



UNIVERSIDADE DE ÉVORA

**ESCOLA DE CIÊNCIAS E TECNOLOGIA**

DEPARTAMENTO DE FÍSICA

**RECONSTRUÇÃO DE SÉRIES DE DADOS  
DE IRRADIAÇÃO SOLAR POR  
PROCESSOS DE MARKOV**

Frederico Steinmetz Alvarez

Orientação: Doutor Paulo Manuel Ferrão Canhoto

Doutor António Heitor da Silva Reis

**Mestrado em Engenharia da Energia Solar**

Dissertação

Évora, 2018





UNIVERSIDADE DE ÉVORA

**ESCOLA DE CIÊNCIAS E TECNOLOGIA**

DEPARTAMENTO DE FÍSICA

**RECONSTRUÇÃO DE SÉRIES DE DADOS  
DE IRRADIAÇÃO SOLAR POR  
PROCESSOS DE MARKOV**

Frederico Steinmetz Alvarez

Orientação: Doutor Paulo Manuel Ferrão Canhoto

Doutor António Heitor da Silva Reis

**Mestrado em Engenharia da Energia Solar**

Dissertação

Évora, 2018



Para Maria da Graça (*in memoriam*) e Frederico.



## RESUMO

Este trabalho apresenta uma técnica de reconstrução de séries de dados de irradiação solar global no plano horizontal com o uso de Processos de Markov e indexação dos níveis de irradiação com o algoritmo Google<sup>TM</sup>PageRank<sup>TM</sup>.

Foram utilizados dados de estações meteorológicas automáticas fornecidos pelo Instituto Nacional de Meteorologia (INMET) localizadas no estado brasileiro de Santa Catarina para o período 2008-2016.

Falhas sintéticas foram geradas para aplicar e avaliar o método proposto no presente trabalho. Os resultados foram avaliados através de um índice de performance global baseado em vários indicadores estatísticos.

Os parâmetros do modelo foram variados e feita uma análise para diferentes escalas de tempo. Os melhores ajustes foram obtidos com 5 a 10 classes de irradiação e coeficientes de amortização do algoritmo Google PageRank entre 0,85 e 0,95 para uma análise de base diária.



# ABSTRACT

## Reconstruction of Solar Irradiance Data Series by Markov's Processes

This work presents a technique for the reconstruction of global solar irradiation data series on the horizontal plane with the use of Markov's Processes and irradiation level indexation with the Google<sup>TM</sup>PageRank<sup>TM</sup>algorithm.

Data series from automatic meteorological stations of the National Institute of Meteorology (INMET) in the Brazilian state of Santa Catarina were used for the period 2008-2016.

Synthetic gaps were generated to apply and evaluate the method proposed in the present work. The results were evaluated by a global performance index based on several statistical indicators.

The parameters of the model were varied and an analyses for different time scales was carried out. The best adjustments were obtained with 5 to 10 irradiation classes and Google<sup>TM</sup>PageRank<sup>TM</sup>algorithm amortization coefficients between 0.85 and 0.95 for a daily basis analysis.



## AGRADECIMENTOS

Aos meus pais, Frederico e Maria da Graça (in memoriam), por sempre terem sido meus maiores motivadores e terem aceito a missão de educarem-me nesta minha passagem pelo planeta, sendo sempre as minhas referências de vida.

Ao meu irmão, Leonardo, que por toda a minha vida tem sido o meu amigo e parceiro e por todos os bons e maus momentos que já passamos e ainda passaremos juntos e, que com a minha cunhada, Rafaella, deram-me um maravilhoso presente e que é mais um motivo para eu ser uma pessoa melhor a cada dia, o meu sobrinho José Leonardo.

À minha madrinha, Marilda, que há muito assumiu o papel de mãe e sempre deu muito amor e carinho.

À minha namorada, Carolina (Pea), que mesmo nos momento que nem eu mesmo conseguia suportar ela estava ao meu lado.

Aos meus familiares, em especial a Frederico e Leninha, que sempre muito torcerem e apoio deram.

