO

Com o atual crescimento populacional no mundo, no qual o número de habitantes deve ultrapassar 11 bilhões em 2100, cresce também a busca por fontes de energia que venham a suprir a demanda elétrica mundial (NAÇÕES UNIDAS, 2017). No Brasil, por exemplo, no ano de 2017, houve um acréscimo de aproximadamente 2 % nas unidades consumidoras de energia elétrica se comparado a 2016, passando de 80.590.377 para 82.236.945 unidades (MINISTÉRIO DE MINAS E ENERGIA, 2018, p. 10).

Vários fatores, tais como desafios climáticos, expansão das unidades consumidoras de energia elétrica, expansão dos hábitos populacionais que envolvem utilização de eletricidade, vêm influenciando a busca por tecnologias capazes de expandir e diversificar a matriz elétrica mundial. Com isso, fontes alternativas de energia, como a solar, por exemplo, vêm obtendo espaço para ampliação em sua participação. Em 1973, as fontes renováveis não hídricas detinham 0,6 % da participação da produção de eletricidade no mundo, enquanto em 2016 sua participação aumentou para 8 % (INTERNATIONAL ENERGY AGENCY, 2018, p. 14).

A energia solar emerge como uma das principais fontes de energia alternativa capazes de contribuir para suprir a demanda energética mundial (WORLD ENERGY COUNCIL, 2017, p. 28). A capacidade instalada de eletricidade gerada por meio da fonte solar apresentou um crescimento exponencial, atingindo cerca de 627 GW no final de 2019 (INTERNATIONAL ENERGY AGENCY, 2020, p. 6).

Conforme o desenvolvimento tecnológico das fontes de energias alternativas, a proporção de utilização desses recursos aumentará na produção de eletricidade dos próximos anos. A geração solar fotovoltaica (FV) está ganhando mais atenção devido a esse avanço tecnológico. Entre os avanços estão: maior eficiência de células solares; vida útil longa dos equipamentos; e redução dos custos de geração de energia elétrica nas últimas décadas (CHAUDHARY e RIZWAN, 2018, p.5). Conseqüentemente, a energia solar tem participação crescente na matriz energética mundial.

1.1 Motivação

Ao contrário da geração de eletricidade a partir de fontes térmicas, por exemplo, que pode ser aumentada ou diminuída de acordo com o consumo, a geração de energia elétrica a partir da fonte solar apresenta caráter intermitente de geração causada por fatores climáticos meteorológico, influenciada, por exemplo, pelo excesso de nuvens. Esta característica pode gerar complicações devido à intermitência e ao não controle da geração, podendo causar falta ou excesso de energia no sistema elétrico (LIMA, 2016, p. 11).

Para a implantação de parques geradores a partir da fonte solar deve ser considerada, além da disponibilidade energética regional, a variabilidade temporal. Há intermitência de curto prazo na geração de eletricidade proveniente da fonte solar, uma vez que, em momentos ensolarados a potência de saída pode ser superior à demanda, porém em situações onde há cobertura de nuvens, essa potência pode ser inferior à demanda.

Devido à influência de fatores climáticos, a produção de energia elétrica a partir da fonte solar se caracteriza como de difícil previsibilidade (CHAUDHARY e RIZWAN, 2018, p. 6). Como os operadores da rede precisam manter sob controle essas variações, a fim de acomodar o balanço de entrada/saída do sistema, são necessários métodos de previsão para melhorar a conexão de recursos energéticos intermitentes. Assim, a previsão de irradiância solar é necessária para também ser possível prever a potência de saída dos sistemas solares (VOYANT, *et al.*, 2017, p.1).

Estudos demonstram que devido aos erros de previsão provenientes de fontes intermitentes de energia na Alemanha, a partir de dados de março a outubro de 2010, a produção de energia elétrica a partir de fontes renováveis intermitentes foi de 2 GWh abaixo do previsto, resultando em um custo adicional de 2,20 euros por MWh gerado (SPETH, 2012, p. 1). Isso se torna uma questão importante quando se enfrenta o fato de que as usinas solares estão amplamente espalhadas e em crescimento na maioria dos atuais sistemas de energia no mundo.

A potência de saída de um sistema FV está principalmente relacionada com a irradiação solar global recebida no plano horizontal dos módulos. Mas, em muitos casos não existe mensuração dessa informação bem como o acompanhamento por métodos de previsibilidade (AGUIAR, *et al.*, 2016, p.1).

Sistemas elétricos com alta inclusão de energia solar requerem também

estratégias de controle de produção e levantamento da demanda. Nesses sistemas, no entanto, a determinação dos níveis corretos da capacidade produtiva requer uma abordagem probabilística, porque geradores solares contam com fenômenos naturais e intermitentes que influenciam na produção elétrica.

Nas últimas décadas, um número crescente de métodos de previsão foi implementado por muitos pesquisadores devido à necessidade de melhorar previsão de sistemas elétricos com fontes intermitentes. Geralmente, essas abordagens podem ser divididas em três classificações principais: métodos convencionais não lineares, técnicas de aprendizagem, também conhecidas como Inteligência Artificial (IA) e modelos híbridos. Abordagens estatísticas não lineares, tais como modelos de regressão linear, média móvel autorregressiva (ARMA), média móvel integrada autorregressiva (ARIMA) e assim por diante, são conhecidas por apresentar a desvantagem de não obterem em sua saída uma variabilidade que acompanhe de forma precisa o comportamento das séries temporais, tornando-as impróprias para previsões de séries temporais complexas e não-lineares (DU, *et al.*, 2018, p. 524).

Com o desenvolvimento das técnicas de aprendizagem nos últimos anos, cada vez mais diferentes algoritmos, tais como *Support Vector Machine* (SVM), lógica Fuzzy e Redes Neurais Artificiais (RNAs), foram apresentados (DU, *et al.*, 2018, p. 524), (AGUIAR, *et al.*, 2016, p. 1). Esses estudos destacam-se por serem constituídos por unidades de processamento para modelar e aprender desde problemas simples a mais complexos e, uma vez treinadas, podem realizar previsões e generalizações com rapidez.

Motivado pelo crescimento do uso de plantas FV no Mundo e sua necessidade de previsibilidade, a presente tese desenvolve uma técnica denominada de PrevTP, que baseia-se no uso estrutural das técnicas de aprendizagem: *Multilayer Perceptron* (MLP), que tem sido aplicada com sucesso para resolver diversos problemas de alto nível de complexibilidade, por meio do seu treinamento de forma supervisionada, sendo um algoritmo muito conhecido (HAYKIN, 2001, p. 183); *Radial Basis Function* (RBF), que assim como a MLP é um aproximador universal, mas difere desta devido à necessidade de maior número de parâmetros, tornando assim a RBF uma rede mais complexa (HAYKIN, 2001, p. 323); *Support Vector Regression* (SVR), proveniente da *Support Vector Machine* (SVM), que assim como a MLP e a RBF, pode ser usada para classificação de padrões e regressão linear. A máquina de vetores de suporte (SVM) foi desenvolvida pela Vapnik em 1992 para resolver o problema de

classificação, baseado na *Statistical Theory of Learning (SLT)* e na *Structural Minimization of Risk (SRM)*. Este método foi estendido para o domínio de regressão e problemas de previsão, sendo assim chamado de SVR (HAYKIN, 2001, p. 349); e *Deep learning (DL)*, que faz parte da família das *Machine Learning*, e que utiliza-se de várias camadas de processamento para aprender uma representação de dados com vários níveis de abstração (BENGIO, 2009, p. 4). As técnicas de aprendizagem escolhidas serão utilizadas em conjunto por meio de algoritmo fundamentado na Teoria do Portfólio (TP), aqui chamada de PrevTP, visando contribuir para a diminuição dos erros de previsibilidade solar.

As técnicas supracitadas foram escolhidas por se tratar de técnicas já consolidadas, com grande capacidade de utilização na previsibilidade de recursos intermitentes de energia e por terem diversos níveis de complexidade de implementação e uso. Com isso, além do desenvolvimento da PrevTP, de posse dos resultados de previsão, é possível apresentar um comparativo entre os resultados e o comportamento das técnicas mencionadas.

Assim, a nova técnica desenvolvida obterá resultados de erros de previsão melhores que os de cada técnica individual de previsão solar, bem como obterá resultados de previsão compatíveis ou melhores em relação a outras técnicas de integração de algoritmos previsores.

A maneira de se integrar estas técnicas de aprendizagem utilizando-se da TP, representa a principal inovação da tese. Onde além da busca de menores erros de previsão através do efeito de diversificação dos ativos (quantidade de previsores), também é desenvolvido um algoritmo com baixo custo computacional.

Com a diversificação de ativos, quando um dos ativos obtiver erros de previsão, o outro ativo realiza uma compensação total ou parcial do erro. TP é utilizada habitualmente no setor financeiro para que os riscos dos investimentos sejam diminuídos por meio da diversificação das aplicações dos investidores (LIMA, *et al.*, 2017, p. 1). Desenvolvida pelo norte americano Harry Max Markowitz no ano de 1952, a teoria tem por objetivo final metodizar a definição do percentual de penetração de cada ativo a fim de melhores retornos financeiros (LIMA, 2016, p. 17).

A metodologia proposta foi aplicada em dados solares de Fortaleza (Brasil) e Algeciras (Espanha) sob desenvolvimento de cotutela internacional entre a Universidade de Cádiz (Espanha) e Universidade Federal do Ceará (Brasil), para obtenção do título de doutor em Engenharia Elétrica e Engenharia Energética e

Sustentável, respectivamente.

1.2 Objetivos

Esta proposta de tese tem como objetivo geral, desenvolver a técnica de integração de previsores (PrevTP), com algoritmo fundamentado na TP e arquitetura preditiva baseada nas técnicas de aprendizagem, MLP, RBF, SVR e DL.

Objetivos específicos:

- Coletar dados de irradiância solar no Brasil e Espanha para estudo do comportamento ao longo do tempo.
- Implementar uma MLP para previsão de irradiância solar.
- Implementar uma RBF para previsão de irradiância solar.
- Implementar uma SVR para previsão de irradiância solar.
- Implementar uma DL para previsão de irradiância solar.
- Desenvolver Algoritmo da técnica da previsão, denominado de PrevTP, para integrar as técnicas de aprendizagem supracitadas.
- Aplicar as técnicas estudadas aos dados coletados no Brasil e Espanha.
- Apresentar e caracterizar os resultados obtidos para as técnicas separadas e integradas com a PrevTP, bem como fazer o comparativo dos resultados obtidos com a PrevTP e outras técnicas de integração de previsores temporais.

1.3 Metodologia

Para o desenvolvimento da PrevTP com finalidade a melhoria da previsão de irradiância solar, as atividades foram realizadas nas seguintes fases: 1) Revisão do estado da arte; 2) Coleta dos dados de irradiância solar e temperatura em Fortaleza, Brasil; 3) Coleta dos dados de irradiância solar e temperatura em Algeciras, Espanha; 4) Implementação da técnica MLP para previsão do recurso solar; 5) Implementação da técnica RBF para previsão do recurso solar; 6) Implementação da técnica SVR para previsão do recurso solar; 7) Implementação da técnica DL para previsão do recurso solar; 8) Aplicação das quatro técnicas de aprendizagem para a previsão solar

em Fortaleza, Brasil e estudo dos erros de previsão; 9) Aplicação das quatro técnicas de aprendizagem para a previsão solar em Algeciras, Espanha e estudo dos erros de previsão; 10) Adaptação da TP para interação das técnicas de previsão (PrevTP); 11) Aplicação da PrevTP para a previsão solar em Fortaleza, Brasil; 12) Aplicação da PrevTP para a previsão solar em Algeciras, Espanha; 13) Análise de resultados, estabelecimento das conclusões.

1.4 Organização dos capítulos

A proposta de tese está dividida em seis capítulos, sendo eles:

1- Introdução, na qual são apresentadas problemáticas relacionadas à implantação da fonte solar. Contribuindo para o melhoramento da previsibilidade solar, é sugerida a criação da técnica denominada PrevTP;

2- Previsibilidade solar. Neste capítulo, é apresentado o levantamento bibliográfico da utilização das técnicas de aprendizagem, MLP, RBF, SVR e DL, na previsibilidade solar, bem como integrações de técnicas para essa previsibilidade.

3- Teoria do portfólio e sua utilização no setor elétrico. Neste capítulo é apresentado o levantamento bibliográfico da utilização da TP para o setor de produção de eletricidade;

4- Materiais e métodos. Neste capítulo são apresentados os métodos de coletas de dados, estruturas das técnicas de aprendizagem, MLP, RBF, SVR e DL, e o desenvolvimento da técnica de previsão do recurso solar denominada PrevTP;

5- Comportamento de técnicas de previsão. Neste capítulo são apresentados os resultados das técnicas aplicadas à previsão solar utilizadas nesse trabalho, bem como os resultados do processamento utilizando a PrevTP.

6- Conclusões. Onde além das conclusões, são apresentadas as sugestões de trabalhos futuros e os artigos desenvolvidos durante a elaboração da tese (são eles: *Portfolio Theory Applied to Solar and Wind Resources Forecast*; *MLP Back Propagation Artificial Neural Network for Solar Resource Forecasting in Equatorial Areas*; *Radial Basis Function for Solar Irradiance Forecasting in Equatorial Areas*; *Improving Solar Forecasting Using Deep Learning and Portfolio Theory Integration*).

2 PREVISIBILIDADE SOLAR

As tecnologias de geração solar FV tem experimentado um forte crescimento do mercado de energia mundial nos últimos anos, com o correspondente aumento nas taxas de penetração desta fonte no sistema elétrico (INMAN, PEDRO, COIMBRA, 2013, p. 1). A integração da energia solar na rede elétrica está se tornando essencial por causa do crescimento contínuo da utilização de eletricidade no mundo, e isso pode ser utilizado como forma de ampliação e diversificação da matriz energética. Esta integração oferecerá uma melhor qualidade de serviço se a variação da irradiância solar, provocada por fatores meteorológicos, puder ser prevista com precisão (DIAGNE, *et al.*, 2013, p. 65).

A inerente variabilidade da geração solar apresenta problemas associados ao custo na produção de eletricidade e confiabilidade da rede elétrica em geral. Como resultado, sistemas de previsão de alta precisão são necessários para múltiplos horizontes de tempo associados à regulação, despacho e programação de geração da unidade produtora de eletricidade pela fonte solar (INMAN, PEDRO, COIMBRA, 2013, p. 1). Três horizontes de previsão são considerados importantes para o produtor de eletricidade que utiliza a fonte solar e para o operador da rede elétrica: intra-hora, intra-dia e dia à frente) (DIAGNE, *et al.*, 2013, p. 66).

Os métodos de previsão estatísticos de séries temporais se dividem em: 1) Modelos lineares, onde se encontram as técnicas como ARIMA, por exemplo, e 2) Modelos não lineares, onde estão as técnicas de aprendizagem (DIAGNE, *et al.*, 2013, p. 67).

Métodos estatísticos não lineares têm sido utilizados com sucesso em previsões de séries temporais há várias décadas. Entretanto, tais técnicas como a ARIMA, por exemplo, têm a desvantagem de uma saída com variabilidade insuficiente para acompanhar o comportamento das séries temporais com grandes variações, como a irradiância solar. Por outro lado, métodos de aprendizagem têm em sua saída variabilidade suficiente para um melhor resultado de previsões de séries temporais se comparados com técnicas estatísticas.

Para ilustrar isso, (LIMA, 2016, p. 84), faz um comparativo entre os erros de previsões de uma RNA MLP *Backpropagation* e o método ARIMA, em que se conclui que a previsão utilizando-se da RNA MLP apresenta um melhor desempenho. A previsão através de RNA MLP *Backpropagation* obteve um total de 20 horas (3,66 %)

a mais de previsões dentro da faixa de -5 % a 5 % de erro em comparação à previsão com o método ARIMA e 53 horas (9,7 %) a mais para a faixa de -10 % a 10 % de erro (LIMA, 2016, p. 84).

Outras técnicas, tais como Imagens de Nuvens, que empregam imagens do céu capturadas por satélites ou câmera terrestre, e *Numerical Weather Prediction (NWP)*, que são utilizadas operacionalmente para prever o estado da atmosfera até 15 dias antes, são bastante utilizadas para a predição da irradiância solar (DIAGNE, *et al.*, 2013, p. 65).

A presente proposta de tese pretende aplicar e integrar técnicas de previsibilidade por aprendizagem, por se tratar de metodologias com resultados satisfatórios, como demonstrado anteriormente. Assim, a metodologia proposta pode ser implementada em qualquer localização onde há um banco de dados do comportamento da irradiância e temperatura ambiente ao longo do tempo, medidos com uso de um piranômetro e sensores de temperatura para atualização das previsões em tempo real. Com isso, almeja-se uma previsão precisa para o balanceamento correto da rede elétrica onde a planta FV estará implementada.

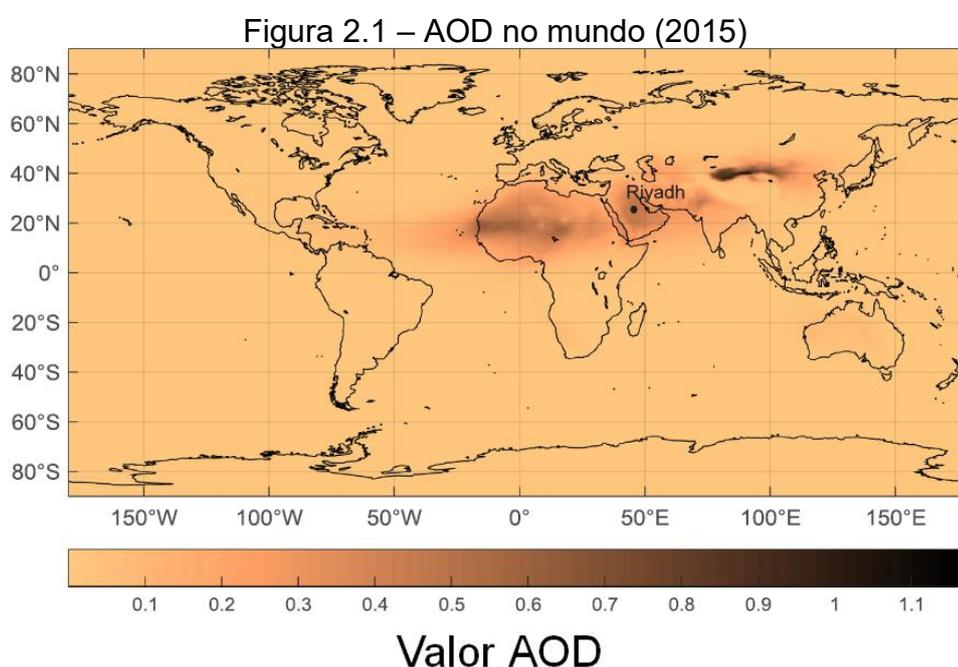
2.1 Técnicas de aprendizagem aplicadas à previsibilidade solar

Nas últimas décadas, tem-se encontrado diversas linhas de pesquisa sobre aplicações das técnicas de aprendizagem no setor de previsibilidade do recurso solar, em vários países que buscam o crescimento dessa fonte como contribuinte da matriz energética nacional. Nesta seção, são apresentados trabalhos que utilizaram-se das técnicas específicas MLP, RBF, SVR e DL, na previsibilidade solar, em que são ordenados por tipo de metodologia.

2.1.1 Alfadda, Rahman e Pipattanasomporn (2018)

Os autores começam o trabalho ressaltando a incerteza produtiva de um sistema solar FV causada por condições meteorológicas flutuantes, como a intensidade da luz do sol, a cobertura de nuvens e a umidade. Destacam ainda que, em áreas desérticas, outro parâmetro que tem um impacto significativo na irradiação solar, é a poeira, que tem sido negligenciada em muitos estudos.

Para atender à necessidade de melhora de previsibilidade solar em área com presença de partículas em suspensão, que se depositam nos sistemas FV a partir do ar, é criado um modelo de previsão de irradiância solar com uma hora de antecedência, considerando como entradas, além da irradiação solar, temperatura, etc., informações sobre *Aerosol Optical Depth (AOD)*, que é uma medida da extinção do feixe solar por poeira e neblina. Para caracterização do impacto do AOD nas previsões de irradiância solar em países desérticos, a distribuição do AOD no mundo em 2015 é demonstrada na Figura 2.1.



Fonte: Adaptada de Alfadda, Rahman e Pipattanasomporn (2018).

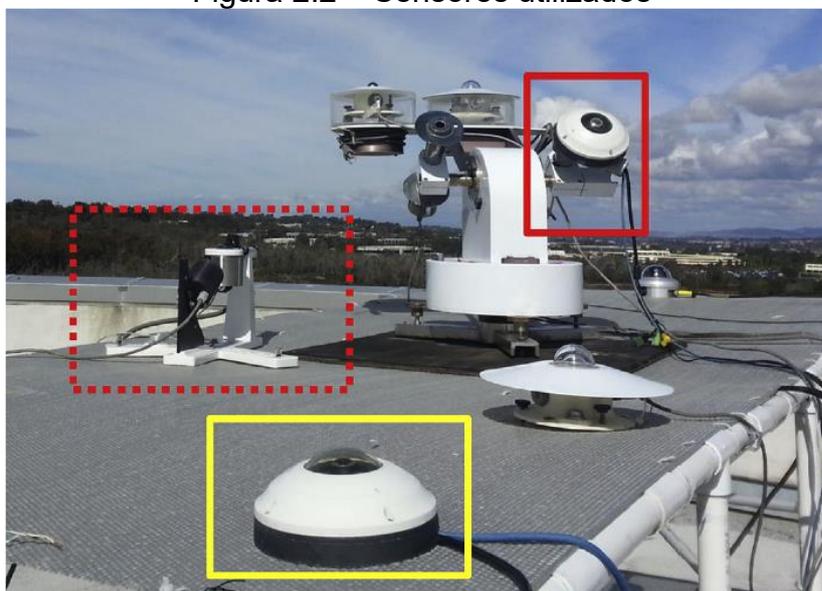
A estrutura da rede MLP implementada tem sete neurônios na primeira camada oculta e cinco neurônios na segunda camada oculta para uma previsão com o horizonte de 1 mês. A aplicação do modelo MLP usando dados da Arábia Saudita mostra um *Root-mean-square Error (RMSE)* de $32,75 \text{ W/m}^2$ para previsão de uma hora à frente.

2.1.2 Chu, Li, e Coimbra (2016)

Os autores utilizam-se de uma MLP para previsibilidade da irradiância solar de curto prazo a partir de imagens do céu. Esse sistema de imagens celestes é composto por uma câmera digital montada em um rastreador solar automático que

segue o padrão de movimentação solar. O Sol fica localizado no centro geométrico das imagens do céu. As imagens deste novo sistema fornecem mais informações sobre a cobertura do céu por nuvens, que disponibiliza dados críticos para previsões solares intra-hora, particularmente para a irradiância direta. Os equipamentos utilizados para a aquisição de dados no território estadunidense são apresentados na Figura 2.2. Dentre eles, uma câmera montada em um seguidor solar (retângulo contínuo vermelho), câmera estacionária (retângulo tracejado vermelho) e piranômetro (retângulo amarelo).

Figura 2.2 – Sensores utilizados



Fonte: Adaptada de Al Chu, Li e Coimbra (2016).

O algoritmo desenvolvido realiza a separação automática de obstáculos em terra, presentes nas bordas das imagens, como prédios por exemplo, e nuvens, que provocam o sombreamento do sistema solar. Em seguida, recursos de imagem alimentam a MLP que realiza as previsões de irradiância direta. Sessenta e sete dias de medições de irradiância e imagem são usados para treinar, otimizar e avaliar os modelos de previsão baseados em MLP para irradiação solar. Foram testados diversos horizontes de previsão de curto prazo, dentre eles, 5 minutos, 10 minutos, 15 minutos e 20 minutos.

Os resultados mostram que as previsões do MLP baseadas no sistema de imagens do céu, proposto por esse trabalho, superam os modelos consolidados em termos de métricas estatísticas em horizontes mais curtos.

O *Mean Absolute Error (MAE)* obtido por uma MLP baseada em dados de irradiância foi de $71,6 \text{ W/m}^2$, enquanto a MLP a partir de imagens do céu obteve o MAE de $65,2 \text{ W/m}^2$ para o horizonte de 5 min, caracterizando uma melhor eficiência nas previsões de 8,94 %. Para o horizonte de 20 minutos, o MAE obtido pela MLP baseada em dados de irradiância foi de $112,8 \text{ W/m}^2$, enquanto a MLP a partir de imagens do céu obteve o MAE de $109,5 \text{ W/m}^2$, caracterizando uma superioridade nas previsões de 2,92 %. Se comparado ao horizonte de 5 minutos, no horizonte de 20 minutos houve uma diminuição proporcional na diferença dos resultados.

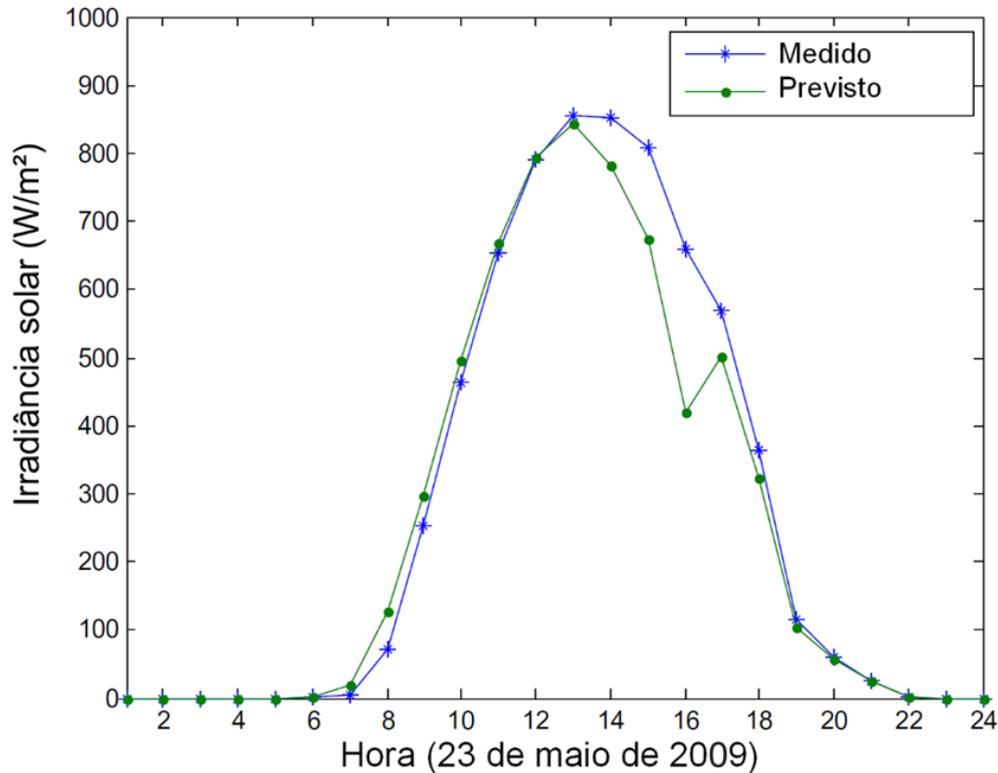
A redução na diferença caracteriza que, para horizontes mais distantes a técnica de previsão solar por imagens do céu não é mais eficiente que técnicas que usam a irradiância solar. Isso pode acontecer devido ao não aparecimento de nuvens, com grandes antecedências, nas imagens utilizadas que impactem a disponibilidade solar.

2.1.3 Mellit e Pavan (2010)

O trabalho inicia-se ressaltando a significância da previsão da irradiância solar aplicada ao planejamento das operações de usinas FV. Em particular, a possibilidade de prever a irradiância solar (até 24 h) em locais onde usinas FV estão conectadas à rede elétrica é fundamental para fazer o balanceamento correto do sistema elétrico a partir da combinação de fontes de energia.

Os autores apresentam um método prático para previsão de irradiação solar utilizando RNA MLP *Backpropagation*, em que a previsão da irradiância solar é feita com dados de entrada de 24 horas, utilizando valores de irradiação solar média diária e de temperatura do ar. A base de dados para treinamento da RNA foi coletada em Trieste, Itália. As previsões de irradiância solar obtidas pela RNA proposta apresentam o horizonte de 1 hora de antecedência. Um comparativo entre a irradiância medida através de um piranômetro e a prevista pela RNA é apresentado na Figura 2.3.

Figura 2.3 – Irradiância solar prevista e observada



Fonte: Adaptada de Mellit e Pavan (2010).

A comparação entre a irradiância prevista e a medida em Trieste, durante o período de análise, apresentou *Mean Percentage Error (MPE)* de 2,75 % e coeficiente de correlação na faixa de 98 % em dias ensolarados e 92 % em dias nublados.

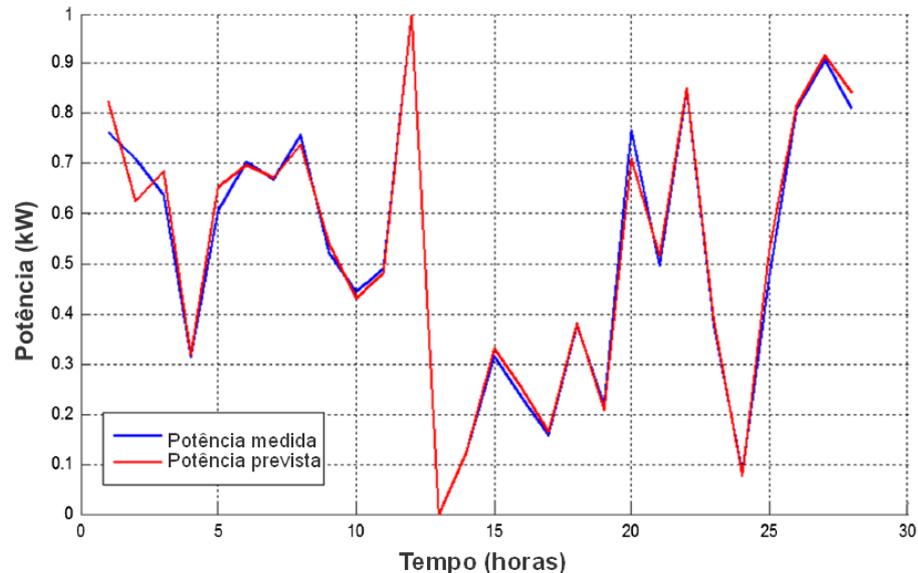
2.1.4 Awad e Qasrawi (2016)

Uma RNA RBF é uma técnica eficiente para previsão de séries temporais, que é um problema relativamente complexo. Assim, as RBFs têm sido usadas para modelar e prever os dados diários de irradiação solar global, bem como outros dados meteorológicos como temperatura do ar, duração da luz do sol e umidade relativa, entre outros. Nesse trabalho, é proposta uma RBF *K-means* e K-vizinhos mais próximos, para otimizar os centros dos neurônios, raio e pesos da RNA RBF. O modelo proposto é aplicado para prever a produção de eletricidade FV na Palestina, usando painéis FV já instalados na cidade de Jericó.

A irradiância solar e a temperatura diária são usadas como um conjunto de dados de treinamento de entrada para o modelo proposto, além da potência de saída

real do ano de 2015, coletados no local em estudo. O modelo é aplicado para prever a potência de saída da planta FV com potência de 1 kWp em cenários de 24 horas, 30 dias e 365 dias. O comportamento das previsões realizadas pelo algoritmo proposto em relação aos dados observados é mostrado na Figura 2.4.

Figura 2.4 – Comparativo da previsão e valor de potência observada



Fonte: Adaptada de Awad e Qasrawi (2016).

Os resultados experimentais mostram que o modelo desenvolvido nessa pesquisa tem um desempenho mais preciso do que os tradicionais métodos de RNAs MLPs, por exemplo, com baixo RMSE. A RBF proposta obteve um RMSE de 0,0667 kW e a MLP, também implementada pelos autores, obteve um RMSE de 0,337032 kW.

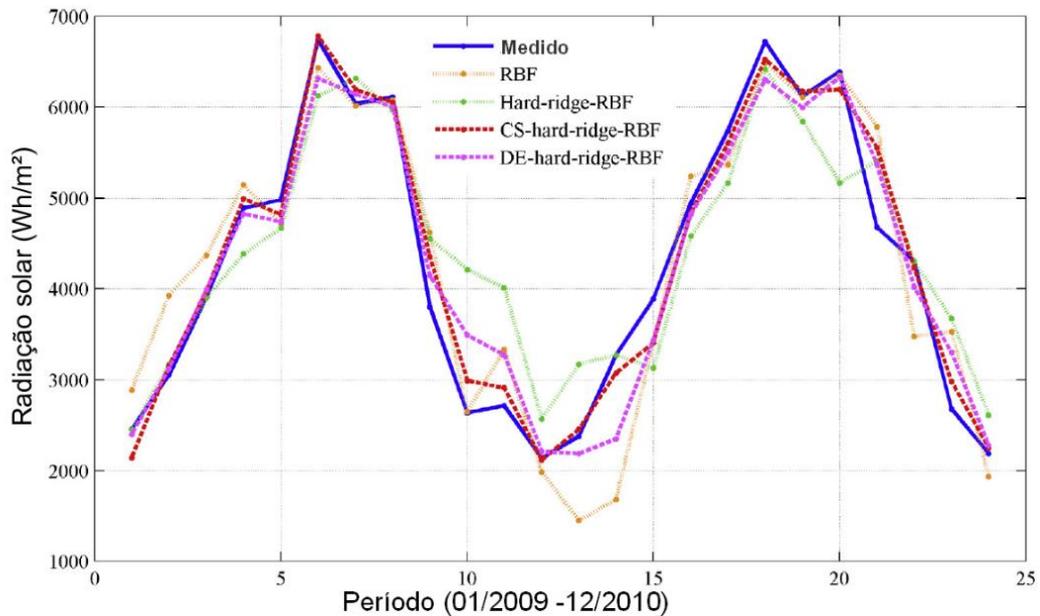
2.1.5 Jiang et al. (2015)

No estudo é afirmado que devido à escassez de equipamentos e aos altos custos de manutenção, os dados de irradiação solar são muito menos observados que temperatura e outros fatores climáticos. Porém, é necessário cada vez mais diversificar o estudo dos vários fatores meteorológicos relevantes para se prever com precisão a irradiação solar. Para essa pesquisa, foram considerados, além da irradiação solar média mensal outros 12 parâmetros meteorológicos, tais como aerossóis, precipitação, velocidade dos ventos, temperatura, entre outros, no período

de 1998 a 2010, em quatro locais nos Estados Unidos. A integração dos 12 parâmetros meteorológicos que podem ser utilizados como entrada da RBF foi estudada através do coeficiente de correlação de Pearson.

Quatro procedimentos com diferentes tipos de RBFs foram desenvolvidos para prever a irradiação solar média mensal, sendo dois modelos considerados inovadores. Foram utilizados modelos RBF clássico e *Hard-ridge-RBF*, além dos algoritmos próprios, *CS-hard-ridge-RBF* e *DE-hard-ridge-RBF*. O comportamento das previsões realizadas utilizando os algoritmos para as médias mensais pode ser visto na Figura 2.5.

Figura 2.5 – Comparativos de previsões



Fonte: Adaptada de Jiang et al. (2015).

Os resultados experimentais mostram que os modelos propostos produzem previsões muito mais precisas do que outros modelos clássicos implementados. Os resultados experimentais mostram que os modelos previram razoavelmente o comportamento da irradiação solar global média mensal nos diferentes locais. Se for considerado Fayetteville, Arkansas, os resultados demonstram que a RBF obteve um *Mean absolute percentage error (MAPE)* de 13,69 %, a *Hard-ridge-RBF* obteve 14,76 %, a *CS-hard-ridge-RBF* obteve 5,44 %, enquanto a *DE-hard-ridge-RBF* obteve 8,34 %.

2.1.6 Meenal e Selvakumar (2018)

Nessa pesquisa é avaliada a previsão de irradiância solar a partir de uma SVR, que usa como parâmetros de alimentação da rede mês, latitude, longitude, horas de sol, duração do dia, umidade relativa e temperatura. Os modelos são avaliados com base em medidas estatísticas, em que é analisada, a previsão de irradiância solar média mensal para diferentes cidades da Índia. Neste trabalho também tenta avaliar o potencial de energia solar das cidades de Tamil Nadu, na Índia, usando o modelo SVR, onde verificou-se que um excelente potencial solar está disponível.

O objetivo principal da pesquisa é a identificação de quais parâmetros podem ser utilizados para previsibilidade solar. Os parâmetros com insignificante influência nas previsões foram removidos para se reduzir a dimensionalidade dos dados, melhorar o coeficiente de correlação, com um menor custo financeiro de implementação de sensoriamento no local das previsões e menor custo computacional. Por meio de uma comparação entre as precisões de previsão, para selecionar um modelo simples e preciso para prever o recurso em qualquer local, foram criados diversos cenários, com diferentes parâmetros de entrada para a SVR.

De acordo com os resultados, os parâmetros de entrada mais influentes são as horas de luz do sol, a temperatura máxima, mês e latitude, e o parâmetro de entrada que menos influência é a umidade relativa. Portanto, foi possível a redução da dimensionalidade dos dados de entrada.

Assim, os modelos SVR selecionados podem ser implementados onde quer que os dados de irradiância solar medidos estejam indisponíveis. Os resultados desse estudo são comparados com outros estudos mensais de irradiação solar global através de métricas estatísticas, em que os autores afirmam que os resultados encontrados são melhores que os demais estudos. O melhor MPE encontrado foi de 0,9726 %.

2.1.7 Belaid e Mellit (2016)

Neste trabalho é evidenciado a importância do conhecimento do comportamento da irradiância solar no local de estudo para uma previsibilidade solar eficiente. Consequentemente, a previsibilidade da disponibilidade do recurso energético solar com resultados satisfatórios pode acarretar em uma melhor gestão,

dimensionamento e controle dos sistemas elétricos, como um todo.

Nesta pesquisa, é aplicada uma SVR para a previsão da irradiância solar média diária e mensal em Gardaia, Argélia, por se tratar de uma região onde o potencial das energias renováveis é fortemente dominado por fontes de energia solar com aplicações FV ou térmicas. Dados de temperatura ambiente, duração máxima de luz solar e irradiância solar foram os parâmetros considerados para o treinamento da SVR, sendo os horizontes de previsão em um dia a frente e um mês a frente.

Os dados medidos utilizados neste estudo são registrados a cada 1 hora por uma estação radiométrica instalada no local de estudo, mostrada na Figura 2.6, em que dois anos (2012 e 2013) foram escolhidos para o treinamento, e um ano (2014) é usado para a fase de testes.

Figura 2.6 – Estação radiométrica



Fonte: Adaptada de Belaid e Mellit (2016).

Os resultados obtidos mostraram uma concordância considerável entre os dados de radiação solar global medida e prevista. A principal vantagem obtida foi que a SVR proposta necessitou de poucos parâmetros para obter precisão nas previsões. Os valores de MAPE variaram de 10,403 % a 10,503 % para a previsão no horizonte de um dia a frente. Para a previsão mensal, o MAPE encontrado foi de 8,940 %.

2.1.8 Zeng e Qiao (2013)

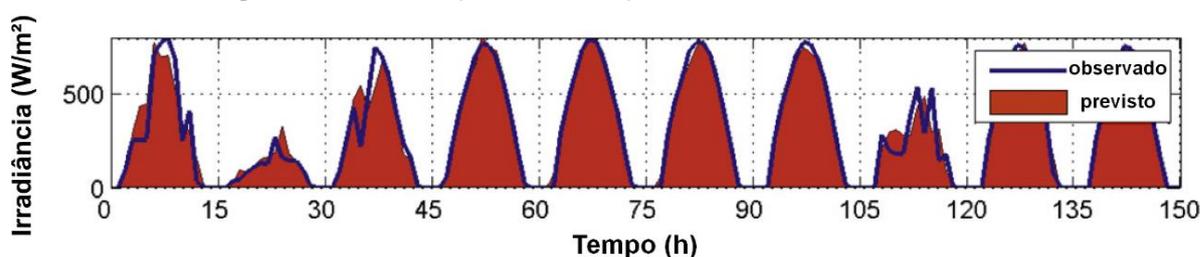
Os autores propõem uma técnica de previsão de irradiância solar em um

horizonte de curto prazo baseada em SVR. A entrada do modelo inclui dados históricos de transmissividade atmosférica e outras variáveis meteorológicas, incluindo cobertura do céu, umidade relativa e velocidade do vento.

Simulações computacionais são realizadas para validar o modelo proposto usando os dados obtidos no Banco Nacional de Radiação Solar dos Estados Unidos. Os dados foram registrados de 1991 a 2005, em 1454 locais nos Estados Unidos e são compostos por irradiância solar horária e outras 46 variáveis meteorológicas. Neste trabalho, três localizações são consideradas, são elas, Seattle, no noroeste, Denver, no Centro-Oeste e Miami no sudeste do país em estudo.

Em termos de precisão de predição, o modelo baseado em SVR proposto superou significativamente os modelos Auto Regressivos. Isso ocorre devido ao SVR ter melhor capacidade de capturar a natureza não linear e a variação da irradiância solar no tempo. Além disso, o modelo SVR obteve um desempenho melhor que os modelos baseados em RBF, e os resultados também indicaram que outras variáveis meteorológicas devem ser usadas para melhorar o sistema de previsão solar. Por exemplo, a cobertura do céu é um recurso proeminente, independentemente do local em análise, que deve ser considerado como uma entrada extra do modelo. O comportamento das previsões realizadas pelo algoritmo proposto em relação aos dados de irradiância observados pode ser visto na Figura 2.7.

Figura 2.7 – Comparativo da previsão e valor observado



Fonte: Adaptada de Zeng e Qiao (2013).

O uso de variáveis adicionais no sistema deve ser analisado em cada local onde pretende-se realizar as previsões. Por exemplo, em Denver, para o horizonte de previsão de 3 h, o MAE é melhorado em $14 W/m^2$ quando se aumenta significativamente as variáveis de entrada no sistema, o que corresponde a 19 % de melhoria em relação à previsão sem o uso de variáveis meteorológicas adicionais (cobertura do céu, umidade relativa do ar e velocidade do vento). No entanto, a

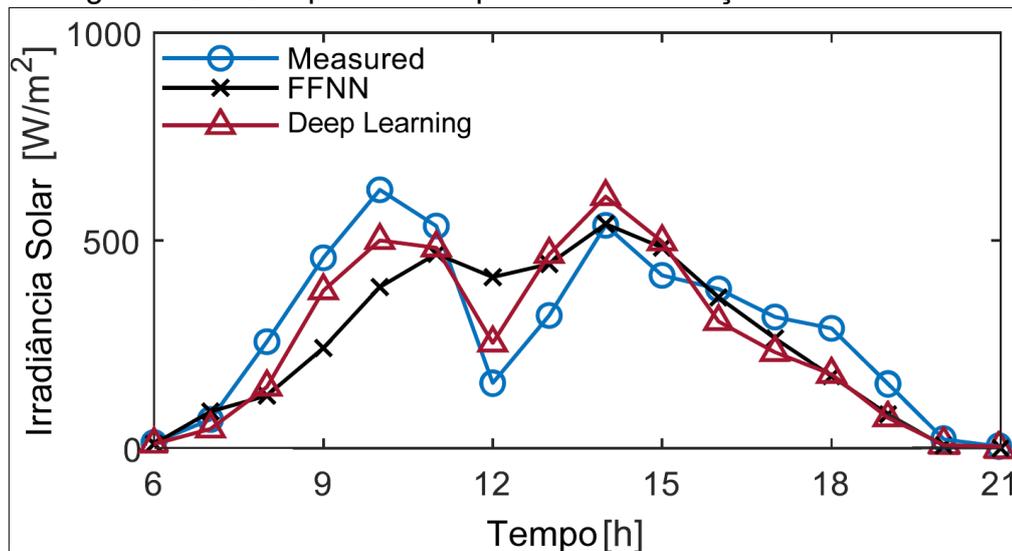
eficiência do uso de variáveis meteorológicas em Miami é inversa, ou seja, o uso de variáveis meteorológicas piora a precisão da previsão para o modelo SVR proposto. Por fim, para 150 horas de previsão solar, o MAE obtido foi de 33,77 W/m², enquanto o MAPE foi de 15,66 %, em Denver, local onde a técnica proposta apresentou os melhores resultados.

2.1.9 Husein e Chung (2019)

Nesse trabalho são desenvolvidas previsões de irradiância solar, devido ao acréscimo na utilização desse recurso na produção de energia elétrica por pequenos e médios produtores, provocando impacto no gerenciamento das *microgrids*. Para prever a produção elétrica a partir do sol, é essencial prever a irradiância solar, que normalmente requer dados históricos de irradiação solar. Esses dados geralmente não estão disponíveis para produtores residenciais e comerciais que incorporam o sistema fornecedor de energia de um país.

Para a solução da problemática apresentada, é proposto um modelo de antevisão de irradiância solar com o horizonte de previsão de um dia. Devido à escassez de dados históricos de irradiância solar para pequenos produtores de energia, que estão amplamente espalhados geograficamente, é proposta uma metodologia que não se utiliza desse histórico como entrada para o mecanismo de previsão. O mecanismo utiliza-se apenas de outros dados climáticos, a saber, temperatura de bulbo seco, temperatura do ponto de orvalho e umidade relativa. O modelo preditivo foi desenvolvido usando uma DL e para comparação foi utilizada uma RNA *Feedforward* (FNN). O comportamento das previsões realizadas pelo algoritmo proposto em comparação a rede FNN e os dados de irradiância observados pode ser visto na Figura 2.8.

Figura 2.8 – Comparativo de previsões e medição de irradiância



Fonte: Adaptada de Husein e Chung (2019).

Para fornecer uma avaliação dessa abordagem, foram realizados seis experimentos usando dados de medição de estações meteorológicas na Alemanha, EUA, Suíça e Coréia do Sul. Os resultados dos experimentos mostram que a abordagem proposta é mais precisa do que a FNN, onde em sua melhor atuação, em Golden, Estados Unidos, a DL obteve um MAE de 36,55 W/m², enquanto a FNN obteve um MAE de 50,66 W/m². A média dos MAEs encontrados para a DL nos seis locais de estudo foi de 47,7 W/m², enquanto a média dos MAEs encontrado para as seis localidades, para a FNN, foi de 56,63 W/m².

2.1.10 Kaba et al. (2018)

Os autores caracterizam a radiação solar como um dado importante para várias aplicações, como clima, energia e engenharia. Por causa disso, a determinação e estimativa da variabilidade temporal dessa grandeza tem importância crítica na realização de planos para o presente e para o futuro. Como meio de estudar e caracterizar a disponibilidade solar, foi empregada uma DL com o objetivo de estimar sua radiação por meio de dados coletados em 34 estações localizadas na Turquia. Como entrada da DL, foram utilizados a duração da luz do sol, cobertura de nuvens, temperatura mínima e temperatura máxima, além da própria radiação solar em períodos anteriores. A localização das estações meteorológicas pode ser vista na Figura 2.9.

Figura 2.9 – Distribuição das estações meteorológicas



Fonte: Adaptada de Kaba, Sargül, Avcı et al (2018).

Os conjuntos de dados das 34 estações, abrangendo as datas de 2001 a 2007, foram usados para treinar e testar a DL e os valores simulados foram comparados com os valores reais medidos pelas estações. O horizonte de previsão foi um dia a frente, sendo previsto a radiação solar global diária.

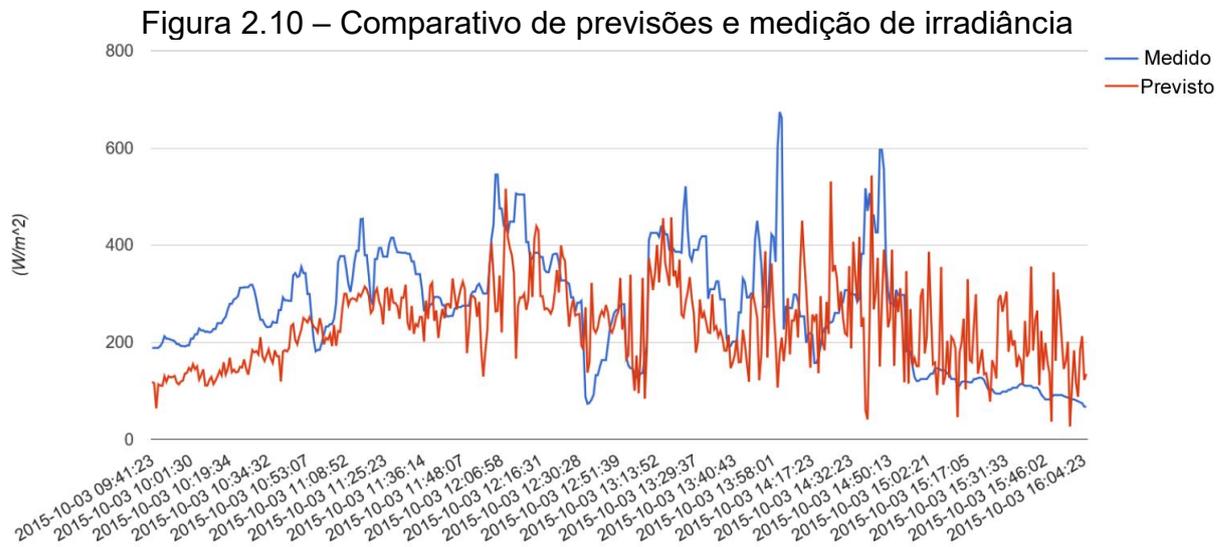
O MAE obtido para as previsões realizadas através da técnica de aprendizagem foi de $0,61 \text{ MJm}^{-2}\text{dia}^{-1}$, o que para os autores, caracterizou a boa qualidade da técnica empregada para previsibilidade da radiação solar. Conseqüentemente, a DL utilizada pode ser uma boa alternativa a ser empregada para previsão e gerenciamento de aplicações que necessitem realizar caracterização solar futura.

2.1.11 Moncada, Richardson e Vega-Avila (2018)

Os autores destacam a importância da previsão intra-hora e o dia seguinte da irradiação solar para a geração distribuída. Como proposta de solução dessa problemática, o trabalho utiliza-se do *SkyImager*, da Universidade do Texas em Santo Antônio (UTSA), que é um sistema de geração de imagens do céu de baixo custo construído com um computador *Raspberry Pi* com câmera acoplada.

O sistema deve ser reconfigurado para cada local de utilização, feito isso, foi implantado no Laboratório Nacional de Energia Renovável, Estados Unidos. O mecanismo de previsão empregado baseia-se na utilização de imagens processadas por meio de Inteligência computacional, especificamente uma DL, capaz de predizer

o comportamento da irradiância solar 15 minutos a frente. O comportamento das previsões realizadas pelo algoritmo proposto em comparação aos dados de irradiância observados pode ser visto na Figura 2.10.



Resultados e métricas de erro são apresentados para um total de 147 dias de dados coletados pelo sistema durante o período de outubro de 2015 a maio de 2016. O MAPE encontrado para a DL foi de 27,13 %, o que é bom, se comparado aos resultados das técnicas de aprendizagem MLP e *Random Forests Technique (RFT)* que foram empregadas nas mesmas condições, com valores de 33,05 % e 28 %, respectivamente.

2.1.12 Comparativos entre técnicas de aprendizagem aplicadas a previsibilidade solar

As informações referentes ao desempenho das técnicas presentes nesse levantamento bibliográfico são condensadas na Tabela 2.1. Vale ressaltar que as diversas metodologias se utilizam de diferentes tipos de Avaliações Estatísticas (AE) e para diferentes horizontes de previsão. Essa característica impossibilita a comparação das metodologias entre si e entre as previsões desenvolvidas nesta tese.

Tabela 2.1 – Comparativo entre diversas técnicas de previsão

	Técnica	AE	Resultado AE	Horizonte	Lugar	Ano
2.1.1	MLP	RMSE	32,75 W/m ²	1 hora	SAU*	2018
2.1.2	MLP	MAE	65,2 W/m ²	5 min.	USA*	2016
2.1.3	MLP	MPE	2,75 %	1 dia	ITA*	2010
2.1.4	RBF	RMSE	0,0667 kW	1 dia	PSE*	2016
2.1.5	RBF	MAPE	5,44 %	1 mês	USA*	2015
2.1.6	SVR	MPE	0,9726 %.	1 mês	IND*	2017
2.1.7	SVR	MAPE	8,94 %.	1 mês	DZA*	2016
2.1.8	SVR	MAPE	15,66 %	1 hora	USA*	2013
2.1.9	DL	MAE	36,55 W/m ²	1 dia	MP*	2019
2.1.10	DL	MAE	0,61 MJm ⁻² dia ⁻¹	1 dia	TUR*	2018
2.1.11	DL	MAPE	27,13 %	15 min	USA*	2018

*ITA: Itália; SAU: Arábia Saudita; USA: Estados Unidos; PSE: Territórios Palestinos; IND: Índia; DZA: Argélia; TUR: Turquia; MP: Múltiplos Países

Fonte: Autor (2020).

2.2 Integração de técnicas de previsibilidade solar

Existem três formas de combinar ou integrar as técnicas de previsão: 1) O processamento em série, em que uma parte da técnica faz a separação dos dados e a outra realiza a previsão propriamente dita, por exemplo; 2) processamento paralelo, em que todas as técnicas realizam as previsões e o resultado final é ponderado de acordo com a metodologia de integração; e 3) processamento combinado série-paralelo.

Uma vantagem do processamento paralelo é a redução do uso do tempo na etapa de treinamento. Isso se deve à capacidade de realizar os treinamentos de cada um dos previsores de forma individual e paralela. Isso não ocorre no processamento em série devido a um passo do processo requer dados da etapa anterior. Outra vantagem das técnicas integradas de forma paralela em relação a integração em série, é que os erros nas técnicas em série são acumulativos, de forma que, se em uma das etapas produz um erro, este erro passara a etapa seguinte, até a saída. No processamento paralelo, os erros entre os passos podem ser suavizados através das ponderações e compensações por meio dos outros ativos. A técnica de integração baseada na TP, a PrevTP, usa um processamento paralelo.

A combinação de técnicas de previsão a partir de ponderações (processamento paralelo) é uma forma muito utilizada para a melhora dos resultados da técnica preditoras (CALSSING, 2015, p. 12). Muitas vezes pode-se comprovar matematicamente que um melhor rendimento é obtido por meio da combinação de

modelos em conjunto, em vez de usar só um ativo preditivo separado.

Os resultados das integrações de técnicas de previsão são fortemente dependentes das metodologias escolhidas para a ponderação dos ativos do modelo proposto. Outro fator importante é o número de previsores, já que uma quantidade maior de ativos capazes de predizer isoladamente um evento, terão uma capacidade conjunta de previsão ainda melhor. Estas combinações de modelos podem ser chamadas de comitês (BISHOP, 2006, p. 655).

Há basicamente dois grupos de integração de previsores em paralelo: a integração subjetiva e a integração quantitativa. Para a combinação subjetiva, os pesos dos impactos de cada previsor são determinados por experiências de especialistas. Muitas vezes, o critério adotado na seleção dos pesos não fica claro, transformando a técnica vulnerável matematicamente e altamente sujeita a erros humanos. A combinação quantitativa, diferente da subjetiva, utiliza-se de critérios para definição dos pesos através de modelos matemáticos, o que caracteriza uma superioridade da metodologia quantitativa (CALISING, 2015, p. 12).

Nesta subseção, serão apresentados trabalhos que se utilizaram de combinações de metodologias de previsibilidade solar, paralelas e quantitativas, que é o caso da PrevTP.

2.2.1 Raza, Mithulananthan e Summerfield (2018)

Raza, Mithulananthan e Summerfield também ressaltam que uma previsão precisa da potência FV é essencial para otimizar a relação entre a oferta e a demanda de energia. No entanto, é uma tarefa desafiadora devido à natureza intermitente da produção FV e ao efeito do número de variáveis meteorológicas sobre ela. Neste artigo, é proposta uma estrutura de previsão utilizando a combinação de RNAs por meio de uma técnica denominada *Bayesian Model Averaging (BMA)*.

Para identificar a estrutura de melhor desempenho, são criadas três RNAs diferentes, são elas: RNA FNN; *Elman backpropagation network (ELM)*; e *cascade-forward backpropagation (NewCF)*. Os dados FV registrados em tempo real, juntamente com outras variáveis meteorológicas da instalação solar da Universidade de Queensland, Austrália, de 2014 a 2015, são usados. Para validar a estrutura de previsão, um dia à frente (24 h), as previsões são selecionadas para diferentes estações do ano.

Como a precisão da previsão de cada RNA é afetada pela seleção dos tipos e quantidades de entradas, esta pesquisa usa um processo de seleção em duas etapas. Primeiro, a estrutura de previsão é treinada usando todas as variáveis de entrada possíveis para obter um erro mínimo; segundo, as variáveis de entrada menos influentes foram removidas por meio de um estudo do coeficiente de correlação entre cada variável e a potência FV de saída. Em uma perspectiva prática, um grande conjunto de entradas para uma RNA de previsão, também leva ao aumento da complexidade computacional, maior necessidade de dados de treinamento, convergência lenta e aumento do custo computacional. Como resultado, a produção FV histórica, a irradiância solar, a temperatura do ar, a velocidade do vento e a umidade foram selecionadas como entradas de estruturas de previsão.

Neste estudo, a saída de cada RNA é combinada ou agregada usando a técnica BMA. Este procedimento estatístico é usado para inferir um consenso em resultados de diferentes RNAs previsoras. A BMA atribui pesos a cada RNA individual, onde, os valores de ponderação são baseados no desempenho de cada rede. Valores de peso mais altos são atribuídos a previsores com melhor desempenho em comparação aos de menor desempenho.

Os resultados mostram que a estrutura do conjunto proposto melhora substancialmente a precisão da previsão da potência FV em comparação aos métodos de previsão individual. Os melhores resultados foram encontrados por meio das RNAs combinadas com um MAPE de 4,17 % para um dos dias de teste.

2.2.2 Monjoly, et al. (2017)

Este artigo introduz uma abordagem híbrida para a previsão de irradiância solar em 1 hora à frente com dados obtidos na ilha de Guadalupe, território francês. Os autores destacam a disponibilidade abundante da energia solar na zona tropical, que é o cenário da ilha estudada. No entanto, este recurso é altamente variável ao longo do tempo, devido principalmente a passagens de nuvens. Conseqüentemente, nesse contexto insular, que a rede elétrica não está conectada à rede, e a produção de energia fotovoltaica é altamente aleatória, o aumento de plantas FV aumentará a variabilidade e a incerteza da produção elétrica.

A partir do estudo de técnicas de decomposição de dados como, *Empirical Mode Decomposition (EMD)*, *Ensemble Empirical Mode Decomposition (EEMD)* e

Wavelet Decomposition (WD), foram construídos componentes de decomposição, bem como a identificação de ruídos nos dados de entrada. Os dados são separados em componentes de pequena escala de tempo e de larga escala de tempo, sendo que cada componente terá uma técnica responsável para sua previsão.

Para a realização das previsões, foram utilizados o modelo linear Autoregressivo (AR) para larga escala de tempo e o modelo não linear RNA MLP para pequena escala de tempo. A escolha do método de previsão é auto adaptativa de acordo com a característica de cada componente.

A previsão de várias etapas com o método híbrido proposto resultou em melhorias adicionais. Por exemplo, em termos de erro RMSE, a previsão obtida com o modelo clássico FNN é de cerca de 25,86 %, este erro diminui para até 7,86 % para o modelo híbrido propostos.

2.2.3 Abuella e Chowdhury (2017)

Para mitigar a incerteza do recurso solar, duas ferramentas foram implantadas para a previsão da geração FV: As SVRs que geram as previsões propriamente ditas; e a técnica *Random Forest (RF)*, que atua como um método de aprendizado conjunto para combinar as previsões.

Neste estudo, no entanto, para as SVRs, o treinamento se deu com diferentes conjuntos de dados extraídos da Austrália no período de abril de 2012 a maio de 2014, totalizando 24 SVRs treinadas para atuar como previsores no local de estudo. Para as RF as previsões atuais e passadas de energia solar de vários modelos, bem como os dados meteorológicos associados, são incorporadas para combinar e melhorar a precisão das previsões de energia solar para o dia seguinte.

Combinar as previsões através da RF levou a previsões mais precisas ao longo do período de teste do sistema de previsão proposto. Essas previsões combinadas são produzidas a partir de uma abordagem de ponderação inteligente que leva em conta as situações climáticas, a previsão anterior dos modelos de previsão (24 SVRs). O horizonte de previsão abordado é de 1 dia.

Para obter uma avaliação mais ampla do desempenho das previsões combinadas, é feito uma comparação com os resultados obtidos pela técnica de *Equal-Weights Integration*. A integração pela RF obteve um RMSE de 0,0725 kW, enquanto a *Equal-Weights Integration* obteve um RMSE de 0,0806 kW.

2.2.4 Wang e Wu (2016)

Recentemente, abordagens híbridas de previsão, como a combinação de previsores lineares e previsores não lineares, por exemplo, demonstraram serem capazes de alavancar efetivamente os resultados em relação ao desempenho de métodos individuais. Uma das técnicas utilizadas para a criação de um comitê de previsores é a decomposição dos dados de entrada do sistema de previsão. Basicamente, com a decomposição dos dados de entrada, cada parte dos dados, de acordo com sua característica, terá um direcionamento a uma técnica específica de previsão, na qual, por meio do algoritmo se determina qual melhor previsor atuará naquela região de dados específica.

Neste artigo é apresentada uma análise sobre a aplicação do algoritmo de decomposição EMD nas previsões de velocidade do vento e irradiação solar. O trabalho utiliza-se de previsores baseados em SVR integradas por EMD, para o horizonte de 1 hora, no caso solar, aplicados a dados obtidos em São Francisco, Estados Unidos. Basicamente, a inovação do trabalho se dá utilizando a detecção de ruídos por meio da decomposição realizada pelo algoritmo proposto.

O erro de previsão encontrado para o modelo de previsão híbrida proposto é de $30,08 \text{ W/m}^2$, que é menor que os resultados de outros modelos utilizados para comparação: EMD com entradas de histórico de irradiação, índice de cobertura de nuvens e umidade ($69,02 \text{ W/m}^2$); SVR sem decomposição com entradas de histórico de irradiação ($62,26 \text{ W/m}^2$).

2.2.5 Wu, Chen e Abdul Rahman (2014)

Os autores destacam que o uso crescente de energia solar como fonte de eletricidade levou a um aumento do interesse em prever sua produção de energia em horizontes de curto prazo. No entanto, a saída de um sistema FV é influenciada pela irradiação, cobertura de nuvens e outras condições meteorológicas. Esses fatores dificultam a realização de previsões de saída de PV de curto prazo.

Para o estudo do comportamento solar, neste trabalho, um banco de energia solar, irradiação solar, temperatura do ar e temperatura do módulo FV foi utilizado. Os dados foram coletados em diferentes pontos, dentre eles, um edifício,

uma central solar térmica e uma universidade na Malásia. Além disso, as previsões foram realizadas pelas técnicas ARIMA, SVR, MLP, *Adaptive Neurofuzzy Inference Systems (ANFISs)*, e em uma etapa posterior, a integração dos modelos foi realizada utilizando-se de Algoritmo Genético (AG). O horizonte de previsão foi de 1 hora.

Resultados da previsão mostram a melhor precisão deste modelo híbrido em comparação aos métodos separados. Para caracterização dos resultados, o trabalho utilizou-se do *Normalized Root Mean Square Error (NRMSE)*. O melhor resultado obtido pela previsão híbrida foi de 3,43%, enquanto para os métodos ARIMA, SVR, MLP e ANFIS, os resultados foram de 16,46 %, 4,78 %, 4,75 % e 6,82 %, respectivamente.

2.2.6 Hossain, Oo e Ali (2013)

Neste trabalho é proposto uma estrutura de um previsor de energia solar híbrido. Os autores investigam a aplicabilidade de algoritmos baseados em MLP, SVR e *Least Median Square (LMS)*, de forma individual, bem como de forma combinada com a perspectiva de diminuição dos erros de previsão de disponibilidade da energia solar, para o horizonte de 6 horas, usando dados de Rockhampton, Austrália. Os dados de irradiância solar foram coletados ao longo de seis anos (2005 a 2010).

Os 3 algoritmos utilizados para a previsão foram escolhidos mediante a análise de um conjunto total de 10 previsores solares, com base em seus desempenhos. Os algoritmos utilizados foram: *Linear Regression (LR)*, RBF, SVR, MLP, *Pace Regression (PR)*, *Simple Linear Regression (SLR)*, *Least Median Square (LMS)*, *Additive Regression (AR)*, *Locally Weighted Learning (LWL)* e *IBK Regression*. Neste contexto, o desempenho de predição foi avaliado apenas em termos de erro de predição, definido como a diferença entre os valores reais e os previstos. Em resumo, depois da escolha dos previsores isolados, será aplicada inferência *fuzzy* para a combinação das técnicas de previsão.

Os resultados experimentais mostram que o método híbrido proposto alcançou uma precisão de previsão aceitável. O MAPE alcançado para previsão híbrida (3,07 %) foi melhor do que qualquer uma das técnicas individuais (LMS 3,49 %, MLP 3,84 %, SVR 4,35 %).

2.2.7 Comparativos entre integrações de técnicas de previsão

Na Tabela 2.2 são condensadas as informações referentes ao desempenho das técnicas híbridas de previsibilidade presentes nesse levantamento bibliográfico. Vale ressaltar que as diversas metodologias se utilizam de diferentes tipos de Avaliações Estatísticas (AE) e para diferentes horizontes de previsão. Essa característica impossibilita a comparação das metodologias entre si e entre as previsões desenvolvidas nesta tese.

Tabela 2.2 – Comparativo entre diversas integrações de técnicas de previsão

	Técnica	AE	Resultado AE	Horizonte	Lugar	Ano
2.2.1	BMA	MAPE	4,17 %	1 dia	AUS*	2018
2.2.2	<i>WD-Hybrid Model</i>	RMSE	7,86 %	1 hora	FRA*	2017
2.2.3	RF	RMSE	0,0725 kW	1 dia	AUS*	2017
2.2.4	EMD	RMSE	30,08 W/m ²	1 hora	USA *	2016
2.2.5	AG	NRMSE	3,43%	1 hora	MAS*	2014
2.2.6	<i>Fuzzy</i>	MAPE	3,07 %	6 horas	AUS*	2013

*AUS: Austrália; FRA: França; USA: Estados Unidos; MAS: Malásia.

Fonte: Autor (2020).

2.3 Conclusões parciais

Com o objetivo de diagnosticar o nível atual de desenvolvimento das técnicas de previsão do recurso solar, neste capítulo, são apresentados os levantamentos bibliográficos do emprego das técnicas de aprendizagem, MLP, RBF, SVR e DL, na antevisão solar. Também é apresentado o levantamento de bibliografia referente a integrações de técnicas de previsão.

3 TEORIA DO PORTFÓLIO E SUA UTILIZAÇÃO NO SETOR ELÉTRICO

A Teoria do Portfólio (TP), ou teoria do portfólio moderno, é uma ferramenta utilizada no setor financeiro para que os riscos de perdas dos investimentos sejam diminuídos por meio da diversificação metodizada das aplicações dos investidores. Essa diversificação é obtida por meio da aplicação dos investimentos em dois ou mais ativos. A teoria propõe que quanto maior o número de ativos, menor será o risco diversificável, até um limite de saturação (Speth, 2013, p.1).

Neste capítulo é apresentada a fundamentação original da TP, obtida por meio de pesquisas e trabalhos que apresentam esse mecanismo da maneira clássica, financeira, e adaptações desta, obtidas por meio de um levantamento bibliográfico de trabalhos que usam esse mecanismo para fins de planejamento e gerenciamento do fornecimento de eletricidade. Para isso, foram considerados trabalhos desenvolvidos a partir do ano 2000. A fundamentação matemática da TP e PrevTP é apresentada posteriormente no Capítulo 4.

3.1 Breve histórico

Desenvolvida pelo norte americano Harry Max Markowitz no ano de 1952, a TP tem por objetivo final metodizar a definição do percentual de penetração de cada ativo a fim de obter o gerenciamento de carteiras de investimentos, através da seleção de portfólios. No ano de 1954, Harry Markowitz concluiu seu doutorado e, posteriormente, no final desta mesma década, publicou um livro com o título de “Seleção do portfólio: Diversificação eficiente”, no qual através deste trabalho, explana toda a teoria da seleção das carteiras de investimento visando o maior retorno possível com o menor risco de perdas possível.

A TP tem como princípio que entre ativos com um mesmo risco, o investidor/gestor optará por aquele que apresentar um retorno esperado mais elevado e aquele de risco menor quando os ativos apresentarem o mesmo retorno esperado. Estes são chamados de portfólios eficientes, pois maximizam os retornos esperados por níveis de riscos, determinando a melhor integração possível, e diminuindo, respectivamente, os riscos de perdas fundamentados na soma ponderada do risco dos mesmos ativos no que diz respeito às suas correlações.

É comum que os investidores diversifiquem suas aplicações a fim de

redução de risco; então Markowitz propõe a integração de dois ativos financeiros correlacionados negativamente, obtendo como resultado a redução do risco do pacote de investimento mediante uma possível complementação e também uma possível compensação entre si. Dessa forma, a TP metodizou a escolha do percentual ideal de penetração de cada ativo no investimento total. Vale ressaltar que o efeito de diversificação deve ser gerado a partir da análise de dados obtidos por meio de coletas e estudo do comportamento dos ativos ao longo do tempo.

3.2 TP no setor de energia elétrica

Nas últimas décadas, têm-se encontrado diversas linhas de pesquisa sobre aplicações da TP no setor de planejamento energético, elaboração de políticas de segurança energética e análise de investimento em geração renovável, objetivando minimizar os riscos dos altos preços de energia elétrica no âmbito empresarial e da sociedade, bem como a otimização do planejamento e distribuição de eletricidade em países da Europa, América do Norte, América do Sul e Central, além da Oceania. O primeiro trabalho científico a adaptar a TP para a previsibilidade de fontes de energia intermitentes, tais como a FV e a eólica, foi publicado em 2012, pela pesquisadora alemã Valerie Speth (SPETH, 2012, p. 1). Porém não se encontrou registros da utilização da TP para a integração de diferentes técnicas de previsão do recurso energético intermitente, como o solar, por exemplo.

Inicialmente, o levantamento bibliográfico da presente tese baseou-se em investigar trabalhos em que houve a utilização da TP aplicada à integração de metodologias de previsibilidade de recursos renováveis intermitentes, em específico RNAs, com o objetivo da diminuição dos erros das técnicas utilizadas. Assim, ficou constatado que o desenvolvimento e aplicação da TP para tais fins é um mecanismo de caráter inovador no mundo.

Em momento posterior à constatação de que a adaptação da TP para melhoramento da previsibilidade de recursos renováveis de energia é um tema com poucos trabalhos desenvolvidos, e buscando uma melhor compreensão da teoria e das possíveis outras adaptações ao setor de produção de eletricidade, a pesquisa bibliográfica da presente tese utiliza-se de fontes a partir do ano de 2000, em que foi aplicada a adaptação da teoria em estudos para os mais diversos fins, tais como, melhoramento e gerenciamento da taxa interna de retorno, produção de energia por

capacidade instalada, custo nivelado de energia, e com isso pode-se constatar que a TP é um campo com diversas aplicações e potencialidades, bem como é possível acompanhar o desenvolvimento do tema ao longo dos anos. A seguir, são descritos os diversos trabalhos para a revisão bibliográfica da TP aplicados ao setor de energia elétrica.

3.2.1 *Shahriari e Blumsack (2018)*

Utilizando grandes conjuntos de dados de produção simulada de energia eólica e solar, foram criados portfólios eólicos, solares e combinados com essas duas fontes renováveis de energia. Nesse contexto, a TP foi utilizada para mensurar os impactos da integração dessas fontes em vários locais da rede elétrica no leste dos Estados Unidos.

A TP nos mercados de energia, proposta nesse trabalho, usa desvio padrão do custo, da receita ou da potência como medida de risco. O custo médio, a receita média ou a produção média de energia é usado como uma medida de retorno.

O uso da TP indicou que o investimento em parques de geração de energia em uma grande diversidade geográfica tende a diminuir o risco do portfólio. Esse tipo de investimento proporciona maior diversidade, oferece maior retorno por unidade, reduz o risco de indisponibilidade e reduz os impactos das falhas na rede de transmissão.

Com isso foi possível constatar que a TP pode ser utilizada para criar portfólios ótimos considerando as interações entre diferentes recursos (eólicos, solares ou até mesmo outros) e diferentes locais (várias instalações eólicas e solares). Isso poderia produzir fatores de disponibilidade energética com melhor desempenho de investimento do que o relatado anteriormente na literatura. Também é constatado que mais estudos sobre impactos de erros de previsão de energia eólica e solar em portfólios ótimos são necessários para entender melhor como esses investimentos poderiam ser influenciados pela incerteza de previsão.

3.2.2 *Santos-Alamillos et al. (2017)*

Alterar a potência de parques eólicos já instalados é considerada uma das mais promissoras e rentáveis estratégias de curto prazo para ampliar a capacidade

de produção elétrica via fonte eólica. Neste estudo, a TP foi aplicada para explorar ações de gerenciamento dessas possíveis alterações de potência na Espanha. Os portfólios eficientes oferecem ótimas alternativas de alterações de potência às atuais integrações de geração de parques eólicos. Eles fornecem a maior saída de energia média possível (rendimento) para um determinado nível de risco de suprimento de demanda. Diferentes cenários de alterações de potência são considerados nesta pesquisa.

Nos resultados é demonstrada que, dependendo da configuração do problema de otimização do portfólio, as flutuações horárias na fonte de energia agregada podem ser reduzidas até 31 %, mantendo o nível atual de produtividade de energia. Além disso, para o nível de risco de fornecimento de energia experimentado com a combinação existente de parques eólicos espanhóis, pode-se obter integrações mais eficientes que aumentam a produtividade em até 55 %.

Então, foi possível demonstrar a boa capacidade de resolução da TP na exploração de diferentes cenários de alteração de potência de parques eólicos já instalados. Estes cenários são compostos por diferentes planos de distribuição espacial de energia eólica caracterizados por vários níveis de rendimento e risco de fornecimento de energia, medidos pela média e desvio padrão da capacidade de geração eólica agregada. Portfólios alteração de potência são ótimos no sentido de que eles entregam o maior rendimento para um dado nível de risco (ou o menor risco para um determinado alvo de retorno).

3.2.3 Narayan e Ponnambalam (2017)

Com o atual apelo ambiental, visando a diminuição na emissão de carbono, espera-se que as energias renováveis sejam bastante utilizadas em microrredes isoladas. O fornecimento de eletricidade a partir de fontes renováveis é variável, além de que essas fontes de energia têm, em comparação com outras técnicas, um grande investimento de capital.

Como forma de contribuição do crescimento de microrredes com grandes contribuições de energias renováveis, neste trabalho é adaptada a TP no sentido de minimizar o risco no investimento devido à natureza incerta dos recursos e também minimizar o custo esperado do investimento.

O risco afeta o planejamento de sistemas de transmissão de energia,

sistemas de distribuição e microrredes. Segundo os autores, a literatura recente em planejamento e projeto de microrredes menciona os riscos, mas a maioria delas não o considera como parte do projeto, embora declarem a importância dessa variável.

Em geral, foi considerado um sistema completo com energia eólica, solar, gerador diesel e baterias, a partir de dados coletados no Canadá. O modelo é genérico e pode ser usado para qualquer local a fim de atender suas necessidades como, por exemplo, de topografia geográfica e demanda/suprimento.

Através da análise da fronteira eficiente, verificou-se que, para um cenário modelado de 10% de não atendimento de energia devido às variações intrínsecas das energias renováveis, os custos se elevam à medida que é feita uma tentativa de diminuição de riscos do não suprimento energético. Isso ocorre devido ao fato de que para diminuir o risco de não atendimento da demanda, é necessária a complementação através de outras fontes de energia para balancear o sistema.

3.2.4 Lima (2016)

Neste trabalho é destacado que a implantação de usinas de energia eólica e solar dependem de fatores climáticos específicos. O Brasil, devido ao seu vasto território e clima, é composto por regiões que podem explorar fontes renováveis de energia para a geração de eletricidade.

Os desafios para a integração dessas fontes de produção de eletricidade em uma grande quantidade dependem principalmente da previsibilidade, da flexibilidade de outras fontes de energia, devido sua variabilidade. Para o atendimento da necessidade de disponibilidade energética, há uma necessidade de desenvolvimento de técnicas que possam ser utilizadas a fim de facilitar a implementação de energias alternativas às matrizes energéticas mundiais produzindo menores custos a sua adaptação.

Neste trabalho é adaptada a TP ao melhoramento da previsibilidade solar e eólica, encontrando um limite em que a combinação dessas fontes de energia resulte em menores erros de previsão. A TP adaptada para aperfeiçoar a previsibilidade de recursos renováveis de energia é pouco utilizada, portanto esta pesquisa constituiu uma investigação pioneira no Brasil.

O processamento de dados de irradiância solar e de velocidade do vento, medidos e previstos, foi executado a fim de encontrar o percentual ideal da inserção

de cada uma das duas fontes por meio da TP. A elaboração dos resultados é realizada por meio de uma comparação entre dados medidos por meio de uma estação meteorológica localizada em Maracanaú – CE e dados de velocidade do vento e irradiância solar previstos para a localidade em estudo, obtidos com o uso de técnicas de previsões desenvolvidas no Laboratório de Energias Alternativas (LEA) da Universidade Federal do Ceará (UFC). Com isso, é feito um comparativo entre a previsão e a medição e, posteriormente, é elaborado o gráfico de fronteiras eficientes.

Através da combinação de 70 % de recurso eólico e 30 % de recurso solar, definidos pela aplicação da TP, houve diminuição de riscos (desvio padrão) de erros de previsão.

3.2.5 Tola (2015)

É avaliada uma abordagem de diversificação de portfólios na Albânia em um cenário onde se utiliza 100 % de energias renováveis na sua matriz energética, além disso, sua geração de energia obteve um incremento de 20 % na capacidade instalada nos últimos anos. Todavia, o ponto central do trabalho é o melhoramento do sistema energético albanês por meio da introdução de fronteiras eficientes de energias renováveis, como a FV e a eólica, criando-se assim, um sistema de suprimento mais confiável em relação aos custos de instalação de parques eólicos e solares diversificados.

Foi observado que a diversificação de tecnologias de geração de energia elétrica pode reduzir o risco de ausência ou excesso de eletricidade em um sistema energético diversificável e manter um custo mínimo para o desempenho do sistema desejado, através da combinação de ativos renováveis de produção de eletricidade em portfólios eficientes.

O percentual de penetração da geração hídrica, eólica e FV no portfólio eficiente foi analisado, objetivando encontrar um limite ideal de investimento, através da construção de fronteiras eficientes, apresentando o menor risco diversificável e o maior retorno esperado possível.

Por meio da aplicação da TP, foi encontrado o menor risco de investimento para a combinação de 0,5 % de energia eólica, 98,5 % de energia solar e 1 % de energia hídrica. Desse modo, conclui-se que uma alta quantidade de energia solar na matriz energética albanesa contribui significativamente para otimizar os retornos

financeiros dos sistemas de produção e transmissão de energia elétrica do país.

3.2.6 Cucchiella, Gastaldi e Trosini (2015)

Nesta pesquisa é apresentada uma análise econômica de investimentos em fontes de geração renováveis no cenário italiano, tais como hídrica, geotérmica, biomassa, eólica e FV, almejando minimizar os riscos de investimentos em fontes renováveis de energia e otimizar a capacidade da geração de eletricidade na Itália a partir da combinação ideal de tecnologias renováveis. Utilizaram-se os fundamentos da TP para selecionar portfólios eficientes que possam minimizar os riscos de perdas de capacidade energética e maximizar os retornos esperados dos ativos para um dado nível de risco.

Diante da sua forte dependência de combustíveis fósseis e derivados do petróleo, bem como da imprescindibilidade de diversificação da geração de eletricidade no cenário italiano, tornou-se crucial a adoção de medidas que pudessem empregar novas tecnologias de produção de energia, em especial as fontes renováveis, na política energética do país. Além disso, considerou-se o intuito de suprir as demandas da sociedade e garantir a sua segurança energética.

Observou-se a capacidade de geração das fontes de energia renovável, especialmente a eólica e a FV, em diferentes cenários de produção de eletricidade, avaliando a rentabilidade das mesmas e destacando as suas correlações no portfólio eficiente.

Selecionaram-se portfólios ótimos de produção de energia analisando a capacidade de geração de cada fonte energética renovável com diversos níveis de potência. Em virtude das avaliações dos retornos esperados, bem como dos riscos diversificáveis dos ativos de geração renovável por capacidade instalada, pôde-se perceber que para um maior retorno, ou seja, 3,2552 €/W, a combinação ideal para a matriz energética em estudo é de 84,54 % de energia hidráulica, 10,48 % de energia eólica e 4,98 % de biomassa, o que coincide com o menor desvio padrão apresentado.

3.2.7 Nazari et al. (2015)

Os autores apresentam uma análise comparativa de investimento entre ativos de combustíveis fósseis e ativos de geração eólica, através da seleção de

portfólios eficientes de produção de energia elétrica.

Com o intuito de otimizar a capacidade de geração de eletricidade no cenário australiano por meio da combinação de ativos de energia, utilizaram-se os princípios da TP para determinar portfólios eficientes que possam minimizar os riscos de investimentos em ativos de geração eólica e maximizar os retornos esperados para um dado nível de variabilidade climática, no que tange à intermitência das fontes de energia renováveis, especialmente a eólica e a FV.

Diante da dificuldade dos investidores em escolher ativos renováveis ideais para a geração de energia elétrica, em meio às variações da irradiância solar e da velocidade do vento no território australiano, tornou-se necessário o desenvolvimento de uma alternativa eficiente para o gerenciamento na produção de eletricidade, com o intuito de atender às demandas energéticas da população e, garantir a segurança e o desenvolvimento dos recursos energéticos renováveis por um longo período de tempo na matriz energética do país.

Mediante essa problemática, aplicaram-se os fundamentos da TP para combinar as opções de investimentos em um portfólio eficiente, para enfrentar os efeitos das variabilidades na produção de eletricidade a partir de fontes renováveis de energia, devido às oscilações climáticas as quais as fontes de energia em estudo estão suscetíveis.

Além disso, o estudo fornece uma estrutura de apoio aos investidores para ajudar na seleção de portfólios eficientes de produção de eletricidade e na identificação de adições ideais de capacidade de geração eólica no setor elétrico tradicional.

Em virtude da análise dos ativos renováveis e convencionais do portfólio de geração eficiente, foi concluído que as tecnologias renováveis de produção de eletricidade, tais como a eólica e a FV, apresentam fatores de perdas de capacidade energética relativamente baixos, com níveis condicionais de riscos de investimentos intermediários, denotando que podem ser exploradas no âmbito das oscilações climáticas da irradiância solar, bem como da velocidade do vento no cenário australiano. Não obstante, para garantir a estabilidade e operacionalidade do sistema elétrico intermitente, torna-se imprescindível a adição de ativos convencionais de energia, tal como os combustíveis fósseis, uma vez que os mesmos exibem uma ampla capacidade de geração instalada na matriz energética australiana.

3.2.8 Cunha e Ferreira (2014)

Neste trabalho é apresentado um modelo de geração de eletricidade desenvolvido através da TP em que é determinada a seleção das combinações eficientes de três fontes de energia renovável, tais como hídrica, eólica e FV, correlacionadas em um portfólio de ativos no cenário português a partir de uma análise de dados medidos e dos impactos dessas fontes no sistema elétrico no território lusitano.

Com o intuito de minimizar o uso de combustíveis fósseis e diminuir as emissões de gases poluentes na atmosfera, tornou-se imprescindível a elaboração de medidas que pudessem maximizar a capacidade de geração de energia elétrica por meio de fontes renováveis, bem como diversificar a matriz energética no cenário europeu.

Visando otimizar a capacidade de produção de eletricidade no cenário português, utilizaram-se os princípios da TP para encontrar um limite ideal de investimento, onde os riscos de perdas sejam mínimos e os retornos esperados sejam máximos, buscando encontrar a taxa máxima de retorno de cada ativo para um dado nível de risco.

Com o intuito de descobrir a sazonalidade diária e anual das fontes de energia renovável, bem como a capacidade de geração das mesmas, em meio a riscos de investimentos e oscilações climáticas, foi analisada a potência de saída das tecnologias renováveis supracitadas para cada 15 minutos, em um período de tempo compreendido de 01 de janeiro de 2009 a 31 de outubro de 2013 no cenário elétrico português.

A análise das potências médias de saída de cada tecnologia renovável tornou possível determinar o comportamento dos ativos do portfólio eficiente ao longo de um ano e as suas instabilidades, bem como prescrever a geração mais compatível e/ou combinação de fontes de geração mais eficazes na produção de eletricidade para o cenário português.

Dessa forma, mediante o processamento de dados de geração a partir da integração dos ativos obtidos através da TP, a geração eólica e a FV foram as que mais se adaptaram às oscilações climáticas de Portugal, uma vez que apresentaram uma menor irregularidade na produção de eletricidade. Em contrapartida, a geração hídrica manifestou uma grande variabilidade de produção e altos valores condicionais

de riscos de investimento.

Os valores dos riscos, obtidos através do desvio padrão, evidenciam o maior risco de investimento para a eletricidade gerada a partir da fonte hídrica com um valor de 0,2859, valor intermediário de 0,2211 para a FV e menor risco de investimento a partir da fonte eólica com valor de 0,1874.

3.2.9 Speth (2013)

Nesta pesquisa são investigados os desafios de uma integração de portfólios solar e eólico através da adaptação da TP para a previsibilidade e também para custo nivelado de energia dessas fontes intermitentes, utilizando dados medidos e de previsão em três anos, de 2010 a 2012, na Alemanha, com o intuito de apresentar uma solução para a otimização da capacidade de geração de eletricidade desta integralização renovável, por meio da construção de situações ótimas de portfólios solares e eólicos.

As situações ótimas de portfólios solar e eólico provocam melhoras na capacidade de balanceamento energético e maximizam a capacidade de previsibilidade de disponibilidade de recurso através da diversificação das fontes de energia, como consequência, a antevisão das necessidades de complementação na geração de eletricidade.

Tendo em vista a otimização da capacidade de geração FV e eólica no cenário alemão, bem como o fornecimento de dados de previsão de irradiância solar e velocidade dos ventos com um dia de antecedência para investidores locais e companhias de energia elétrica, almejando suprir a capacidade de produção de eletricidade demandada pelo setor empresarial e residencial do país, analisou-se a eficiência e a confiabilidade do potencial de previsibilidade das tecnologias renováveis em larga escala para determinar um limite ótimo de investimento, onde os riscos de perdas de rendimento energético fossem mínimos e os retornos esperados do portfólio renovável máximos.

Diante da análise percentual dos erros de previsão no portfólio eficiente por capacidade instalada dos ativos, pôde-se concluir que em 63 % das horas dos anos, os erros de previsão da geração FV oscilaram entre -1 e + 1 %. Por outro lado, apenas 25 % da previsão de energia eólica está dentro dessa faixa.

Para análise dos erros de previsão de disponibilidade dos recursos

renováveis de energia e definição da porcentagem ideal de penetração de cada uma das fontes solar e eólica utilizadas na produção de eletricidade, levando-se em consideração os dados alemães, foram traçados os gráficos de fronteiras eficientes.

A análise demonstrou que em relação às previsibilidades das 4 combinações, uma elevada porcentagem de energia solar, entre 50 % - 62 %, pode ser benéfica para diminuir os erros de previsão, resultando na possível redução de necessidades de balanceamento do sistema elétrico.

3.2.10 Roques, Hiroux e Saguan (2010)

Os autores aplicam os princípios da TP para avaliar o potencial de geração eólica na Espanha, Alemanha, Áustria, Dinamarca e França, no intuito de selecionar portfólios eficientes de geração de eletricidade em termos de capacidade instalada e pico de demanda, almejando minimizar os riscos de perdas de rendimento energético das tecnologias renováveis e otimizar a produção de energia elétrica no cenário europeu.

Foram estudadas as fronteiras eficientes para combinação de dois portfólios e seus respectivos riscos, buscando encontrar o portfólio mais eficiente para a geração eólica nos países europeus estudados. Desse modo, foi possível maximizar a contribuição da geração eólica para a confiabilidade do sistema elétrico para os países europeus em estudo.

Neste caso, foi limitado o estudo com dados de potência correspondentes ao pico de demanda em horas em relação à capacidade de geração eólica. Em seguida, construíram-se portfólios que maximizam a produção de eletricidade por unidade de capacidade instalada (fator de capacidade) e que minimizavam a variância nos horários de pico dos locais em estudo.

Há uma grande diferença no recurso eólico utilizado em todos os países europeus, e a correlação entre a geração elétrica a partir do vento diminui com a distância entre dois parques eólicos, de modo que deve haver benefícios nas políticas de implantação coordenada entre os países europeus de forma a incentivar o investimento em localizações geográficas com boas propriedades de disponibilidade eólica a partir de uma perspectiva do sistema.

Os modelos de planejamento de investimento convencionais, aplicados para a definição de investimento de implantação de novos parques de produção de

eletricidade, não têm a capacidade de representar a natureza intermitente de geração a partir das energias renováveis. Consequentemente, não apresentam os reais impactos financeiros provocados pela oscilação da geração de eletricidade proveniente dessas fontes.

3.2.11 Jansen, Beurskens e Tilburg (2006)

Neste trabalho é investigada a eficiência de tecnologias de geração renovável e ativos convencionais de produção de energia elétrica, por meio da seleção de portfólios eficientes, objetivando otimizar a capacidade de geração de eletricidade, diminuir os riscos de perdas de investimento dos ativos e diversificar a matriz energética holandesa, almejando determinar a viabilidade econômica dos ativos renováveis, bem como encontrar portfólios eficientes de produção de eletricidade com o menor risco diversificável e maior retorno esperado possível.

Analisou-se o potencial de produção de eletricidade de diferentes combinações a partir de vários ativos renováveis, tais como a geração eólica, FV e biomassa, em conjunto com as fontes de energia tradicionais da Holanda, como o petróleo, o carvão e o gás natural, em diferentes portfólios eficientes, com o intuito de determinar um cenário ideal de diversificação energética sustentável que pudesse ser explorado até o ano de 2030 no âmbito das variabilidades climáticas do território holandês.

Uma estimativa do potencial de geração de eletricidade das fontes de energia envolvidas no portfólio eficiente em dois cenários ideais de investimento na Holanda é fornecida. Foi verificado que o limite mínimo de contribuição do Gás natural é de 11,4 TWh e máximo de 96,1 TWh, enquanto para o petróleo o limite mínimo é de 31,1 TWh e máximo de 72,9 TWh. Para as fontes, carvão, nuclear, eólica, biomassa, solar, o limite mínimo de contribuição 0 TWh, bem como, no máximo de contribuição, 55,7 TWh, 1,1 TWh, 16,8 TWh, 8,8 TWh e 1,5 TWh respectivamente.

3.2.12 Krey e Zweifel (2006)

Os autores utilizam os princípios da TP para selecionar ativos ideais de geração renovável, tais como a eólica, FV e hídrica, em portfólios eficientes, para minimizar os riscos de investimentos e maximizar os retornos esperados dos ativos,

com o intuito de otimizar a capacidade de produção de energia elétrica no cenário suíço-americano.

Analisou-se o comportamento dos ativos de geração renováveis em diversas integrações de produção de eletricidade, contendo as fontes convencionais de energia da Suíça e dos Estados Unidos, tais como o petróleo, gás natural, nuclear e o carvão mineral, para determinar portfólios eficientes ideais de investimentos, com riscos de perdas mínimos e maior retorno esperado possível.

Alicerçados na análise comportamental dos ativos de geração renovável em portfólios eficientes, bem como no cenário de políticas climáticas da Suíça e dos Estados Unidos, conclui-se que a geração FV é mais viável para a Suíça, haja vista que o país apresenta uma maior incidência de irradiância solar ao longo do ano. Em contrapartida, a geração eólica é mais viável aos Estados Unidos devido à melhor adaptação às variabilidades climáticas dos EUA, evidenciando altos valores de rendimento energético.

Diante da análise de integração de ativos convencionais e renováveis de geração de eletricidade, pôde-se concluir que a combinação ideal de capacidade energética seria 96 % de nuclear e 4 % de FV para a Suíça, bem como 95 % de carvão mineral e 5 % de eólica para os EUA.

Dessa forma, verificou-se a matriz energética da Suíça e dos Estados Unidos para conhecer as fontes de energia predominantes na geração de eletricidade e as tecnologias que podem ser otimizadas para diversificar e ampliar a capacidade de produção de energia elétrica nos respectivos países.

3.2.13 Awerbuch e Berger (2003)

Neste trabalho, os autores buscam integrar ativos de geração de energia elétrica, tais como eólica, nuclear e combustíveis fósseis, em portfólios eficientes, visando minimizar os riscos de investimentos dos ativos e otimizar o planejamento da geração e distribuição de eletricidade dos países da União Europeia. Utiliza-se também a integração proposta pela TP para a segurança energética e a sustentabilidade dos recursos energéticos no cenário europeu por um considerável período de tempo, almejando diminuir os altos preços de energia elétrica no âmbito social.

Outrossim, sugere uma nova forma de organização e desenvolvimento de

políticas de segurança energética para universidades e institutos de pesquisa e extensão tecnológica que trabalham na área de diversificação e sustentabilidade energética, através da seleção de portfólios eficientes de produção de eletricidade, misturando-se ativos de geração de energia elétrica renovável e tradicional.

Mediante a análise dos ativos de geração renovável e convencional, determinou-se um portfólio de geração sustentável, definindo a participação ideal de cada uma das tecnologias de produção de eletricidade na matriz energética europeia. O portfólio de geração eficiente, bem como o percentual médio da integração dos ativos de produção de eletricidade no cenário europeu são apresentados, onde verifica-se que o menor risco encontrado foi para aproximados 2 % de gás natural, 18 % de carvão mineral, 2 % de petróleo, 23 % de nuclear e 65 % de energia eólica.

3.3 Conclusões parciais

Para verificação do desenvolvimento do tema específico a TP no setor de energia, neste capítulo é apresentado o levantamento bibliográfico da utilização desta técnica no setor de produção de eletricidade. Foram considerados trabalhos a partir do ano de 2000, contabilizando duas décadas utilizadas no presente levantamento bibliográfico. Por meio deste levantamento bibliográfico, é possível constatar que o uso da TP para a integração de técnicas de previsão do recurso solar é um projeto inovador, sendo este jamais realizado no mundo.

4 MATERIAIS E MÉTODOS

Nesta tese é proposto o processamento de dados meteorológicos, a fim de aplicar as técnicas de previsibilidade solar baseadas em MLP, RBF, SVR e DL, bem como o desenvolvimento de uma metodologia para integração das técnicas de previsibilidade de séries temporais utilizadas, aqui denominada de PrevTP, que tem sua estrutura baseada na Teoria do Portfólio. O desenvolvimento dessa técnica pode trazer contribuições significativas para a diminuição dos erros de previsibilidade solar, bem como ser utilizada em estudos futuros para a previsão de outras séries temporais, como a disponibilidade eólica, por exemplo.

Neste capítulo é apresentada a metodologia para a obtenção e tratamento dos dados de irradiância solar e temperatura ambiente, as estruturas das técnicas de aprendizagem utilizadas (MLP, RBF, SVR e DL), assim como é apresentado o desenvolvimento da técnica de integração PrevTP.

4.1 Obtenção de dados

Considerando a forte utilização de energias renováveis descentralizadas no Brasil e na Espanha, nessa proposta de tese de doutorado foram levadas em consideração dados coletados no Brasil, através de estudos e projetos desenvolvidos pela Universidade Federal do Ceará – UFC, por meio do Programa de Pós-Graduação em Engenharia Elétrica - PPGEE, bem como dados da Espanha obtidos através de estudos e projetos desenvolvidos pela Universidade de Cádiz – UCA, por meio do seu programa de Pós-Graduação em Engenharia Energética e Sustentável.

4.1.1 *Dados coletados no Brasil*

Para estudo do comportamento da intermitência do recurso solar, foram considerados por este trabalho, dados de irradiância solar e temperatura ambiente. A coleta de dados de irradiância foi realizada utilizando um piranômetro fabricado pela NRG Systems Inc. e pertence à linha de LI-200SZ, com precisão de 0,04%, o mesmo fornece valores de irradiância solar em W/m^2 (Figura 4.1).