Aos meus orientadores, Paulo Canhoto e Heitor Reis, por toda a paciência e conhecimento transmitidos e tornaram-se muito mais do que professores, transformaram-se verdadeiros amigos que nunca se recusaram a estender a mão e muito apoio deram em momentos difíceis.

A Germilly e Joel, que ao longo desses quase dois anos tornaram-se verdadeiros irmãos e por toda a motivação e apoio que sempre deram.

Aos meus novos amigos portugueses Samuel, David, Carolina, Sara, Edgar, Ricardo, Gonçalo, Miguel, Massud e Eliane, além dos antigos amigos brasileiros - principalmente Fabiana - por todas as conversas e apoio.

À Lidia, Daniel e Cookie, por terem me recebido em vossa casa e darem-me a sensação de lar, sensação essa tão importante quando estamos longe do nosso.

Ao Instituto Nacional de Meteorologia (INMET) pelo fornecimento dos dados utilizados na realização do presente trabalho.

A todos, meu muito obrigado.



*Há uma força motriz mais poderosa do que o vapor, a electricidade ou a energia atómica:*

*a **vontade.***

*(Albert Einstein)*



# Índice

Lista de Figuras	xv
Lista de Tabelas	xx
Siglas	xx
Nomenclatura	xx
<b>1 Introdução</b>	<b>1</b>
1.1 Objetivo . . . . .	5
1.2 Estado da Arte . . . . .	5
1.2.1 Modelos lineares . . . . .	6
1.2.2 Modelos não-lineares . . . . .	6
1.2.3 Lógica <i>fuzzy</i> . . . . .	7
1.2.4 Redes neuronais artificiais . . . . .	9
1.3 Motivação . . . . .	10
1.4 Organização da dissertação . . . . .	11
<b>2 Energia Solar: Fundamentos, medição e avaliação do recurso</b>	<b>13</b>
2.1 Geometria Sol-Terra . . . . .	13
2.1.1 Órbita terrestre: afélio, periélio, solstício e equinócio . . . . .	13
2.1.2 Declinação solar . . . . .	15
2.1.3 Ângulo solar zenital . . . . .	15
2.1.4 Ângulo de elevação . . . . .	16
2.1.5 Ângulo de azimute . . . . .	16
2.1.6 Ângulo horário . . . . .	16
2.1.7 Ângulo de incidência . . . . .	17
2.2 Radiação solar . . . . .	17
2.2.1 O Sol como fonte de energia . . . . .	17
2.2.2 Espectro solar na superfície da Terra . . . . .	19

2.2.3	Medição do recurso solar disponível na superfície terrestre . . . . .	23
<b>3</b>	<b>Fundamentos Matemáticos do Processamento Realizado</b>	<b>29</b>
3.1	Fundamentos matemáticos das cadeias de Markov . . . . .	29
3.1.1	Equações de Chapman-Kolmogorov . . . . .	31
3.1.2	Algoritmo Google™ PageRank™ . . . . .	33
3.2	Indicadores estatísticos para avaliação de modelos . . . . .	35
3.2.1	Erro relativo máximo absoluto . . . . .	35
3.2.2	Erro médio . . . . .	36
3.2.3	Erro absoluto médio . . . . .	36
3.2.4	Erro absoluto relativo médio . . . . .	36
3.2.5	Erro quadrático médio . . . . .	36
3.2.6	Erro quadrático médio relativo . . . . .	36
3.2.7	Raiz da média dos desvios quadráticos relativos . . . . .	37
3.2.8	Erro estatística-t . . . . .	37
3.2.9	Coefficiente de correlação . . . . .	37
3.2.10	Incerteza a 95% . . . . .	38
3.2.11	Índice de desempenho global . . . . .	38
<b>4</b>	<b>Aplicação de Processos de Markov na Reconstrução de séries de Radiação Solar Global</b>	<b>41</b>
4.1	Obtenção dos dados . . . . .	41
4.2	Montagem da base de dados . . . . .	43
4.2.1	Nomes dos ficheiros . . . . .	44
4.2.2	Nomes das variáveis . . . . .	44
4.2.3	Número de colunas dos ficheiros . . . . .	45
4.3	Tratamento e filtragem dos dados . . . . .	45
4.3.1	Verificação da sincronização dos dados . . . . .	46
4.3.2	Dados nulos de irradiação solar global . . . . .	47
4.3.3	Validação dos dados . . . . .	47
4.4	Processamento realizado . . . . .	50
4.4.1	Identificação das falhas . . . . .	50
4.4.2	Seleção dos dados para geração da simulação . . . . .	50
4.4.3	Filtragem e tratamento dos dados selecionados . . . . .	51
4.4.4	Cálculo dos limites de irradiação utilizados nos modelos . . . . .	52
4.4.5	Geração das classes de irradiação . . . . .	52
4.4.6	Geração da matriz de transição de estados . . . . .	53

4.4.7	Obtenção do valor final da estimativa . . . . .	54
4.4.8	Seleção da melhor combinação de parâmetros . . . . .	55
<b>5</b>	<b>Análise e discussão dos resultados</b>	<b>57</b>
<b>6</b>	<b>Conclusões e sugestões para trabalhos futuros</b>	<b>67</b>
<b>A</b>	<b>Explicações sobre as tabelas e gráficos dos apêndices</b>	<b>75</b>
<b>B</b>	<b>Resultados para a estação A841</b>	<b>77</b>
<b>C</b>	<b>Resultados para a estação A858</b>	<b>91</b>
<b>D</b>	<b>Resultados para a estação A859</b>	<b>105</b>
<b>E</b>	<b>Resultados para a estação A860</b>	<b>119</b>
<b>F</b>	<b>Resultados para a estação A875</b>	<b>133</b>
<b>G</b>	<b>Resultados para a estação A876</b>	<b>147</b>



# Lista de Figuras

1.1	Consumo energético mundial estimado para o ano de 2017. . . . .	1
1.2	Proporção de demanda de calor industrial por gamas de temperatura. . . . .	4
1.3	Exemplo com escala de temperaturas para ilustrar a lógica <i>fuzzy</i> . <b>Fonte:</b> Adaptado de [1] . . . . .	8
1.4	Exemplo esquemático de uma rede neuronal artificial para predição de irradiação solar global. . . . .	9
1.5	Representação esquemática dos neurónios presentes nas camadas de uma RNA. <b>Fonte:</b> Adaptado de [2] . . . . .	9
2.1	Posição da Terra em relação aos raios solares incidentes nos solstícios de dezembro e de junho. . . . .	14
2.2	Representação dos ângulos solar zenital ( $\theta$ ), de elevação ( $e$ ) e de azimute ( $\Phi$ ) .	16
2.3	Dimensões do Sol e da Terra e seu afastamento. . . . .	18
2.4	Comparativo do espectro de radiação de um corpo negro ideal com a radiação solar que chega ao topo da atmosfera e à superfície terrestre. . . . .	19
2.5	Representação dos fenómenos aos quais a radiação solar está sujeita ao atravessar a atmosfera terrestre. <b>Fonte:</b> Adaptado de [3] . . . . .	20
2.6	Valores médios de longo prazo de GHI. . . . .	21
2.7	Valores aproximados de albedo da superfície terrestre. . . . .	22
2.8	Pireliómetros montados em um seguidor solar durante processo de medição da radiação solar direta. . . . .	23
2.9	Piranómetro sombreado por uma banda para medição da radiação difusa. . . . .	24
2.10	Exemplo de piranómetro sem a banda de sombreamento, utilizado para medir a GHI. . . . .	25
2.11	Impacto nos valores de irradiância solar direta normal, difusa e global no plano horizontal com a variação da espessura óptica. . . . .	25
2.12	Impacto nos níveis de DNI, DHI e GHI em função do tipo de aerossóis na atmosfera. . . . .	26