Figura 4.1 – Sensor de irradiância solar



Fonte: Adaptado de Lima (2016).

Os dados de temperatura ambiente são provenientes de um sensor de temperatura fabricado pela NRG Systems Inc. e pertencem à linha de precisão #110S, que possuem uma precisão de $\pm 1,11$ °C e operam em um limite de -40 °C a $52,5$ °C. A constituição do sensor de temperatura é bastante simples, formado apenas de uma sonda de alumínio e estrutura de termoplástico. O sensor é excitado por uma tensão de 4 a 35 V e gera um sinal de tensão de saída de 0 a 2,5 V, proporcional à temperatura ambiente. A estrutura de termoplástico protege a sonda de alumínio da incidência solar (raios UV) de modo a garantir uma coerência nas medições de temperatura (Figura 4.2).

Figura 4.2 – Sensor de temperatura



Fonte: Adaptado de Carneiro (2014).

Ambos os equipamentos foram instalados a 6 metros de altura, precisamente no teto do Departamento de Engenharia Elétrica - DEE da UFC, que

fica localizada na cidade de Fortaleza – CE, onde Latitude: -3.71839, Longitude: -38.5434 3 ° 43' 6" Sul, 38° 32' 36" Oeste.

Os dados foram coletados e armazenados por meio de planilhas eletrônicas em intervalos de 10 min (obtidos por meio de médias aritméticas a partir de dados processados a cada 2 s). Os dados de irradiância solar e temperatura ambiente foram coletados de maio de 2003 a abril de 2005, totalizando 24 meses e resultando em 105.120 medições. As medições foram realizadas durante o período de 05:00 horas às 18:00 horas. A Figura 4.3 apresenta a localização das medições realizadas.

Figura 4.3 – Localização das medições, Fortaleza, Ceará, Brasil

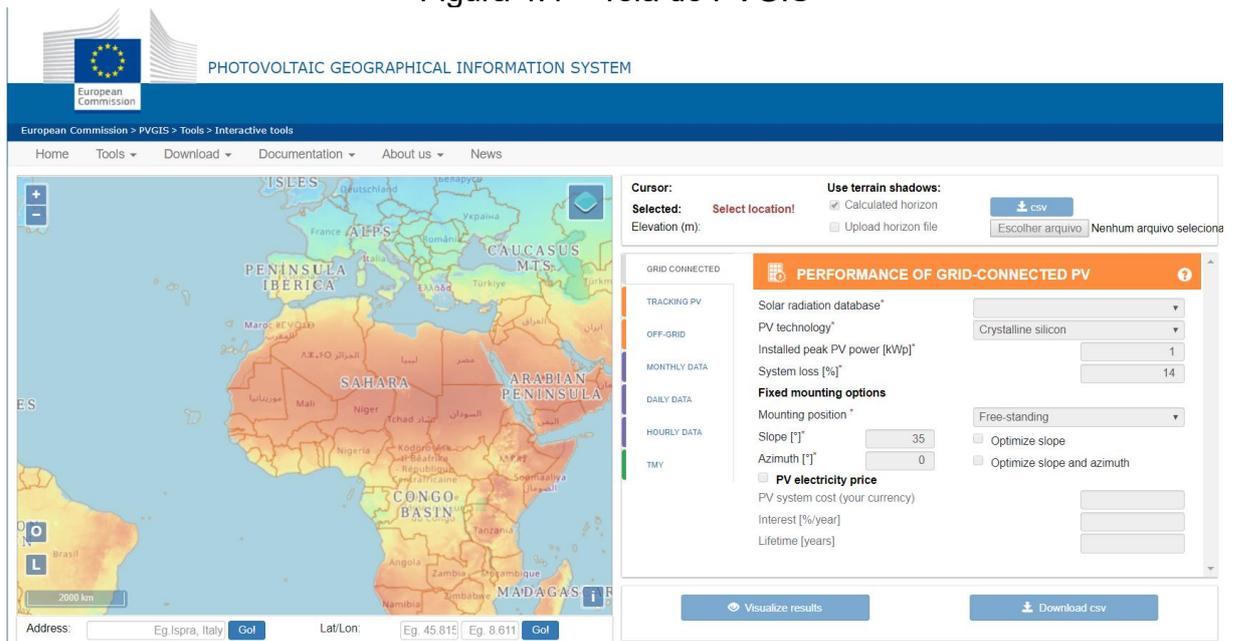


Fonte: Adaptado de Google (2018).

4.1.2 Coleta de dados na Espanha

Durante o estágio de doutorado sanduíche/cotutela, que ocorreu no período de novembro de 2018 a outubro de 2019, foram adquiridos dados de irradiância solar e temperatura ambiente da Espanha, com o apoio e orientação de membros do *Grupo de Investigación en Tecnologías Eléctricas Sostenibles y Renovables (TESYR)* da UCA. Esses dados foram obtidos usando o *Photovoltaic Geographical Information System (PVGIS)* da *European Commission/Institute for Energy and Transport (IET)*, disponível na internet por meio do site <http://re.jrc.ec.europa.eu/pvgis/>. O Sistema de informações utilizado é demonstrado na Figura 4.4.

Figura 4.4 – Tela do PVGIS



Fonte: Adaptado de PVGIS (2019).

Os dados de irradiância solar e temperatura ambiente foram obtidos na cidade de Algeciras, província de Cádiz, Espanha, cidade em que fica localizada a *Escuela Politécnica Superior de Algeciras*, sede do doutorado em Engenharia Elétrica e Sustentável da UCA. Sendo os dados obtidos para a localização: Latitude: 36.128, Longitude: -5.450 36 ° 08' 12.9" Norte, 5° 27' 12.0" Oeste. Os dados de irradiância solar e temperatura são coletados e armazenados em planilhas eletrônicas em intervalos de 1 hora. O período de coleta de dados é de janeiro de 2007 a dezembro de 2016, totalizando dez anos de coleta e resultando em 87.672 medições de irradiância solar e temperatura ambiente. A Figura 4.5 apresenta a localização das medições realizadas.

Figura 4.5 – Localização das medições, Algeciras, Cádiz, Espanha



Fonte: Adaptado de Google (2019).

4.2 Tratamento dos dados

Os dados foram processados em busca de *outliers* (valor atípico), onde, para isso, foram determinados um limite superior e inferior de temperatura ambiente e irradiância solar com base em informações históricas obtidas no local de estudo. As informações que balizaram a determinação dos limites superiores e inferiores foram adquiridas por meio do Instituto Nacional de Meteorologia (INMET) no caso de Fortaleza e pela IET no caso de Algeciras. Para Fortaleza, a faixa de temperatura adotada foi de 21,7 °C a 39 °C e a faixa de irradiância considerada foi de 0 W/m² a 1250 W/m² (INSTITUTO NACIONAL DE METEOROLOGIA, 2019). Para Algeciras, a faixa de temperatura adotada foi de 5,02 °C a 31,36 °C e a faixa de irradiância considerada foi de 0 W/m² a 1163,29 W/m² (INSTITUTE FOR ENERGY AND TRANSPORT, 2019). Em todos os casos, os *outliers* são posteriormente substituídos pelos valores da medição anterior na qual não se apresentou falha no sistema.

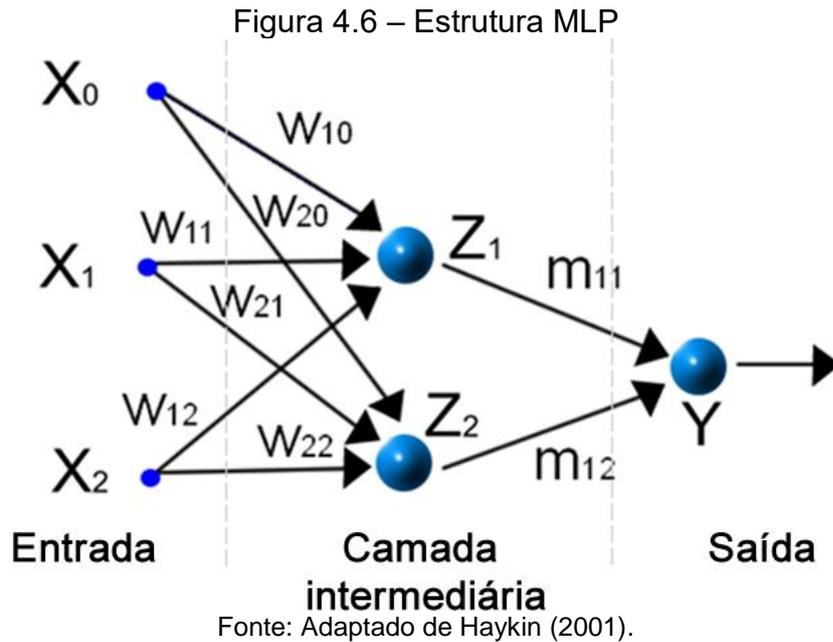
4.3 Técnicas de aprendizagem e seu uso na previsibilidade

Dentre as técnicas de aprendizagem utilizadas para a previsibilidade de séries temporais, as RNAs recebem atenção considerável por serem uma poderosa técnica de modelagem estatística, com o uso de MLP e RBF, por exemplo. Seus resultados são consideravelmente bons se comparados a outras técnicas preditivas, como ARIMA (LIMA, 2016, p. 84). Outra metodologia bastante utilizada é o SVM, devido ao grande embasamento teórico desenvolvido e alta capacidade de generalização. A partir da SVM a SVR foi desenvolvida para trabalhar com previsões (HAYKIN, 2001, p. 373). Já um dos temas emergentes no campo das técnicas de aprendizagem, é a DL. A DL é uma subcategoria de aprendizado de máquina relacionada a oportunidades de aprendizado profundo, com capacidade de aprimoramento em relação a outros métodos de IA (BEDI e TOSHNIWAL, 2019, p. 1).

4.3.1 MLP

A MLP consiste em uma RNA organizada em camadas. A camada de entrada é referente aos dados, já a camada de saída e as camadas ocultas (escondidas e intermediárias), são constituídas de neurônios que podem processar dados resultando em saídas atribuídas através de excitações de entradas e pesos respectivos. Na Figura 4.6 é apresentada uma RNA do tipo múltiplas camadas, tendo três neurônios na camada de entrada, dois neurônios na camada oculta e um neurônio na camada de saída.

O modelo MLP é uma ferramenta usada com sucesso na solução de padrões que não tenham característica linearmente separável. Essa RNA tem a capacidade de acompanhar os padrões com base em um algoritmo de treinamento com a propriedade de redefinir automaticamente os parâmetros livres com base no conjunto de dados de treino.



Na Figura 4.6, X_0 , X_1 e X_2 , estão representando os neurônios de entrada, que na verdade, são os dados de entrada do sistema, sendo Z_1 e Z_2 os neurônios intermediários e Y o neurônio que equivale à saída da rede. Uma RNA MLP possui uma ou mais camadas intermediárias. Conforme representada na Figura 4.6, a MLP possui alta conectividade entre cada neurônio da camada com todos os neurônios da próxima camada. Os pesos de cada associação entre neurônios estão sendo representados pelas variáveis w e m .

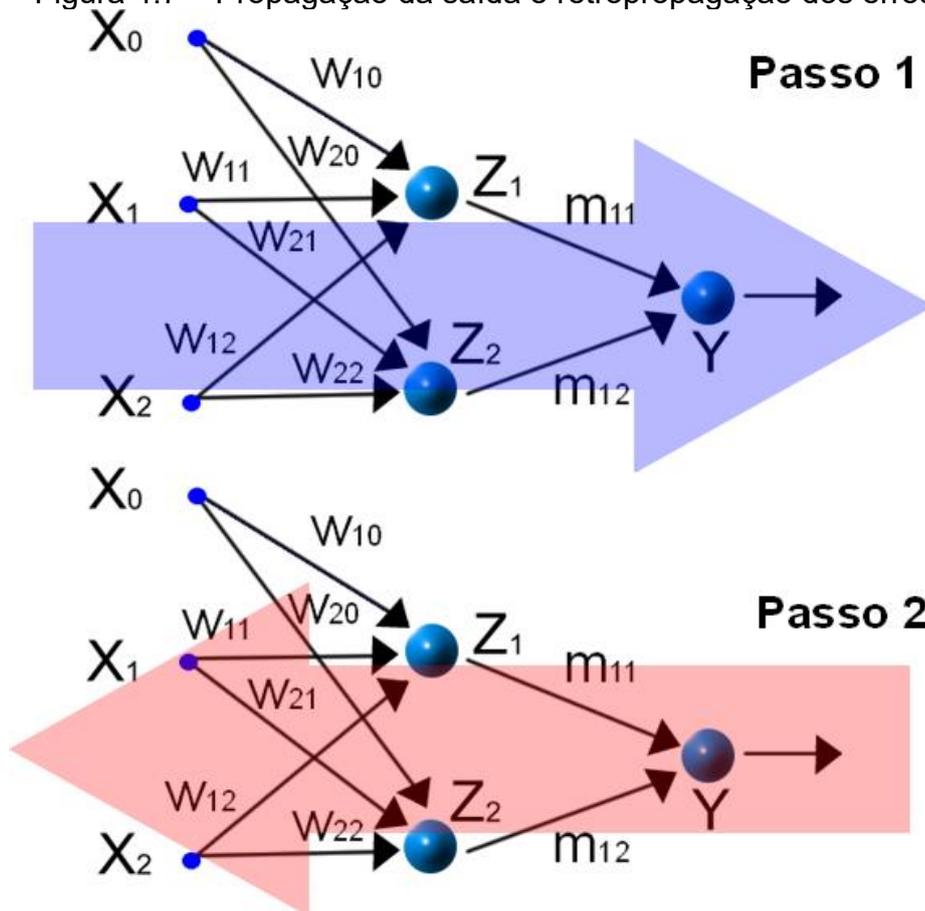
O algoritmo de treinamento, denominado de *Backpropagation*, tem esse nome por realizar a propagação do erro no sentido oposto ao processamento dos dados que vão da entrada à saída. Durante o treinamento, a rede MLP *Backpropagation* realiza dois tipos de processamento:

1 – Os dados são apresentados na entrada da RNA, onde é feito o processamento das informações a cada camada até a definição de um valor em sua saída;

2 – É calculado o erro da saída obtida na rede em relação à saída desejada, e este erro é propagado no sentido oposto ao primeiro passo.

Os dois passos são representados na Figura 4.7.

Figura 4.7 – Propagação da saída e retropropagação dos erros



Fonte: Autor (2018).

Esse procedimento é realizado por várias vezes até os critérios de parada arbitrados pelo programador serem alcançados, de maneira a viabilizar que a RNA possa ter respostas condizentes ao conjunto de dados de treinamento, o que é denominado de treinamento da rede.

Dentre as possíveis funções de ativação dos neurônios, a função de ativação usada na presente pesquisa tanto para a camada de neurônios ocultos como para a camada de saída foi a sigmoide logística, devido sua capacidade de gerar valores contínuos no intervalo de 0 a 1, diferente da função limiar que assume o valor de 0 ou 1. Nesta tese, os dados utilizados como padrões de treinamento foram normalizados de 0 a 1 para estarem compatíveis com a metodologia proposta. Esse processo de normalização é revertido logo quando a resposta da RNA é apresentada. A equação 4.1 representa a função de ativação utilizada na MLP presente neste estudo, onde y_j é a saída do neurônio e u_j é a soma ponderada de todas as entradas.

$$y_j = \frac{1}{1 + \exp(-u_j)} \quad (4.1)$$

A cada época, é calculado o erro da saída da RNA em relação ao valor desejado de saída obtido através dos padrões de treinamento. Isso ocorre com base na equação 4.2, onde e_j é o erro, d_j é o valor desejado de saída e y_j é a saída do neurônio.

$$e_{j(n)} = d_{j(n)} - y_{j(n)} \quad (4.2)$$

A partir do cálculo de erro da RNA, é realizada a retropropagação dos erros. Com o cálculo do erro encontrado apenas na camada de saída, o algoritmo *Backpropagation* determina a influência do erro para cada neurônio das camadas intermediárias através da sensibilidade. A sensibilidade é encontrada através da equação 4.3, onde δ é a sensibilidade.

$$\delta_{(n)} = e_{j(n)} \cdot y_{j(n)} (1 - y_{j(n)}) \quad (4.3)$$

Calculadas as sensibilidades, a atualização dos pesos e *bias* tanto da camada oculta como da camada de saída são dadas pelas equações 4.4 e 4.5, onde w é o peso, α é a taxa de aprendizagem arbitrada pelo programador e b é o *bias*.

$$w_{(t+1)} = w_{(t)} + \alpha \cdot \delta \cdot y_{i(t)} \quad (4.4)$$

$$b_{(t+1)} = b_{(t)} - \alpha \cdot \delta \quad (4.5)$$

O procedimento de treinamento realizado pela MLP *Backpropagation*,

desenvolvida nesta tese, pode ser resumido por meio da Figura 4.8.

Figura 4.8 – Procedimento MLP Backpropagation utilizado

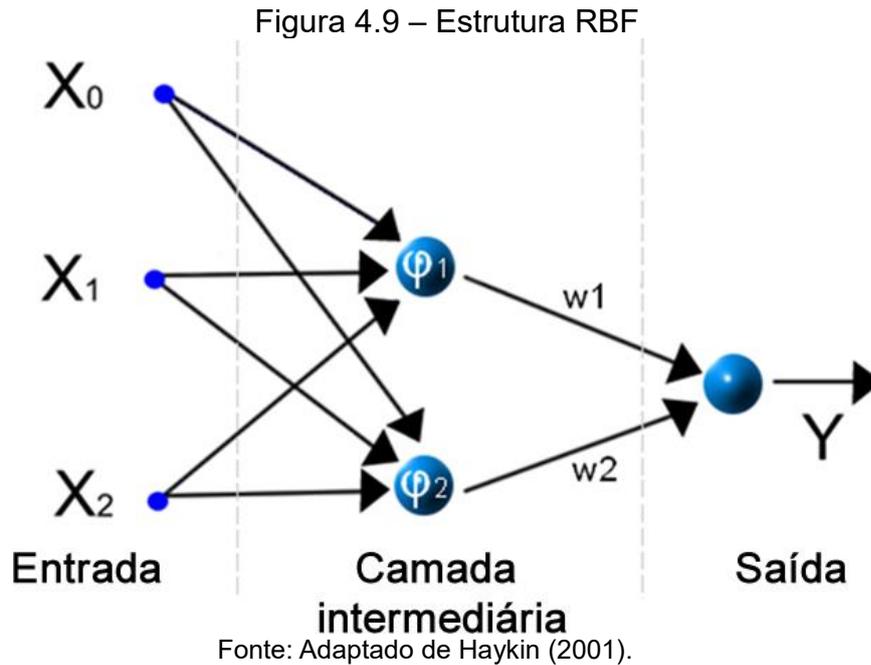
Procedimento
1: leitura e preparação de dados coletados
2: inicialização aleatória de pesos e <i>bias</i> enquanto (critérios de parada)
3: processamento da camada oculta
4: processamento da camada de saída
5: cálculo dos erros de previsão
6: cálculo e retropropagação das sensibilidades
fim enquanto
7: teste da RNA com os pesos e <i>bias</i> finais

Fonte: Autor (2020).

Para o treinamento da RNA MLP Backpropagation desenvolvida nesta tese, em relação aos dados coletados no Brasil, foram utilizados 70 % de todos os dados coletados (512 dias). Para o treinamento com dados coletados na Espanha, são utilizados 8 anos de todos os dados obtidos (2.921 dias). O algoritmo foi desenvolvido no software Matlab, e prevê dados de irradiância solar com uma hora de antecedência. Isso se aplica a todas as outras técnicas de previsão. Os critérios de parada do treinamento foram definidos pelo acompanhamento do erro quadrático médio treinamento, com limite inferior de 0,01 % para parada do treinamento, bem como o limite de 10.000 épocas de treinamento, ou seja, 10.000 processamentos sequenciais do laço enquanto.

4.3.2 RBF

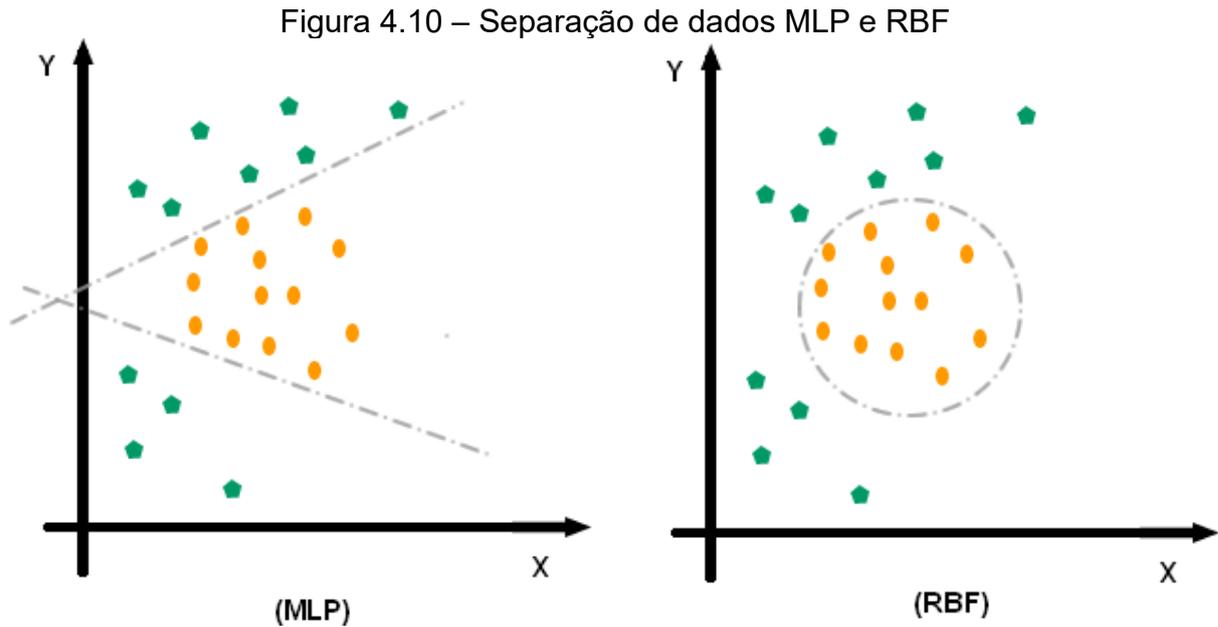
Uma RBF, trata-se de uma RNA com múltiplas camadas, onde em cada uma dessas camadas, há execução de atividades diferentes: A camada de entrada, ou seja, seus neurônios de entrada, é o ponto de conexão da RNA com o ambiente de dados que se quer processar. A segunda camada, que é uma camada única, aplica uma transformação não-linear do espaço de entrada para uma representação no espaço gerado pelas ativações dos neurônios da camada escondida. A sua terceira camada, é a saída da RNA, onde obtem-se a resposta da rede. A estrutura da RNA RBF é representada através da Figura 4.9.



X_0 , X_1 e X_2 representam os neurônios de entrada, que na verdade, são os dados de entrada do sistema; sendo ϕ_1 e ϕ_2 os neurônios intermediários, onde cada neurônio apresenta uma função de base radial; y o neurônio que equivale a saída da rede; os parâmetros w_1 e w_2 , são os pesos das conexões da camada intermediária à camada de saída.

A RBF utiliza-se de metodologia baseada em alguns tipos de neurônios biológicos que são podem responder de forma seletiva a dados em um espaço pré-estabelecido. Na Figura 4.10 é demonstrada o tipo de classificação, no caso, separação de dois tipos diferentes de dados, realizado por uma RBF em comparação à classificação realizada por uma MLP.

A MLP representada utilizou-se de dois neurônios onde a classificação dos dados foi realizada pelo posicionamento de duas retas no plano bidimensional. A RBF pode, no exemplo, de separar o mesmo conjunto de dados apenas com um neurônio, ajustando a posição do centro de um círculo, bem como o espalhamento.



Quando uma rede RBF é usada para realizar uma tarefa complexa de classificação de padrões, o problema é resolvido basicamente pela transformação do espaço de entrada para um espaço de alta dimensionalidade, de forma não-linear (HAYKIN, 2001. p. 284). Isso ocorre baseado no Teorema de Cover onde é afirmado que, “um problema complexo de classificação de padrões disposto não-linearmente em um espaço de alta dimensão, tem maior probabilidade de ser linearmente separável do que em um espaço de baixa dimensionalidade” (HAYKIN, 2001. p. 285).

Estas redes utilizam funções de ativação com campos receptivos locais (*local receptive fields*), como citado anteriormente. Para isso, as equações 4.6 e 4.7 foram consideradas para utilização da função Gaussiana, onde φ é a saída de cada neurônio da camada oculta, r é a diferença entre a entrada x e o centro t e σ é a medida do espalhamento da curva.

$$\varphi = \exp\left(-\frac{r^2}{2\sigma^2}\right) \quad (4.6)$$

$$r = |x - t| \quad (4.7)$$

A saída da RBF utilizada é formada por um único neurônio linear, onde é realizada a soma de cada saída dos neurônios da camada oculta, ponderadas pelos seus respectivos pesos. Isso está representado na equação 4.8, onde y é a saída da RNA e w é o peso.

$$y = \sum w_j \cdot \varphi_j \quad (4.8)$$

O treinamento da RNA RBF utilizada nesta tese, seguiu dois passos: primeiramente é feito o reposicionamento dos centros e espalhamento; posteriormente é feito o ajuste dos outros parâmetros livres da RNA RBF, no caso, é realizado o ajuste de pesos.

A localização dos centros de cada neurônio da RBF é definida de forma aleatória a partir dos dados do conjunto de treinamento da RNA. O algoritmo de agrupamento de centros escolhido, é o *K-means*. Para a execução do *K-means*, é extraído um vetor x do conjunto de dados de treinamento a fim de se encontrar o centro mais próximo do vetor em evidência. A verificação da distância entre centros e o vetor em análise (k) é encontrada por meio da equação 4.9, onde também se extrai a informação de qual o centro mais próximo. Onde x é o vetor em evidência e C_k é o centro do neurônio.

$$k = \arg \min_k \left\| x_{(n)} - C_{k(n)} \right\| \quad (4.9)$$

A partir dessa informação, o centro mais próximo do vetor x é atualizado por meio da equação 4.10, onde α é a taxa de aprendizagem arbitrada pelo programador. O procedimento de atualização de centros é repetido até que não se perceba mais mudanças nos centros dos neurônios.

$$C_{k(n+1)} = C_{k(n)} + \alpha \left[x_{(n)} - C_{k(n)} \right] \quad (4.10)$$

Vencida a etapa de ajuste dos centros, o algoritmo utiliza-se da equação 4.11 para a realização da segunda etapa do treinamento da RNA RBF, ou seja, atualização de pesos. Onde w_j é o peso a ser atualizado, e_j é o erro da saída da rede, que pode ser encontrado por meio da equação 4.2.

$$w_{j(n+1)} = w_{j(n)} + \alpha \cdot e_{j(n)} \cdot \varphi \quad (4.11)$$

Para o treinamento da RNA RBF desenvolvida por nesta tese, em relação aos dados coletados no Brasil, foram utilizados 70 % de todos os dados coletados (512 dias). Para o treinamento com dados coletados na Espanha, são utilizados 80 % de todos os dados obtidos (2.921 dias). O algoritmo foi desenvolvido no *software* Matlab, e prevê dados de irradiância solar com uma hora de antecedência.

São avaliados como entrada da RNA os dados coletados de irradiância solar, temperatura, mês e hora da coleta, sendo a janela de dados anteriores utilizados, definidos pelo método do incremento de neurônios (partindo de um neurônio) e verificação do erro. Os ajustes finos para definição da quantidade de neurônios na camada oculta seguem a mesma metodologia.

A cada aumento na quantidade de neurônios, a rede é retreinada e o MAPE é considerado para a tomada de decisão de um novo aumento ou não para a definição final da estrutura do RNA. Os critérios de paradas do treinamento foram definidos pelo acompanhamento do gráfico do erro quadrático médio treinamento, com limite inferior de 0,01 % para parada do treinamento, bem como o limite de 10.000 épocas de treinamento, ou seja, 10.000 processamentos sequenciais do laço enquanto.

O procedimento de treinamento realizado pela RBF, desenvolvida nesta tese, pode ser resumido por meio da Figura 4.11.

Figura 4.11 – Procedimento RBF Utilizada

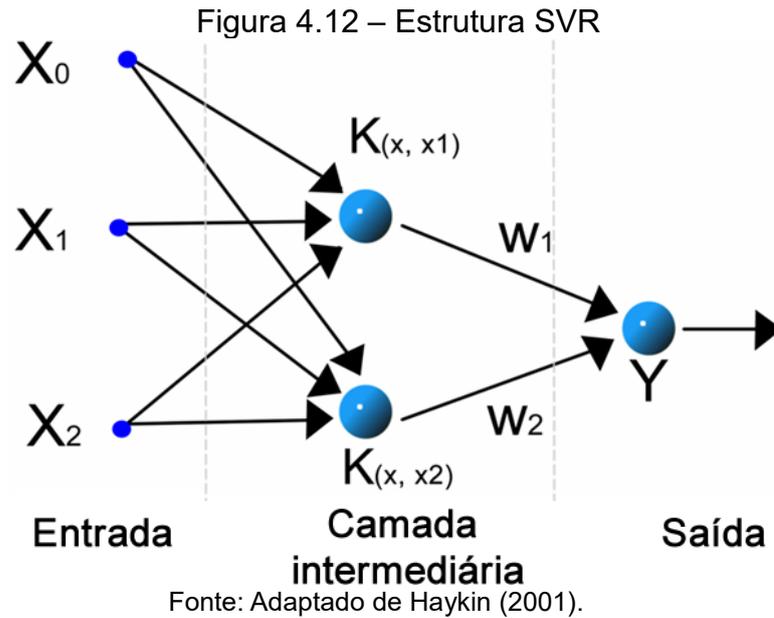
Procedimento
1: leitura e preparação de dados coletados
2: inicialização aleatória de centros enquanto (critérios de parada)
3: extração do vetor para análise
4: cálculo das distâncias entre vetor e centros
5: verificação de centro mais próximo
6: atualização do centro mais próximo fim enquanto
enquanto (critérios de parada)
7: processamento da camada oculta
8: processamento da camada de saída
9: cálculo dos erros de previsão
10: atualização de pesos fim enquanto
11: teste da RNA com os pesos e <i>bias</i> finais

Fonte: Autor (2020).

4.3.3 SVR

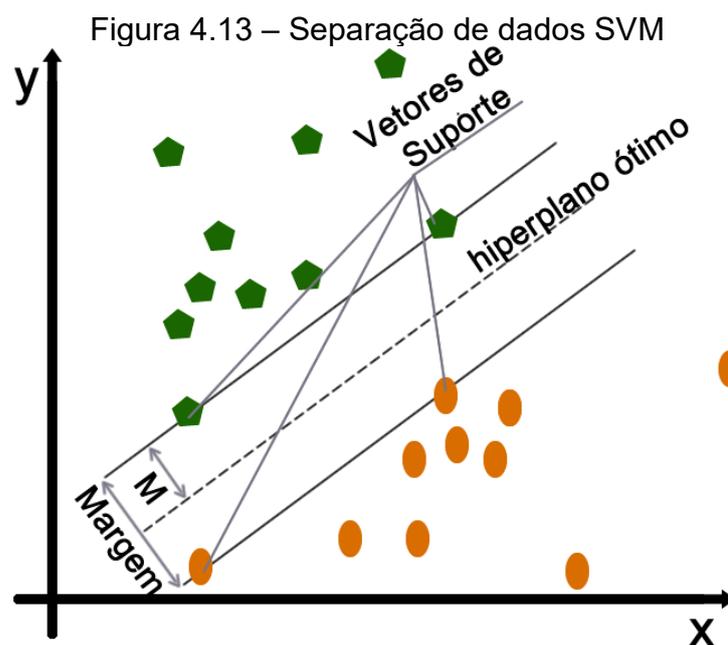
A ideia principal de uma SVM é construir um hiperplano com superfície de decisão de tal forma que a margem de separação entre exemplos positivos e negativos seja máxima (HAYKIN, 2001, p. 349). A SVM, assim como a MLP e a RBF, são técnicas de aprendizado supervisionado, em que o aprendizado é conduzido pelo sinal de erro (diferença entre a resposta desejada e a atual). A SVM foi desenvolvida por Vapnik em 1992 para resolver o problema de classificação (HAYKIN, 2001, p. 349). Esse método foi estendido ao domínio de regressão e problemas de previsão, sendo chamado de SVR.

Conforme apresentado no levantamento bibliográfico, o algoritmo SVR vem sendo empregado como um amplo contribuinte na área de previsibilidade solar. Assim, acredita-se que sua estrutura, aliada à estrutura de outras técnicas de previsibilidade, causará efeitos positivos no desenvolvimento da PrevTP. A SVR consiste em uma técnica de aprendizagem que também está organizada em camadas. A camada de entrada é referente aos dados, a camada intermediária é composta pelos núcleos do produto interno e a camada de saída é a resposta da rede aos estímulos de entrada. Na Figura 4.12 é apresentada a estrutura de uma SVR.



X_0 , X_1 e X_2 representam as variáveis de entrada, $K_{(x, x_1)}$ e $K_{(x, x_2)}$ são os neurônios intermediários, Y é o neurônio que representa a saída da SVR. Os parâmetros w_1 e w_2 são os pesos das conexões entre a camada intermediária e a camada de saída.

Uma SVM trabalha com a separação de padrões através de um hiperplano ótimo. Na Figura 4.13 é apresentado um exemplo de separação de padrões linearmente separáveis realizado por uma SVM.



As observações mais próximas ao hiperplano ótimo são chamadas de vetores de suporte devido a sua função de influência sobre o posicionamento do hiperplano de separação. A margem de separação é representada pela distância entre as linhas tracejadas equidistantes do hiperplano ótimo. O hiperplano ótimo pode ser representado por meio da equação 4.12, onde x é um vetor de entrada, w são os pesos que podem ser ajustados no processo de treinamento e b_0 é um *bias*.

$$w^T \cdot x + b_0 = 0 \quad (4.12)$$

O valor ótimo da margem de separação é encontrado por meio da equação 4.13. Onde, p é a margem ótima de separação e w_0 o vetor de pesos.

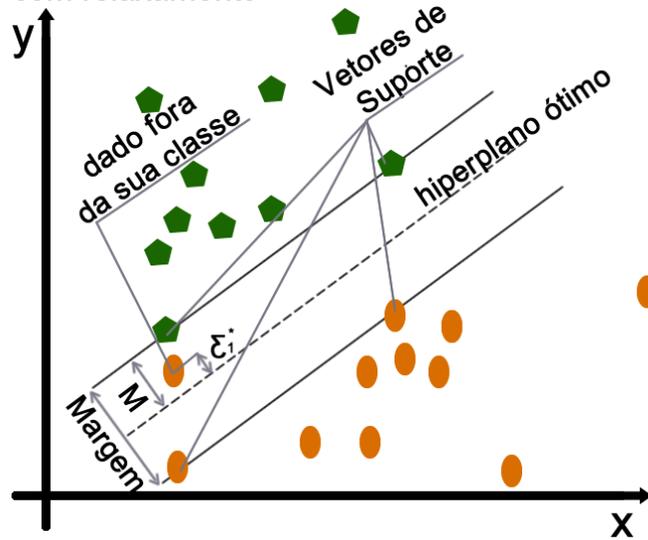
$$p = \frac{2}{\|w_0\|} \quad (4.13)$$

Para aumentar a flexibilidade do classificador e ser possível realizar a separação em situações que alguns dados de uma classe ultrapassam a fronteira do hiperplano, onde conseqüentemente estão posicionados na classe diferente da sua, é inserido um relaxamento apresentado na equação 4.14.

Onde, ξ_i é a distância entre o dado de classe errônea em relação ao hiperplano de separação e C é o limite de relaxamento atribuído pelo programador. Isso permite que o hiperplano realize a separação da maior parte dos dados, tolerando alguns elementos que atrapalhariam a definição de posicionamento do classificador. Na Figura 4.14 é exemplificada essa situação.

$$\sum \xi_i \leq C \quad (4.14)$$

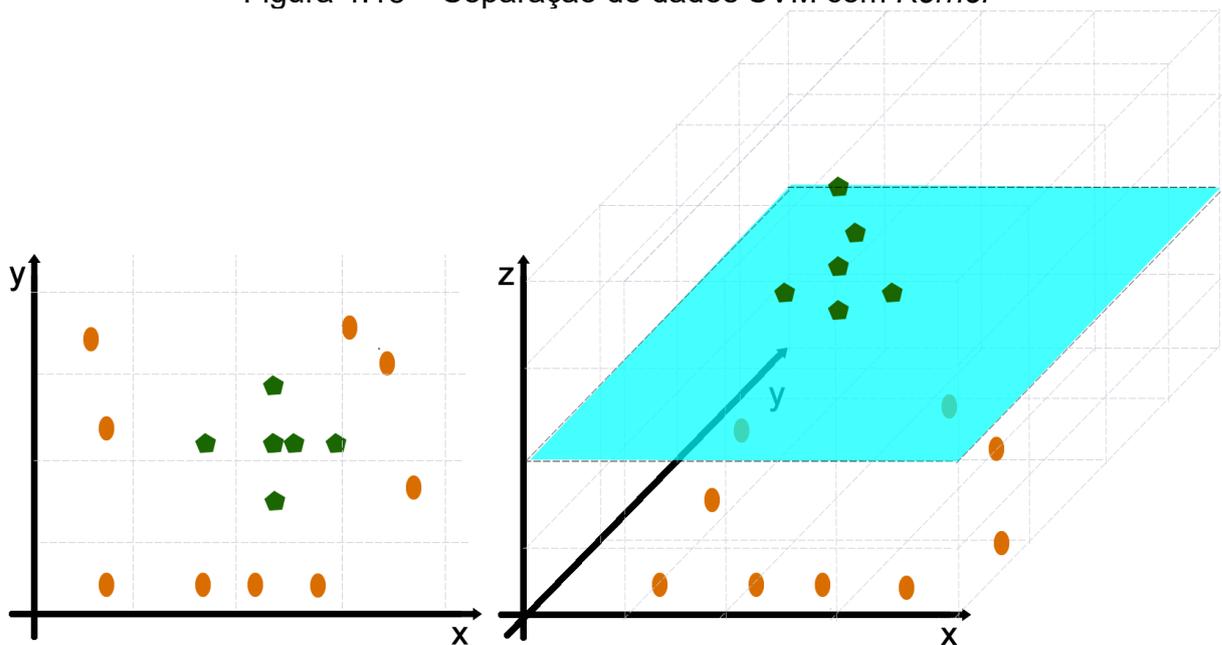
Figura 4.14 – Separação de dados SVM com relaxamento



Fonte: Autor (2020).

Para a separação não linear ser possível de ser realizada, utiliza-se o *Kernel* com o objetivo de aumentar a dimensionalidade dos dados a fim de que seja possível encontrar um hiperplano ótimo de separação. Na Figura 4.15 são apresentados dados linearmente não separáveis em duas dimensões, que em três dimensões podem ser classificados.

Figura 4.15 – Separação de dados SVM com *Kernel*



Fonte: Autor (2020).

O Kernel é utilizada para executar a ampliação da dimensionalidade dos

Assim, pode-se definir que a principal função de uma SVR é encontrar o hiperplano ou curva que represente a tendência dos dados, podendo então prever os valores futuros. Assim como a SVM, a SVR mapeia a entrada para um espaço de alta dimensionalidade. A função que estima a saída da SVR é representada na equação 4.17. Onde, w é o peso, x é o vetor de entrada, b é o *bias*, α são os multiplicadores de Lagrange e K é o *Kernel*.

$$f(x,w)=w^T \cdot x+b=\sum (\alpha_i-\alpha_i^*) \cdot K(x,x_i)+b \quad (4.17)$$

Os multiplicadores de Lagrange ($Q(\alpha,\alpha^*)$) podem ser encontrados por meio da equação 4.18 e 4.19, onde ε é variável de folga, de modo a admitir erros no processo de regressão e y a saída desejada.

$$Q(\alpha,\alpha^*)=-\frac{1}{2} \sum (\alpha_i-\alpha_i^*) \cdot (\alpha_j-\alpha_j^*) \cdot K(x_i,x_j)-\varepsilon \sum (\alpha_i+\alpha_i^*)+\sum (\alpha_i-\alpha_i^*) \cdot y_i \quad (4.18)$$

Sujeito a:

$$\sum (\alpha_i-\alpha_i^*)=0 \text{ e } \alpha_i, \alpha_i^* \in [0,C] \quad (4.19)$$

O procedimento de treinamento realizado pela SVR, desenvolvida nesta tese, pode ser resumido por meio da Figura 4.17.

Figura 4.17 – Procedimento SVR Utilizada

Procedimento
1: leitura e preparação de dados coletados
2: inicialização dos alfas em zero enquanto (critérios de parada)
3: Cálculo dos multiplicadores de Lagrange fim enquanto
4: Cálculo dos pesos e <i>bias</i>
5: Cálculo das saídas de teste (previsão)
6: teste da SVR com os pesos e <i>bias</i> finais

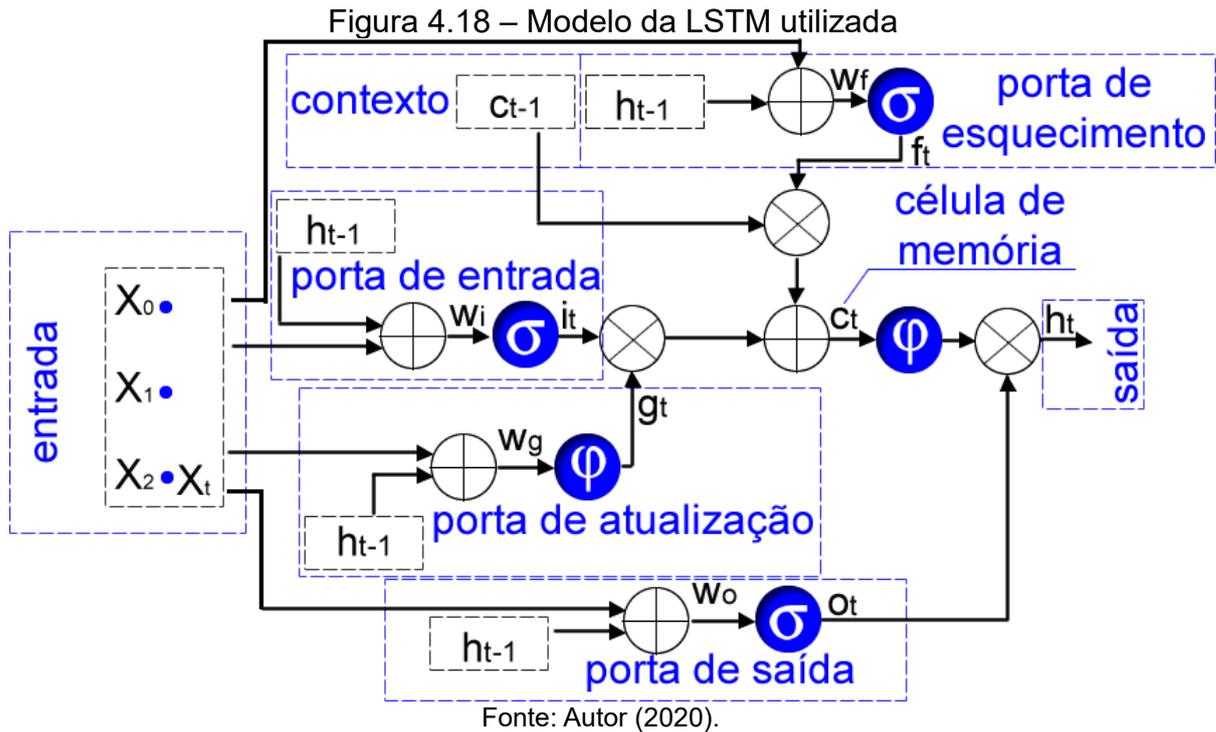
Fonte: Autor (2020).

4.3.4 Deep Learning

Um dos temas emergentes no campo da IA é a DL, uma subcategoria de aprendizado de máquina com capacidade de aprimoramento em relação a outros métodos de aprendizagem computacional. As arquiteturas de técnicas de DL fornecem recursos para modelar com detalhes características do conjunto de dados imperceptíveis para outras técnicas, fornecendo uma representação mais eficiente que os modelos rasos, melhorando assim a generalização (BEDI e TOSHNIWAL, 2019, p. 1315). Para explorar essas características e produzir previsões de irradiância solar, a técnica denominada *Long Short Term Memory (LSTM)* foi implementada, que é uma arquitetura de *Recurrent Neural Network (RNN)* no campo das DL (WANG, QI, e LIU, 2019, p. 2).

Os LSTMs têm uma vantagem sobre as RNAs convencionais devido à sua propriedade de se lembrar de padrões, seletivamente, por longos períodos de tempo, aonde essa metodologia foi introduzida por Hochreiter e Schmidhuber em 1997 (WANG, QI, e LIU, 2019, p. 11).

A estrutura da LSTM utilizada é composta por entrada, porta de entrada, porta de atualização, porta de esquecimento, porta de saída, contexto, célula de memória e saída. Na Figura 4.18 é apresentada a estrutura utilizada, bem como o fluxo de informação em uma LSTM.



As variáveis apresentadas e todo o fluxograma da LSTM podem ser representados matematicamente por meio das equações 4.20, 4.21, 4.22, 4.23, 4.24 e 4.25, onde f_t , i_t , g_t e o_t são a porta de esquecimento, porta de entrada, porta de atualização e porta de saída, respectivamente. c_t representa a célula de memória, h_t representa a saída da rede, σ é a função sigmoide, φ é a função hiperbólica e x_t é a entrada da LSTM. w refere-se aos pesos de cada estágio (w_f , w_i , w_g , w_o), assim como b é o *bias* de cada estágio (b_f , b_i , b_g , b_o).

$$f_t = \sigma(w_f \cdot [h_{t-1}, x_t]) + b_f \quad (4.20)$$

$$i_t = \sigma(w_i \cdot [h_{t-1}, x_t]) + b_i \quad (4.21)$$

$$g_t = \varphi(w_g \cdot [h_{t-1}, x_t]) + b_g \quad (4.22)$$

$$c_t = f_t \cdot c_{t-1} + i_t \cdot g_t \quad (4.23)$$

$$o_t = \sigma(w_o \cdot [h_{t-1}, x_t]) + b_o \quad (4.24)$$

$$h_t = o_t \cdot \varphi(c_t) \quad (4.25)$$

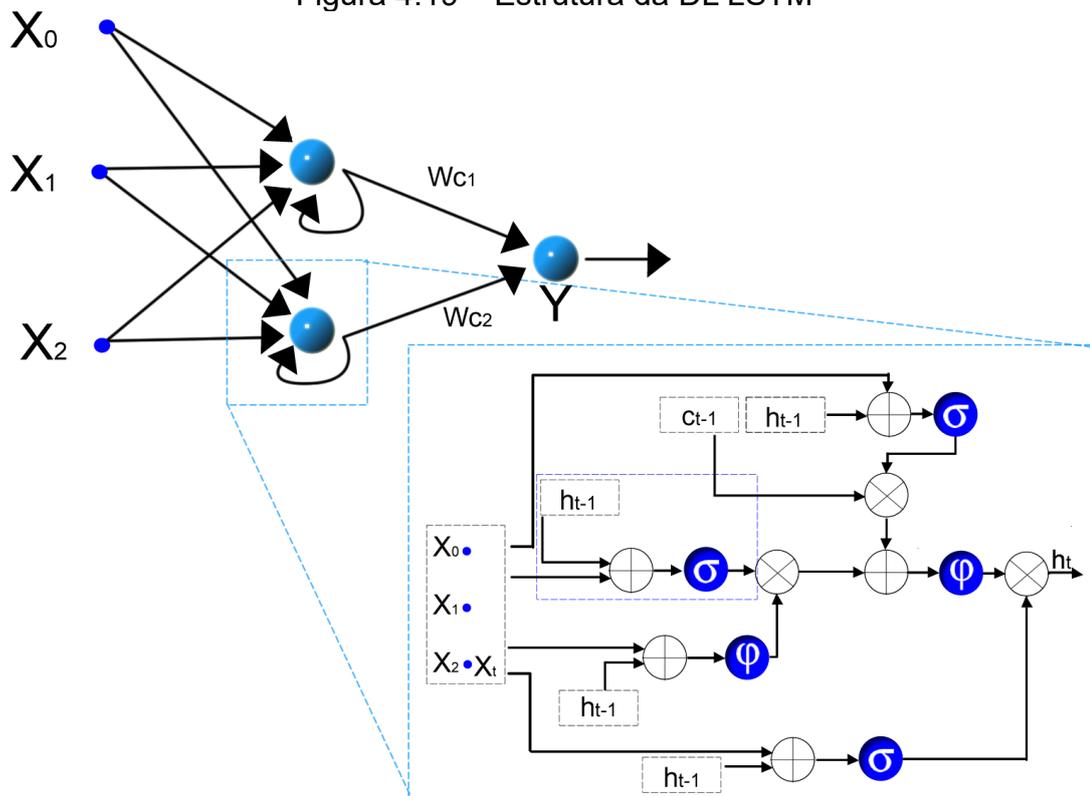
Para tomada de decisões, a LSTM pode utilizar-se de informações recentes e dos estados anteriores para executar o cálculo de saída. A partir de suas portas, a LSTM tem a capacidade de remover ou adicionar informações que circulam por sua estrutura. De forma criteriosa, a rede em questão pratica a escolha do fluxo de informações através das ponderações e funções de cada porta.

Cada etapa que compõe a LSTM tem uma função específica para o funcionamento da técnica. A porta de esquecimento é responsável por descartar ou manter a informação no sistema. Através de uma ponderação que varia de 0 a 1, a porta define o quanto a informação é relevante para a resolução do problema, sendo 0 para que a informação seja esquecida completamente e 1 para que a informação seja considerada em sua totalidade. Como pode ser verificado por meio da estrutura da LSTM, a porta de esquecimento considera além da entrada da rede a informação h_{t-1} emitindo uma ponderação.

Para a definição de quais as novas informações serão inseridas em cada célula da LSTM, são combinadas as portas de entrada e de atualização. A porta de entrada define qual a informação específica da entrada deve ser inserida na célula de memória. Através de uma função sigmoide, obtém-se ponderações de 0 a 1 para a informação que circula por essa etapa da LSTM. Em seguida, a porta de atualização cria um novo candidato a c_t a partir de sua função hiperbólica. Por conseguinte, a célula de memória, c_t , sofre influências das portas de entrada, atualização e esquecimento conforme representado na estrutura da LSTM. Finalmente, a saída será baseada na célula de memória e na porta de saída da RNN.

A possibilidade da LSTM poder definir o fluxo de informações, inclusive permitindo a entrada ou não de dados, é uma evolução em relação as técnicas de aprendizagem convencionais. Por meio dessa característica essa técnica pode filtrar ruídos na entrada, por exemplo, simplesmente mantendo o estado anterior do sistema. Na Figura 4.19 é apresentada a estrutura de uma DL LSTM aplicada à previsibilidade solar.

Figura 4.19 – Estrutura da DL LSTM



Fonte: Autor (2020).

A saída da LSTM pode ser encontrada por meio da equação 4.26, onde w_c é o peso e h_t é a saída de cada célula da LSTM.

$$y = \sigma(\sum w_{c_j} \cdot h_{t_j}) \quad (4.26)$$

A cada época do treinamento, é calculado o erro da saída da LSTM em relação ao valor desejado de saída. Isso ocorre com base na equação 4.27, onde, e_j é o erro, d_j é o valor desejado de saída e y_j é a saída.

$$e_{j(n)} = d_{j(n)} - y_{j(n)} \quad (4.27)$$

Também a cada época do treinamento, é calculado o erro interno para todas as células da LSTM. Isso ocorre com base na equação 4.28. Onde, e_c é o erro interno de cada célula LSTM, y_j é a saída e w_c são os pesos.

$$e_{c(n)} = y_{j(n)} \cdot (\sum w_{cj} \cdot \delta_{(n)}) \quad (4.28)$$

A sensibilidade para o uso de algoritmo *Backpropagation*, que determina a atualização dos parâmetros livres da rede é encontrada por meio da equação 4.29 para os pesos da camada de saída e 4.30 para os pesos da camada oculta, onde, δ_j é a sensibilidade da camada de saída, δ_c é a sensibilidade da camada oculta, σ é a função sigmoide, w_c são os pesos da camada de saída, h_t é a saída de cada célula da LSTM e e_j é o erro da rede.

$$\delta_{j(n)} = 2\sigma'(\sum w_{cj} \cdot h_{tj}) \cdot e_j \quad (4.29)$$

$$\delta_{c(n)} = 2\sigma'(w_{cj} \cdot h_{tj}) \cdot (\sum w_{cj} \cdot \delta_j) \quad (4.30)$$

Calculadas as sensibilidades, a atualização dos pesos da camada oculta, assim como da camada de saída, é realizada pela equação 4.31, onde w é o peso, α é a taxa de aprendizagem arbitrada pelo programador e y é a saída da rede.

$$w_{(t+1)} = w_{(t)} + \alpha \cdot \delta \cdot y_{(t)} \quad (4.31)$$

O procedimento de treinamento realizado pela DL LSTM, desenvolvida nesta tese, pode ser resumido por meio da Figura 4.20.

Figura 4.20 – Procedimento LSTM *Backpropagation* utilizado

Procedimento
1: leitura e preparação de dados coletados
2: inicialização aleatória de pesos
enquanto (critérios de parada)
3: processamento da camada oculta
4: processamento da camada de saída
5: cálculo dos erros de previsão
6: cálculo e retropropagação das sensibilidades
fim enquanto
7: teste da RNA com os pesos e <i>bias</i> finais

Fonte: Autor (2020).

4.4 Ajustes finos nas técnicas de previsão

São avaliados como entrada da RNA os dados coletados de irradiância solar, temperatura, mês e hora da coleta, sendo a quantidade de dados anteriores utilizados definidos pelo método do incremento de neurônios (partindo de um neurônio) e verificação do erro. Os ajustes finos para definição da quantidade de neurônios na camada oculta seguem a mesma metodologia. Portanto, com cada aumento no número de entradas, a partir de 1, as técnicas de previsão são retreinadas.

O algoritmo encontra um valor de avaliação da situação atual e o armazena em um vetor. Depois que o limite de incrementos é atingido, o refinador utilizado encontra o ponto ideal, ou seja, a quantidade ideal de entradas do sistema que gera uma quantidade menor de erros. Essa metodologia é aplicada às quatro técnicas de previsão solar usadas na presente tese.

O algoritmo também é aplicado para o refinamento do número de unidades de processamento de camada oculta de MLP, RBF e DL. Para o SVR, a própria estrutura de treinamento da técnica define a quantidade de vetores de suporte na camada oculta. O algoritmo de refinamento de IA é definido por meio da equação 4.32, onde D_p são os dados previstos, D_o são os dados observados, n é a quantidade de previsões realizadas e m é o limite de incrementos.

$$A_o = \min_{j=1}^m \left[\left(\left(\sum_{i=1}^n \left| \frac{(D_{p(i)} - D_{o(i)}) \cdot 100}{D_{o(i)}} \right| \right) \cdot \frac{1}{n} \right) \right]_j \quad (4.32)$$

4.5 PrevTP

Além da aplicação e comparação das técnicas de previsão solar acima mencionadas, é proposta uma nova estratégia de integração dessas técnicas, a fim de reduzir os erros de previsão. A integração proposta, aqui denominada PrevTP, utiliza-se como fundamento a TP. Essa teoria, no contexto financeiro, tem como objetivo final fornecer um método para definir o percentual de penetração de cada ativo, a fim de aumentar o retorno de um investidor. Assim, a TP propõe alcançar os mesmos lucros, ou maiores lucros, combinando ativos de investimento (LIMA, *et al.*, 2017, p. 1). Já a PrevTP desenvolve uma nova topologia de integração das técnicas de previsão com estrutura adaptativa e também pesos adaptativos, utilizando-se das previsões das técnicas MLP, RBF, SVR e DL.

As técnicas são integradas e ponderadas por meio de pontos de interconexão definidos por essa adaptação, a fim de obter menores erros de previsão utilizando os princípios de diminuição de riscos da TP. Com a diversificação dos ativos previstos, espera-se que quando um dos ativos obtiver erros de previsão de sinal negativo, outro ou outros ativos complementem com um valor de sinal contrário, para que haja um cancelamento de erro completo ou parcial.

4.5.1 Diversificação dos ativos

Na teoria original, mediante o efeito da diversificação em relação aos riscos de investimentos, apresentados na Figura 4.21, percebe-se que quanto maior a quantidade de ativos, menor será o risco diversificável. Desse modo, a melhor forma de atingir uma rentabilidade elevada com um risco menor, é diversificando os investimentos em todas as classes de ativos. Pode-se perceber também que o risco permanece presente mesmo com a implementação de vários ativos; nesse caso, este recebe o nome de risco não diversificável. O fenômeno de diversificação de ativos também é considerado na PrevTP, e por isso é proposta a integração de quatro técnicas de previsão.

Figura 4.21 – Curva de efeito da diversificação
Risco do Portfólio



Fonte: Adaptado de Speth (2013).

Na Tabela 4.1 é apresentado o efeito proporcionado pela diversificação através de um estudo do risco médio de investimentos relacionados com a quantidade de ativos de uma carteira, em que se busca o investimento em vários ativos para diminuição do risco diversificável. Observa-se uma redução dos riscos. Portanto, conforme apresentado anteriormente, a diversificação tende a alcançar um ponto onde não haverá mais diminuição dos riscos.

Tabela 4.1 – Evolução do risco mediante a diversificação

Número de ações do Portfólio	Risco médio dos retornos anuais da carteira
2	37,36 %
4	29,69 %
6	26,64 %
8	24,98 %
10	23,93 %
20	21,68 %
30	20,87 %
40	20,46 %
50	20,20 %
100	19,69 %
200	19,42 %
300	19,34 %

Fonte: Adaptado de Caixe (2015).

O conceito de correlação dos ativos está fortemente ligado à eficiência das integrações. A correlação é uma medida de relação entre uma série de dados

(GITMAN, 2005, p. 197). O Coeficiente de Correlação pode ter os seus valores variando de -1 a +1, isso significa que quando o coeficiente de correlação for igual a +1, as variáveis em estudo estão positivamente correlacionadas, ou seja, é uma correlação que não favorece a diversificação proposta pela teoria, já que essa característica faz com que não haja compensação de um ativo mediante uma possível perda do outro.

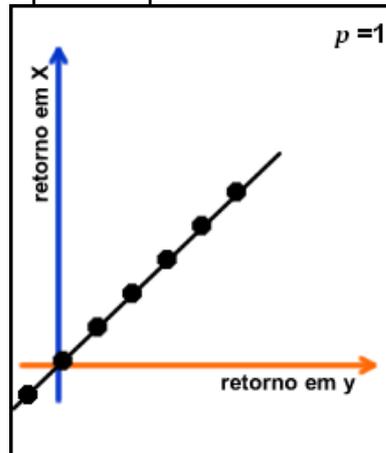
Por exemplo, no setor financeiro, se as ações de duas empresas estiverem fortemente ligadas através de um coeficiente de correlação positivo, isso significa que esses dois investimentos são incompatíveis para ocupar o mesmo portfólio, pois não haveria complementação conforme a proposta da TP, já que, se uma empresa gerasse prejuízos ao investidor devido às oscilações do mercado financeiro, a outra empresa provavelmente teria a mesma reação em relação às instabilidades.

Correlação explica o grau de relacionamento mostrado no comportamento de duas ou mais variáveis numa amostra estatística, sendo simples ou múltipla. Indica-nos de que maneira os ativos movem-se em conjunto (GITMAN, 2005, p. 198).

A característica ideal do coeficiente de correlação entre os ativos que a teoria necessita para ser aplicada é o menor valor possível, ou seja, -1, para que haja uma complementação quando um dos ativos gerar perdas ao investidor. Isso proporcionará uma ação de compensação entre os ativos. A oscilação dos valores comportamentais das variáveis é representada nas Figuras 4.22, 4.23, 4.24, 4.25 e 4.26.

Os valores obtidos através da integração dos ativos x e y têm comportamentos diferentes para as diversas situações de coeficientes de correlação. Quando a correlação entre os ativos é positiva, perfeita ou não, no momento em que há elevação do valor de um dos dois ativos, o outro também apresenta uma elevação proporcional. Quando o coeficiente de correlação é nulo, não há correlação. Quando o coeficiente de correlação é negativo, perfeita ou não, no momento em que há elevação do valor de um dos dois ativos, o ativo complementar apresenta crescimento proporcional, porém, de sinal invertido. Essa característica apresenta-se como a compensação de valores através da integração.

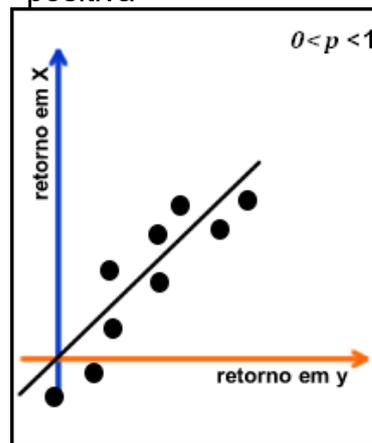
Figura 4.22 – Correlação perfeita positiva



Correlação Perfeita Positiva

Fonte: Adaptado de Speth (2013).

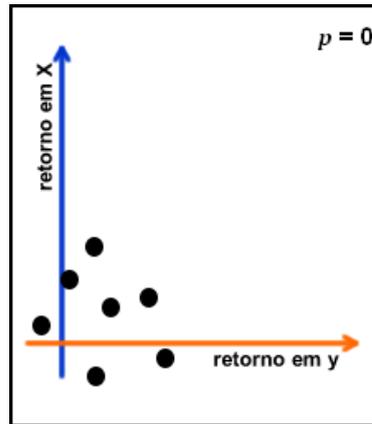
Figura 4.23 – Correlação positiva



Correlação Positiva

Fonte: Adaptado de Speth (2013).

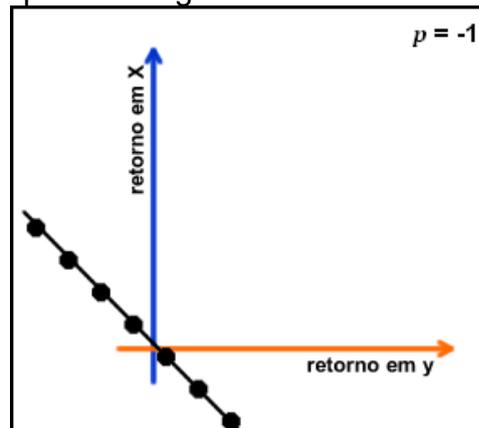
Figura 4.24 – Correlação nula



Correlação Nula

Fonte: Adaptado de Speth (2013).

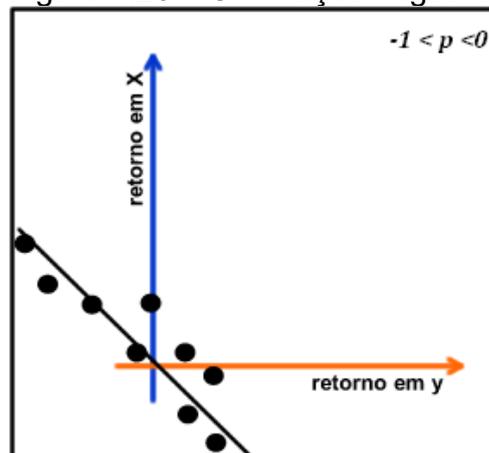
Figura 4.25 – Correlação perfeita negativa



Correlação Perfeita
Negativa

Fonte: Adaptado de Speth (2013).

Figura 4.26 – Correlação negativa



Correlação Negativa

Fonte: Adaptado de Speth (2013).

A diversificação dos ativos de um investimento, ou no caso da PrevTP, a medida de complementação de previsores, medida pelo coeficiente de correlação, pode ser vista na Equação 4.33, em que $\rho_{x,y}$ é o Coeficiente de Correlação entre os ativos x e y , $\text{Cov}(y, x)$ é a covariância entre os ativos x e y , σ_x é o desvio padrão do ativo x e σ_y é o desvio padrão do ativo y .

$$\rho_{x,y} = \frac{\text{Cov}(y, x)}{\sigma_x \cdot \sigma_y} \quad (4.33)$$

A Covariância entre os ativos x e y é determinada pela Equação 4.34, em que x_i são os valores do ativo x , \bar{x} é a média dos valores do ativo x , y_i são os valores do ativo y , \bar{y} é a média dos valores do ativo y e n é a quantidade de valores dos ativos.

$$\text{Cov}(y,x) = \frac{\sum_{i=1}^n (x_i - \bar{x}) \cdot (y_i - \bar{y})}{n} \quad (4.33)$$

O risco de um Portfólio pode ser determinado pelo cálculo do desvio padrão, conhecendo-se a probabilidade de ocorrer determinado resultado. Desta forma, com dados históricos de rendimento de um ativo pode-se estimar as probabilidades de ocorrência de vários resultados.

O desvio padrão, ou seja, o risco que os resultados finais obtidos sejam diferentes do desejado, é encontrado por meio da Equação 4.34, em que σ é o desvio padrão, n é a quantidade de valores dos ativos, x_i são os valores do ativo x , \bar{x} é a média dos valores do ativo.

$$\sigma = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2} \quad (4.34)$$

O risco de uma carteira não só é reflexo da volatilidade de cada ativo e de sua representatividade total na carteira, mas principalmente da maneira como seus

componentes se relacionam entre si, ou seja, covariam. Portanto, define-se risco como o desvio padrão das variações de retorno de um ativo; quanto maior for o valor do desvio padrão, maior será o grau de dispersão absoluta dos valores ao redor da média.

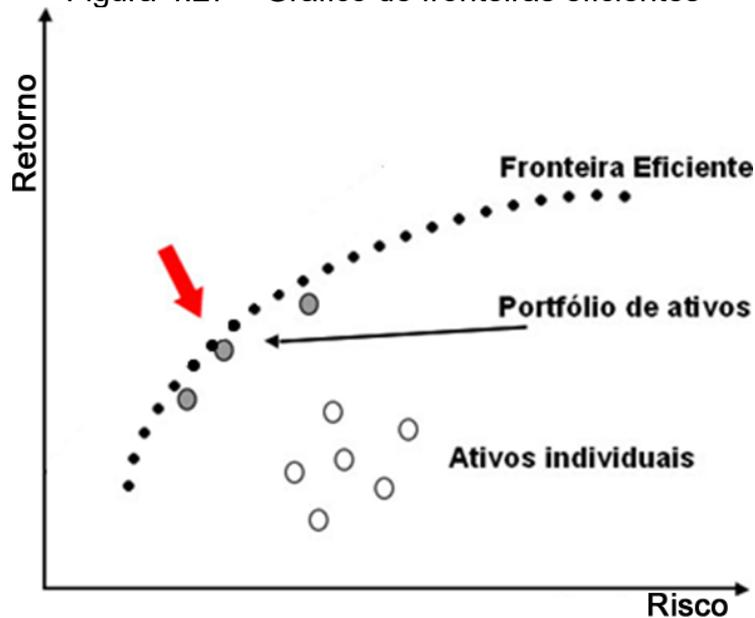
O desvio padrão, utilizado como forma de medição de risco, é encontrado na maioria dos trabalhos que utilizam a TP para gerenciamento e planejamento no setor de energia elétrica, em vários tipos distintos de retorno. Outra forma de medição do risco é o valor condicional de risco, utilizado em apenas 1 de 13 trabalhos obtidos no levantamento bibliográfico.

4.5.2 Fronteiras Eficientes

Para fim de definição do percentual de cada ativo, com o intuito de se reduzir os erros de previsão, é necessária a construção do gráfico de Fronteiras Eficientes. Esse limite são linhas formadas pelas diferentes proporções dos ativos envolvidos no portfólio e que representa graficamente a relação de que um determinado retorno promoverá um menor risco possível (SPETH, 2013, p. 7).

O gráfico de fronteiras eficientes é apresentado na Figura 4.27. A percepção da porcentagem de cada ativo do portfólio será definida pela obtenção de um ponto de equilíbrio entre o retorno e o desvio padrão (risco do portfólio). A representação desse ponto pode ser observada por meio da indicação da seta vermelha.

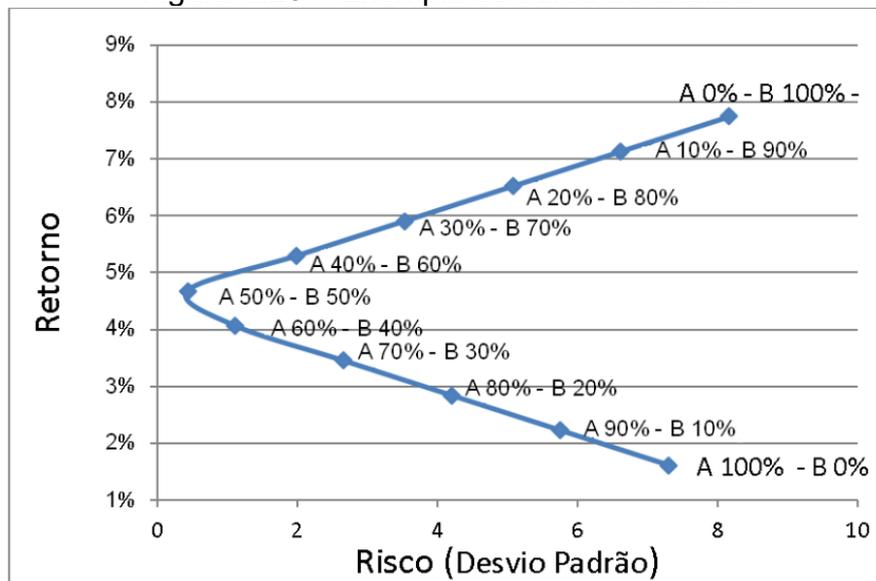
Figura 4.27 – Gráfico de fronteiras eficientes



Fonte: Adaptada de (Speth, 2013).

Na Figura 4.28 é apresentada uma situação hipotética da diversificação das aplicações através dos dois ativos, A e B, como forma de exemplo da curva de análise de retorno e risco (Fronteira Eficiente).

Figura 4.28 – Exemplo de curva de análise



Fonte: Autor (2020).

Observa-se que para o caso de investimento efetuado apenas em ações do tipo A, há obtenção de um retorno abaixo de 2 %, com desvio padrão, ou seja, o risco, próximo a 7. Já para o caso de aplicação em 100 % nas ações do tipo B, o

retorno é bem maior, próximo a 8 %, porém o risco é maior que na primeira situação, chegando a aproximadamente 8. Verifica-se que a medida em que as aplicações são diversificadas entre as duas ações o risco é diminuído. Nesse exemplo, o menor risco é encontrado para 50 % de aplicação em A e 50 % de aplicação em B. Destaca-se que o investidor pode vir a escolher outros níveis de investimentos, diferentes de A 50 % e B 50 % para aumento do retorno, porém, através da fronteira eficiente, verifica-se que esse é o menor risco possível.

4.5.3 Erros de previsão

Os erros percentuais da previsão são encontrados por meio da equação 4.35. Em que E_p é o erro de previsão, D_m são os dados medidos e D_p são os dados previstos.

$$E_p = \frac{(D_p - D_m) \cdot 100}{D_m} \quad (4.35)$$

Os erros de previsão solar serão encontrados em diferentes horas do dia, ou seja, onde há diferentes níveis de disponibilidade de recurso energético. Se um erro de previsão solar, por exemplo, acontecer no período de pôr do sol, fenômeno que ocorre das 17 h às 18 h em Fortaleza, os impactos desses erros a uma geração de eletricidade serão menores do que erros que acontecerem as 12 h, quando é encontrada a maior disponibilidade de recurso solar. Para nivelar os erros de previsão levando-se em consideração a amplitude de disponibilidade de recurso, é aplicado um filtro denominado Fator de Impacto.

Os valores dos erros de previsão ponderados podem ser encontrados a partir das equações 4.36 e 4.37. Nestas equações, E_{pon} é o erro de previsão ponderado, E_p é o erro de previsão, FI é o fator de impacto, D_m é o dado medido e Mr é o maior valor encontrado do recurso.

$$E_{pon} = E_p \cdot FI \quad (4.36)$$

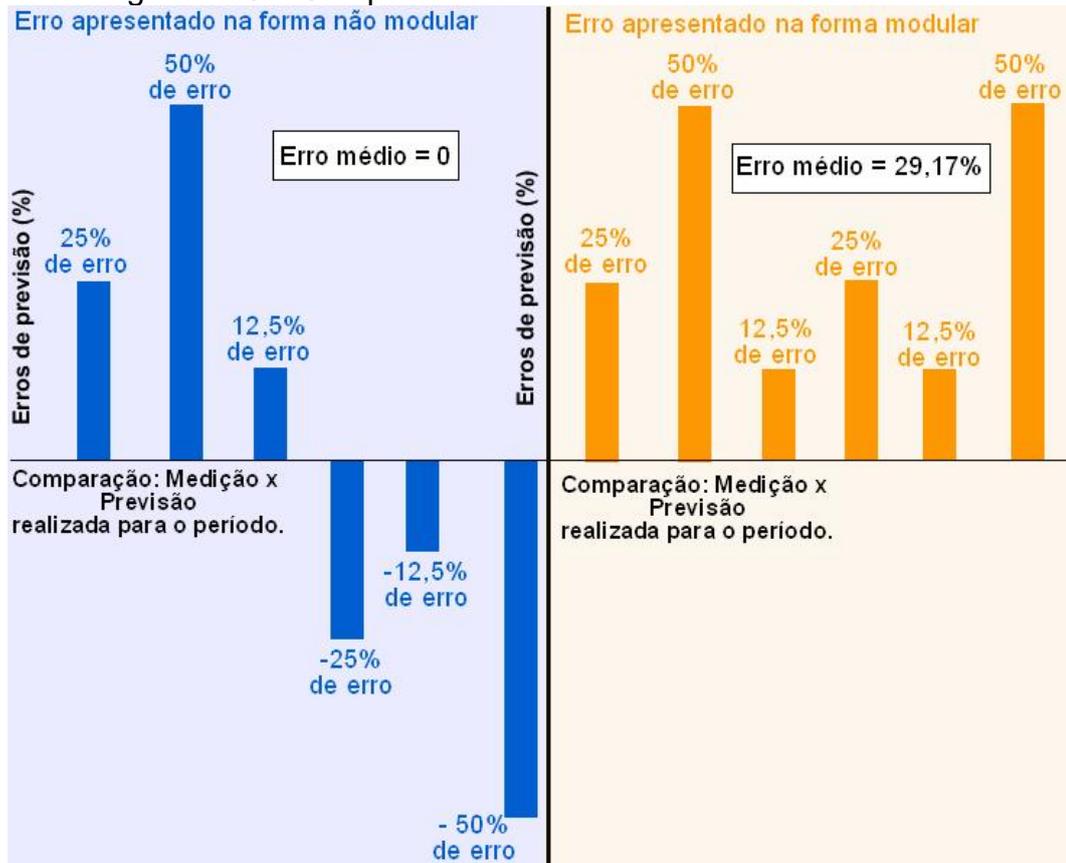
$$FI = \frac{Dm}{Mr} \quad (4.37)$$

Os erros de previsão podem ter os seus percentuais encontrados com sinais positivos e negativos. Quando encontrado no eixo negativo isso significa que a previsão cometeu o erro de subestimar a quantidade de energia para o período de análise. No caso do erro positivo, essa característica determina que o sistema de previsão superestimou a quantidade de energia disponível.

A presente tese analisa erros com sinais positivos e negativos para que, no desenvolvimento da PrevTP, possa ser compreendida a tendência da combinação em relação a subestimar ou superestimar a quantidade de recurso energético. Porém, para que os dados possam dar compreensão do afastamento das previsões do seu valor ideal, também serão apresentados os módulos dos erros. O erro médio pode ter o seu valor anulado caso haja o confronto de erros positivos e negativos.

O efeito entre o estudo dos erros da forma modular e não modular, onde propositalmente criou-se um cenário da análise dos erros com sinais positivos e negativos com o estudo dos módulos está representado na Figura 4.29.

Figura 4.29 – Comparativo entre erros modular e não modular



Fonte: Lima (2016).

Verifica-se, nesse caso, que houve uma anulação no valor do erro médio no primeiro exemplo, conforme explicado anteriormente, enquanto no segundo exemplo há a medição do afastamento das previsões em relação aos dados observados.

Com a implementação de geradores a partir de fontes intermitentes de produção de eletricidade, dependentes de fatores climáticos, as técnicas de previsão de disponibilidade de recurso devem ser reforçadas a fim de se reduzir os impactos provocados pela diferença entre a energia elétrica produzida e a demandada. Desta forma, necessitando de menos balanceamento no sistema elétrico.

4.5.4 Gráfico de Fronteiras Eficientes

A TP adaptada para a integração de técnicas de previsibilidade visando a diminuição dos erros da predição de irradiância solar leva em consideração três itens: correlação entre os erros de previsão dos ativos; o risco de erros de previsão definido pelo desvio padrão de cada ativo; e os erros de previsão propriamente ditos, para

cada ativo analisado separadamente. Na PrevTP, os ativos são as técnicas de previsão aplicadas a previsibilidade solar.

A partir do processamento de dados referentes aos erros de previsão solar, a PrevTP pode ser utilizada para a determinação da quantidade ideal do impacto que cada IA tem no ambiente integrado de previsão, ou seja, definição do percentual de penetração de cada técnica no contexto geral.

Para exemplificar, uma hipotética integração das técnicas de previsão a partir de RNAs MLP e RBF, com uma definição de hipotéticos 65 % de MLP e 35 % de RBF, calculada por meio da PrevTP. Isso significa que essa porcentagem, conforme a utilização proposta por este trabalho, representa o cenário de menores possibilidades de erros de previsão e com o menor risco possível. Em resumo, considerando os dados do exemplo hipotético, as previsões da RNA MLP recebem uma ponderação de 0,65 a cada previsão realizada, enquanto as previsões a partir da RNA RBF recebem uma ponderação de 0,35 a cada previsão.

Do ponto de vista dos benefícios, isso significa que, com o aprimoramento dos métodos de previsão do recurso solar, as usinas solares que utilizarem a PrevTP poderão determinar com maior precisão a quantidade de energia elétrica que será injetada na matriz energética.

A diversificação sugerida pela TP é feita pela complementação dos ativos. Para a adaptação da TP no melhoramento da previsibilidade solar, ou seja, criação da PrevTP, espera-se que, quando um dos dois ativos obter erros de previsão de sinal negativo, por exemplo, o outro complemente com um valor de sinal contrário, para que haja a anulação completa ou parcial do erro.

No caso da adaptação da TP para melhoramento da previsibilidade do recurso solar, a elaboração do gráfico de fronteira eficiente é desenvolvida de forma a criar situações onde existam combinações de diversas porcentagens de penetração de cada técnica de previsibilidade.

A representação da obtenção da diversificação entre os diferentes níveis dos ativos do portfólio é encontrada na Tabela 4.2. Para cada uma das 21 faixas percentuais de cada ativo, é elaborado o erro ponderado de todas as previsões realizadas do recurso solar. Neste caso, E é o erro de previsão integrado, E_a é o erro do ativo A, E_b é o erro de previsão do ativo B e n é o número da previsão realizada.

Tabela 4.2 – Integração das técnicas de previsão

A 100 % - B 0 %	A 95 % - B 5 %	...	A 0 % - B 100 %
$E=E_{a1}.1+E_{b1}.0$	$E=E_{a1}.0,95+E_{b1}.0,05$...	$E=E_{a1}.0+E_{b1}.1$
$E=E_{a2}.1+E_{b2}.0$	$E=E_{a2}.0,95+E_{b2}.0,05$...	$E=E_{a2}.0+E_{b2}.1$
$E=E_{a3}.1+E_{b3}.0$	$E=E_{a3}.0,95+E_{b3}.0,05$...	$E=E_{a3}.0+E_{b3}.1$
$E=E_{a4}.1+E_{b4}.0$	$E=E_{a4}.0,95+E_{b4}.0,05$...	$E=E_{a4}.0+E_{b4}.1$
$E=E_{a5}.1+E_{b5}.0$	$E=E_{a5}.0,95+E_{b5}.0,05$...	$E=E_{a5}.0+E_{b5}.1$
$E=E_{a6}.1+E_{b6}.0$	$E=E_{a6}.0,95+E_{b6}.0,05$...	$E=E_{a6}.0+E_{b6}.1$
$E=E_{a7}.1+E_{b7}.0$	$E=E_{a7}.0,95+E_{b7}.0,05$...	$E=E_{a7}.0+E_{b7}.1$
$E=E_{a8}.1+E_{b8}.0$	$E=E_{a8}.0,95+E_{b8}.0,05$...	$E=E_{a8}.0+E_{b8}.1$
.	.	.	.
.	.	.	.
.	.	.	.
$E=E_{an}.1+E_{bn}.0$	$E=E_{an}.0,95+E_{bn}.0,05$...	$E=E_{an}.0+E_{bn}.1$

Fonte: Autor (2020).

Os cenários criados para obtenção do gráfico de fronteiras eficientes variam conforme a seguir: 100 % de utilização de A e 0 % de utilização de B; 95 % de utilização de A e 5 % de utilização de B; e assim, de maneira sucessiva, até 0 % de utilização de A e 100 % de utilização de B. Para isso, foram desenvolvidas ao todo na presente tese, 21 situações que retratam a progressão e a reação da diversificação por meio da percepção das variações do risco.

Os mecanismos necessários para o desenvolvimento do gráfico de fronteiras eficientes podem ser encontrados por meio da Tabela 4.3: Ri é o risco da integração, R é o risco, a refere-se ao ativo A, b refere-se ao ativo B e Em é o erro médio.

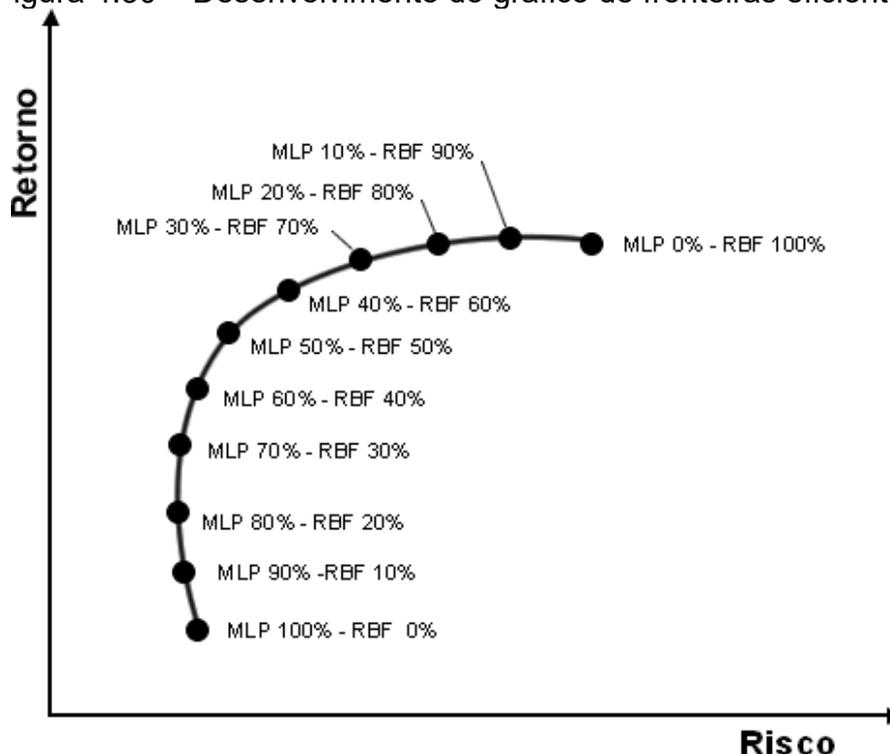
Tabela 4.3 – Elaboração de Gráfico de fronteiras eficientes

Cenários	Risco	Erros
A 100 % - B 0 %	$R_i=R(E(100 \% a 0 \% b))$	$Em=Em_a.1+Em_b.0$
A 95 % - B 5 %	$R_i=R(E(95 \% a 5 \% b))$	$Em=Em_a.0,95+Em_b.0,5$
A 90 % - B 10 %	$R_i=R(E(90 \% a 10 \% b))$	$Em=Em_a.0,9+Em_b.0,1$
A 85 % - B 15 %	$R_i=R(E(85 \% a 15 \% b))$	$Em=Em_a.0,85+Em_b.0,15$
A 80 % - B 20 %	$R_i=R(E(80 \% a 20 \% b))$	$Em=Em_a.0,8+Em_b.0,2$
A 75 % - B 25 %	$R_i=R(E(75 \% a 25 \% b))$	$Em=Em_a.0,75+Em_b.0,25$
A 70 % - B 30 %	$R_i=R(E(70 \% a 30 \% b))$	$Em=Em_a.0,7+Em_b.0,3$
A 65 % - B 35 %	$R_i=R(E(65 \% a 35 \% b))$	$Em=Em_a.0,65+Em_b.0,35$
A 60 % - B 40 %	$R_i=R(E(60 \% a 40 \% b))$	$Em=Em_a.0,6+Em_b.0,4$
A 55 % - B 45 %	$R_i=R(E(55 \% a 45 \% b))$	$Em=Em_a.0,55+Em_b.0,45$
A 50 % - B 50 %	$R_i=R(E(50 \% a 50 \% b))$	$Em=Em_a.0,5+Em_b.0,5$
.	.	.
.	.	.
.	.	.
A 0 % - B 100 %	$R_i=R(E(0 \% a 100 \% b))$	$Em=Em_a.0+Em_b.1$

Fonte: Autor (2020).

A elaboração do gráfico de fronteiras eficientes conta com a diversificação de dois ativos que estão compondo o portfólio ao qual pretende-se propor a integração. Um cenário hipotético da evolução dos diferentes percentuais das técnicas de previsibilidade MLP e RBF é visualizado na Figura 4.30.

Figura 4.30 – Desenvolvimento do gráfico de fronteiras eficientes



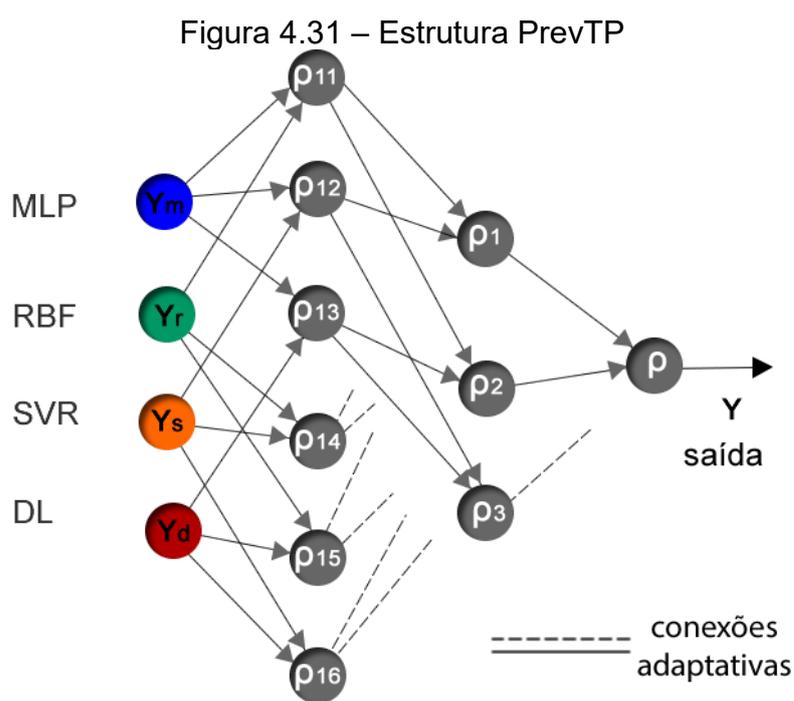
Fonte: Autor (2020).

Vale ressaltar que a Figura 4.30 é hipotética e tem o caráter apenas de representar e facilitar o entendimento da elaboração do gráfico de fronteiras eficientes.

4.5.5 Estrutura adaptativa PrevTP

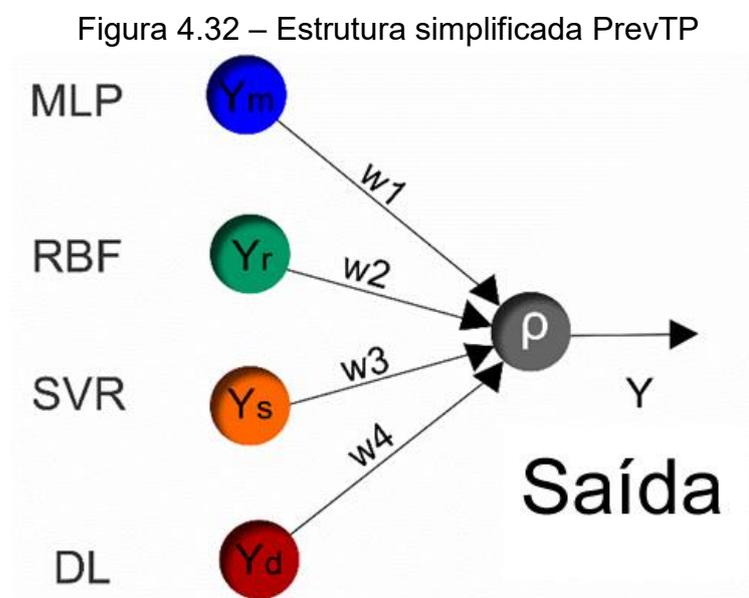
A estrutura PrevTP é mostrada na Figura 4.31, demonstrando o uso das topologias MLP, RBF, SVR e DL e sua integração por meio dos pontos de conexão ((p_{11} a p_{16}). Na primeira camada, A PrevTP cria todas as combinações possíveis entre os pares de técnicas de previsão, realizando assim o gráfico de fronteira eficiente de cada uma das conexões elaboradas. Por meio da análise dessas informações, a PrevTP em sua característica de estrutura auto-adaptativa, escolhe as três melhores combinações. As combinações escolhidas são renomeadas de p_{11} a p_{13} .

Com as conexões p_{11} a p_{13} definidas, o algoritmo PrevTP as integra gerando outras 3 combinações possíveis, p_1 a p_3 , elaborando e analisando os seus respectivos gráficos de fronteira eficiente. Por meio da análise dessas informações, a PrevTP escolhe as duas melhores combinações. Nesta etapa, as combinações são renomeadas de p_1 e p_2 . A saída da PrevTP, ou seja, p , é a combinação de p_1 e p_2 por meio da análise da fronteira eficiente entre esses pontos de conexão.



Fonte: Autor (2020).

Depois do treinamento, no período de testes, a PrevTP pode ter a sua estrutura simplificada como visto na Figura 4.32, atribuindo pesos finais para a interconexão das técnicas de previsão.

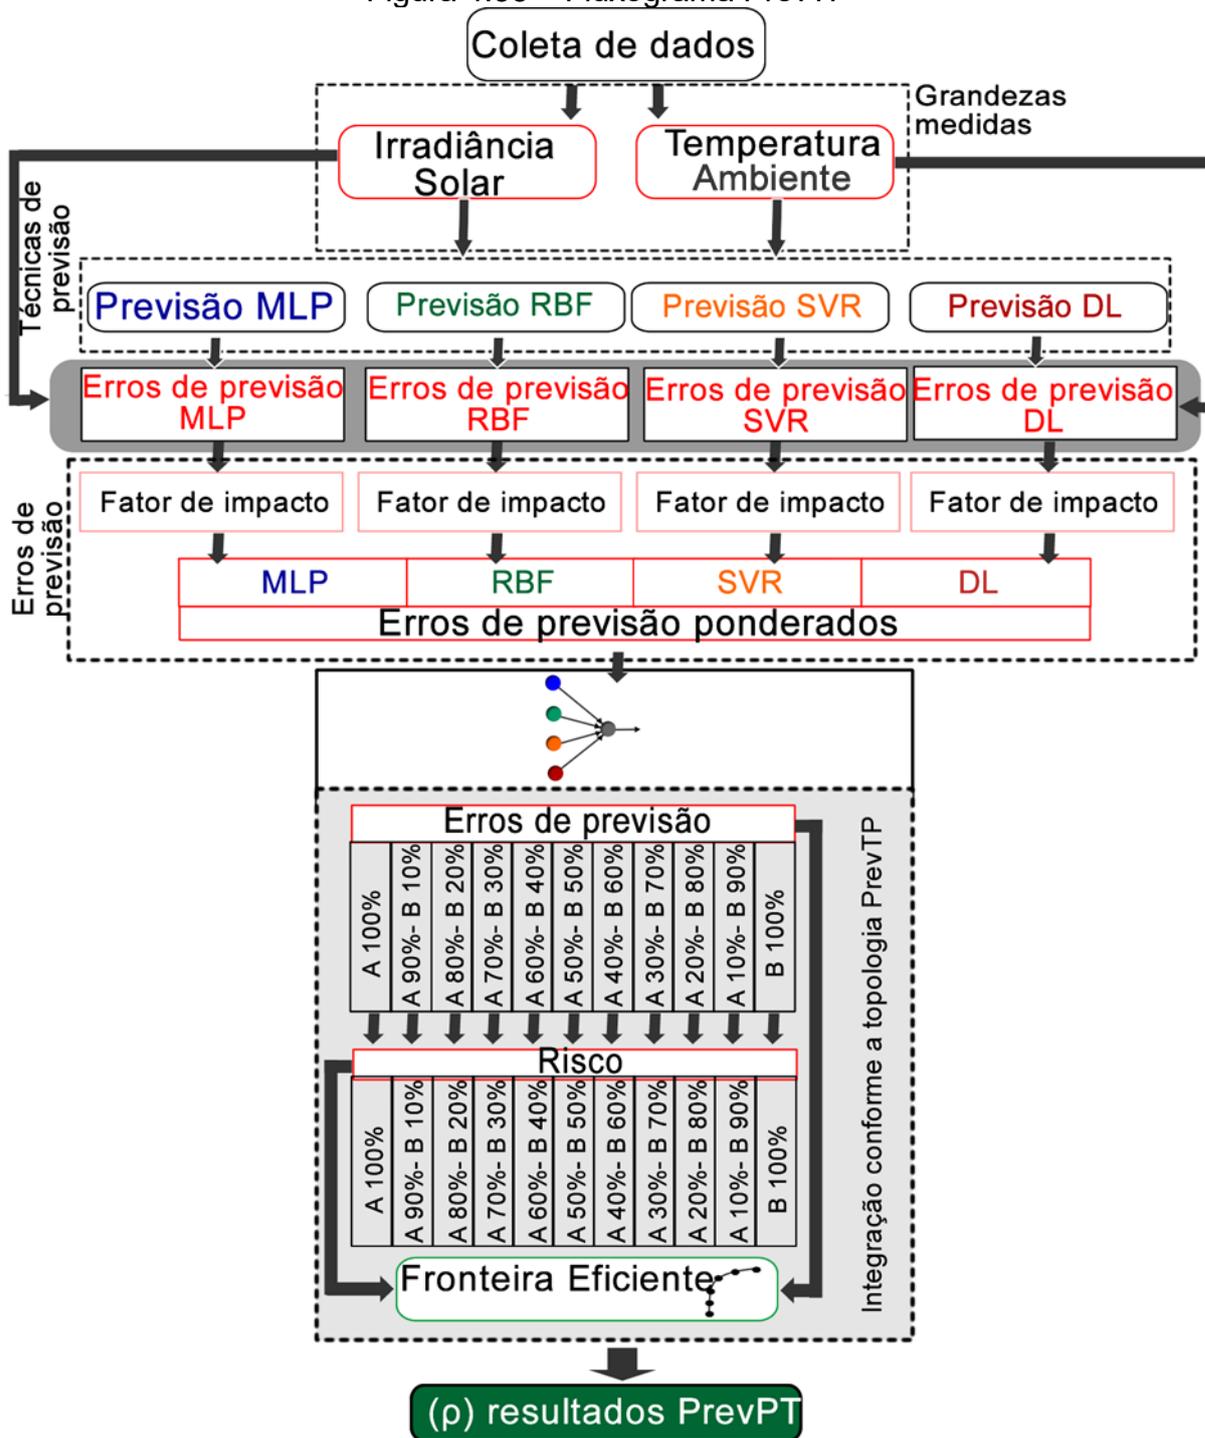


Fonte: Autor (2020).

4.5.6 Etapas para funcionamento da PrevTP

O desenvolvimento da PrevTP, nesse caso utilizada para previsibilidade solar, está ilustrado na Figura 4.33.

Figura 4.33 – Fluxograma PrevTP



Os pesos finais são definidos com base nos dados coletados em cada local de estudo, bem como na capacidade de cada técnica de prever com precisão o valor da disponibilidade solar de cada local. Portanto, para obter a combinação ideal e definir a porcentagem de cada ativo de previsão em um novo local, a técnica é retreinada com dados desse novo lugar, obtendo assim os novos pesos finais.

Por fim, vale ressaltar que a metodologia proposta pode ser aplicada a qualquer tecnologia que exija previsão de recursos solares para definir a energia disponível no sistema. Por exemplo, usinas FV conectadas à rede elétrica, sistemas de bombeamento FV desconectados da rede, plantas solares de concentração, entre outros.

Para validação e análise dos erros de previsão das 4 técnicas de previsão isoladas, bem como trabalhando de forma integrada, o MAPE é utilizado, onde este pode ser encontrado por meio da equação 4.38. Nesta equação, A é o valor atual, F é o valor da previsão e n é a quantidade total de amostras.

$$\text{MAPE} = \frac{1}{n} \cdot \sum \frac{|A - F|}{A} \cdot 100 \quad (4.38)$$

4.6 Conclusões parciais

Neste capítulo são apresentados os métodos de coletas de dados no Brasil e na Espanha, estruturas das técnicas de aprendizagem, MLP, RBF, SVR e DL e suas respectivas fundamentações matemáticas para a execução de respostas e treinamento. Além disso, é apresentado o desenvolvimento da técnica de previsão do recurso solar denominada PrevTP.

5 RESULTADOS

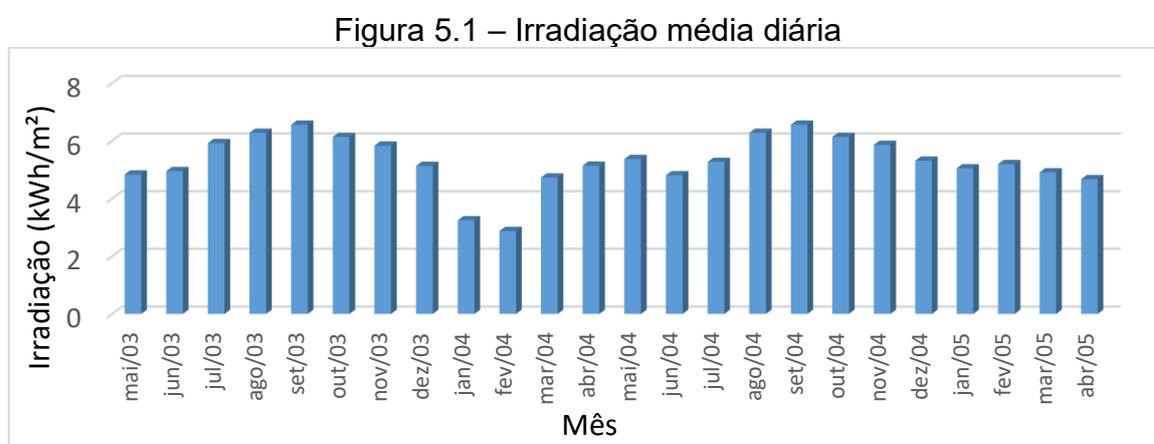
No presente capítulo, são apresentados os resultados referentes à caracterização dos dados de irradiância solar e temperatura ambiente, resultados da integração das RNAs após o processamento da PrevTP, dados referentes a erros de previsão, bem como a definição da ponderação de cada RNA no comitê (integração de técnicas de aprendizagem).

5.1 Resultado para dados do Brasil

5.1.1 Dados coletados

Após a verificação dos dados de irradiância solar e temperatura ambiente obtidos em Fortaleza, foram encontrados 9 pontos inconsistentes de dados de irradiância solar. Esses pontos apresentaram valores negativos ou valores superiores ao limite de 1250 W/m^2 , o que representa 0,016 % de todos os dados coletados. Para temperatura em Fortaleza foram encontrados 3.190 pontos inconsistentes de medição, o que representa 5,52 % do total de medições durante o período de estudo. O pior caso de temperatura inconsistente medida foi de $-6.999,9 \text{ }^\circ\text{C}$, demonstrando que nesse momento o equipamento estava com problemas técnicos.

Na Figura 5.1 são apresentados os dados de irradiação solar, que foram coletados no período de maio de 2003 a abril de 2005, totalizando 2 anos de coleta.

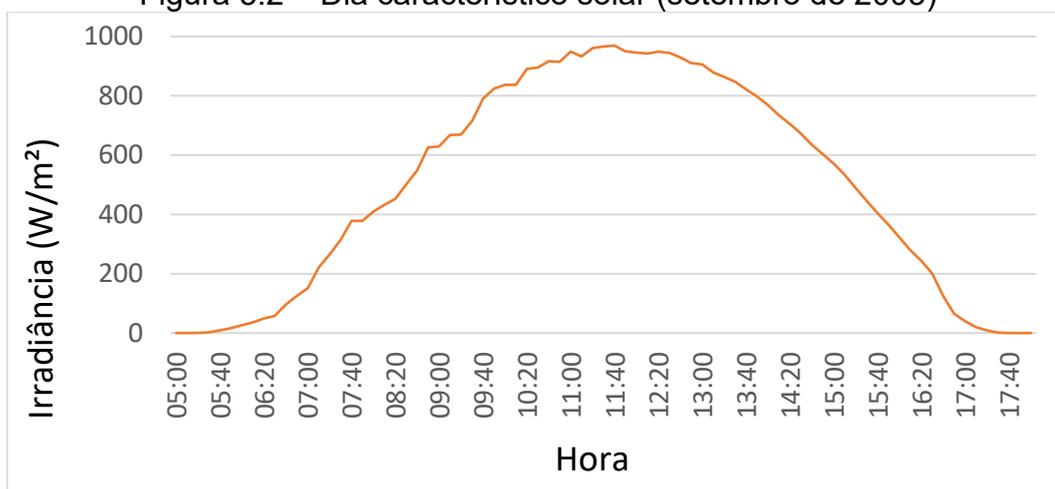


Fonte: Autor (2020).

É possível verificar que, apesar da grande diferença de comportamentos entre os meses de janeiro e fevereiro de 2004, em relação a janeiro e fevereiro de 2005, o comportamento da disponibilidade solar apresenta-se como cíclico, onde a menor disponibilidade do recurso acontece no primeiro semestre do ano. Isso ocorre devido a irradiação solar ser profundamente afetada pela presença de nuvens do período chuvoso cearense, conhecido como quadra invernos. O auge da disponibilidade solar foi em setembro, para os dois anos de dados coletados.

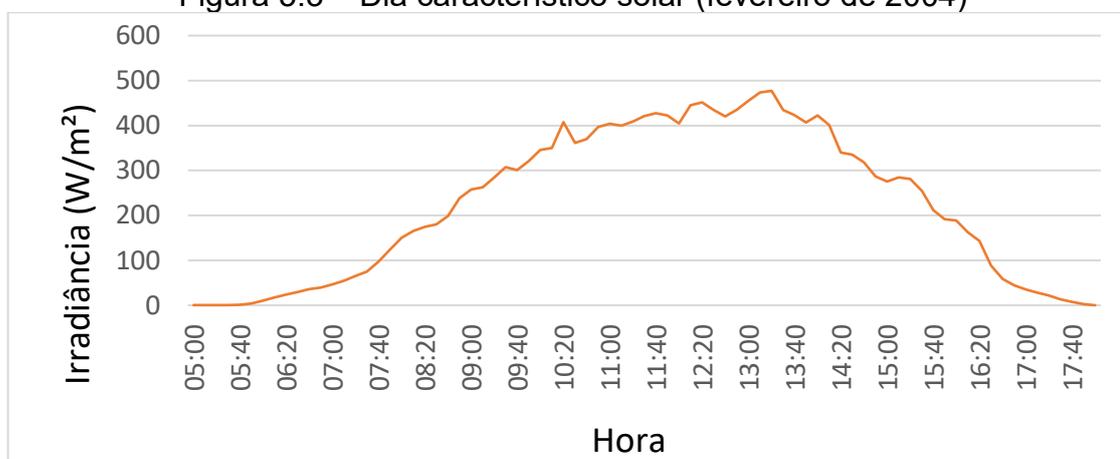
Os dias característicos nos meses de setembro de 2003 e fevereiro de 2004, com as irradiações solares de 6,56 kWh/m² e 2,87 kWh/m² respectivamente, meses com a maior e a menor irradiação solar, são apresentados nas Figuras 5.2 e 5.3.

Figura 5.2 – Dia característico solar (setembro de 2003)



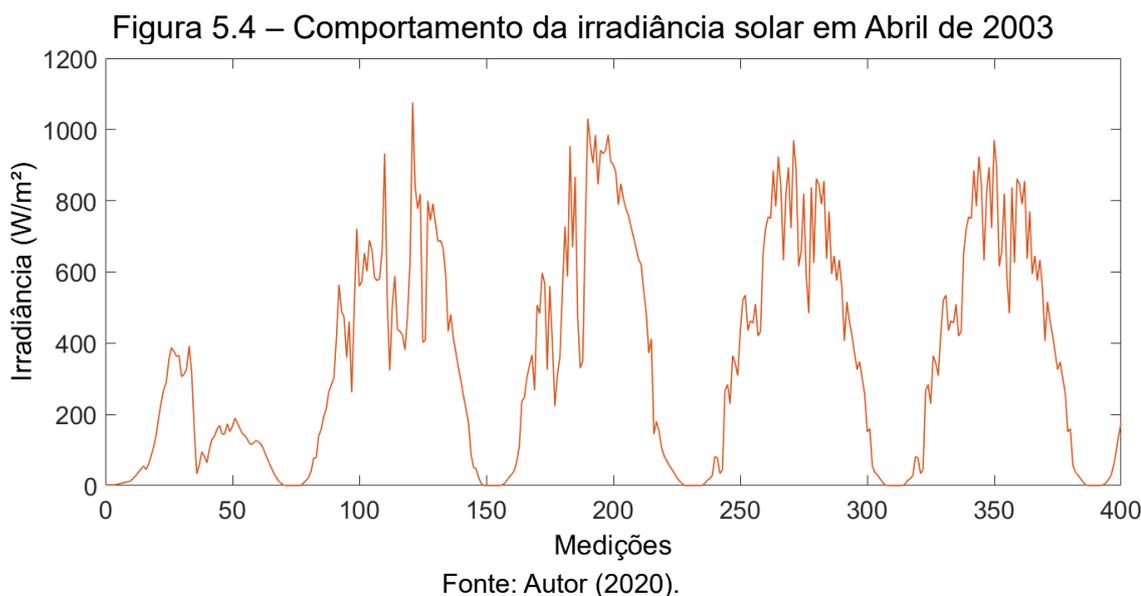
Fonte: Autor (2020).

Figura 5.3 – Dia característico solar (fevereiro de 2004)



Fonte: Autor (2020).

A irradiância solar influencia diretamente na eletricidade entregue à carga e, conseqüentemente, no impacto produtivo de plantas FV. Desta forma, é necessário entender o comportamento da intermitência solar ao longo do dia. Na Figura 5.4 é apresentada parte do comportamento da irradiância solar ao longo do tempo, para 5 dias de coleta de dados, de 05:00 às 18:00 horas, ressaltando que o período noturno foi desconsiderado devido à ausência de irradiância solar.



É possível destacar que durante as medições podem acontecer oscilações bruscas causadas por cobertura de nuvens. Para demonstração, devido à grande quantidade de dados de medições de irradiância solar, foram demonstrados apenas 5 dias coletados em abril de 2003, início da coleta de dados e período com diferentes comportamentos de irradiância solar ao longo do dia, onde no primeiro dia demonstrado, é possível verificar que houve baixos valores de disponibilidade solar.

5.1.2 Resultados MLP

Na Tabela 5.1 e 5.2, para a verificação de quais variáveis são benéficas à previsibilidade realizada pela MLP, o coeficiente de correlação entre as grandezas observadas, bem como as combinações de variáveis testadas como entrada da RNA e suas respectivas avaliações obtidas pelo MAPE, testado duas vezes, são apresentadas.

Tabela 5.1 – Coeficiente de correlação entre as grandezas

	Coeficiente de Correlação com a Irradiância
Irradiância	1
Temperatura	0,0042
Hora	0,1376
Mês	0,1037

Fonte: Autor (2020).

A temperatura apresenta correlação com a irradiância próxima a nula (aleatória), o que define que essa grandeza não garante impactos positivos à saída da RNA MLP. As grandezas hora e mês obtiveram coeficiente de correlação com a irradiância maiores que a temperatura, com destaque para a hora com 0,1376.

Tabela 5.2 – Impacto das entradas nas previsões da RNA MLP

Irradiância	Temperatura	Hora	Mês	MAPE 1	MAPE 2
Sim	-	-	-	9,85 %	10,99 %
Sim	Sim	-	-	10,97 %	10,42 %
Sim	-	Sim	-	9,58 %	9,06 %
Sim	-	-	Sim	9,83 %	10,03 %
Sim	Sim	Sim	-	12,32 %	13,17 %
Sim	Sim	-	Sim	18,19 %	15,88 %
Sim	-	Sim	Sim	10,26 %	10,07 %
Sim	Sim	Sim	Sim	12,77 %	11,91 %

Fonte: Autor (2020).

Com as grandezas disponíveis avaliadas pelo coeficiente de correlação e testes do seu impacto na previsibilidade realizada pela RNA MLP, as variáveis de irradiância e hora foram determinadas como as entradas da rede. Nas Tabelas 5.3 e 5.4 são apresentados os resultados dos ensaios para determinação da quantidade de entradas da RNA MLP e quantidade de neurônios da camada oculta respectivamente.

Tabela 5.3 – Definição da quantidade de entradas da MLP

Neurônios	Treinamentos		Média (%)	Neurônios	Treinamentos		Média (%)
	MAPE 1 (%)	MAPE 2 (%)			MAPE 1 (%)	MAPE 2 (%)	
1	9,92	8,77	9,34	31	9,66	10,10	9,88
2	9,93	9,89	9,91	32	9,90	10,18	10,04
3	9,54	8,73	9,14	33	10,09	10,21	10,15
4	9,72	8,77	9,24	34	10,23	9,83	10,03
5	9,26	9,77	9,52	35	10,05	10,42	10,24
6	8,95	8,93	8,94	36	9,97	10,02	10,00
7	9,05	9,08	9,07	37	10,21	10,32	10,27
8	9,07	9,13	9,10	38	10,86	10,58	10,72
9	9,09	9,21	9,15	39	10,77	10,30	10,54
10	9,48	9,02	9,25	40	10,66	10,53	10,60
11	8,89	9,17	9,03	41	10,60	10,70	10,65
12	9,08	9,00	9,04	42	10,72	10,82	10,77
13	9,46	9,15	9,30	43	13,33	13,16	13,25
14	9,11	9,20	9,16	44	13,58	10,95	12,26
15	11,16	9,26	10,21	45	11,03	15,86	13,45
16	9,02	9,16	9,09	46	13,50	14,47	13,98
17	9,26	9,59	9,42	47	13,86	15,88	14,87
18	9,59	9,58	9,58	48	11,19	11,24	11,22
19	9,34	9,35	9,35	49	10,99	14,26	12,63
20	9,38	9,37	9,38	50	11,16	13,98	12,57
21	9,55	9,43	9,49	51	11,67	11,69	11,68
22	9,86	9,93	9,89	52	11,60	11,04	11,32
23	9,73	9,65	9,69	53	11,07	11,32	11,19
24	9,78	9,74	9,76	54	11,98	11,89	11,93
25	9,92	10,02	9,97	55	11,28	11,36	11,32
26	9,94	9,68	9,81	56	11,90	11,61	11,76
27	9,55	9,78	9,67	57	12,38	11,74	12,06
28	9,50	10,28	9,89	58	12,21	11,77	11,99
29	11,75	11,74	11,74	59	11,86	15,44	13,65
30	9,99	10,26	10,13	60	15,67	12,26	13,97

Fonte: Autor (2020).

Tabela 5.4 – Definição da quantidade de neurônios da camada oculta MLP

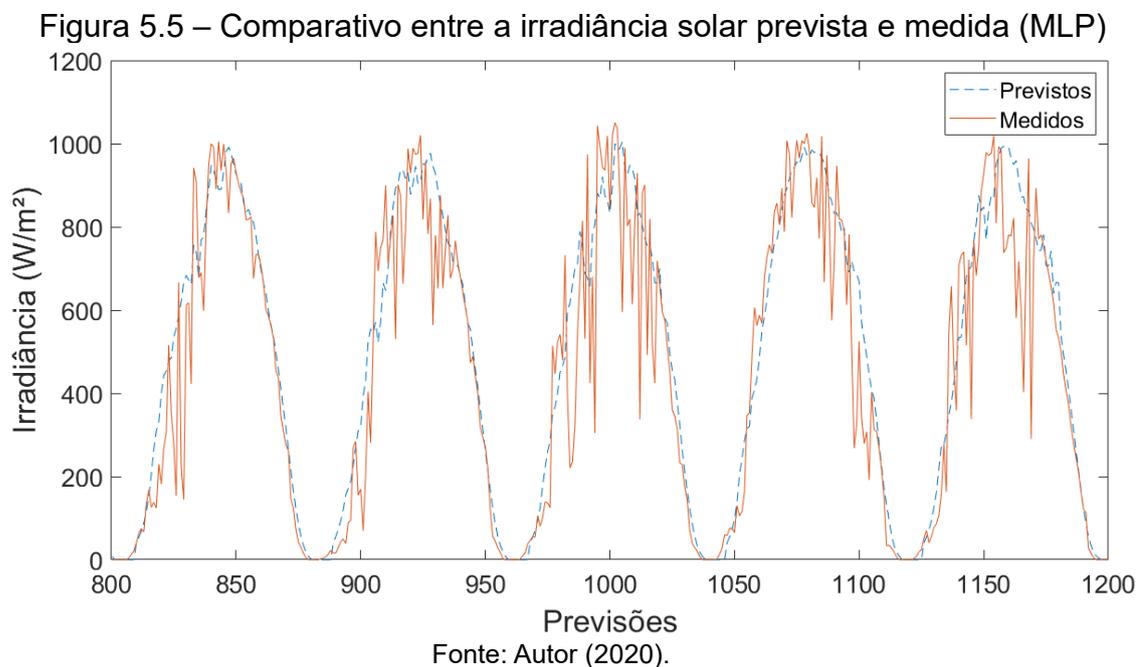
Neurônios	Treinamentos		Média (%)	Neurônios	Treinamentos		Média (%)
	MAPE 1 (%)	MAPE 2 (%)			MAPE 1 (%)	MAPE 2 (%)	
1	12,08	12,08	12,08	31	8,76	10,52	9,64
2	10,26	10,26	10,26	32	8,73	10,01	9,37
3	11,27	9,56	10,42	33	8,77	8,73	8,75
4	10,05	11,30	10,67	34	9,86	8,74	9,30
5	9,16	9,16	9,16	35	8,71	8,53	8,62
6	10,94	9,05	10,00	36	9,96	8,70	9,33
7	8,93	8,86	8,89	37	8,74	9,97	9,36
8	8,93	9,10	9,02	38	9,98	9,82	9,90
9	8,88	8,86	8,87	39	8,75	8,76	8,76
10	8,86	10,28	9,57	40	8,65	10,06	9,35
11	8,88	9,02	8,95	41	8,73	8,78	8,75
12	8,81	9,16	8,98	42	10,07	10,08	10,08
13	9,50	8,78	9,14	43	8,73	8,75	8,74
14	8,89	10,52	9,70	44	9,97	8,74	9,35
15	9,96	10,43	10,19	45	8,73	10,00	9,37
16	8,84	9,68	9,26	46	10,01	9,59	9,80
17	10,38	8,72	9,55	47	8,74	8,76	8,75
18	10,59	9,92	10,25	48	8,68	8,83	8,75
19	8,75	8,74	8,74	49	8,76	8,73	8,74
20	10,44	10,51	10,47	50	9,53	9,66	9,59
21	10,36	10,33	10,34	51	8,75	9,75	9,25
22	10,54	10,47	10,50	52	10,14	9,75	9,94
23	10,47	9,94	10,21	53	8,77	10,03	9,40
24	8,74	10,51	9,62	54	9,58	8,73	9,15
25	9,60	8,73	9,17	55	8,73	9,96	9,35
26	10,49	8,72	9,60	56	8,91	9,76	9,34
27	10,37	10,47	10,42	57	10,10	8,80	9,45
28	8,82	9,89	9,36	58	8,76	9,96	9,36
29	9,54	8,73	9,14	59	8,77	9,54	9,16
30	9,46	8,78	9,12	60	8,71	9,99	9,35

Fonte: Autor (2020).

Depois dos testes realizados, a estrutura da MLP é definida com: Matriz com 6 atrasos e 1 saída; 6 neurônios na camada de entrada; 35 neurônios na camada oculta; 1 neurônio na camada de saída. Vale ressaltar que os parâmetros apresentados foram escolhidos com base em uma série de treinamentos realizados, onde foram determinados os parâmetros de melhor desempenho.

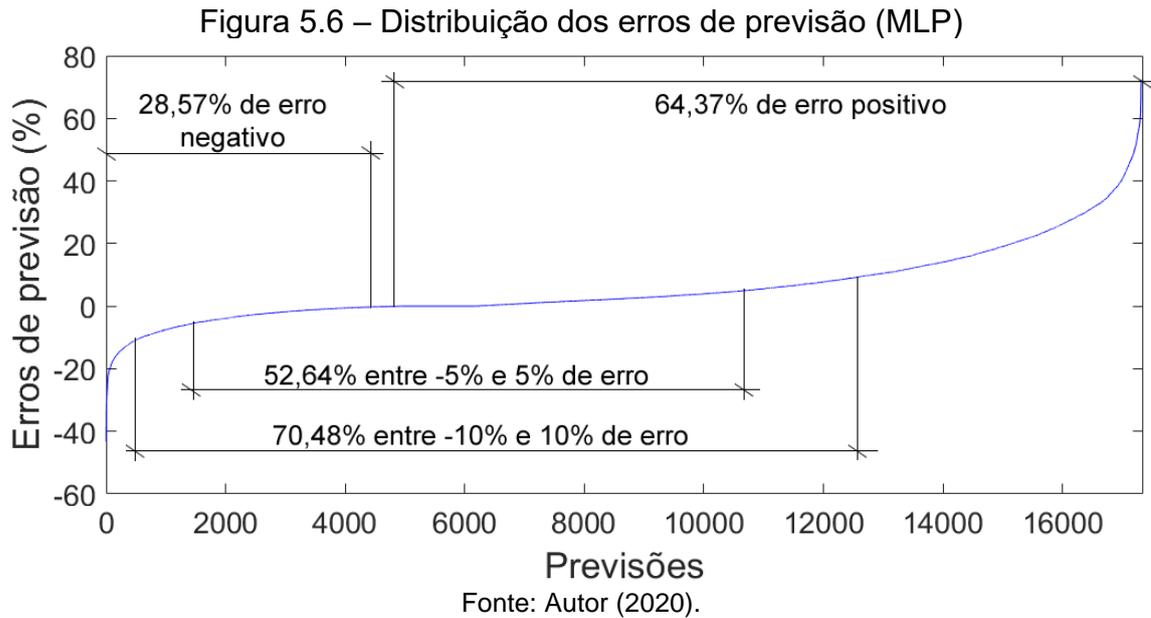
Na Figura 5.5 são comparados os valores de irradiância solar, em W/m^2 , obtidos através das previsões da RNA MLP e os valores medidos pelo piranômetro

localizado no Campus do Pici da UFC, para uma janela de demonstração de 5 dias, de 4 a 8 de outubro de 2004.

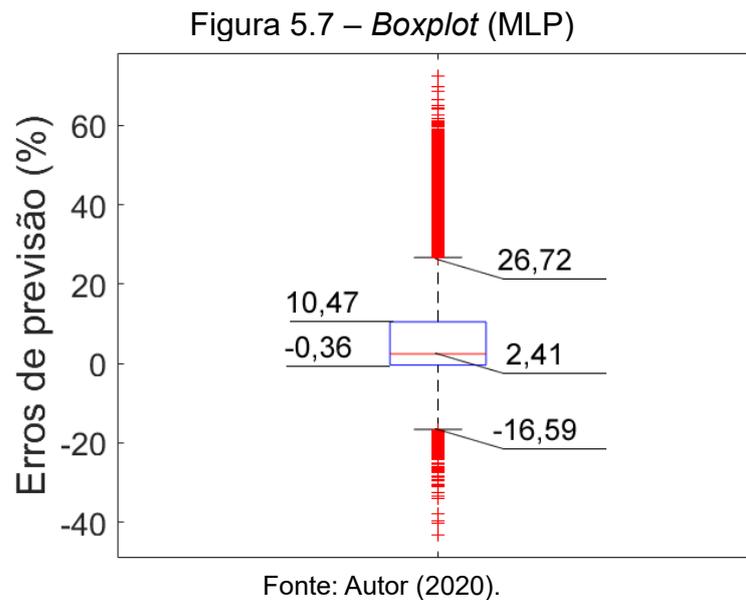


As previsões de irradiância solar da RNA MLP *Backpropagation* conseguem acompanhar as variações de amplitudes ao longo do período analisado. De forma geral, a previsão manteve-se de forma estável, fazendo um acompanhamento da característica de intermitência da irradiância solar no decorrer das horas.

Na RNA MLP, um total de 28,57 % das previsões subestima a disponibilidade energética solar, 7,06 % das previsões obteve erro 0 e 64,37 % das previsões superestima o recurso solar. O erro negativo mais acentuado obtem um valor de -43,19 %, enquanto o positivo é de 72,4 %. Um total de 70,48 % das previsões está entre -10 % e 10 % de erro de previsão e 52,64 % das previsões está entre -5 % e 5 % de erro. O erro médio das previsões é de 6,01 % e o MAPE, para esta RNA foi de 8,53 %. Na Figura 5.6 é apresentada a distribuição dos erros de previsão.



Na Figura 5.7 é apresentada o *Boxplot* das previsões da RNA MLP.



Os limites da amplitude interquadrática (50% dos dados de previsão) são -0,36 % a 10,47 %. O valor da mediana dos erros de previsão é de 2,41 %, o que nesse caso representa a tendência assimétrica positiva das previsões, como também demonstrado também na Figura 5.6. Foram encontrados *outliers* de erros de previsão, onde os negativos variam de -43,18 % a -16,61 % e positivos que variam de 26,73 % a 72,4 %.

5.1.3 Resultados RBF

Para definição de quais entradas são benéficas para a previsibilidade solar a partir da RBF, foram testadas todas as combinações possíveis entre as variáveis irradiância, temperatura, hora e mês, duas vezes. Os resultados são apresentados na Tabela 5.5, onde verifica-se que para previsões de irradiância solar, no Brasil, a partir da RBF, a irradiância utilizada isoladamente é a melhor condição de entrada da técnica de previsão em estudo.

Tabela 5.5 – Impacto das entradas nas previsões da RNA RBF

Irradiância	Temperatura	Hora	Mês	MAPE 1	MAPE 2
Sim	-	-	-	8,92 %	8,63 %
Sim	Sim	-	-	12,72 %	10,26 %
Sim	-	Sim	-	11,5 %	12,95 %
Sim	-	-	Sim	10,93 %	9,16 %
Sim	Sim	Sim	-	12,58 %	14,93 %
Sim	Sim	-	Sim	15,29 %	15,89 %
Sim	-	Sim	Sim	15,91 %	15,48 %
Sim	Sim	Sim	Sim	13,32 %	14,85 %

Fonte: Autor (2020).

A seguir, nas Tabelas 5.6 e 5.7 são apresentados os resultados dos ensaios para determinação da quantidade de entradas da RNA RBF e quantidade de neurônios da camada oculta respectivamente.

Tabela 5.6 – Definição da quantidade de entradas da RBF

Neurônios	Treinamentos		Média (%)	Neurônios	Treinamentos		Média (%)
	MAPE 1 (%)	MAPE 2 (%)			MAPE 1 (%)	MAPE 2 (%)	
1	39,07	28,01	33,54	31	39,77	30,69	35,23
2	12,45	12,87	12,66	32	38,35	36,66	37,50
3	7,58	7,73	7,66	33	37,66	32,86	35,26
4	15,41	10,85	13,13	34	39,65	39,66	39,65
5	31,23	26,85	29,04	35	38,70	35,85	37,28
6	19,42	13,26	16,34	36	37,77	35,22	36,49
7	16,53	19,81	18,17	37	39,58	40,85	40,22
8	20,06	28,81	24,44	38	36,69	32,54	34,62
9	18,51	23,57	21,04	39	27,09	27,44	27,27
10	37,66	37,35	37,51	40	29,41	29,04	29,22
11	44,40	37,86	41,13	41	29,23	29,22	29,23
12	38,70	37,26	37,98	42	36,99	37,75	37,37
13	34,84	37,51	36,18	43	18,84	16,97	17,91
14	28,59	34,50	31,55	44	17,27	18,57	17,92
15	34,65	32,87	33,76	45	21,29	24,93	23,11
16	36,25	30,79	33,52	46	34,48	33,01	33,74
17	37,99	35,16	36,57	47	31,89	29,89	30,89
18	40,54	40,45	40,50	48	29,84	28,11	28,97
19	42,32	39,79	41,06	49	25,51	26,53	26,02
20	35,78	39,10	37,44	50	30,03	27,73	28,88
21	31,33	28,08	29,71	51	31,85	32,16	32,00
22	19,66	14,47	17,06	52	17,91	17,15	17,53
23	18,82	18,71	18,76	53	20,30	20,30	20,30
24	30,01	30,27	30,14	54	32,95	29,48	31,21
25	28,47	27,99	28,23	55	22,48	21,02	21,75
26	20,47	22,88	21,67	56	22,37	25,81	24,09
27	19,70	19,72	19,71	57	23,4	22,7	23,09
28	21,80	20,16	20,98	58	20,83	19,18	20,01
29	22,99	21,26	22,13	59	21,41	21,92	21,67
30	25,89	25,58	25,74	60	22,29	21,22	21,76

Fonte: Autor (2020).

Tabela 5.7 – Definição da quantidade de neurônios da camada oculta da RBF

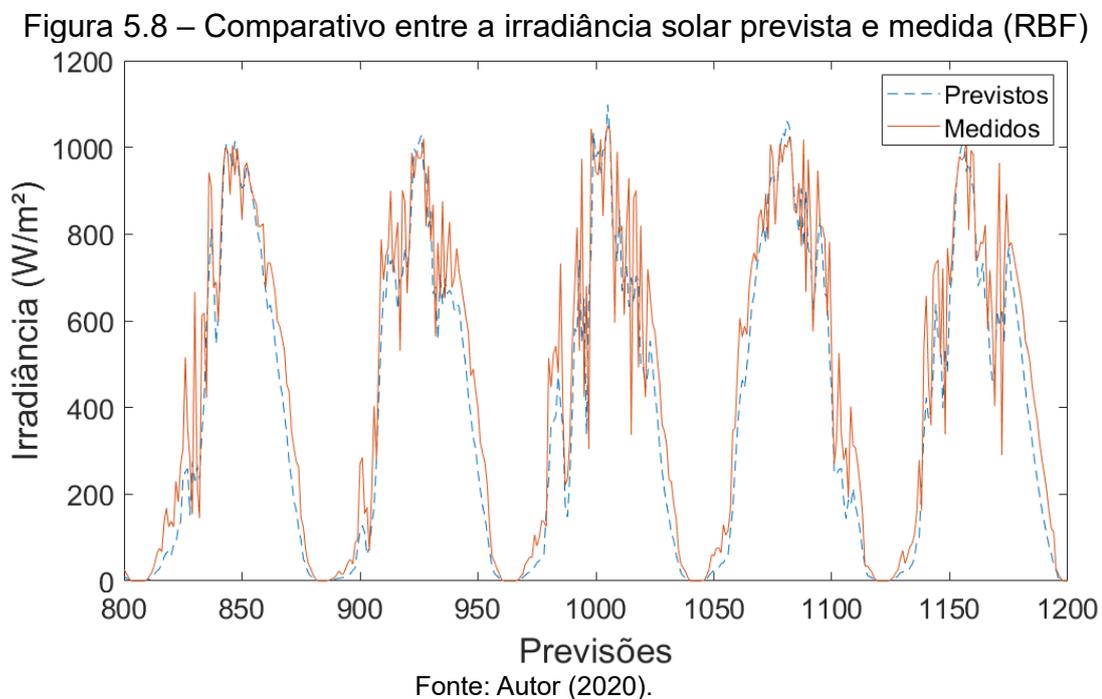
Neurônios	Treinamentos		Média (%)	Neurônios	Treinamentos		Média (%)
	MAPE 1 (%)	MAPE 2 (%)			MAPE 1 (%)	MAPE 2 (%)	
1	24,46	24,41	24,44	31	10,98	10,89	10,93
2	21,02	21,32	21,17	32	10,43	10,66	10,55
3	18,65	17,69	18,17	33	10,77	11,39	11,08
4	19,48	19,64	19,56	34	9,45	9,15	9,30
5	17,42	17,42	17,42	35	10,42	10,30	10,36
6	16,78	17,13	16,95	36	10,18	10,26	10,22
7	16,77	16,55	16,66	37	9,86	9,13	9,49
8	18,83	21,83	20,33	38	9,76	10,26	10,01
9	20,26	19,16	19,71	39	7,09	7,89	7,49
10	17,87	17,37	17,62	40	9,47	9,11	9,29
11	20,13	21,77	20,95	41	8,80	9,28	9,04
12	23,49	24,99	24,24	42	8,52	8,54	8,53
13	24,44	24,06	24,25	43	8,83	7,95	8,39
14	21,10	21,89	21,50	44	7,93	9,33	8,63
15	14,35	11,25	12,80	45	7,08	8,71	7,89
16	20,88	22,88	21,88	46	9,82	9,92	9,87
17	15,77	13,61	14,69	47	7,02	8,69	7,85
18	14,47	15,45	14,96	48	7,66	8,38	8,02
19	14,25	14,22	14,23	49	8,72	8,66	8,69
20	16,60	18,21	17,41	50	8,75	7,03	7,89
21	13,11	12,31	12,71	51	7,47	8,45	7,96
22	15,39	14,29	14,84	52	7,21	7,25	7,23
23	11,85	11,87	11,86	53	8,86	8,57	8,72
24	13,79	12,01	12,90	54	8,99	9,99	9,49
25	11,08	10,97	11,02	55	7,50	7,40	7,45
26	11,34	13,33	12,33	56	6,82	7,50	7,16
27	15,17	13,72	14,44	57	6,32	6,89	6,61
28	10,96	10,86	10,91	58	9,04	9,04	9,04
29	10,99	11,55	11,27	59	11,80	10,80	11,30
30	10,83	10,31	10,57	60	12,81	11,83	12,32

Fonte: Autor (2020).

Depois dos testes realizados, a estrutura da RBF ficou definida com: Matriz com 3 atrasos e 1 saída; 3 neurônios na camada de entrada; 57 neurônios na camada oculta; 1 neurônio na camada de saída. Vale ressaltar que os parâmetros apresentados foram escolhidos com base em uma série de treinamentos realizados, onde foram determinados os parâmetros de melhor desempenho.

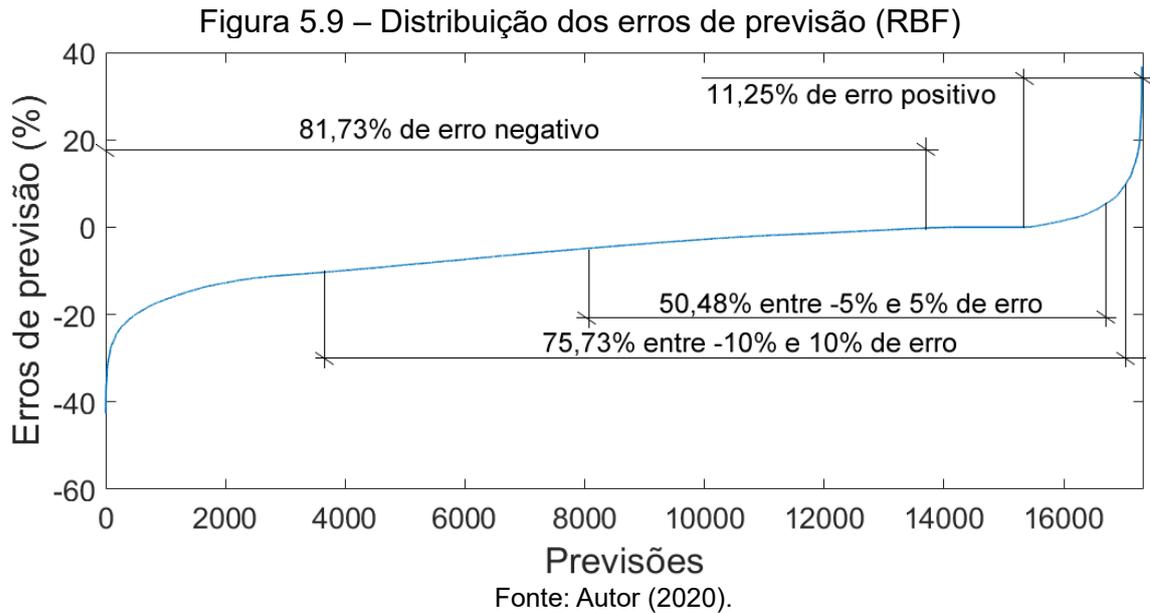
Na Figura 5.8 são comparados os valores de irradiância solar, em W/m^2 , obtidos por meio das previsões da RNA RBF e os valores medidos pelo piranômetro

localizado no Campus do Pici da UFC, para uma janela de demonstração de 5 dias, de 4 a 8 de outubro de 2004.

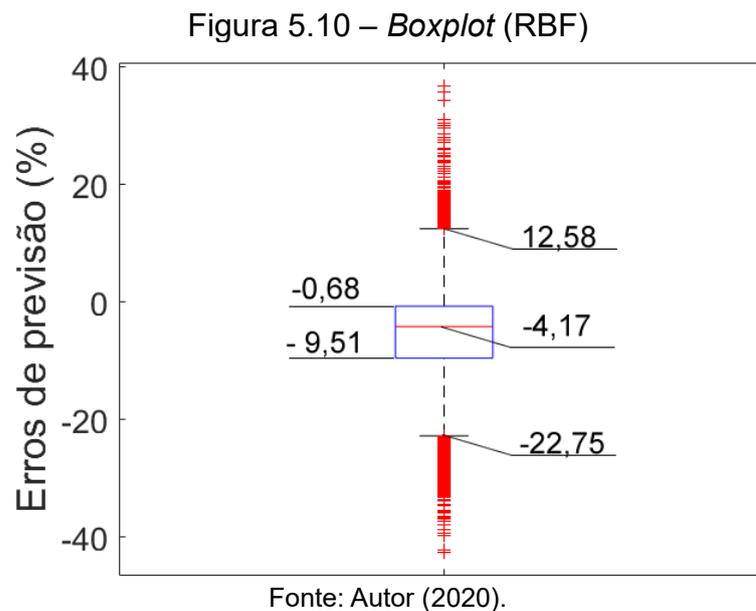


As previsões de irradiância solar da RNA RBF consegue acompanhar as variações de amplitudes ao longo do período analisado. De forma geral, a previsão se matém de forma estável, fazendo um acompanhamento da característica de intermitência da irradiância solar no decorrer das horas.

Na RNA RBF, um total de 81,73 % das previsões subestima a disponibilidade energética solar, 7,02 % das previsões obtém erro 0 e 11,25 % das previsões superestima o recurso solar. O erro negativo mais acentuado obtém um valor de -42,58 %, enquanto o positivo é de 36,77 %. Um total de 75,73 % das previsões está entre -10 % e 10 % de erro de previsão e 50,48 % das previsões está entre -5 % e 5 % de erro. O erro médio das previsões é de -5,27 % e o MAPE para esta RNA é de 6,32 %. Na Figura 5.9 é apresentada a distribuição dos erros de previsão.



Na Figura 5.10 é apresentado o *boxplot* das previsões da RNA RBF.



Os limites da amplitude interquadrática são -9,51 % a -0,68 %. O valor da mediana dos erros de previsão é de -4,17%, o que nesse caso representa a tendência assimétrica negativa das previsões, como também demonstrado também na Figura 5.9. Foram encontrados *outliers* de erros de previsão, onde os negativos variam de -42,58 % a -22,75 % e positivos que variam de 12,58 % a 36,77 %.

5.1.4 Resultados SVR

Por meio da Tabela 5.8 é possível determinar que para previsões de irradiância solar, no Brasil, a partir da SVR. A irradiância utilizada isoladamente é a melhor condição de entrada da técnica de previsão em estudo.

Tabela 5.8 – Impacto das entradas nas previsões da SVR

Irradiância	Temperatura	Hora	Mês	MAPE 1	MAPE 2
Sim	-	-	-	9,89 %	9,97 %
Sim	Sim	-	-	11,88 %	12,15 %
Sim	-	Sim	-	10,45 %	10,99 %
Sim	-	-	Sim	10,97 %	10,52 %
Sim	Sim	Sim	-	11,12 %	12,08 %
Sim	Sim	-	Sim	13,45 %	14,01 %
Sim	-	Sim	Sim	13,82 %	13,56 %
Sim	Sim	Sim	Sim	12,24 %	12,67 %

Fonte: Autor (2020).

Na Tabela 5.9 são apresentados os resultados dos ensaios para determinação da quantidade de entradas da SVR.

Tabela 5.9 – Definição da quantidade de entradas da SVR

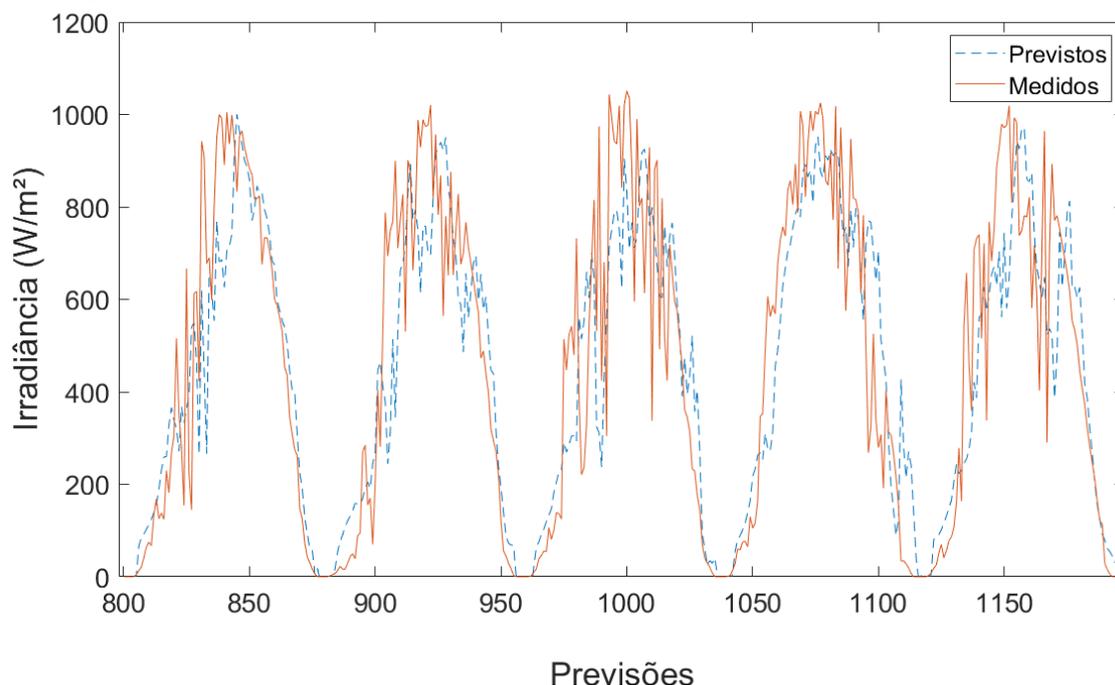
Neurônios	Treinamentos		Média (%)	Neurônios	Treinamentos		Média (%)
	MAPE 1 (%)	MAPE 2 (%)			MAPE 1 (%)	MAPE 2 (%)	
1	41,98	38,11	40,05	31	20,51	19,51	20,01
2	15,33	14,68	15,01	32	19,41	19,47	19,44
3	12,95	12,67	12,81	33	26,10	25,99	26,04
4	15,41	15,99	15,70	34	27,87	27,88	27,88
5	10,65	10,32	10,49	35	26,43	26,03	26,23
6	14,19	13,87	14,03	36	30,73	32,09	31,41
7	10,25	10,91	10,58	37	29,12	30,81	29,97
8	8,95	8,00	8,47	38	31,59	32,82	32,20
9	9,55	9,47	9,51	39	28,12	27,2109	27,67
10	15,43	15,68	15,56	40	23,29	22,2901	22,79
11	19,53	19,47	19,50	41	20,43	21,01	20,72
12	14,34	16,53	15,44	42	19,19	18,23	18,71
13	20,99	22,49	21,74	43	19,91	20,00	19,96
14	22,06	23,45	22,76	44	13,19	12,87	13,03
15	32,54	30,44	31,49	45	20,20	20,32	20,26
16	36,61	32,17	34,39	46	21,82	21,92	21,87
17	32,24	30,26	31,25	47	22,98	23,13	23,06
18	33,25	33,31	33,28	48	23,17	22,04	22,61
19	40,52	39,82	40,17	49	20,10	21,30	20,70
20	30,21	29,35	29,78	50	25,28	27,44	26,36
21	31,88	28,98	30,43	51	22,12	22,08	22,10
22	20,9	21,47	21,19	52	16,81	17,90	17,36
23	17,43	18,46	17,95	53	20,62	20,62	20,62
24	15,33	14,99	15,16	54	19,33	18,89	19,11
25	37,29	38,43	37,86	55	28,48	25,42	26,95
26	40,22	38,44	39,33	56	21,64	25,01	23,33
27	23,48	20,89	22,19	57	23,73	22,41	23,07
28	12,67	13,19	12,93	58	17,25	18,18	17,72
29	15,33	15,78	15,56	59	32,99	31,83	32,41
30	16,81	14,12	15,47	60	40,01	36,25	38,13

Fonte: Autor (2020).

Depois dos testes realizados, a SVR ficou definida com: Matriz com 8 atrasos e 1 saída. Vale ressaltar que os parâmetros apresentados foram escolhidos com base em uma série de treinamentos realizados, onde foram determinados os parâmetros de melhor desempenho.

Na Figura 5.11 é comparada os valores de irradiância solar, em W/m^2 , obtidos através das previsões da SVR e os valores medidos pelo piranômetro localizado no Campus do Pici da UFC, para uma janela de demonstração de 5 dias, de 4 a 8 de outubro de 2004.

Figura 5.11 – Comparativo entre a irradiância solar prevista e medida (SVR)

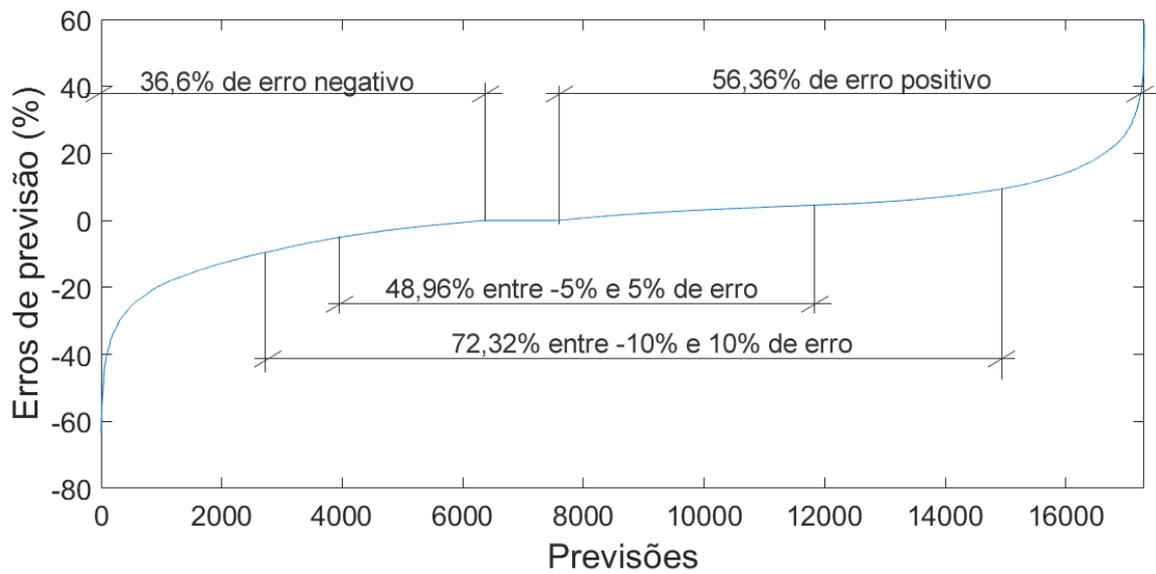


Fonte: Autor (2020).

As previsões de irradiância solar da SVR conseguem acompanhar as variações de amplitudes ao longo do período analisado. De forma geral, a previsão mantém-se de forma estável, fazendo um acompanhamento da característica de intermitência da irradiância solar no decorrer das horas.

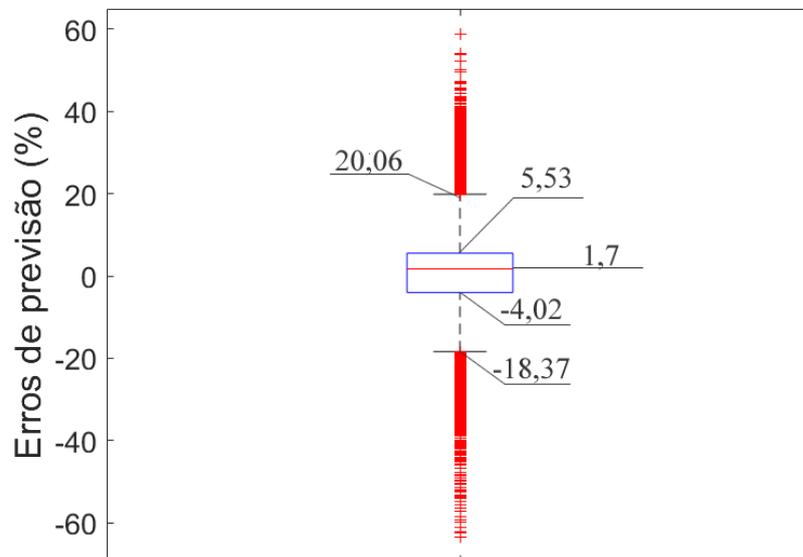
Na SVR, um total de 36,6 % das previsões subestima a disponibilidade energética solar, 7,04 % das previsões obtém erro 0 e 56,36 % das previsões superestima o recurso solar. O erro negativo mais acentuado obtém um valor de -63,49 %, enquanto o positivo é de 58,81 %. Um total de 72,32 % das previsões está entre -10 % e 10 % de erro de previsão e 48,96 % das previsões está entre -5 % e 5 % de erro. O erro médio das previsões é de 0,35 % e o MAPE é de 8 %. Na Figura 5.12 é apresentada a distribuição dos erros de previsão.

Figura 5.12 – Distribuição dos erros de previsão (SVR)



Fonte: Autor (2020).

Na Figura 5.13 é apresentado o *Boxplot* das previsões da SVR.

Figura 5.13 – *Boxplot* (SVR)

Fonte: Autor (2020).

Os limites da amplitude interquadrática são -4,02 % a 5,53 %. O valor da mediana dos erros de previsão é de 1,7 %, o que representa uma tendência assimétrica positiva das previsões. Foram encontrados *outliers* de erros de previsão, onde os negativos variam de -63,49 % a -18,37 % e positivos que variam de 20,61 % a 58,81 %.

5.1.5 Resultados DL

Para definição de quais entradas são benéficas para a previsibilidade solar a partir da DL, são testadas todas as combinações possíveis entre as variáveis irradiância, temperatura, hora e mês, duas vezes. Os resultados são apresentados na Tabela 5.10, onde verifica-se que para previsões de irradiância solar, no Brasil, a partir da DL, a irradiância utilizada isoladamente é a melhor condição de entrada da técnica de previsão em estudo.

Tabela 5.10 – Impacto das entradas nas previsões da DL

Irradiância	Temperatura	Hora	Mês	MAPE 1	MAPE 2
Sim	-	-	-	7,26 %	7,41 %
Sim	Sim	-	-	10,14 %	11,07 %
Sim	-	Sim	-	9,25 %	9,63 %
Sim	-	-	Sim	10,42 %	10,98 %
Sim	Sim	Sim	-	11,45 %	11,23 %
Sim	Sim	-	Sim	10,76 %	11,18 %
Sim	-	Sim	Sim	13,88 %	13,75 %
Sim	Sim	Sim	Sim	12,11 %	12,40 %

Fonte: Autor (2020).

A seguir, nas Tabelas 5.11 e 5.12 são apresentados os resultados dos ensaios para determinação da quantidade de entradas da DL e da quantidade de unidades ocultas respectivamente.

Tabela 5.11 – Definição da quantidade de entradas da DL

Neurônios	Treinamentos		Média (%)	Neurônios	Treinamentos		Média (%)
	MAPE 1 (%)	MAPE 2 (%)			MAPE 1 (%)	MAPE 2 (%)	
1	20,48	20,93	20,71	31	13,62	13,09	13,35
2	13,16	12,66	12,91	32	11,49	10,77	11,13
3	8,37	7,43	7,90	33	10,72	10,18	10,45
4	7,19	7,08	7,13	34	10,92	10,97	10,94
5	8,39	7,87	8,13	35	11,67	12,32	12,00
6	8,84	8,56	8,70	36	10,65	10,05	10,35
7	8,97	8,64	8,81	37	11,04	11,01	11,02
8	10,03	9,79	9,91	38	9,97	10,44	10,21
9	9,86	9,01	9,44	39	10,81	10,23	10,52
10	9,70	9,74	9,72	40	10,87	10,35	10,61
11	10,35	10,92	10,63	41	12,61	11,76	12,18
12	10,42	9,96	10,19	42	10,18	9,45	9,82
13	11,58	10,98	11,28	43	8,86	9,26	9,06
14	13,08	12,46	12,77	44	11,07	11,01	11,04
15	12,10	11,26	11,68	45	10,88	10,86	10,87
16	14,42	14,25	14,33	46	11,54	11,24	11,39
17	13,43	12,83	13,13	47	13,81	13,96	13,89
18	12,07	11,00	11,53	48	13,59	13,08	13,33
19	12,51	12,89	12,70	49	13,20	12,39	12,80
20	12,15	12,31	12,23	50	11,75	11,35	11,55
21	11,50	11,89	11,70	51	12,17	13,04	12,61
22	12,94	12,40	12,67	52	12,07	12,56	12,32
23	11,36	10,71	11,04	53	11,24	11,15	11,20
24	10,95	10,16	10,56	54	13,07	13,44	13,26
25	10,97	10,71	10,84	55	11,85	11,50	11,68
26	8,62	8,06	8,34	56	12,05	11,54	11,80
27	9,72	8,94	9,33	57	9,78	9,95	9,86
28	10,04	9,80	9,92	58	8,08	8,04	8,06
29	10,44	10,14	10,29	59	8,35	8,07	8,21
30	11,56	12,45	12,00	60	9,94	9,03	9,48

Fonte: Autor (2020).

Tabela 5.12 – Definição da quantidade de unidades ocultas da DL

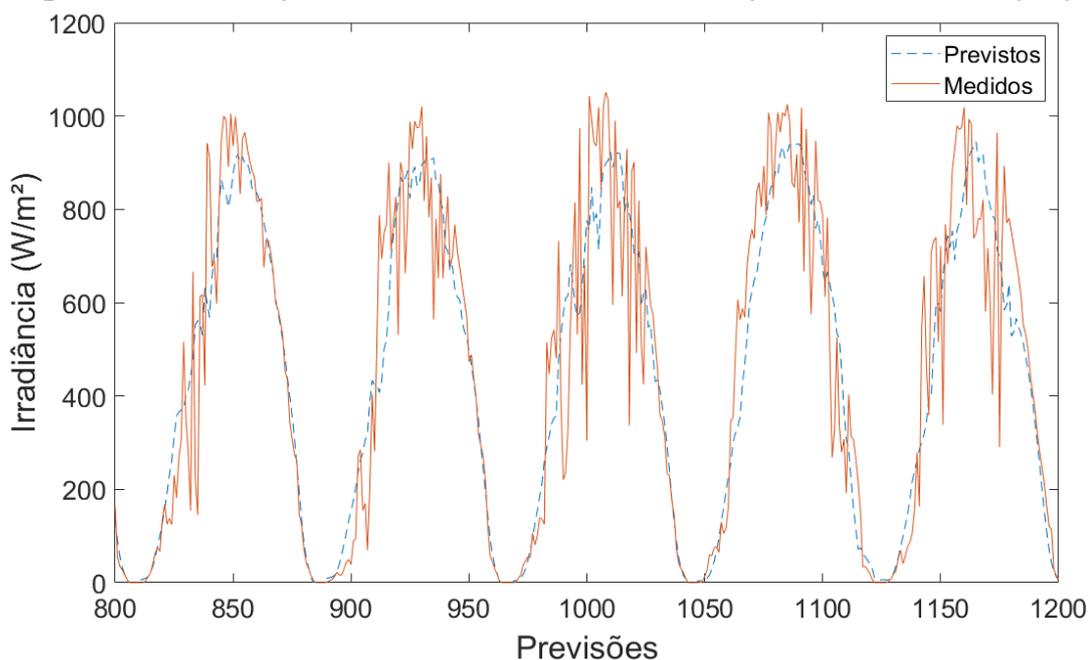
Neurônios	Treinamentos		Média (%)	Neurônios	Treinamentos		Média (%)
	MAPE 1 (%)	MAPE 2 (%)			MAPE 1 (%)	MAPE 2 (%)	
1	17,11	17,06	17,09	31	7,14	7,52	7,33
2	12,00	12,51	12,26	32	7,39	7,78	7,59
3	10,27	10,21	10,24	33	6,99	7,42	7,21
4	10,07	10,79	10,43	34	8,71	9,91	9,31
5	7,84	8,44	8,14	35	7,00	7,28	7,14
6	9,89	10,30	10,10	36	7,44	7,54	7,49
7	7,48	7,42	7,45	37	7,81	8,37	8,09
8	7,59	8,34	7,97	38	7,51	8,77	8,14
9	7,14	7,92	7,53	39	7,59	8,94	8,27
10	7,62	8,06	7,84	40	7,06	7,12	7,09
11	7,30	7,83	7,57	41	7,49	7,68	7,59
12	7,65	8,18	7,92	42	7,30	7,67	7,49
13	7,26	7,84	7,55	43	7,03	7,98	7,51
14	7,32	7,70	7,51	44	7,49	7,83	7,66
15	7,50	8,51	8,01	45	6,34	6,08	6,21
16	7,38	7,26	7,32	46	7,38	7,87	7,63
17	7,37	7,16	7,27	47	7,67	8,17	7,92
18	7,25	7,77	7,51	48	7,43	7,46	7,45
19	7,42	7,91	7,67	49	7,14	7,25	7,20
20	7,25	7,89	7,57	50	7,38	7,92	7,65
21	7,13	7,48	7,31	51	7,34	7,80	7,57
22	7,57	8,26	7,92	52	7,58	8,08	7,83
23	7,40	7,46	7,43	53	8,30	8,51	8,41
24	7,56	8,08	7,82	54	7,18	7,74	7,46
25	7,34	7,69	7,52	55	7,20	7,38	7,29
26	7,31	7,16	7,24	56	7,05	7,27	7,16
27	7,12	7,72	7,42	57	7,16	7,05	7,11
28	7,09	7,59	7,34	58	8,00	8,43	8,22
29	7,43	7,96	7,70	59	7,58	8,14	7,86
30	7,51	8,87	8,19	60	8,41	8,15	8,28

Fonte: Autor (2020).

Depois dos testes realizados, a estrutura da DL ficou definida com: 4 entradas; 45 unidades ocultas; e 1 uma saída. Vale ressaltar que os parâmetros apresentados foram escolhidos com base em uma série de treinamentos realizados, onde foram determinados os parâmetros de melhor desempenho.

Na Figura 5.14 são comparados os valores de irradiância solar, em W/m^2 , obtidos através das previsões da DL e os valores medidos pelo piranômetro localizado no Campus do Pici da UFC, para uma janela de demonstração de 5 dias, de 4 a 8 de outubro de 2004.

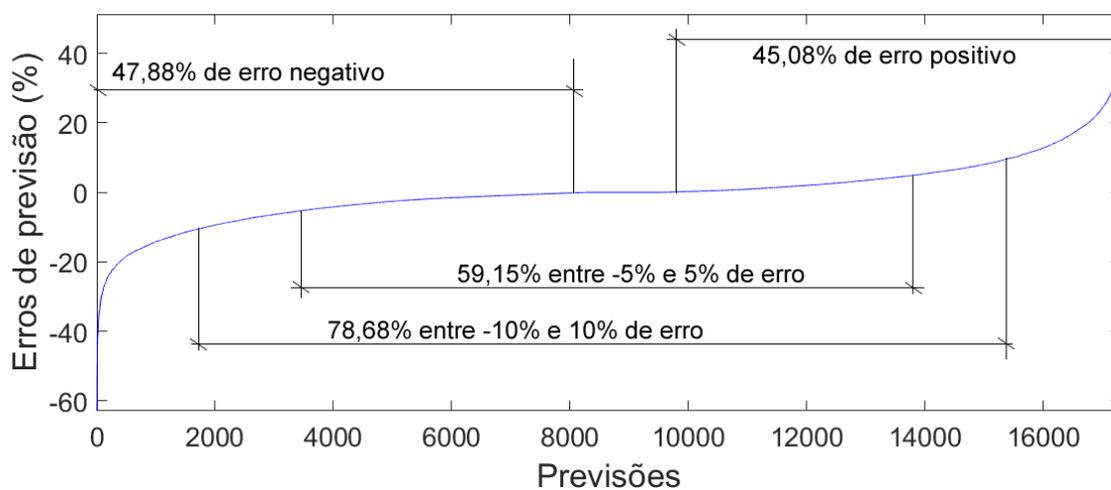
Figura 5.14 – Comparativo entre a irradiância solar prevista e medida (DL)



As previsões de irradiância solar da DL conseguem acompanhar as variações de amplitudes ao longo do período analisado. De forma geral, a previsão mantém-se de forma estável, fazendo um acompanhamento da característica de intermitência da irradiância solar no decorrer das horas.

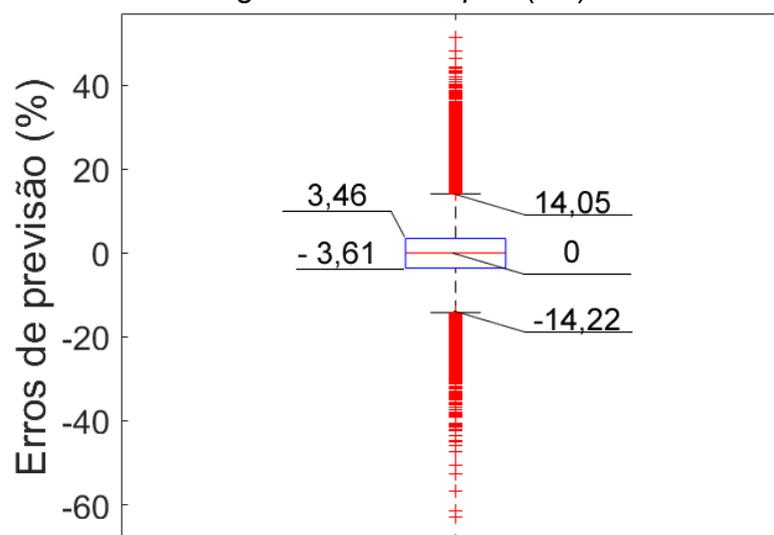
Na DL, um total de 47,88 % das previsões subestima a disponibilidade energética solar, 7,04 % das previsões obtém erro 0 e 45,08 % das previsões superestima o recurso solar. O erro negativo mais acentuado obtém um valor de -62,93 %, enquanto o positivo é de 51,34 %. Um total de 78,68 % das previsões está entre -10 % e 10 % de erro de previsão e 59,15 % das previsões está entre -5 % e 5 % de erro. O erro médio das previsões é de 0,06 % e o MAPE para esta técnica é de 6,08 %. Na Figura 5.15 são apresentadas a distribuição dos erros de previsão.

Figura 5.15 – Distribuição dos erros de previsão (DL)



Fonte: Autor (2020).

Na Figura 5.16 é apresentado o *Boxplot* das previsões da DL.

Figura 5.16 – *Boxplot* (DL)

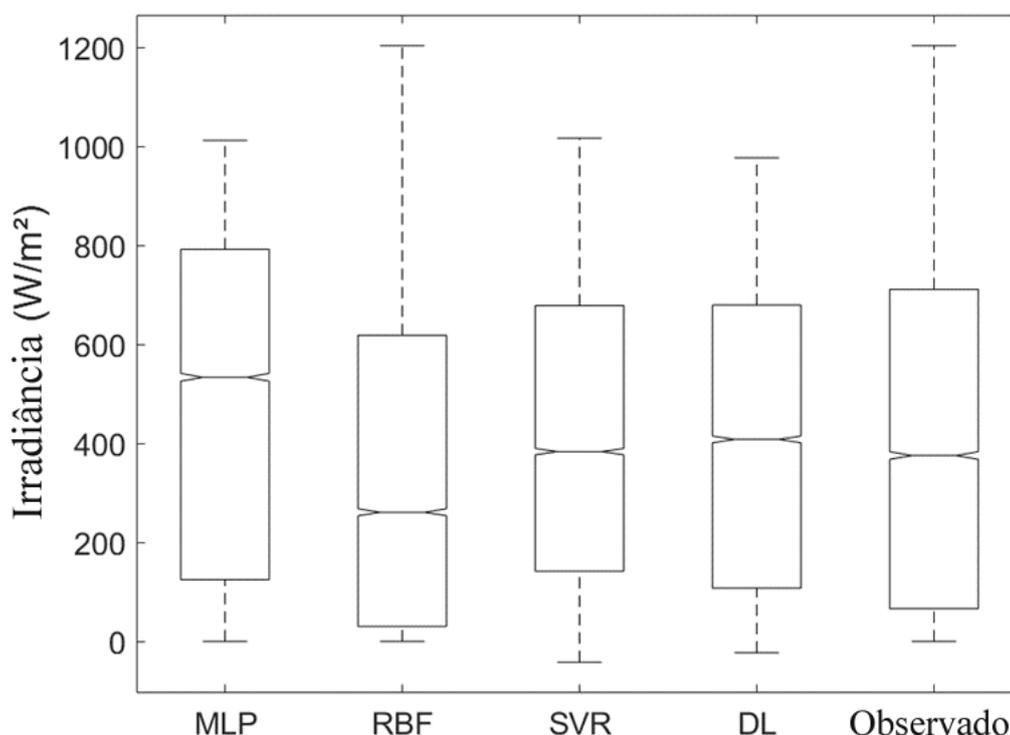
Fonte: Autor (2020).

Os limites da amplitude interquadrática são -3,61 % a 3,46 %. O valor da mediana dos erros de previsão é de 0%, o que representa a tendência simétrica das previsões. Foram encontrados *outliers* de erros de previsão, onde os negativos variam de -62,93 %, a -14,22 % e positivos que variam de 14,05 % a 51,34 %.

5.1.6 Integração das técnicas de previsão no Brasil

A caracterização dos dados antecipados pelas técnicas de previsão do recurso solar bem como os dados coletados em Fortaleza, podem ser vistos na Figura 5.17 que representa o *Boxplot* dos dados supracitados.

Figura 5.17 – *Boxplot* dos dados observados e previstos em Fortaleza, Brasil

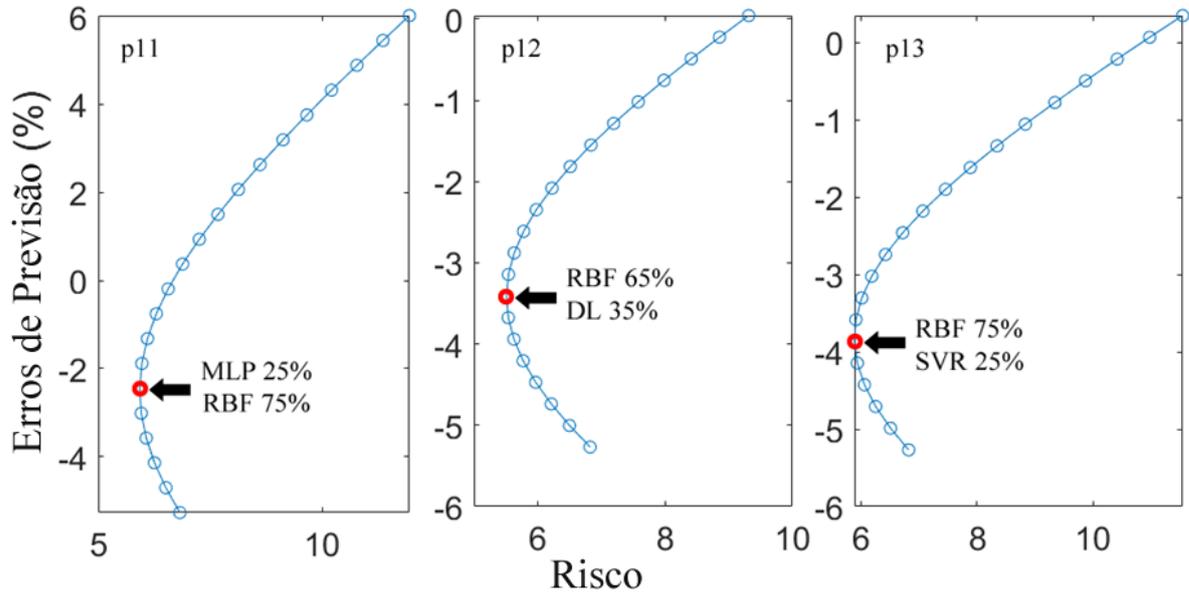


Fonte: Autor (2020).

Os limites da amplitude interquadrática são de 124,6 W/m² a 791,88 W/m² para a MLP, 30,19 W/m² a 618,14 W/m² para a RBF, 141,76 W/m² a 678,23 W/m² para a SVR, 107,66 W/m² a 679,25 W/m² para a DL e 66,04 W/m² a 711 W/m² para os dados coletados no período de teste. Através do comparativo, pode-se perceber que o melhor resultado foi obtido pela DL pela similaridade com dados observados.

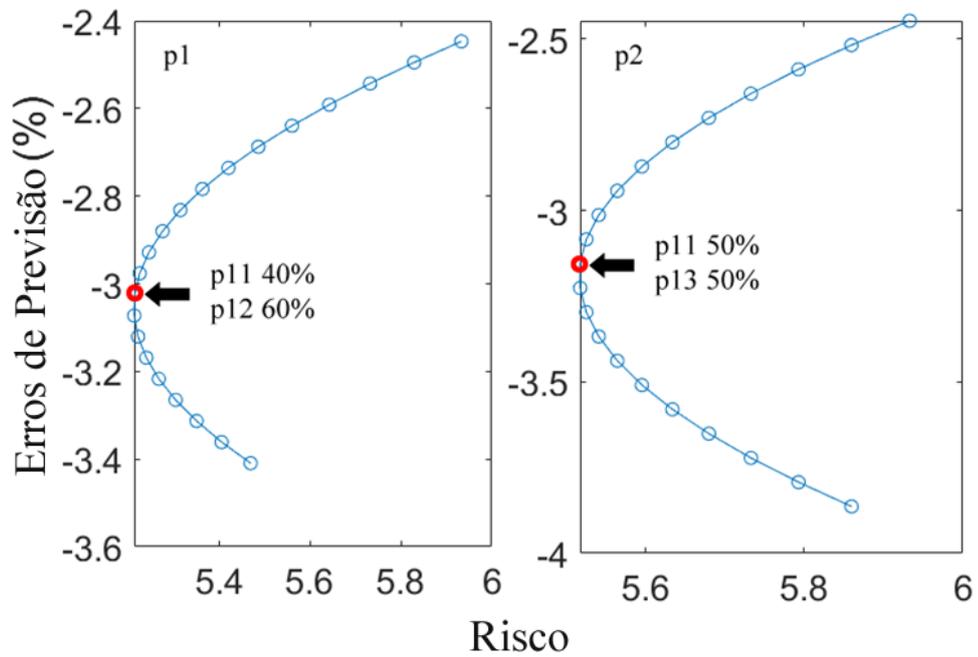
A partir dos resultados encontrados para as técnicas de previsão do recurso solar, bem como a metodologia de integração dos ativos propostas pela PrevTP, são criados os gráficos de Fronteiras Eficientes das conexões presentes nas 3 camadas do algoritmo proposto. Nass Figuras 5.18, 5.19 e 5.20 são apresentados os gráficos de Fronteiras Eficientes das três camadas da PrevTP no Brasil.

Figura 5.18 – Desenvolvimento das Fronteiras Eficientes (primeira camada)



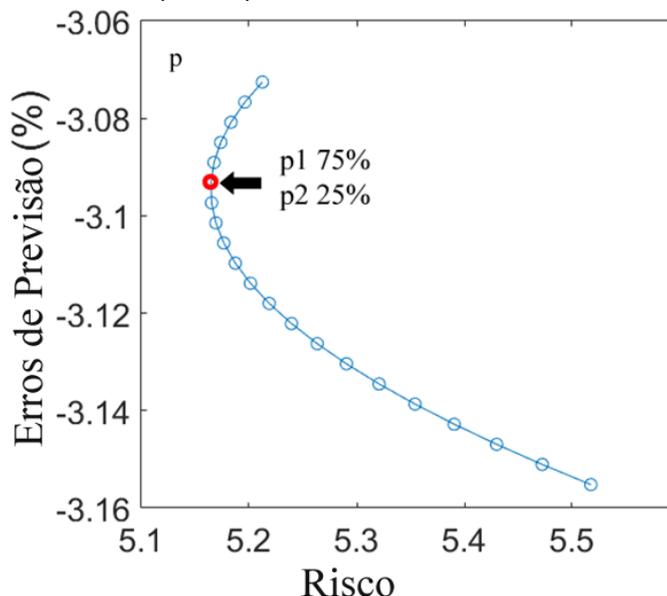
Fonte: Autor (2020).

Figura 5.19 – Desenvolvimento das Fronteiras Eficientes (segunda camada)



Fonte: Autor (2020).

Figura 5.20 – Desenvolvimento das Fronteiras Eficientes (saída)



Fonte: Autor (2020).

A primeira camada da PrevTP é definida com uma conexão p11 (25 % MLP – 75 % RBF), conexão p12 (65 % RBF – 35 % DL) e conexão p13 (75 % RBF – 25 % SVR). A segunda camada é definida a partir da conexão p1 (40 % p11 – 60 % p12) e conexão p2 (50 % p11 – 50 % p13). A saída da PrevTP no Brasil é definida 75 % da conexão p1 e 25 % de p2.

Os resultados das Fronteiras Eficientes apresentam o portfólio ótimo da integração, ou seja, a combinação com os menores riscos de erros de previsão.

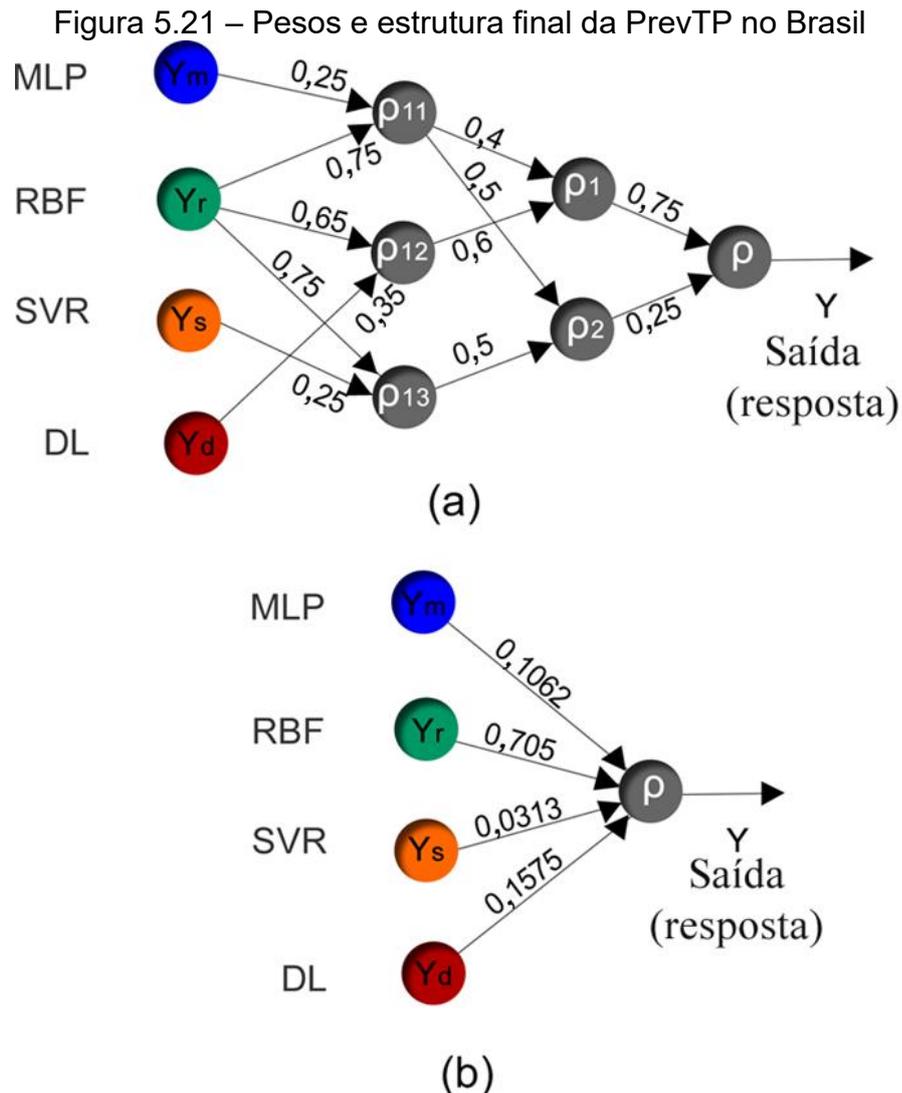
Todas as conexões apresentadas anteriormente podem ser matematicamente simplificadas para uma ponderação com 10,62 % de MLP, 70,5 % de RBF, 3,13 % de SVR e 15,75 % de DL.

O maior uso da técnica RBF, mesmo a DL tendo alcançado os melhores resultados, pode ser justificado pela distribuição dos erros de previsão. Enquanto a MLP, a SVR e a DL têm uma mediana de 2,41 %, 1,7 % e 0 %, respectivamente, apresentando uma assimetria positiva das previsões no caso das duas primeiras e simetria de previsões no caso da DL, a RBF possui uma mediana de -4,17 % de erro de previsão.

Pela proposta da PrevTP, ou seja, para que exista a compensação dos erros de previsão a partir da integração de ativos, quando um dos ativos tende a ter

erros de um sinal, a compensação deve ser executada por um ativo de sinal oposto, chegando então a uma maior ponderação, nesse caso, da RBF.

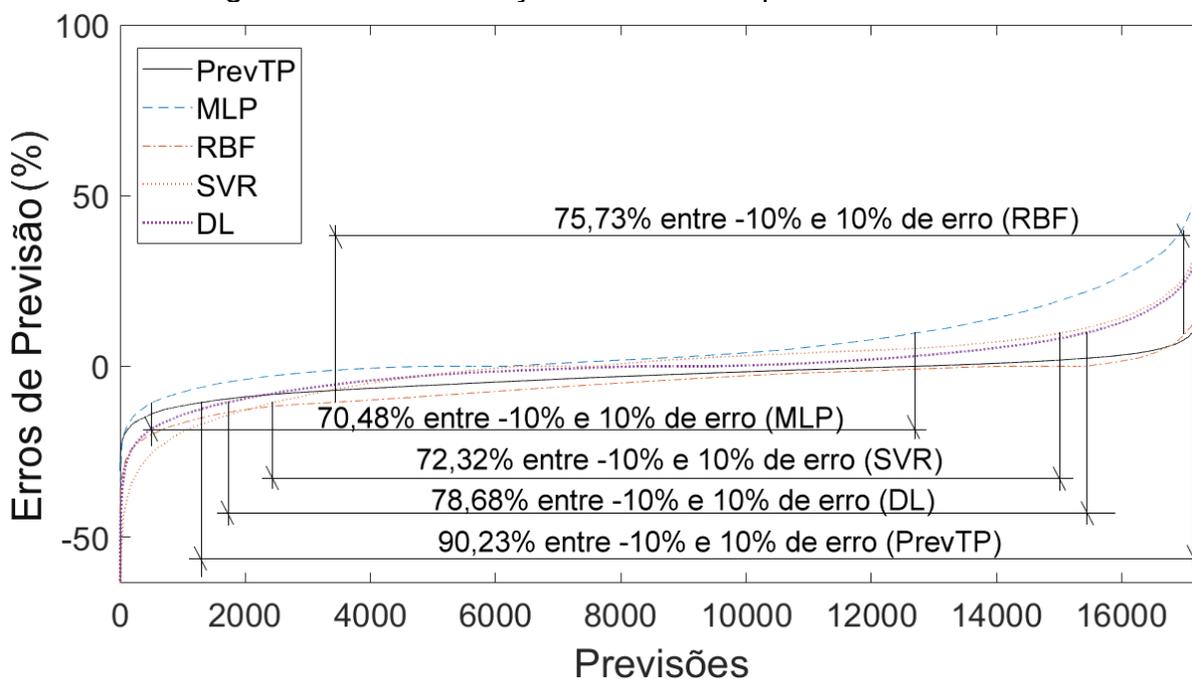
A PrevTP, em sua característica de estrutura auto-adaptativa, encontrou a melhor combinação que pode ser vista na Figura 5.21 (a) em sua estrutura completa e (b) em sua forma simplificada matematicamente.



Fonte: Autor (2020).

Na Figura 5.22 é apresentada a comparação entre as distribuições dos erros das técnicas MLP, RBF, SVR, DL e PrevTP.

Figura 5.22 – Distribuição dos erros de previsão no Brasil



Fonte: Autor (2020).

Para a PrevTP, 73,62 % das previsões subestimam a disponibilidade da energia solar e 26,37 % superestimam o recurso solar. O erro negativo mais acentuado obtém um valor de -30,64 %, enquanto o erro positivo mais acentuado é de 24,69 %. Um total de 90,23 % das previsões está entre -10% e 10 % de erro de previsão.

O erro médio das previsões é de -3,05 % e o MAPE é de 4,52 %, que define a metodologia de integração como uma melhoria dos resultados individuais de cada técnica utilizada, uma vez que o MAPE da MLP é 8,53 %, O MAPE da RBF é 6,32 %, o MAPE da SVR é 8 % e a DL obtém um MAPE de 6,08 %.

Na Tabela 5.13 são comparados os resultados individuais das técnicas utilizadas, bem como as integrações parciais e finais feitas pela PrevTP para os dados brasileiros. Na comparação é utilizada o mesmo banco de dados, horizontes e período de previsão, para gerar um comparativo entre as técnicas de previsão.

Tabela 5.13 – Comparação entre as técnicas de previsão solar

	MAPE (%)	MPE (%)	Faixa -10 (%) a 10 (%)
MLP	8,53	6,01	70,48
RBF	6,32	-5,27	75,73
SVR	8	0,35	72,32
DL	6,08	0,06	78,68
MLP/RBF	4,82	-2,45	88,8
MLP/SVR	6,57	3,18	77,71
RBF/SVR	5,3	-3,86	85,82
MLP/RBF/SVR	5,06	-3,28	84,65
MLP/RBF/SVR/DL	4,52	-3,05	90,23

Fonte: Autor (2020).

Na cidade de Fortaleza, o clima pode ser bem definido como período chuvoso (fevereiro, março, abril e maio) e sem chuvas. Por esse motivo, os dados coletados para essas duas sessões foram separados durante o período de teste para comprovar a aplicabilidade das técnicas utilizadas em diferentes condições climáticas. Na Tabela 5.14 são comparados os valores de MAPEs obtidos para as duas sessões. Os valores de MAPEs das técnicas de previsão são muito semelhantes para as sessões com chuva e sem chuva.

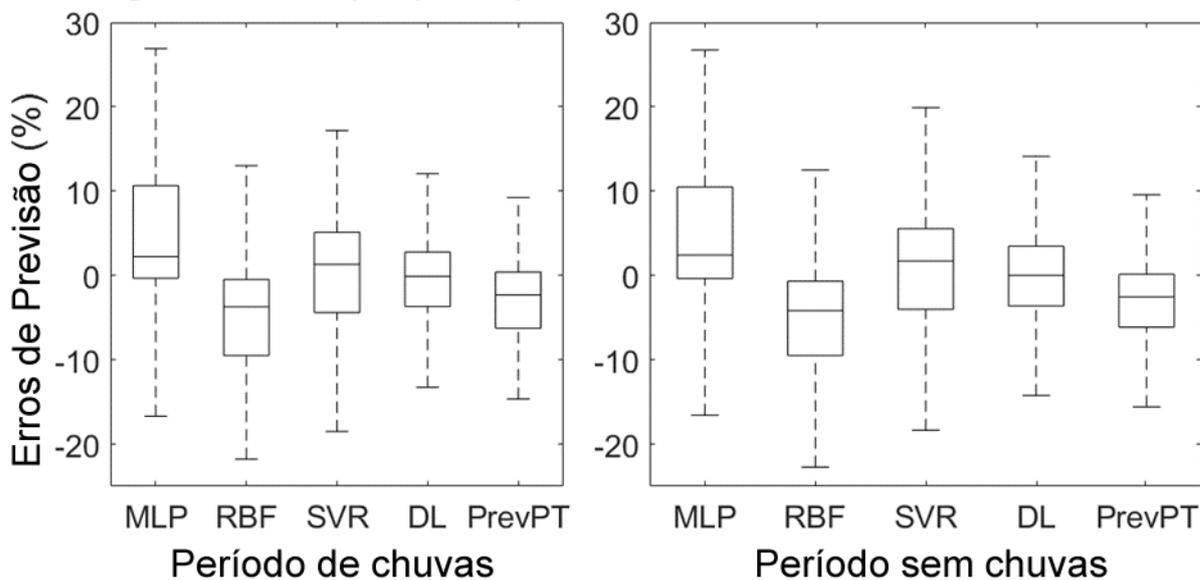
Tabela 5.14 – MAPE para as sessões chuvosas e sem chuva no Brasil

	Período chuvoso	Período sem chuvas
MLP	8,52 %	8,77 %
RBF	6,32 %	6,16 %
SVR	8,01 %	7,71 %
DL	6,09 %	5,59 %
PrevTP	4,52 %	4,51 %

Fonte: Autor (2020).

Na Figura 5.23 é apresentado o *Boxplot* das técnicas de previsão para o período chuvoso e sem chuvas. Os resultados mostram que o comportamento das técnicas é muito semelhante para as duas sessões de disponibilidade solar diferente. Essa característica pode ser observada comparando os limites da amplitude interquadrática da DL, por exemplo: -3,69 % a 2,75 % para a estação chuvosa e -3,62 % a 3,47 % para o período sem chuva.

Figura 5.23 – *Boxplot* para o período de chuvas e sem chuvas no Brasil



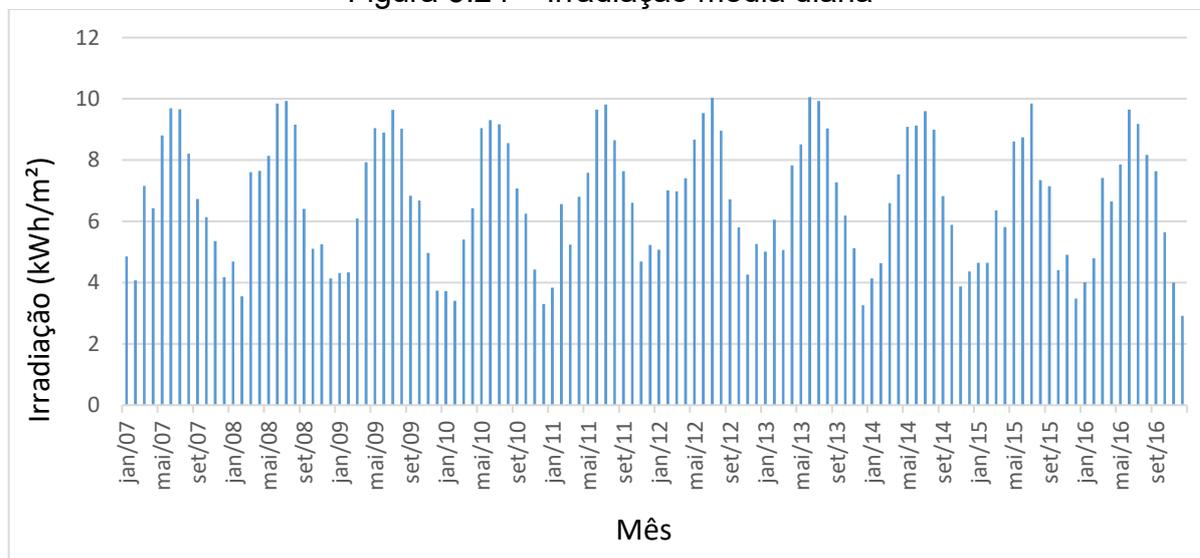
Fonte: Autor (2020).

5.2 Resultado para dados da Espanha

5.2.1 Dados coletados

Os dados de irradiação solar e temperatura ambiente foram coletados no período de janeiro de 2007 a dezembro de 2016, totalizando 10 anos de coleta. Na Figura 5.24 é apresentado o comportamento da irradiação média diária no período.

Figura 5.24 – Irradiação média diária

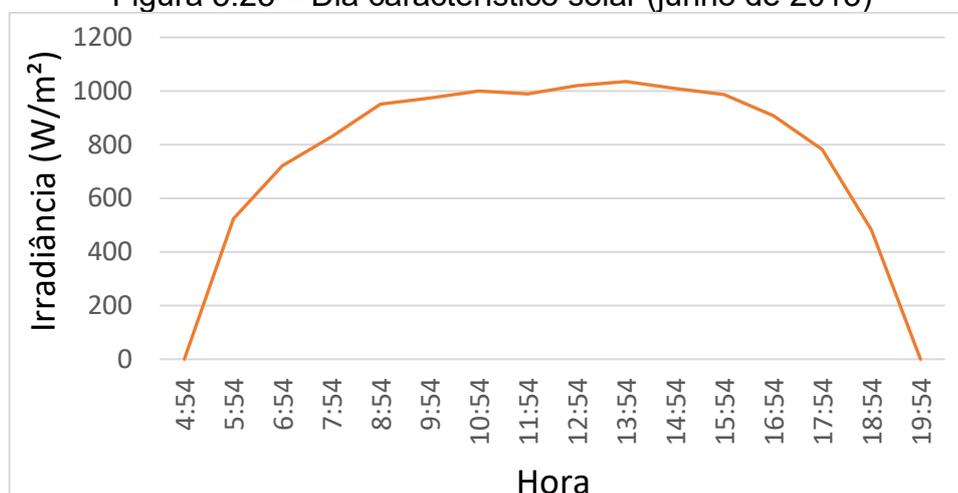


Fonte: Autor (2020).

Por meio da Figura 5.17, é possível verificar que o comportamento da disponibilidade solar se apresenta como cíclico, onde a maior disponibilidade do recurso acontece nos meses de abril a setembro, período onde ocorre a primavera e o verão Espanhol. O auge da disponibilidade solar média foi em junho para os dez anos de dados coletados. Para os dados obtidos em Algeciras, não são encontrados *outliers*.

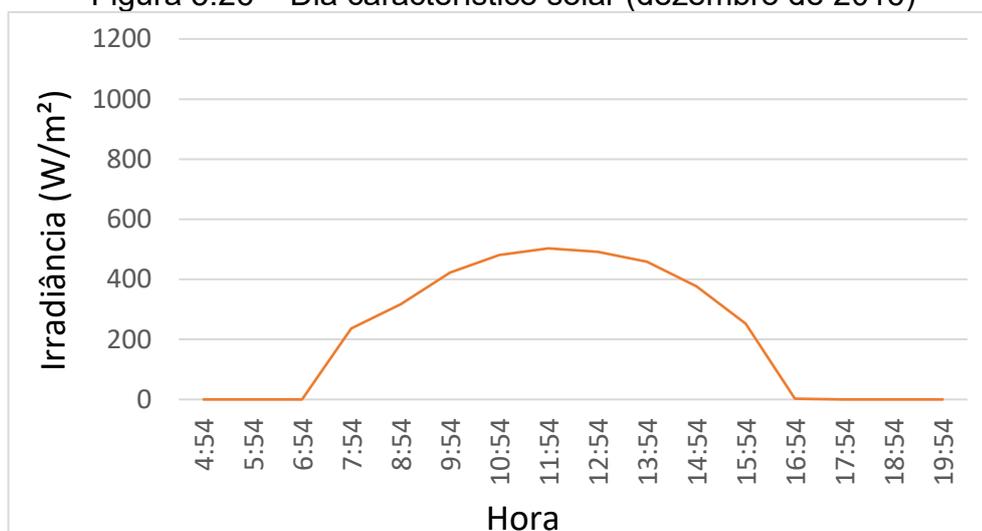
Os dias característicos nos meses de junho de 2013 e dezembro de 2016, com as irradiações solares de 10,05 kWh/m² e 2,91 kWh/m² respectivamente, meses com a maior e a menor irradiação solar, são apresentados nas Figuras 5.25 e 5.26.

Figura 5.25 – Dia característico solar (junho de 2013)



Fonte: Autor (2020).

Figura 5.26 – Dia característico solar (dezembro de 2016)



Fonte: Autor (2020).

5.2.2 Resultados MLP

Na Tabela 5.15 e 5.16, o coeficiente de correlação entre as grandezas observadas, bem como as combinações de variáveis testadas como entrada da RNA e suas respectivas avaliações obtidas pelo MAPE, calculadas duas vezes, são apresentadas, para a verificação de quais variáveis são benéficas a previsibilidade realizada pela MLP.

Tabela 5.15 – Coeficiente de correlação entre as grandezas

	Coeficiente de Correlação com a Irradiância
Irradiância	1
Temperatura	-0,0013
Hora	0,2058
Mês	-0.0234

Fonte: Autor (2020).

A temperatura apresenta correlação com a irradiância próxima a nula (aleatória), o que define que essa grandeza não garante impactos positivos a saída da RNA MLP. A grandeza hora tem coeficiente de correlação com a irradiância maior que a temperatura, e a variável mês tem coeficiente de correlação negativo.

Tabela 5.16 – Impacto das entradas nas previsões da RNA MLP

Irradiância	Temperatura	Hora	Mês	MAPE 1	MAPE 2
Sim	-	-	-	13,8 %	12,96 %
Sim	Sim	-	-	17,43 %	17,63 %
Sim	-	Sim	-	12,46 %	12,42 %
Sim	-	-	Sim	9,17 %	9,42 %
Sim	Sim	Sim	-	15,06 %	14,95 %
Sim	Sim	-	Sim	12,59 %	11,1 %
Sim	-	Sim	Sim	8,91 %	8,84 %
Sim	Sim	Sim	Sim	9,7 %	9,1 %

Fonte: Autor (2020).

Com as grandezas disponíveis avaliadas pelo coeficiente de correlação e testes do seu impacto na previsibilidade realizada pela RNA MLP, as variáveis de irradiância, hora e mês foram determinadas como as entradas da rede. Nas Tabelas 5.17 e 5.18 são apresentados os resultados dos ensaios para determinação da quantidade de entradas da RNA MLP e quantidade de neurônios da camada oculta.

Tabela 5.17 – Definição de entradas MLP

Neurônios	Treinamentos		Média (%)	Neurônios	Treinamentos		Média (%)
	MAPE 1 (%)	MAPE 2 (%)			MAPE 1 (%)	MAPE 2 (%)	
1	9,20	9,27	9,24	31	9,70	9,26	9,48
2	9,49	9,33	9,41	32	10,13	9,24	9,68
3	9,01	9,27	9,14	33	11,56	9,38	10,47
4	8,97	8,24	8,61	34	10,10	10,10	10,10
5	9,17	9,12	9,15	35	9,78	9,02	9,40
6	9,08	9,04	9,06	36	9,07	10,05	9,56
7	9,24	9,26	9,25	37	9,63	9,69	9,66
8	9,07	9,13	9,10	38	8,78	9,47	9,12
9	9,00	9,42	9,21	39	9,48	8,62	9,05
10	8,18	9,08	8,63	40	9,28	9,98	9,63
11	9,95	8,76	9,36	41	10,02	10,38	10,20
12	9,10	9,04	9,07	42	9,15	10,07	9,61
13	9,24	9,03	9,13	43	9,75	9,86	9,80
14	9,00	9,04	9,02	44	10,22	9,22	9,72
15	9,29	8,98	9,14	45	8,98	9,04	9,01
16	9,77	9,19	9,48	46	8,77	9,39	9,08
17	8,63	9,37	9,00	47	10,82	10,12	10,47
18	8,70	9,78	9,24	48	8,94	9,38	9,16
19	9,41	8,70	9,06	49	10,29	11,20	10,74
20	9,30	9,10	9,20	50	8,86	10,18	9,52
21	8,40	9,79	9,09	51	9,81	10,01	9,91
22	8,34	9,85	9,09	52	9,91	9,28	9,60
23	8,46	9,62	9,04	53	9,71	9,91	9,81
24	9,69	8,57	9,13	54	10,03	9,94	9,99
25	9,15	8,28	8,71	55	10,61	8,92	9,76
26	8,28	9,16	8,72	56	10,51	10,30	10,41
27	9,38	9,42	9,40	57	9,49	9,61	9,55
28	8,66	9,16	8,91	58	9,98	9,75	9,86
29	9,29	8,66	8,97	59	10,09	9,22	9,65
30	9,63	8,95	9,29	60	11,07	10,43	10,75

Fonte: Autor (2020).

Tabela 5.18 – Definição de neurônios da camada oculta MLP

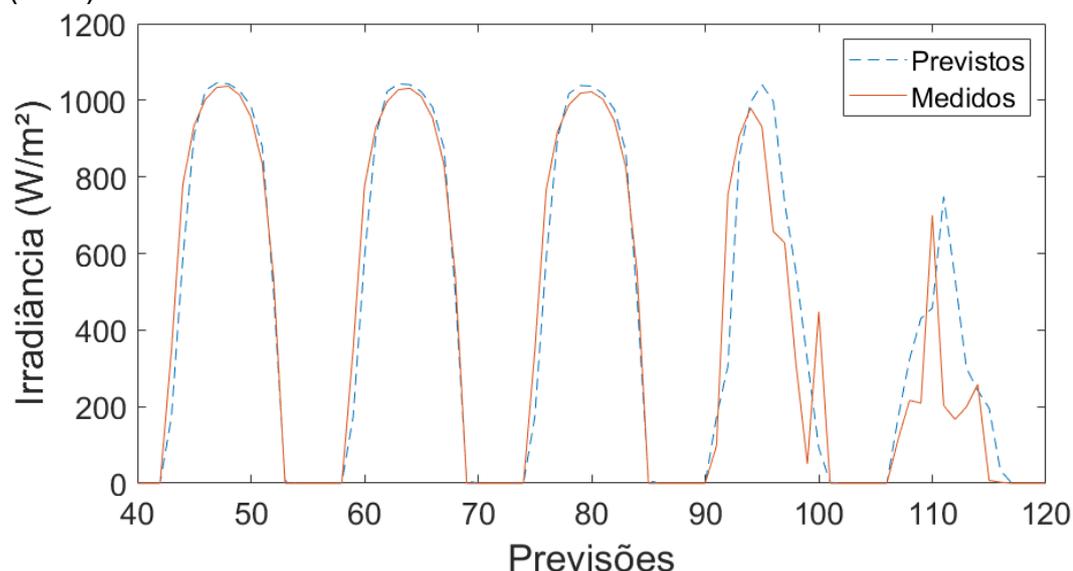
Neurônios	Treinamentos		Média (%)	Neurônios	Treinamentos		Média (%)
	MAPE 1 (%)	MAPE 2 (%)			MAPE 1 (%)	MAPE 2 (%)	
1	9,77	9,86	9,81	31	8,97	8,06	8,52
2	9,73	9,61	9,67	32	9,12	8,90	9,01
3	10,21	8,91	9,56	33	8,95	9,11	9,03
4	9,61	11,52	10,56	34	9,10	9,01	9,06
5	8,89	11,18	10,03	35	9,47	9,03	9,25
6	8,82	10,02	9,42	36	9,20	8,96	9,08
7	8,56	9,72	9,14	37	9,01	9,02	9,01
8	8,32	8,88	8,60	38	8,97	8,98	8,97
9	8,22	8,45	8,34	39	8,95	9,06	9,01
10	8,94	8,42	8,68	40	8,95	8,95	8,95
11	8,70	8,24	8,47	41	9,13	9,03	9,08
12	8,93	8,14	8,49	42	9,07	8,99	9,03
13	8,27	8,02	8,54	43	8,98	9,14	9,06
14	8,78	8,88	8,83	44	9,13	8,99	9,06
15	8,65	8,66	8,66	45	8,77	8,08	8,43
16	8,06	8,07	8,07	46	8,97	9,01	8,99
17	8,12	8,13	8,12	47	8,95	9,59	9,27
18	8,99	8,21	8,60	48	9,12	8,90	9,01
19	8,11	8,08	8,09	49	8,94	8,94	8,94
20	8,98	8,06	8,52	50	9,00	9,17	9,09
21	8,71	8,20	8,45	51	9,01	9,14	9,07
22	8,12	8,48	8,30	52	8,98	9,05	9,02
23	9,03	9,04	9,04	53	8,98	8,99	8,98
24	8,12	8,10	8,11	54	8,99	9,12	9,05
25	8,19	8,02	8,11	55	9,15	8,88	9,02
26	8,93	8,95	8,94	56	8,14	8,74	8,44
27	8,09	9,10	8,60	57	8,99	9,06	9,03
28	8,93	8,19	8,56	58	9,04	8,98	9,01
29	8,12	8,12	8,12	59	8,06	8,11	8,08
30	8,14	8,08	8,11	60	9,02	8,98	9,00

Fonte: Autor (2020).

Depois dos testes realizados a estrutura da MLP ficou definida com: Matriz com 4 atrasos e 1 saída; 4 neurônios na camada de entrada; 16 neurônios na camada oculta; 1 neurônio na camada de saída. Vale ressaltar que os parâmetros apresentados foram escolhidos com base em uma série de treinamentos realizados, onde foram determinados os parâmetros de melhor desempenho.

Na Figura 5.27 são comparados os valores de irradiância solar em W/m^2 , obtidos através das previsões da RNA MLP e os valores medidos em Algeciras, para uma janela de demonstração de 5 dias, de 3 a 7 de janeiro de 2015.

Figura 5.27 – Comparativo entre a irradiância solar prevista e medida (MLP)

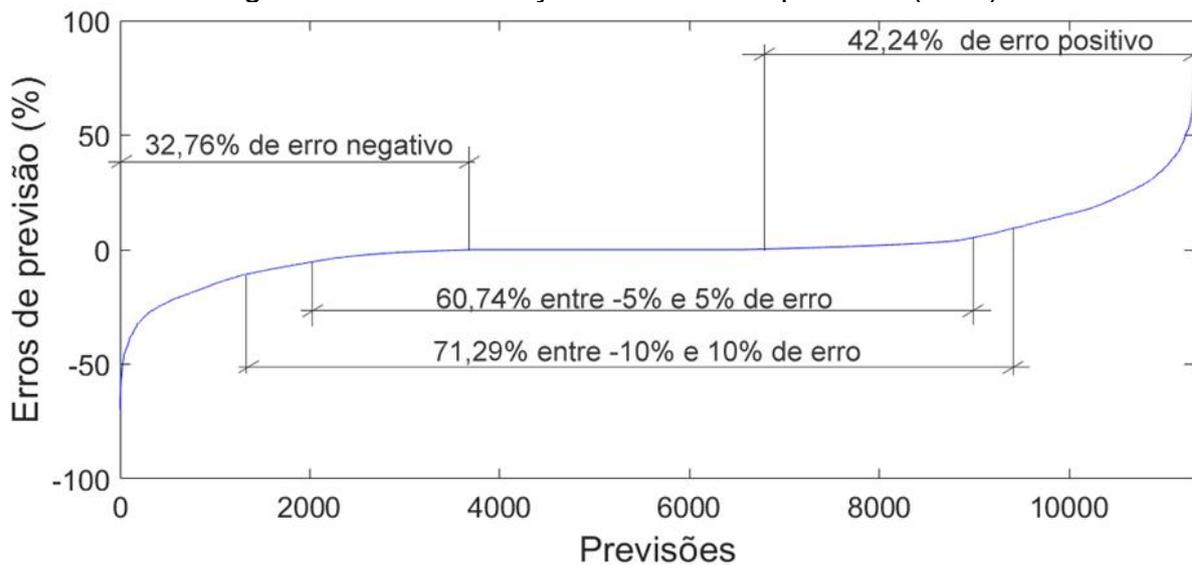


Fonte: Autor (2020).

As previsões de irradiância solar da RNA MLP *Backpropagation* conseguem acompanhar as variações de amplitudes ao longo do período analisado. De forma geral, a previsão se mantém de forma estável, fazendo um acompanhamento da característica de intermitência da irradiância solar no decorrer das horas.

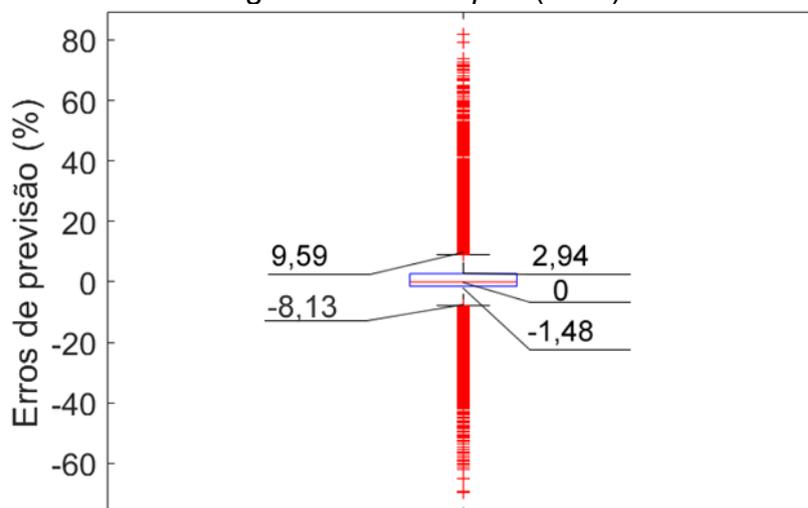
Na RNA MLP, um total de 32,76 % das previsões subestima a disponibilidade energética solar, 25 % das previsões obtém erro 0 e 42,24 % das previsões superestima o recurso solar. O erro negativo mais acentuado obtém um valor de -69,52 %, enquanto o positivo é de 81,78 %. Um total de 71,28 % das previsões estão entre -10 % e 10 % de erro de previsão e 60,74 % das previsões estão entre -5 % e 5 % de erro. O erro médio das previsões é de 1,29 % e o MAPE para esta RNA é de 8,06 %. Na Figura 5.28 são apresentados a distribuição dos erros de previsão.

Figura 5.28 – Distribuição dos erros de previsão (MLP)



Fonte: Autor (2020).

A figura 5.29 apresenta o *Boxplot* das previsões da RNA MLP.

Figura 5.29 – *Boxplot* (MLP)

Fonte: Autor (2020).

Os limites da amplitude interquadrática são -1,48 % a 2,94 %. O valor da mediana dos erros de previsão é de 0 %, o que representa a tendência simétrica das previsões. Foram encontrados *outliers* de erros de previsão, onde os negativos variam de -69,52 % a -8,13 % e positivos que variam de 9,59 % a 81,78 %.

5.2.3 Resultados RBF

Para definição de quais entradas são benéficas para a previsibilidade solar a partir da RBF, foram testadas todas as combinações possíveis entre as variáveis irradiância, temperatura, hora e mês. Os resultados são apresentados na Tabela 5.19, onde verificou-se que para previsões de irradiância solar, na Espanha, a partir da RBF, a irradiância utilizada isoladamente é a melhor condição de entrada da técnica de previsão em estudo.

Tabela 5.19 – Impacto das entradas nas previsões da RNA RBF

Irradiância	Temperatura	Hora	Mês	MAPE 1	MAPE 2
Sim	-	-	-	8,29 %	8,72 %
Sim	Sim	-	-	21,13 %	20,67 %
Sim	-	Sim	-	10,97 %	11,04 %
Sim	-	-	Sim	15,79 %	14,71 %
Sim	Sim	Sim	-	11,92 %	13,86 %
Sim	Sim	-	Sim	24,12 %	22,71 %
Sim	-	Sim	Sim	15,96 %	17,52 %
Sim	Sim	Sim	Sim	30,63 %	29,68 %

Fonte: Autor (2020).

Nas Tabelas 5.20 e 5.21 são apresentados os resultados dos ensaios para determinação da quantidade de entradas da RNA RBF e quantidade de neurônios da camada oculta respectivamente.

Tabela 5.20 – Definição da quantidade de entradas da RBF

Neurônios	Treinamentos		Média (%)	Neurônios	Treinamentos		Média (%)
	MAPE 1 (%)	MAPE 2 (%)			MAPE 1 (%)	MAPE 2 (%)	
1	32,75	32,62	32,69	31	26,10	30,51	28,30
2	16,76	18,41	17,58	32	25,96	27,94	26,95
3	10,05	10,74	10,39	33	21,58	22,20	21,89
4	7,28	7,60	7,44	34	29,23	30,66	29,94
5	16,87	12,20	14,54	35	16,43	17,71	17,07
6	29,80	22,89	26,34	36	23,14	20,11	21,62
7	26,62	23,19	24,90	37	30,92	33,01	31,97
8	30,06	29,21	29,63	38	23,05	18,69	20,87
9	25,79	26,36	26,07	39	25,59	21,20	23,39
10	23,86	26,75	25,30	40	22,46	26,60	24,53
11	17,19	18,66	17,92	41	27,00	27,87	27,43
12	23,17	21,17	22,17	42	19,28	20,84	20,06
13	31,53	24,25	27,89	43	22,12	18,55	20,33
14	32,74	26,84	29,79	44	23,94	20,74	22,34
15	17,50	18,03	17,77	45	21,97	27,74	24,85
16	28,79	30,50	29,65	46	30,58	24,16	27,37
17	30,00	24,71	27,36	47	29,31	30,10	29,71
18	19,10	21,78	20,44	48	19,20	23,21	21,21
19	22,58	22,62	22,60	49	18,05	17,23	17,64
20	28,58	24,40	26,49	50	27,32	25,50	26,41
21	21,55	24,54	23,05	51	25,93	28,17	27,05
22	22,49	26,18	24,33	52	29,81	26,37	28,09
23	28,56	26,85	27,71	53	20,54	19,78	20,16
24	22,64	26,08	24,36	54	22,07	25,40	23,73
25	30,71	29,75	30,23	55	24,15	21,78	22,97
26	28,68	29,03	28,85	56	18,85	19,82	19,33
27	21,89	22,38	22,14	57	25,16	29,05	27,10
28	20,41	25,36	22,89	58	28,08	28,49	28,28
29	20,79	22,72	21,76	59	25,11	26,99	26,05
30	25,93	29,19	27,56	60	27,80	28,93	28,36

Fonte: Autor (2020).

Tabela 5.21 – Definição da quantidade de neurônios da camada oculta da RBF

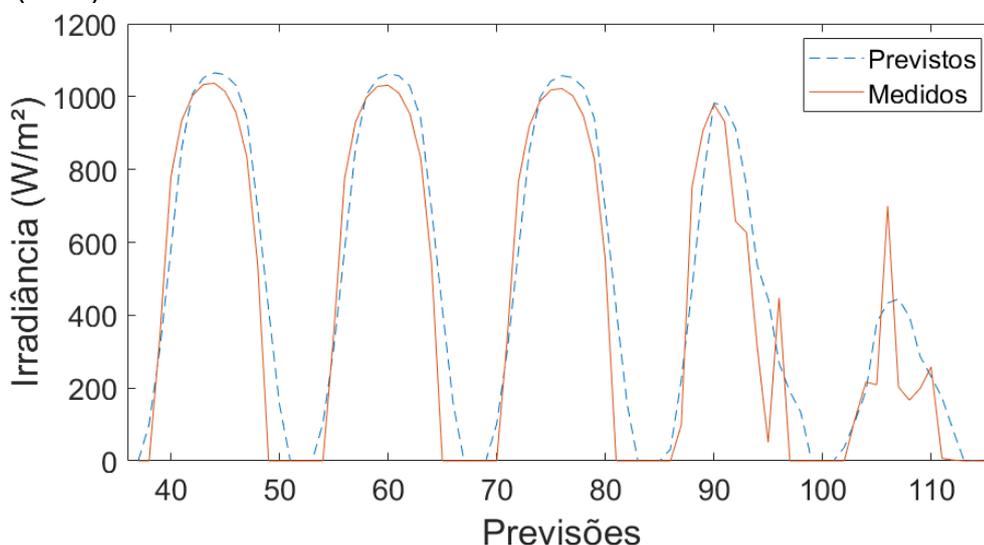
Neurônios	Treinamentos		Média (%)	Neurônios	Treinamentos		Média (%)
	MAPE 1 (%)	MAPE 2 (%)			MAPE 1 (%)	MAPE 2 (%)	
1	26,94	21,51	24,22	31	14,22	14,23	14,23
2	30,99	31,25	31,12	32	13,40	14,61	14,00
3	23,05	25,66	24,36	33	13,42	13,98	13,70
4	17,00	23,65	20,32	34	10,98	13,76	12,37
5	18,81	18,81	18,81	35	13,62	11,36	12,49
6	14,35	18,28	16,32	36	11,26	13,65	12,46
7	20,03	15,29	17,66	37	13,49	13,43	13,46
8	17,81	22,14	19,97	38	12,08	9,79	10,93
9	21,21	20,05	20,63	39	11,59	13,38	12,48
10	16,47	16,53	16,50	40	10,20	9,30	9,75
11	17,05	18,57	17,81	41	12,45	10,92	11,68
12	16,22	18,56	17,39	42	9,84	11,43	10,63
13	24,84	27,60	26,22	43	12,58	11,54	12,06
14	17,06	20,09	18,58	44	8,26	8,05	8,16
15	20,59	18,28	19,43	45	12,44	11,31	11,87
16	16,89	19,14	18,02	46	9,68	11,28	10,48
17	16,81	14,86	15,84	47	10,78	12,06	11,42
18	21,57	20,53	21,05	48	10,17	11,62	10,89
19	19,25	18,88	19,06	49	10,61	10,00	10,31
20	15,57	15,33	15,45	50	7,97	7,99	7,98
21	15,16	15,00	15,08	51	10,63	10,86	10,75
22	15,26	16,00	15,63	52	10,73	10,14	10,43
23	19,51	14,10	16,81	53	11,62	11,15	11,38
24	16,44	16,12	16,28	54	9,86	9,31	9,59
25	16,36	17,25	16,81	55	10,57	6,98	8,77
26	15,37	15,66	15,52	56	9,41	8,15	8,78
27	15,57	14,46	15,02	57	7,16	7,41	7,29
28	14,74	15,23	14,99	58	15,68	19,90	17,79
29	14,95	14,11	14,53	59	8,94	9,47	9,20
30	16,05	14,45	15,25	60	18,62	17,77	18,19

Fonte: Autor (2020).

Depois dos testes realizados, a estrutura da RBF ficou definida com: Matriz com 4 atrasos e 1 saída; 4 neurônios na camada de entrada; 57 neurônios na camada oculta; 1 neurônio na camada de saída. Vale ressaltar que os parâmetros apresentados foram escolhidos com base em uma série de treinamentos realizados, onde foram determinados os parâmetros de melhor desempenho.

Na Figura 5.30 são comparados os valores de irradiância solar em W/m^2 , obtidos através das previsões da RNA RBF e os valores medidos em Algeciras, para uma janela de demonstração de 5 dias, de 3 a 7 de janeiro de 2015.

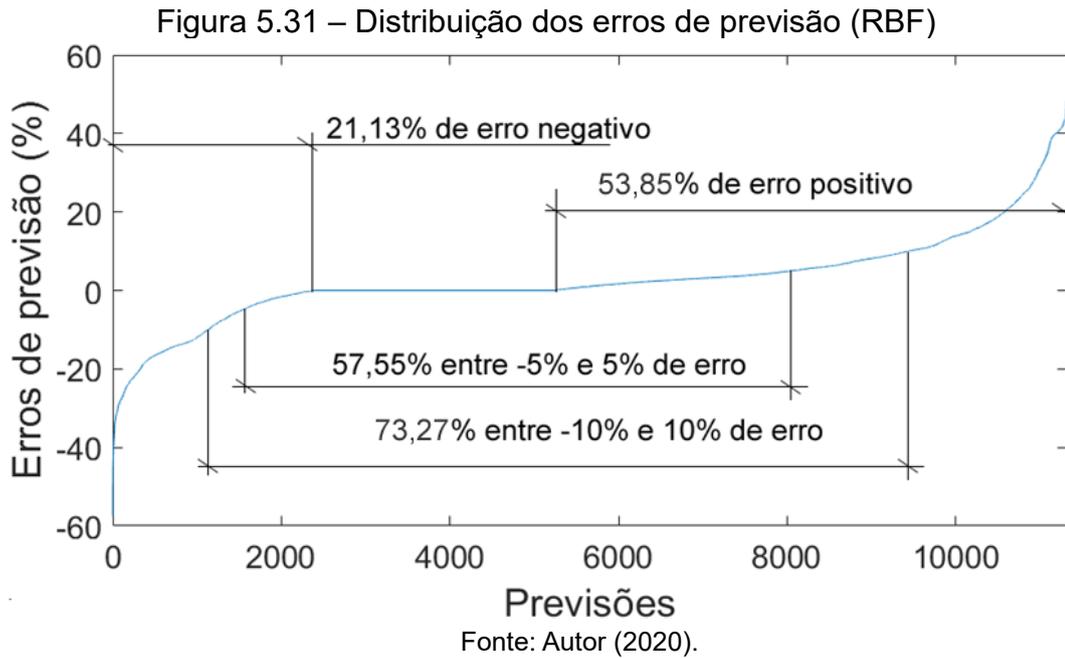
Figura 5.30 – Comparativo entre a irradiância solar prevista e medida (RBF)



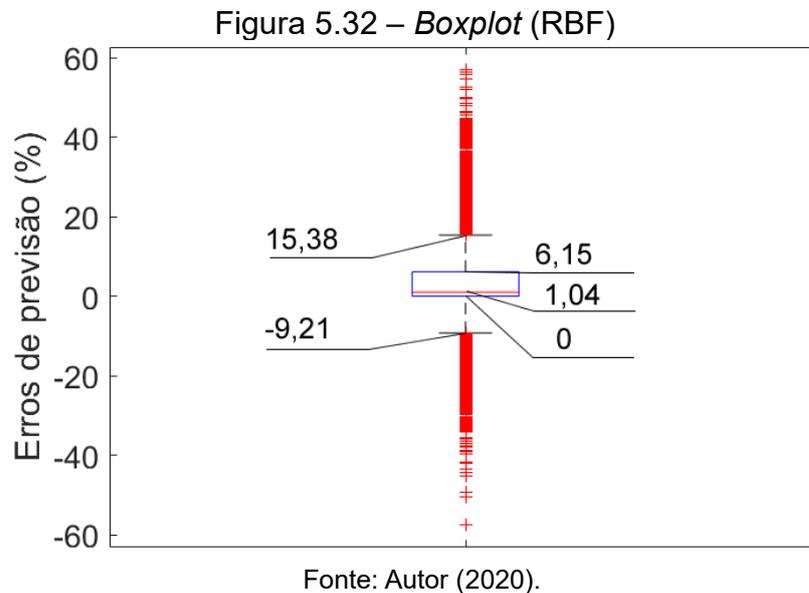
Fonte: Autor (2020).

As previsões de irradiância solar da RNA RBF conseguem acompanhar as variações de amplitudes ao longo do período analisado. De forma geral, a previsão se mantém de forma estável, fazendo um acompanhamento da característica de intermitência da irradiância solar no decorrer das horas.

Na RNA RBF, um total de 21,13 % das previsões subestima a disponibilidade energética solar, 25,02 % das previsões obtém erro 0 e 53,85 % das previsões superestima o recurso solar. O erro negativo mais acentuado obtém um valor de -57,45 %, enquanto o positivo é de 56,96 %. Um total de 73,27 % das previsões está entre -10 % e 10 % de erro de previsão e 57,55 % das previsões está entre -5 % e 5 % de erro. O erro médio das previsões é de 2,76 % e o MAPE para esta RNA é de 7,16 %. Na Figura 5.31 é apresentada a distribuição dos erros de previsão.



A figura 5.32 apresenta o *boxplot* das previsões da RNA RBF.



Os limites da amplitude interquadrática são 0 % a 6,15 %. O valor da mediana dos erros de previsão é de 1,04 %, o que nesse caso representa uma leve tendência assimétrica positiva das previsões. Foram encontrados *outliers* de erros de previsão, onde os negativos variam de -57,45 % a -9,21 % e positivos que variam de 15,38 % a 56,96 %.

5.2.4 Resultados SVR

Por meio da Tabela 5.22 é possível determinar que para previsões de irradiância solar na Espanha, a partir da SVR, a irradiância solar é a melhor condição de entrada da técnica de previsão em estudo.

Tabela 5.22 – Impacto das entradas nas previsões da SVR

Irradiância	Temperatura	Hora	Mês	MAPE 1	MAPE 2
Sim	-	-	-	9,44 %	9,34 %
Sim	Sim	-	-	11,90 %	11,58 %
Sim	-	Sim	-	10,99 %	10,93 %
Sim	-	-	Sim	10,10 %	10,68 %
Sim	Sim	Sim	-	11,89 %	11,36 %
Sim	Sim	-	Sim	13,55 %	13,95 %
Sim	-	Sim	Sim	12,95 %	12,93 %
Sim	Sim	Sim	Sim	12,24 %	12,22 %

Fonte: Autor (2020).

A seguir, na Tabela 5.23 são apresentados os resultados dos ensaios para determinação da quantidade de entradas da SVR.

Tabela 5.23 – Definição da quantidade de entradas da SVR

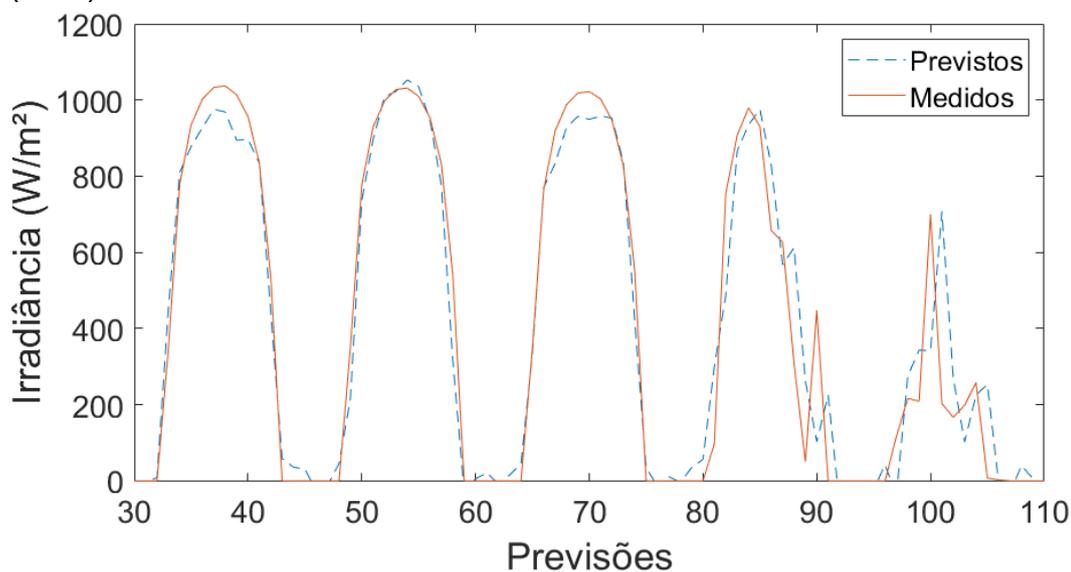
Neurônios	Treinamentos		Média (%)	Neurônios	Treinamentos		Média (%)
	MAPE 1 (%)	MAPE 2 (%)			MAPE 1 (%)	MAPE 2 (%)	
1	32,90	32,85	32,88	31	13,58	13,69	13,63
2	17,62	17,15	17,38	32	15,22	15,13	15,18
3	15,65	15,94	15,80	33	12,92	12,83	12,88
4	14,70	13,60	14,15	34	14,32	14,04	14,18
5	12,74	12,21	12,48	35	17,23	16,48	16,85
6	15,88	16,31	16,09	36	14,60	14,07	14,34
7	12,06	11,64	11,85	37	12,32	12,54	12,43
8	14,58	13,41	13,99	38	15,66	15,60	15,63
9	10,62	9,92	10,27	39	15,43	15,21	15,32
10	8,34	9,05	8,70	40	14,09	14,04	14,07
11	16,59	16,77	16,68	41	15,54	15,14	15,34
12	18,09	19,98	19,03	42	13,75	13,97	13,86
13	20,56	21,90	21,23	43	12,30	12,23	12,26
14	17,83	17,54	17,69	44	11,59	11,15	11,37
15	13,59	13,05	13,32	45	13,80	14,02	13,91
16	11,29	10,06	10,68	46	14,94	14,81	14,87
17	12,54	11,75	12,14	47	15,72	15,65	15,69
18	12,62	12,16	12,39	48	13,97	14,02	13,99
19	17,02	16,84	16,93	49	15,11	14,98	15,05
20	19,20	20,64	19,92	50	15,98	15,87	15,93
21	17,27	17,08	17,17	51	14,76	14,39	14,58
22	14,82	13,80	14,31	52	15,60	15,43	15,51
23	10,26	9,85	10,06	53	19,53	21,49	20,51
24	11,57	10,43	11,00	54	19,10	20,41	19,75
25	14,91	14,97	14,94	55	20,01	21,51	20,76
26	18,76	20,15	19,45	56	23,49	23,81	23,65
27	18,02	18,77	18,39	57	24,85	28,66	26,75
28	15,58	15,17	15,37	58	32,35	31,43	31,89
29	14,49	14,06	14,28	59	30,35	29,78	30,07
30	14,66	14,13	14,40	60	28,76	29,61	29,19

Fonte: Autor (2020).

Depois dos testes realizados, a SVR ficou definida com: Matriz com 10 atrasos e 1 saída. Vale ressaltar que os parâmetros apresentados foram escolhidos com base em uma série de treinamentos realizados, onde foram determinados os parâmetros de melhor desempenho.

Na Figura 5.33 são comparados os valores de irradiância solar em W/m^2 , obtidos através das previsões da SVR e os valores medidos em Algeciras, para uma janela de demonstração de 5 dias, de 3 a 7 de janeiro de 2015.

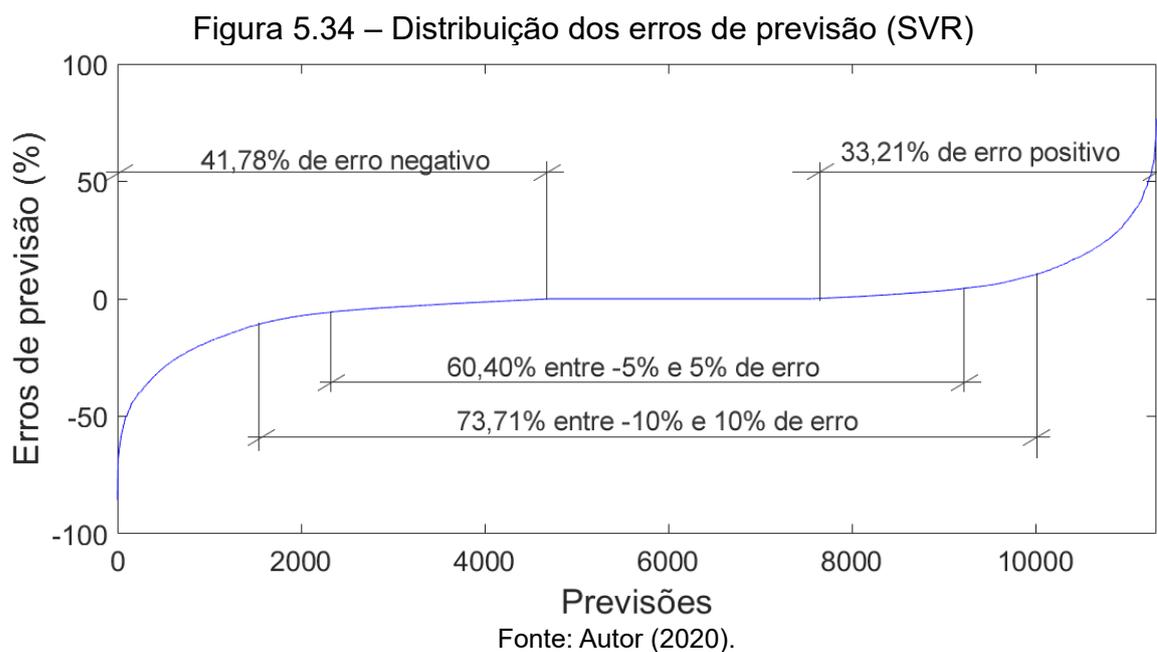
Figura 5.33 – Comparativo entre a irradiância solar prevista e medida (SVR)



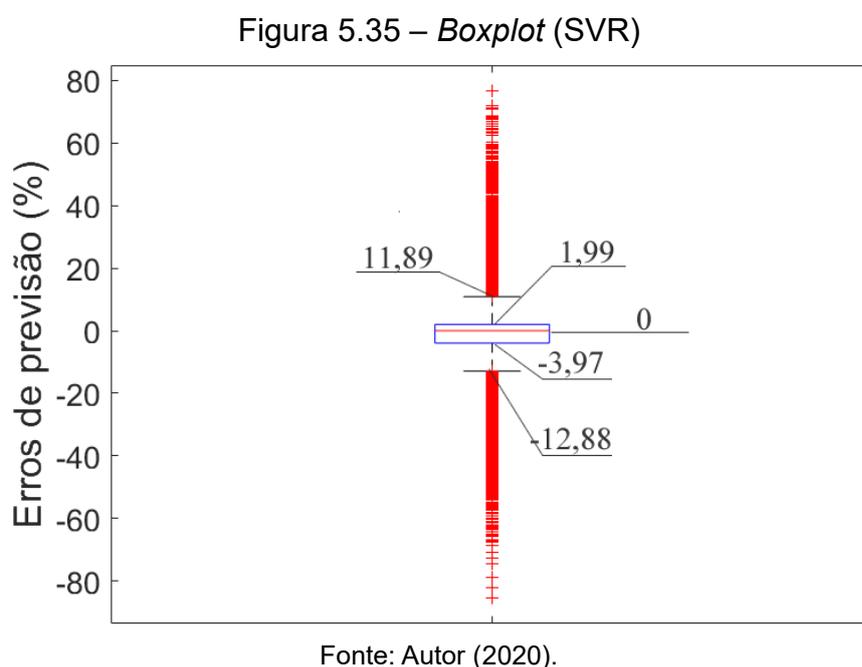
Fonte: Autor (2020).

As previsões de irradiância solar da SVR conseguem acompanhar as variações de amplitudes ao longo do período analisado. De forma geral, a previsão se mantém de forma estável, fazendo um acompanhamento da característica de intermitência da irradiância solar no decorrer das horas.

Na SVR, um total de 41,78 % das previsões subestima a disponibilidade energética solar, 25,01 % das previsões obtém erro 0 e 33,21 % das previsões superestima o recurso solar. O erro negativo mais acentuado obtém um valor de -85,49 %, enquanto o positivo é de 75,77 %. Um total de 73,71 % das previsões está entre -10 % e 10 % de erro de previsão e 60,40 % das previsões está entre -5 % e 5 % de erro. O erro médio das previsões é de -0,89 % e o MAPE é de 8,34 %. Na Figura 5.34 é apresentada a distribuição dos erros de previsão.



Na Figura 5.35 é apresentado o *Boxplot* das previsões da SVR.



Os limites da amplitude interquadrática são -3,97 % a 1,99 %. O valor da mediana dos erros de previsão é de 0%, o que representa uma tendência simétrica das previsões. Foram encontrados outliers de erros de previsão, onde os negativos variam de -85,49 % a -12,88 % e positivos que variam de 11,88 % a 75,77 %.

5.2.5 Resultados DL

Para definição de quais entradas são benéficas para a previsibilidade solar a partir da DL, foram testadas todas as combinações possíveis entre as variáveis irradiância, temperatura, hora e mês. Os resultados são apresentados na Tabela 5.24, onde verificou-se que para previsões de irradiância solar, no Brasil, a partir da DL, a irradiância utilizada isoladamente é a melhor condição de entrada da técnica de previsão em estudo.

Tabela 5.24 – Impacto das entradas nas previsões da DL

Irradiância	Temperatura	Hora	Mês	MAPE 1	MAPE 2
Sim	-	-	-	7,42 %	7,67 %
Sim	Sim	-	-	12,04 %	11,38 %
Sim	-	Sim	-	10,09 %	10,76 %
Sim	-	-	Sim	9,67 %	9,22 %
Sim	Sim	Sim	-	12,65 %	11,75 %
Sim	Sim	-	Sim	12,14 %	12,19 %
Sim	-	Sim	Sim	12,84 %	12,61 %
Sim	Sim	Sim	Sim	11,75 %	11,12 %

Fonte: Autor (2020).

Nas Tabelas 5.25 e 5.26 são apresentados os resultados dos ensaios para determinação da quantidade de entradas da DL e quantidade de unidades de processamento da camada oculta respectivamente.

Tabela 5.25 – Definição da quantidade de entradas da DL

Neurônios	Treinamentos		Média (%)	Neurônios	Treinamentos		Média (%)
	MAPE 1 (%)	MAPE 2 (%)			MAPE 1 (%)	MAPE 2 (%)	
1	36,43	31,63	34,03	31	39,72	33,99	36,85
2	11,69	13,13	12,41	32	39,65	40,78	40,22
3	6,97	9,62	8,30	33	34,95	35,83	35,39
4	15,45	9,98	12,71	34	39,96	35,58	37,77
5	29,62	23,85	26,74	35	44,51	38,50	41,50
6	22,68	14,62	18,65	36	39,21	36,19	37,70
7	16,50	20,05	18,27	37	40,01	47,13	43,57
8	18,69	29,04	23,87	38	34,00	34,43	34,21
9	20,92	26,53	23,73	39	27,15	30,36	28,75
10	43,68	38,71	41,20	40	30,64	28,94	29,79
11	43,85	40,14	41,99	41	31,67	29,14	30,40
12	34,84	42,23	38,54	42	36,41	41,94	39,18
13	33,00	41,52	37,26	43	18,64	15,67	17,15
14	28,56	35,35	31,95	44	19,94	17,32	18,63
15	36,09	29,98	33,03	45	19,19	23,13	21,16
16	33,75	28,74	31,24	46	39,09	32,31	35,70
17	39,39	40,06	39,72	47	36,19	33,67	34,93
18	44,02	34,75	39,38	48	33,00	31,20	32,10
19	38,94	39,71	39,33	49	22,84	23,38	23,11
20	32,50	35,37	33,94	50	27,96	27,83	27,90
21	29,96	32,76	31,36	51	30,52	33,30	31,91
22	19,59	16,13	17,86	52	19,00	17,27	18,14
23	18,47	19,36	18,92	53	18,27	21,88	20,07
24	30,52	30,46	30,49	54	35,38	31,20	33,29
25	25,04	24,84	24,94	55	20,25	19,92	20,08
26	19,97	24,43	22,20	56	23,45	25,58	24,52
27	21,48	17,76	19,62	57	24,26	19,87	22,07
28	19,50	17,76	18,63	58	23,52	22,20	22,86
29	26,77	22,08	24,42	59	23,28	20,58	21,93
30	28,55	22,67	25,61	60	25,48	18,91	22,19

Fonte: Autor (2020).

Tabela 5.26 – Definição da quantidade de neurônios da camada oculta da DL

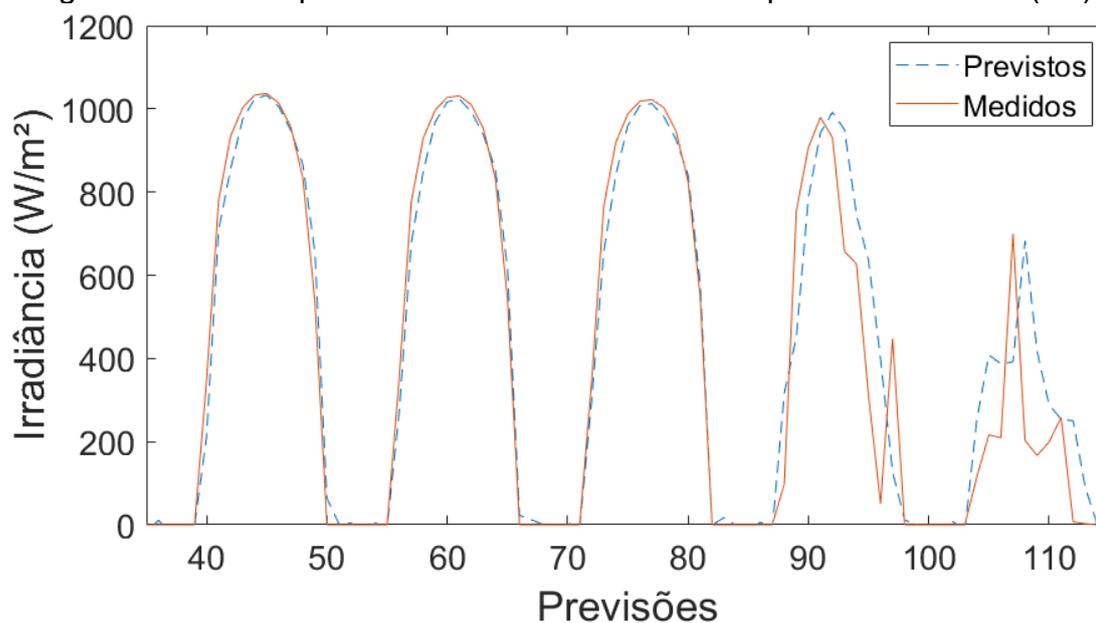
Neurônios	Treinamentos		Média (%)	Neurônios	Treinamentos		Média (%)
	MAPE 1 (%)	MAPE 2 (%)			MAPE 1 (%)	MAPE 2 (%)	
1	23,85	24,08	23,96	31	11,09	10,94	11,01
2	19,90	20,23	20,06	32	12,06	11,19	11,62
3	19,06	16,00	17,53	33	10,27	11,93	11,10
4	18,58	17,81	18,19	34	10,91	10,54	10,72
5	19,96	17,42	18,69	35	11,33	11,09	11,21
6	19,62	15,49	17,56	36	10,46	12,02	11,24
7	14,99	17,40	16,20	37	9,72	10,19	9,95
8	20,33	22,40	21,36	38	9,90	12,37	11,14
9	19,20	20,91	20,06	39	7,71	7,72	7,72
10	18,06	19,18	18,62	40	8,81	9,61	9,21
11	20,61	23,61	22,11	41	9,88	9,02	9,45
12	27,35	22,47	24,91	42	8,65	9,40	9,03
13	24,08	21,14	22,61	43	8,78	8,69	8,73
14	25,08	20,84	22,96	44	8,74	8,32	8,53
15	13,76	12,05	12,91	45	7,14	8,89	8,01
16	22,91	24,03	23,47	46	9,74	9,53	9,64
17	16,75	13,76	15,25	47	8,14	10,02	9,08
18	14,93	17,46	16,20	48	7,39	9,64	8,51
19	15,19	16,01	15,60	49	9,89	9,03	9,46
20	18,01	21,26	19,63	50	10,14	8,02	9,08
21	12,53	12,82	12,67	51	8,93	9,70	9,31
22	14,22	14,21	14,22	52	7,52	6,93	7,23
23	14,05	11,21	12,63	53	9,56	9,21	9,39
24	13,07	12,93	13,00	54	8,57	9,87	9,22
25	10,17	12,24	11,20	55	8,96	9,11	9,04
26	12,23	13,17	12,70	56	8,24	7,33	7,79
27	17,54	12,62	15,08	57	9,11	9,51	9,31
28	12,46	10,36	11,41	58	6,89	7,14	7,01
29	10,18	10,39	10,29	59	12,66	11,11	11,88
30	11,11	10,39	10,75	60	11,97	13,62	12,80

Fonte: Autor (2020).

Depois dos testes realizados, a estrutura da DL ficou definida com: Matriz com 3 atrasos e 1 saída; 3 neurônios na camada de entrada; 58 unidades ocultas de processamento; 1 neurônio na camada de saída. Vale ressaltar que os parâmetros apresentados foram escolhidos com base em uma série de treinamentos realizados, onde foram determinados os parâmetros de melhor desempenho.

Na Figura 5.36 são comparados os valores de irradiância solar em W/m^2 , obtidos através das previsões da DL e os valores medidos em Algeciras, para uma janela de demonstração de 5 dias, de 3 a 7 de janeiro de 2015.

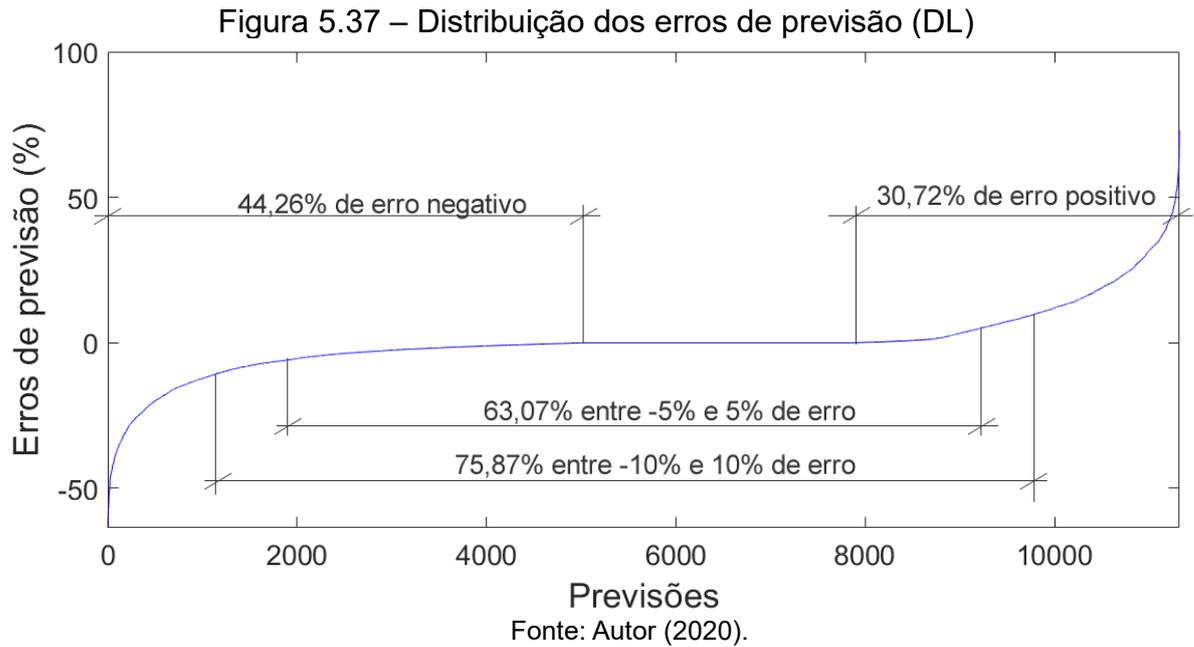
Figura 5.36 – Comparativo entre a irradiância solar prevista e medida (DL)



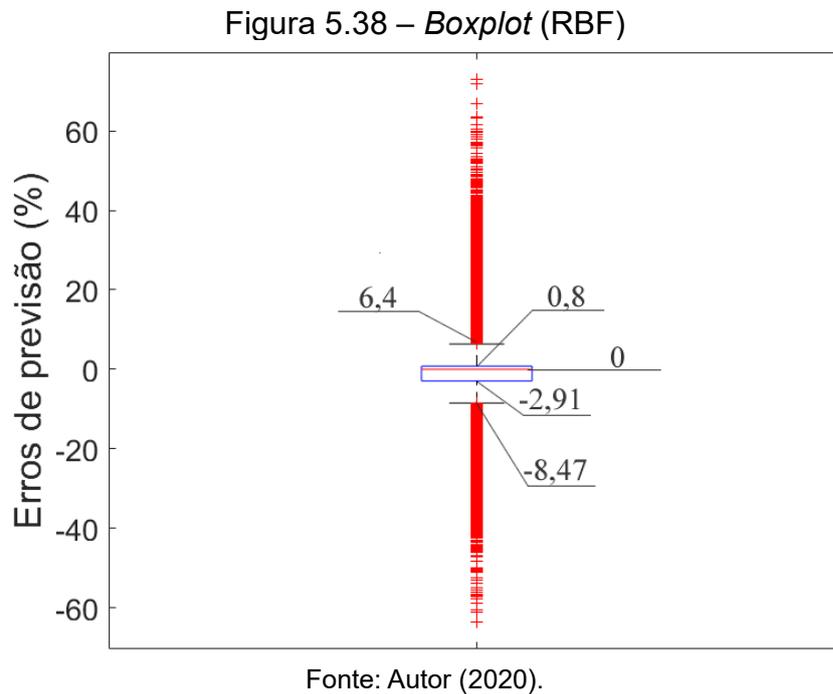
Fonte: Autor (2020).

As previsões de irradiância solar da DL conseguem acompanhar as variações de amplitudes ao longo do período analisado. De forma geral, a previsão se matém de forma estável, fazendo um acompanhamento da característica de intermitência da irradiância solar no decorrer das horas.

Na DL, um total de 44,26 % das previsões subestima a disponibilidade energética solar, 25,02 % das previsões obtém erro 0 e 30,72 % das previsões superestima o recurso solar. O erro negativo mais acentuado obtém um valor de -63,52 %, enquanto o positivo é de 72,93 %. Um total de 75,87 % das previsões está entre -10 % e 10 % de erro de previsão e 63,07 % das previsões está entre -5 % e 5 % de erro. O erro médio das previsões é de 0,36 % e o MAPE é de 6,89 %. Na Figura 5.37 é apresentada a distribuição dos erros de previsão.



A figura 5.38 apresenta o *Boxplot* das previsões da DL.

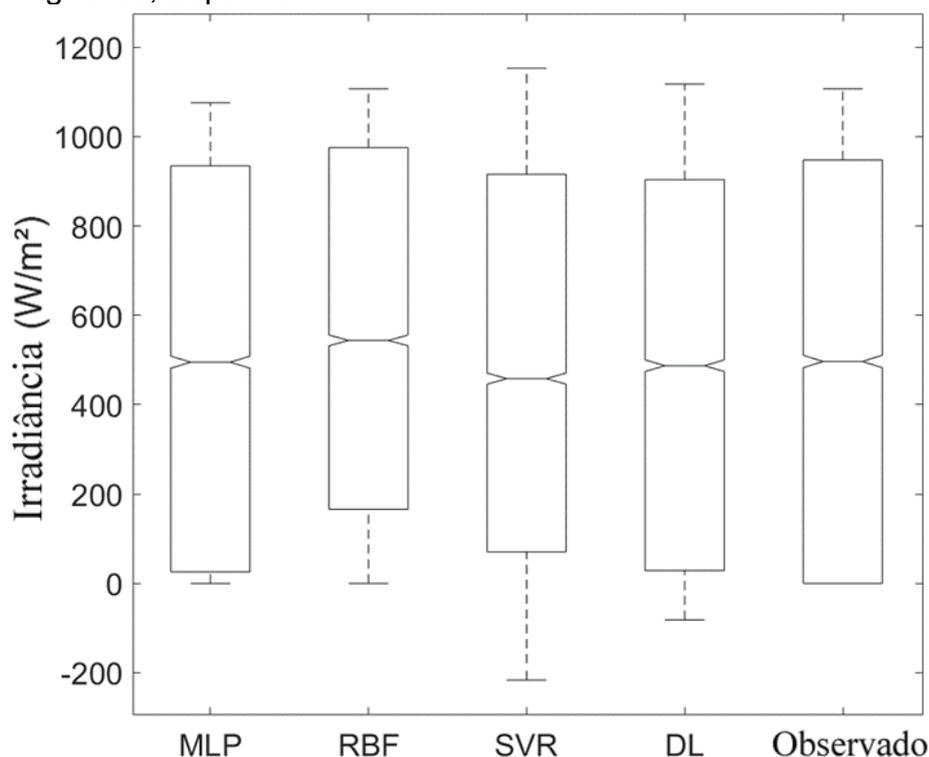


Os limites da amplitude interquadrática são -2,91 % a 0,8 %. O valor da mediana dos erros de previsão é de 0%, o que representa a tendência simétrica das previsões. Foram encontrados *outliers* de erros de previsão, onde os negativos variam de -63,52 % a -8,47 % e positivos que variam de 6,4 % a 72,93 %.

5.2.6 Integração das técnicas de previsão na Espanha

A caracterização dos dados antecipados pelas técnicas de previsão do recurso solar bem como os dados coletados em Algeciras, podem ser vistos na Figura 5.39 que representa o *Boxplot* dos dados supracitados.

Figura 5.39 – *Boxplot* dos dados observados e previstos em Algeciras, Espanha

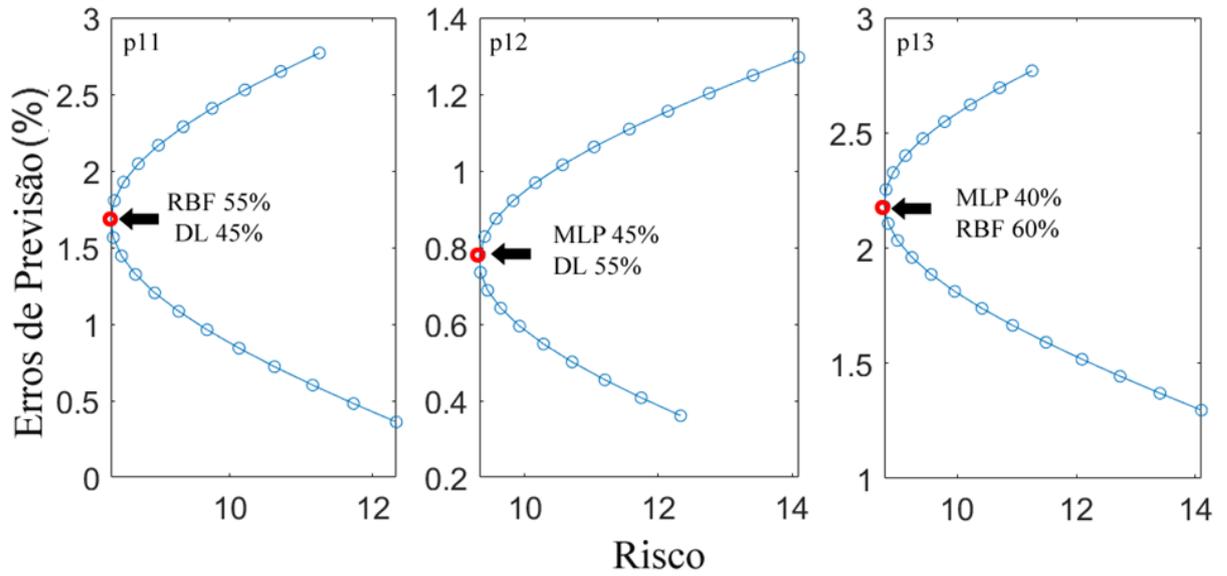


Fonte: Autor (2020).

Os limites da amplitude interquadrática são de 27,07 W/m² a 934,47 W/m² para a MLP, 165,86 W/m² a 975,16 W/m² para a RBF, 70,5 W/m² a 915,45 W/m² para a SVR, 28,76 W/m² a 903,17 W/m² para a DL e 0 W/m² a 947,5 W/m² para os dados coletados no período de teste. Através do comparativo, pode-se perceber que o melhor resultado foi obtido pela DL.

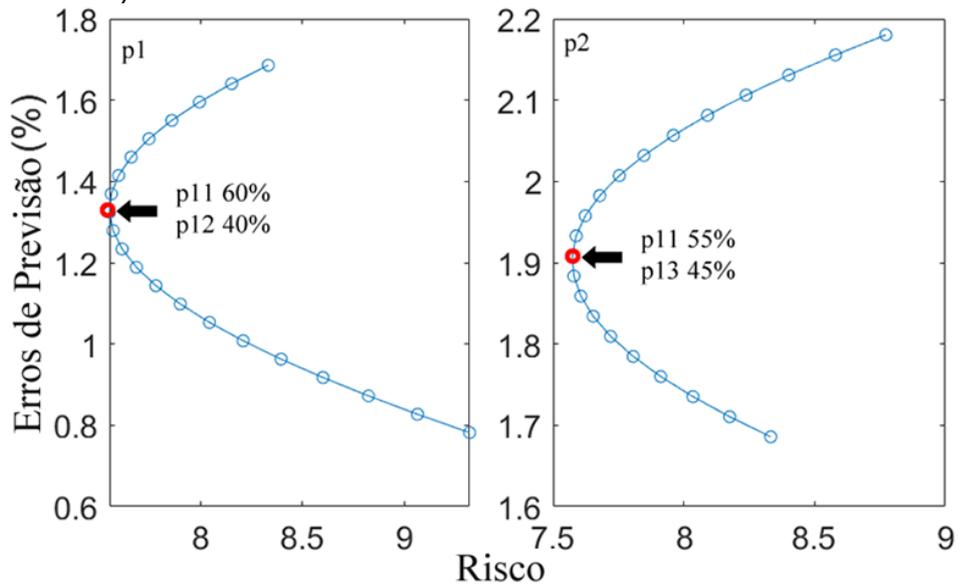
A partir dos resultados encontrados para as técnicas de previsão do recurso solar, bem como a metodologia de integração dos ativos propostas pela PrevTP, são criados os gráficos de Fronteiras Eficientes das conexões presentes nas 3 camadas do algoritmo proposto. As Figuras 5.40, 5.41 e 5.42 apresentam os gráficos de Fronteiras Eficientes das três camadas da PrevTP na Espanha.

Figura 5.40 – Desenvolvimento das Fronteiras Eficientes (primeira camada)



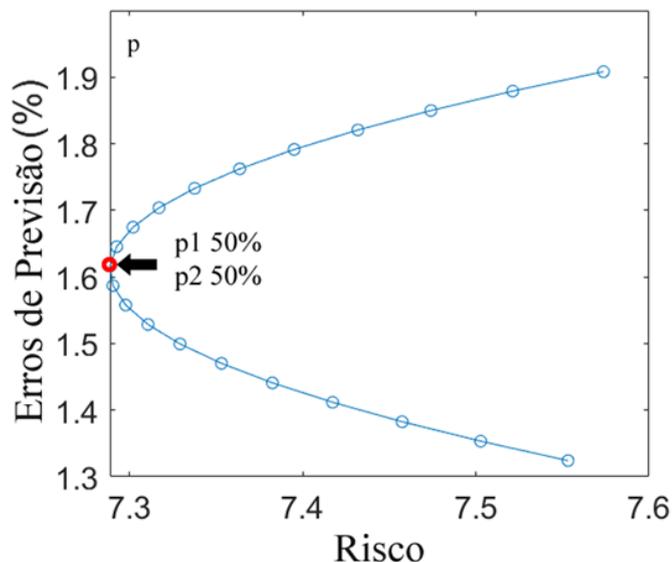
Fonte: Autor (2020).

Figura 5.41 – Desenvolvimento das Fronteiras Eficientes (segunda camada)



Fonte: Autor (2020).

Figura 5.42 – Desenvolvimento das Fronteiras Eficientes (saída)



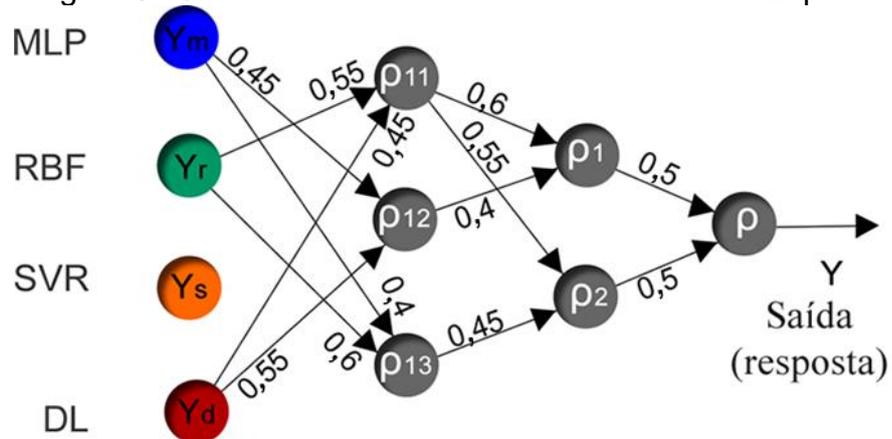
Fonte: Autor (2020).

A primeira camada da PrevTP é definida com uma conexão p11 (55 % RBF – 45 % DL), conexão p12 (45 % MLP – 55% DL) e conexão p13 (40 % MLP – 60 % RBF). A segunda camada é definida a partir da conexão p1 (60 % p11 – 40 % p12) e conexão p2 (55 % p11 – 45 % p13). A saída da PrevTP na Espanha é definida com 50 % da conexão p1 e 50 % de p2.

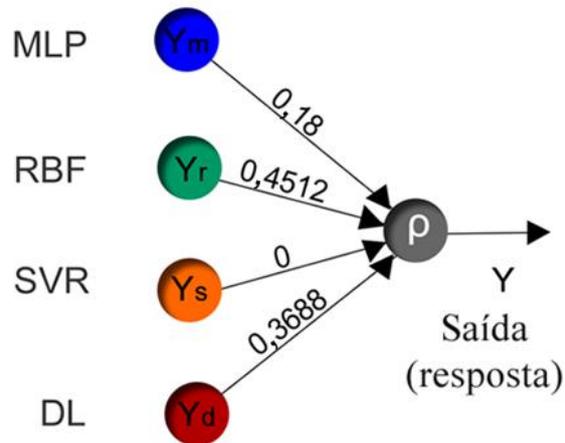
Os resultados das Fronteiras Eficientes apresentam o portfólio ótimo da integração, ou seja, a combinação com os menores riscos de erros de previsão. Todas as conexões apresentadas anteriormente podem ser matematicamente simplificadas para uma ponderação com 18 % de MLP, 45,12 % de RBF, 0 % de SVR e 36,88 % de DL.

A PrevTP, em sua característica de estrutura auto-adaptativa, encontrou a melhor combinação que pode ser vista na Figura 5.43 (a) em sua estrutura completa e (b) em sua forma simplificada matematicamente.

Figura 5.43 – Pesos e estrutura final da PrevTP na Espanha



(a)

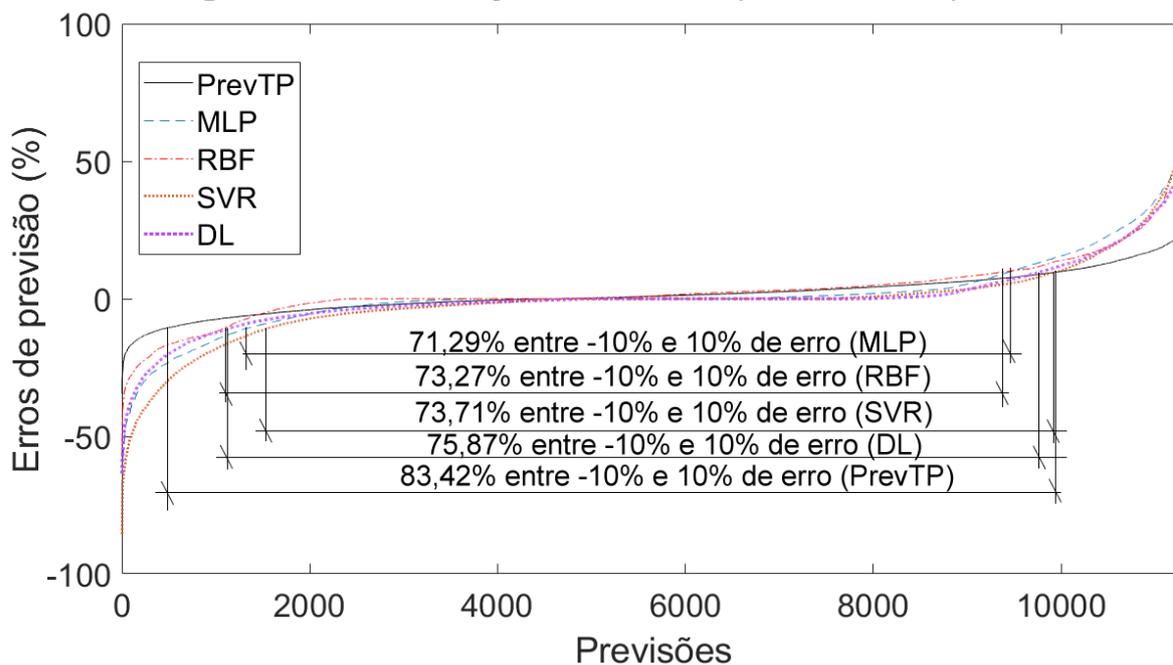


(b)

Fonte: Autor (2020).

Na Figura 5.44 é apresentada a comparação entre as distribuições dos erros das técnicas MLP, RBF, SVR, DL e PrevTP.

Figura 5.44 – Distribuição dos erros de previsão na Espanha



Fonte: Autor (2020).

Para a PrevTP, 39,76 % das previsões subestimaram a disponibilidade da energia solar e 58,84% superestimaram o recurso solar. O erro negativo mais acentuado obtém um valor de -34,47 %, enquanto o erro positivo mais acentuado é de 38,16 %. Um total de 83,42 % das previsões está entre -10% e 10% de erro de previsão.

O erro médio das previsões é de 1,61 % e o MAPE é de 5,36 %, que define a metodologia de integração como uma melhoria dos resultados individuais de cada técnica utilizada, uma vez que o MAPE da MLP é 8,06 %, O MAPE da RBF é de 7,16 %, o MAPE da SVR é de 8,34 % e a DL obtém um MAPE de 6,89 %. Na Tabela 5.27 são comparados os resultados individuais das técnicas utilizadas, bem como as integrações parciais e finais feitas pela PrevTP para os dados espanhóis. A comparação utiliza o mesmo banco de dados, horizontes e período de previsão, para gerar um comparativo entre as técnicas de previsão.

Tabela 5.27 – Comparação entre as técnicas de previsão solar

	MAPE (%)	MPE (%)	Faixa -10 (%) a 10 (%)
MLP	8,06	1,29	71,29
RBF	7,16	2,76	73,27
SVR	8,34	-0,89	73,71
DL	6,89	0,36	75,87
MLP/RBF	6,28	2,18	78,09
MLP/SVR	6,88	0,31	73,99
RBF/SVR	6,29	1,48	77,33
MLP/RBF/SVR	5,66	1,7	82,02
MLP/RBF/SVR/DL	5,36	1,61	83,42

Fonte: Autor (2020).

Na cidade de Algeciras, o clima é bem definido com quatro estações (inverno, primavera, verão, outono). Por esse motivo, os dados coletados para essas quatro sessões foram separados durante o período de teste para comprovar a aplicabilidade das técnicas utilizadas em diferentes condições climáticas. Na Tabela 5.28 são comparados os valores de MAPEs obtidos para as quatro estações. Os valores de MAPEs das técnicas de previsão são muito semelhantes para todos os períodos analisados.

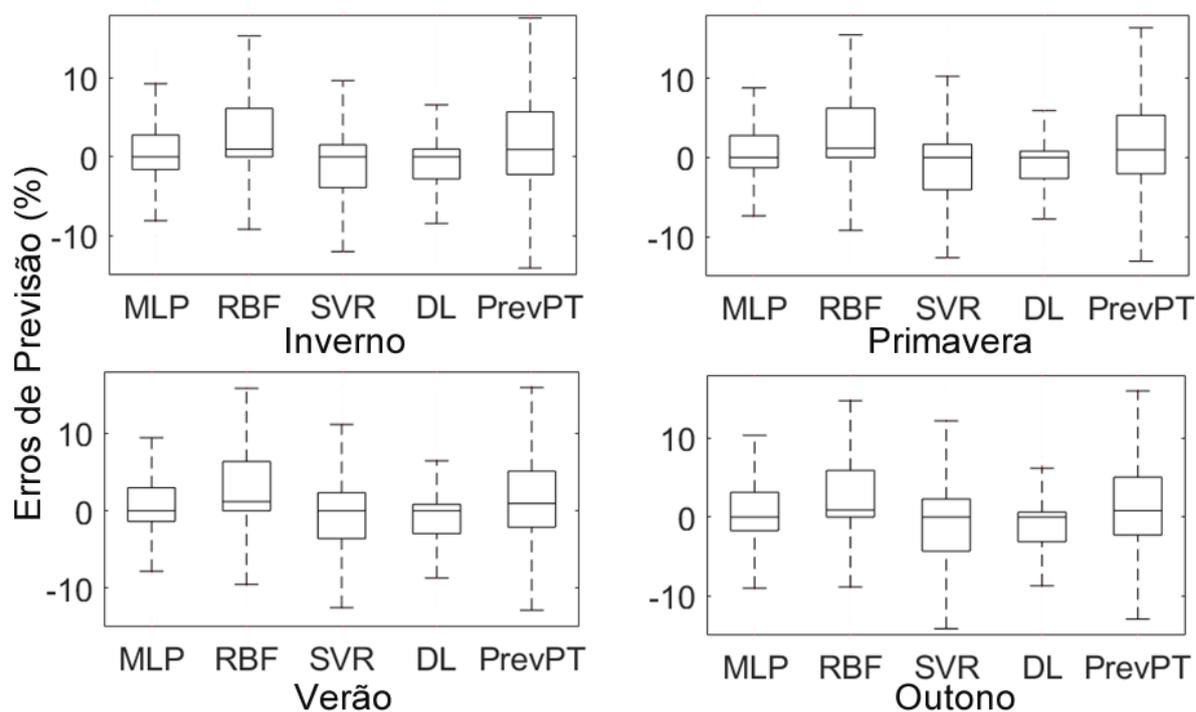
Tabela 5.28 – MAPE para as sessões chuvosas e sem chuva no Brasil

	Inverno	Primavera	Verão	Outono
MLP	8,16 %	8,14 %	7,8 %	8,17 %
RBF	7,22 %	7,13 %	7,23 %	7,07 %
SVR	8,12 %	8,5 %	8,07 %	8,64 %
DL	7,19 %	6,67 %	6,89 %	6,81 %
PrevTP	5,54 %	5,25 %	5,37 %	5,27 %

Fonte: Autor (2020).

Na Figura 5.45 é apresentado o *Boxplot* das técnicas de previsão para ambas as situações. Os resultados mostram que o comportamento das técnicas é muito semelhante para as quatro estações com disponibilidade solar diferente. Essa característica pode ser observada, por exemplo, comparando os limites da amplitude interquadrática da DL: -2,79 % a 0,98 % para o inverno, -2,66 % a 0,78 % para a primavera, -2,96 % a 0,84 % para o verão e -3,11 % a 0,63 % para o outono.

Figura 5.45 – *Boxplot* para as quatro estações do ano na Espanha



Fonte: Autor (2020).

5.3 Conclusões parciais

Neste capítulo são apresentados os resultados das técnicas aplicadas à previsão solar utilizadas nesse trabalho, em dois locais, Brasil e Espanha, bem como os resultados do processamento utilizando a PrevTP. Os resultados caracterizam que a PrevTP pode ser utilizada em diferentes locais, com diferentes propriedades climáticas, apresentando uma melhora das previsões através da integração de previsores.

6 CONCLUSÃO

A característica de intermitência de geração da fonte solar é um dos principais fatores de dificuldade de implementação dessa fonte na matriz elétrica mundial. Então, essa propriedade deve ser estudada no sentido de desenvolvimento de técnicas que possam reduzir os custos adicionais à produção de eletricidade provenientes de erros de previsão. Com isso, conclui-se que além da necessidade de ampliação das técnicas que possam ser utilizadas para previsibilidade, há também a necessidade do desenvolvimento de técnicas que possam ser aplicadas para o melhoramento de metodologias já existentes.

Na metodologia proposta, denominada de PrevTP, é apresentada uma definição da quantidade percentual de cada ativo, ou seja, apresenta uma ponderação para que diversas técnicas de previsão do recurso solar possam trabalhar conjunto. Nesta tese, onde foram consideradas 4 técnicas, foi possível perceber a redução dos erros de previsão através da integração.

Com os dados obtidos de previsão de irradiância solar, por meio da fundamentação matemática da PrevTP, é possível encontrar os percentuais de erros de previsão e posteriormente determinar a complementação ideal dos ativos para que os erros de uma técnica sejam amortizados pelos acertos ou erros de sinal contrário da outra. Com isso verifica-se que a PrevTP pode ser aplicada para integrar diversas técnicas de previsões diferentes.

A DL usada para previsão do recurso solar se destaca em comparação com todas as outras técnicas de previsão isoladas (MLP, RBF e SVR). Portanto, o uso da DL como preditor de recursos solares é altamente benéfico para a expansão da energia solar; a implementação desta técnica permite melhorias significativas em relação às outras técnicas usadas para comparação.

Considerando o uso da PrevTP para a integração de técnicas de previsão, a metodologia encontrou uma ponderação ideal para o impacto de cada uma das técnicas de previsão individuais, bem como em sua estrutura adaptativa, é capaz de desconsiderar alguma técnica que possa estar causando resultados negativos a um sistema de previsão de recursos solares. A PrevTP, em sua integração final obtém um desempenho melhor que os erros individuais de cada ativo. A comparar:

- O MAPE para MLP, RBF, SVR e DL no Brasil foi de 8,53 %, 6,32 %, 8 % e 6,08 %, respectivamente; enquanto a PrevTP obteve um

MAPE de 4,52 %. Na Espanha, o MAPE para MLP, RBF, SVR e DL foi de 8,06 %, 7,16 %, 8,34 % e 6,89 %, respectivamente; para PrevTP foi de 5,36 %;

- A faixa de -10 % a 10 % de erro de previsão para MLP, RBF, SVR e DL no Brasil foi de 70,48 %, 75,73 %, 72,32 % e 78,68 %, respectivamente; para PrevTP, foi de 90,23 %. Na Espanha, a faixa de -10 % a 10 % de erro de previsão para MLP, RBF, SVR e DL foi de 71,29 %, 73,27 %, 73,71 % e 75,87 %, respectivamente; para PrevTP foi de 83,42 %;

Conforme demonstrado pelo MAPE, as técnicas obtiveram resultados satisfatórios em relação à previsão de recursos solares. Características como maior variância e desvio padrão podem justificar piores índices de previsão obtidos na Espanha por quase todas as técnicas. O pior desempenho foi obtido pela SVR, com MAPE de 8 % no caso do Brasil e MAPE de 8,34 % no caso da Espanha, o que ainda pode ser definido como bom, considerando que essa técnica obteve uma taxa média de acerto de 92 % e 91,66 %, respectivamente. Considerando todas as metodologias apresentadas e locais estudados, as técnicas obtiveram uma taxa média de acerto de 91,66 % a 95,48 %, destacando a alta qualidade dos previsores empregados.

O uso da PrevTP é proposto como uma metodologia para encontrar os impactos ideais de cada técnica de previsão em um conjunto de técnicas integradas, com o objetivo de reduzir erros de previsibilidade. Pode-se concluir que o PrevTP é uma ferramenta com impactos positivos significativos para uma melhor gestão da energia solar, que pode ser submetida a diferentes condições climáticas, com diferentes disponibilidades de recursos solares e diferentes locais, conforme apresentado e testado aqui.

Para fins de comparação da PrevTP com outras técnicas de integração, seriam necessários a aplicação dos métodos ao mesmo banco de dados, horizontes, frequência, técnica de avaliação e período de previsão. Para exemplificar isso, a mesma técnica, A PrevTP, mesmo com resultados bons na Espanha e Brasil, obtém distintos MAPES para os dois locais. Então pode-se concluir que não é possível gerar um comparativo justo com outras técnicas aplicadas a outras variáveis.

Sugestões para trabalhos futuros

- Aplicar modelos matemáticos para determinar a capacidade de geração de eletricidade através dos recursos de irradiância solar, previstos e observados, presentes nesta tese.
- Desenvolver estudos dos impactos financeiros para os erros de previsibilidade de fontes intermitentes de energia.
- A partir de uma coleta de velocidade dos ventos, adaptar e utilizar a PrevTP para previsão do recurso eólico.
- Utilizar-se de outras técnicas de aprendizagem empregadas à previsibilidade de séries temporais, como ativo da PrevTP, seja para o recurso solar, seja para o recurso eólico.
- Aplicar técnicas de previsibilidade a partir de imagens do céu, unidas a técnicas que utilizem-se de métricas estatísticas de irradiância solar, com integração realizada pela PrevTP.

Artigos publicados vinculados ao projeto de pesquisa

Artigos publicados:

LIMA, M. A. F. B.; CARVALHO, P. C. M.; CARNEIRO, T. C.; LEITE, J. R.; BESSA NETO, L. J.; RODRIGUES, G. K. L.; MELO, F. E. *Portfolio Theory Applied to Solar and Wind Resources Forecast. IET Renewable Power Generation*, 2017.

LIMA, M. A. F. B.; CARVALHO, P. C. M.; BRAGA, A. P. S.; RAMÍREZ, L. M. F.; LEITE, J. R. *MLP Back Propagation Artificial Neural Network for Solar Resource Forecasting in Equatorial Areas. International Conference on Renewable Energies and Power Quality (ICREPQ'18), Salamanca (Spain)*, 2018.

LIMA, M. A. F. B.; CARVALHO, P. C. M.; BRAGA, A. P. S.; RAMÍREZ, L. M. F.; LEITE, J. R. *MLP Back Propagation Artificial Neural Network for Solar Resource Forecasting in Equatorial Areas. Renewable Energy and Power Quality Journal (RE&PQJ)*, 2018.

LIMA, M. A. F. B.; CARVALHO, P. C. M.; BRAGA, A. P. S.; PEREIRA, R. I. S.; JUCÁ, S. C. S.; RAMÍREZ, L. M. F.; LEITE, J. R. *Radial Basis Function for Solar Irradiance Forecasting in Equatorial Areas. International Conference on Renewable Energies and Power Quality (ICREPQ'19), Tenerife (Spain)*, 2019.

LIMA, M. A. F. B.; CARVALHO, P. C. M.; BRAGA, A. P. S.; PEREIRA, R. I. S.; JUCÁ, S. C. S.; RAMÍREZ, L. M. F.; LEITE, J. R. *Radial Basis Function for Solar Irradiance Forecasting in Equatorial Areas. Renewable Energy and Power Quality Journal (RE&PQJ)*, 2019.

LIMA, M. A. F. B.; CARVALHO, P. C. M.; BRAGA, A. P. S.; RAMÍREZ, L. M. F.; *Improving Solar Forecasting Using Deep Learning and Portfolio Theory Integration. Energy*, 2020.

REFERÊNCIAS

- ABUELLA, M.; CHOWDHURY, B. Random forest ensemble of support vector regression models for solar power forecasting. *In: 2017 IEEE POWER & ENERGY SOCIETY INNOVATIVE SMART GRID TECHNOLOGIES CONFERENCE (ISGT), 2017, Washington. Anais [...]* Washington: IEEE, 2017. p. 1-5. Disponível em: <http://ieeexplore.ieee.org/document/8086027/>. Acesso em: 12 nov. 2018.
- AGUIAR, M. *et al.* Combining solar irradiance measurements, satellite-derived data and a numerical weather prediction model to improve intra-day solar forecasting. **Renewable Energy**, v. 97, p. 599-610, nov. 2016. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0960148116305390>. Acesso: em 17 jan. 2017.
- ALFADDA, A.; RAHMAN, S.; PIPATTANASOMPORN, M. Solar irradiance forecast using aerosols measurements: a data driven approach. **Solar Energy**, v.170, p. 924-939, ago. 2018. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0038092X18305309>. Acesso em: 18 abr. 2019.
- AWAD, M; QASRAWI, I. Enhanced RBF neural network model for time series prediction of solar cells panel depending on climate conditions (temperature and irradiance). **Neural Computing and Applications**, v.30, p. 1757-1768, set. 2018. Disponível em: <http://link.springer.com/10.1007/s00521-016-2779-5>. Acesso em: 18 ago. 2019.
- AWERBUCH, S.; BERGER, M. **Applying portfolio theory to EU electricity planning and policy-making**. IEA/EET working paper, v. 3, p. 69, 2003. Disponível em: <https://www.osti.gov/etdeweb/biblio/20354690>. Acesso em: 15 ago. 2018.
- BEDI, J.; TOSHNIWAL, D. Deep learning framework to forecast electricity demand. **Applied Energy**, v. 238, p.1312-1326, mar. 2019. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0306261919301217>. Acesso em: 12 set. 2019.
- BELAID, S.; MELLIT, A. Prediction of daily and mean monthly global solar radiation using support vector machine in an arid climate. **Energy Conversion and Management**, v.118, p. 105-118, jun. 2016. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0196890416302199>. Acesso em: 20 set. 2018.
- BENGIO, Y. Learning deep architectures for AI. **Foundations and Trends in Machine Learning**, v. 2, n. 1, p. 1-127, 2009. Disponível em: <http://www.nowpublishers.com/article/Details/MAL-006>. Acesso em: 15 mar. 2019.
- BISHOP, C. **Pattern recognition and machine learning**. 1. ed. New York: Springer-Verlag New York, 2006, 738p.
- CAIXE, D. F. **Administração financeira**. 1. ed. Rio de Janeiro: SESES, 2015. 152 p.

CALSING, L. C. **Previsão de demanda combinada a partir de métodos quantitativos e opinião de especialistas**. 2015. 68 f. Dissertação (Mestrado Profissional em Engenharia de Produção) – Escola de Engenharia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2015. Disponível em: <http://hdl.handle.net/10183/127809>. Acesso em 10 out. 2018.

CARNEIRO, T. C. **Caracterização de potencial eólico para fins de geração eolielétrica**: Estudo de caso Para Maracanaú (CE), Parnaíba (PI) e Petrolina (PE). 2014. 207 f. Dissertação (Mestrado em Engenharia Elétrica) – Departamento de Engenharia Elétrica, Universidade Federal do Ceará, Fortaleza, 2014. Disponível em: <http://www.repositorio.ufc.br/handle/riufc/10666>. Acesso em 19 set. 2018.

CHAUDHARY, P.; RIZWAN, M. Energy management supporting high penetration of solar photovoltaic generation for smart grid using solar forecasts and pumped hydro storage system. **Renewable Energy**, v. 118, p. 928-946, abr. 2018. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0960148117310911>. Acesso em: 18 dez. 2018.

CHU, Y.; LI, M.; COIMBRA, C.F.M. Sun-tracking imaging system for intra-hour DNI forecasts, **Renewable Energy**, v.96, p. 792-799, out. 2016. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0960148116304529>. Acesso em: 20 maio 2018.

CUCCHIELLA, F.; GASTALDI, M.; TROSINI, M. Investments and cleaner energy production: a portfolio analysis in the Italian electricity market. **Journal of Cleaner Production**, v. 142, p. 121-132, jan. 2017. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0959652616310964>. Acesso em: 12 set. 2019.

CUNHA, J.; FERREIRA, P. Designing electricity generation portfolios using the mean-variance approach. **International Journal of Sustainable Energy Planning and Management**, v. 4, p. 17-30, 2014. Disponível em: <https://journals.aau.dk/index.php/sepm/article/view/562>. Acesso em: 11 abr. 2018.

DIAGNE, M.; *et al.* Review of solar irradiance forecasting methods and a proposition for small-scale insular grids. **Renewable and Sustainable Energy Reviews**, v. 27, p. 65-76, nov. 2013. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S1364032113004334>. Acesso em:

DU, P.; *et al.* Multi-step ahead forecasting in electrical power system using a hybrid forecasting system. **Renewable Energy**, v. 122, p. 533-550, jul. 2018. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S096014811830123X>. Acesso em: 10 dez. 2018.

EUROPEAN COMMISSION/INSTITUTE FOR ENERGY AND TRANSPORT. **Photovoltaic Geographical Information System**, 2019. Disponível em: <http://re.jrc.ec.europa.eu/pvgis/>. Acesso em: 04 set. 2019.

GITMAN, L. J. **Princípios de administração financeira**. 10. ed. São Paulo:

Pearson. 2005, 745 p.

GOOGLE. **UFC - campus do Pici - google my maps**, 2018. Disponível em: <https://www.google.com/maps/d/u/0/viewer?msa=0&ll=-3.7451590048256027%2C-38.57294400000001&spn=0.005813%2C0.010568&iwloc=0004b26637e4156c0a3c9&mid=1Q11xYZf7gY6o48TO56P6Zv3ARjc&z=16>. Acesso em 18 ago. 2018.

_____. **Reino de Algeciras**. Cadiz, Espanha, 2019. Disponível em: https://www.google.com/maps?sxsrf=ACYBGNT-leT_OAClik8pvzpSb2qqR--xvg:1581435502500&q=Algeciras,+C%C3%A1diz,+Espanha+google+map&uact=5&um=1&ie=UTF-8&sa=X&ved=2ahUKEwint_-26snnAhWiLLkGHchzA9EQ_AUoAXoECAsQAw. Acesso em 15 abr. 2019.

HAYKIN, S. **Redes Neurais: princípios e prática**. 2. ed. Porto Alegre: bookman. 2001, 902 p.

HOSSAIN, M. R.; OO, A. M. T.; ALI, A. B. M. S. Hybrid prediction method for solar power using different computational intelligence algorithms. **Smart Grid and Renewable Energy**, v. 04, n. 01, p. 76-87, 2013. Disponível em: <http://www.scirp.org/journal/doi.aspx?DOI=10.4236/sgre.2013.41011>. Acesso em: 20 ago. 2018.

HUSEIN, M.; CHUNG, I-YOP. Day-ahead solar irradiance forecasting for microgrids using a long short-term memory recurrent neural network: a deep learning approach. **Energies**, v. 12, n. 10, p. 1856, 15 maio 2019. Disponível em: <https://www.mdpi.com/1996-1073/12/10/1856>. Acesso em: 25 jan. 2018.

INMAN, R. H.; PEDRO, H. T. C.; COIMBRA, C. F. M. Solar forecasting methods for renewable energy integration. **Progress in Energy and Combustion Science**, v. 39, n. 6, p. 535-576, dez. 2013. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0360128513000294>. Acesso em: 20 fev. 2017.

INSTITUTO NACIONAL DE METEOROLOGIA. **Banco de dados meteorológicos para ensino e pesquisa**, 2019. Disponível em: <http://www.inmet.gov.br/portal/index.php?r=bdmep/bdmep>. Acesso em 04 set. 2019.

INTERNATIONAL ENERGY AGENCY. **Key world energy statistics 2018 energy statistics**. Report, 2018. 51 p. Disponível em: www.iea.org. Acesso em: 12 set. 2019.

INTERNATIONAL ENERGY AGENCY. **Snapshot of Global PV Markets 2020**. Report, 2020. 20 p. Disponível em: https://iea-pvps.org/wp-content/uploads/2020/04/IEA_PVPS_Snapshot_2020.pdf. Acesso em: 19 mai. 2020.

JANSEN J. C.; BEURSKENS, L. W. M.; TILBURG, X. V. 2006. **Application of portfolio analysis to the dutch generating mix reference case and two renewables cases: year 2030 – SE and GE scenario**. Energy Research Centre of the Netherlands, v.37, p. 1-67, fev. 2006. Disponível em: <https://publicaties.ecn.nl/PdfFetch.aspx?nr=ECN-C--05-100>. Acesso em: 19 out. 2018.

JIANG, H.; DONG, Y.; WANG, J. *et al.* Intelligent optimization models based on hard-ridge penalty and RBF for forecasting global solar radiation. **Energy Conversion and Management**, v.95, p. 42-58, maio. 2015.

Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0196890415001338>.

Acesso em: 20 maio 2018.

KABA, K.; *et al.* Estimation of daily global solar radiation using deep learning model. **Energy**, v. 162, p. 126-135, nov. 2018. Disponível em:

<https://linkinghub.elsevier.com/retrieve/pii/S0360544218315007>. Acesso em: 01 out. 2019.

KREY, B.; ZWEIFEL, P. **Efficient electricity portfolios for Switzerland and the United States**, University of Zurich, Working Paper, n. 602, p. 1-29, 2006. Disponível em: http://www.econ.uzh.ch/static/wp_soi/wp0602.pdf. Acesso em: 10 fev. 2018.

LIMA, M. A. F. B. **Teoria do portfólio aplicada à previsão de recursos solar e eólico**. 2016. 105 f. Dissertação (Mestrado em Engenharia Elétrica) – Departamento de Engenharia Elétrica, Universidade Federal do Ceará, Fortaleza, 2016. Disponível em: <http://www.repositorio.ufc.br/handle/riufc/22068>. Acesso em: 16 dez. 2018.

LIMA, M. A. F. B. *et al.* Portfolio theory applied to solar and wind resources forecast. **IET Renewable Power Generation**, v. 11, n. 7, p. 973-978, jun. 2017. Disponível em: <https://digital-library.theiet.org/content/journals/10.1049/iet-rpg.2017.0006>.

Acesso em: 29 nov. 2018.

MEENAL, R.; SELVAKUMAR, A. I. Assessment of SVM, empirical and ANN based solar radiation prediction models with most influencing input parameters. **Solar Energy**, v.121, p. 324-343, jun. 2018.

Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0960148117312016>.

Acesso em: 15 out 2019.

MELLIT, A.; PAVAN, A. M. A 24-h forecast of solar irradiance using artificial neural network: application for performance prediction of a grid-connected PV plant at Trieste, Italy. **Solar Energy**, v.84, p. 807-821, may. 2010.

Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0038092X10000782>.

Acesso em: 25 mar. 2018.

MINISTÉRIO DE MINAS E ENERGIA (Brasil). **Boletim mensal de monitoramento do sistema elétrico brasileiro**. Secretaria de Energia Elétrica, 2018. 29 p.

Disponível em: <http://www.mme.gov.br/web/guest/secretarias/energia-eletrica/publicacoes/boletim-de-monitoramento-do-sistema-eletrico/2018>. Acesso em: 18 ago. 2019.

MONCADA, A.; RICHARDSON, W.; VEGA-AVILA, R. Deep learning to forecast solar irradiance using a six-month UTSA skylmager dataset. **Energies**, v. 11, n. 8, p. 1988, 31 jul. 2018. Disponível em: <http://www.mdpi.com/1996-1073/11/8/1988>. Acesso em: 15 out. 2019.

MONJOLY, S. *et al.* Hourly forecasting of global solar radiation based on multiscale

decomposition methods: a hybrid approach. **Energy**, v. 119, p. 288-298, jan. 2017. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0360544216316668>. Acesso em: 10 out 2018.

NAÇÕES UNIDAS. **Apesar de baixa fertilidade, mundo terá 9,8 bilhões de pessoas em 2050**, desenvolvimento sustentável. Bruxelas, 2017. Disponível em: <https://nacoesunidas.org/apesar-de-baixa-fertilidade-mundo-tera-98-bilhoes-de-pessoas-em-2050/>. Acesso em: 28 Ago. 2018.

NARAYAN, A.; PONNAMBALAM, K. Risk-averse stochastic programming approach for microgrid planning under uncertainty. **Renewable Energy**, v. 101, p. 399 – 408, fev. 2017. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0960148116307741>. Acesso em: 12 jan. 2018.

NAZARI, M. S. *et al.* Climate policy uncertainty and power generation investments: a real options-CVaR portfolio optimization approach. **Energy Procedia**, v. 75, p. 2649 – 2657, ago. 2015. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S1876610215011352>. Acesso em: 21 maio 2018.

RAZA, M. Q.; MITHULANANTHAN, N.; SUMMERFIELD, A. Solar output power forecast using an ensemble framework with neural predictors and bayesian adaptive combination. **Solar Energy**, v.166, p. 236-241, maio 2018. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0038092X18302998>. Acesso em: 16 set. 2018.

ROQUES, F.; HIROUX, C.; SAGUAN, M. Optimal wind power deployment in Europe—a portfolio approach. **Energy Policy**, v. 38, n. 7, p. 3245-3256, jul. 2010. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S030142150900545X>. Acesso em: 20 jul. 2018.

SANTOS-ALAMILLOS, F. J. *et al.* Exploring the mean-variance portfolio optimization approach for planning wind repowering actions in Spain. **Renewable Energy**, v. 106, n. 2017, p. 335-342, jun. 2017. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0960148117300514>. Acesso em: 03. dez. 2018.

SHAHRIARI, M.; BLUMSACK, S. The capacity value of optimal wind and solar portfolios. **Energy**, v. 148, p. 992-1005, nov. 2018. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0360544217321643>. Acesso em 15 mar. 2019.

SPETH, V. Wind and solar portfolios and their impact on predictability: german case study 2010-2011. *In*: 11TH INTERNATIONAL WORKSHOP ON LARGE-SCALE INTEGRATION OF WIND POWER INTO POWER SYSTEMS AS WELL AS ON TRANSMISSION NETWORKS FOR OFFSHORE WIND POWER PLANTS. 11., 2012, Lisbon. **Anais** [...] Lisbon: energynautics, 2012. 1-6p. Disponível em: <https://windintegrationworkshop.org/lisbon2012/index.html>. Acesso em 10 set. 2018.

SPETH, V. **Diversification of wind and solar energy portfolio risk an explorative analysis for Germany 2010-2012**. 2013. 116f. Doctor dissertation (Doctor of Philosophy in Management) - School of Management, Economics, Law, Social Science and International Affairs, University of St. Gallen, Germany, 2013. Disponível em: [https://www1.unisg.ch/www/edis.nsf/SysLkpByIdentifier/4184/\\$FILE/dis4184.pdf](https://www1.unisg.ch/www/edis.nsf/SysLkpByIdentifier/4184/$FILE/dis4184.pdf). Acesso em 12 jun. 2017.

TOLA, M. Applying modern portfolio theory to plant electricity planning in Albania. **European Scientific Journal**, v. 11, p. 247-252, 2015. Disponível em: <https://eujournal.org/index.php/esj/article/view/5423>. Acesso em: 17 out. 2017.

VOYANT, C., NOTTON, G., KALOGIROU, S., et al. Machine learning methods for solar radiation forecasting: a review. **Renewable Energy**, v. 105, p. 569-582, maio. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0960148116311648>. Acesso em: 10 jul. 2018.

WANG, K.; QI, X.; LIU, H. Photovoltaic power forecasting based LSTM-convolutional network. **Energy**, v. 189, p. 116225, dez. 2019. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0360544219319206>. Acesso: 10 jan. 2020.

WANG, Y.; WU, L. On practical challenges of decomposition-based hybrid forecasting algorithms for wind speed and solar irradiation. **Energy**, v. 112, p. 208 - 220, out. 2016. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0360544216308490>. Acesso em: 28 abr. 2019.

WORLD ENERGY COUNCIL. **World energy resources | 2016**, World Energy Council 2016. London, 2017. Disponível em: <https://www.worldenergy.org/assets/images/imported/2016/10/World-Energy-Resources-Full-report-2016.10.03.pdf>. Acesso em: 30 ago. 2018.

WU, Y. K.; CHEN, C. R.; ABDUL RAHMAN, H. A novel hybrid model for short-term forecasting in PV power generation. **International Journal of Photoenergy**, v. 2014, p. 1 - 9, 2014. Disponível em: <http://www.hindawi.com/journals/ijp/2014/569249/>. Acesso em: 29 ago. 2018

ZENG, J.; QIAO, W. Short-term solar power prediction using a support vector machine. **Renewable Energy**, v.52, p. 118-127, abr. 2013. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0960148112006465>. Acesso em: 30 jul. 2019.