2.13	Comportamento das componente de irradiância direta normal (verde), difusa (vermelho) e global no plano horizontal (azul) para diferentes situações de cobertura de nuvens. Valores em $W/m^2$ entre as 06 e 18 horas UTC.	
	<b>Fonte:</b> [4].	27
3.1	Exemplo de um processo estocástico para a construção da Cadeia de Markov.	30
4.1	Localização das estações meteorológicas automáticas da rede INMET utilizadas no presente trabalho.	42
4.2	Exemplo da distribuição dos dados nos ficheiros recebidos do INMET.	44
5.1	Comparativo entre os valores medidos e estimados através dos parâmetros de melhor ajuste para a análise diária e mensal numa situação de céu limpo na estação A841 durante o mês de abril de 2015.	61
5.2	Comparativo entre os valores medidos e estimados através dos parâmetros de melhor ajuste para a análise diária e mensal numa situação de céu limpo na estação A860 durante o mês de junho de 2016.	62
5.3	Comparativo entre os valores medidos e estimados através dos parâmetros de melhor ajuste para a análise diária e mensal numa situação de céu em transição na estação A858 durante o mês de outubro de 2012.	63
5.4	Comparativo entre os valores medidos e estimados através dos parâmetros de melhor ajuste para a análise diária e mensal numa situação de céu em transição na estação A859 durante o mês de junho de 2013.	64
5.5	Comparativo entre os valores medidos e estimados através dos parâmetros de melhor ajuste para a análise diária e mensal numa situação de céu instável na estação A875 durante o mês de junho de 2012.	65
B.1	Análises para a estação A841 para o mês de fevereiro de 2015.	79
B.2	Análises para a estação A841 para o mês de abril de 2015.	81
B.3	Análises para a estação A841 para o mês de junho de 2015.	83
B.4	Análises para a estação A841 para o mês de agosto de 2015.	85
B.5	Análises para a estação A841 para o mês de outubro de 2015.	87
B.6	Análises para a estação A841 para o mês de dezembro de 2015.	89
C.1	Análises para a estação A858 para o mês de fevereiro de 2012.	93
C.2	Análises para a estação A858 para o mês de abril de 2012.	95
C.3	Análises para a estação A858 para o mês de junho de 2012.	97
C.4	Análises para a estação A858 para o mês de agosto de 2012.	99

C.5	Análises para a estação A858 para o mês de outubro de 2012. . . . .	101
C.6	Análises para a estação A858 para o mês de dezembro de 2012. . . . .	103
D.1	Análises para a estação A859 para o mês de fevereiro de 2013. . . . .	107
D.2	Análises para a estação A859 para o mês de abril de 2013. . . . .	109
D.3	Análises para a estação A859 para o mês de junho de 2013. . . . .	111
D.4	Análises para a estação A859 para o mês de agosto de 2013. . . . .	113
D.5	Análises para a estação A859 para o mês de outubro de 2013. . . . .	115
D.6	Análises para a estação A859 para o mês de dezembro de 2013. . . . .	117
E.1	Análises para a estação A860 para o mês de fevereiro de 2016. . . . .	121
E.2	Análises para a estação A860 para o mês de abril de 2016. . . . .	123
E.3	Análises para a estação A860 para o mês de junho de 2016. . . . .	125
E.4	Análises para a estação A860 para o mês de agosto de 2016. . . . .	127
E.5	Análises para a estação A860 para o mês de outubro de 2016. . . . .	129
E.6	Análises para a estação A860 para o mês de dezembro de 2016. . . . .	131
F.1	Análises para a estação A875 para o mês de fevereiro de 2012. . . . .	135
F.2	Análises para a estação A875 para o mês de abril de 2012. . . . .	137
F.3	Análises para a estação A875 para o mês de junho de 2012. . . . .	139
F.4	Análises para a estação A875 para o mês de agosto de 2012. . . . .	141
F.5	Análises para a estação A875 para o mês de outubro de 2012. . . . .	143
F.6	Análises para a estação A875 para o mês de dezembro de 2012. . . . .	145
G.1	Análises para a estação A876 para o mês de fevereiro de 2009. . . . .	149
G.2	Análises para a estação A876 para o mês de abril de 2009. . . . .	151
G.3	Análises para a estação A876 para o mês de junho de 2009. . . . .	153
G.4	Análises para a estação A876 para o mês de agosto de 2009. . . . .	155
G.5	Análises para a estação A876 para o mês de outubro de 2009. . . . .	157
G.6	Análises para a estação A876 para o mês de dezembro de 2009. . . . .	159



# Lista de Tabelas

1.1	Gamas de temperatura de alguns processos industriais. . . . .	3
1.2	Redução do consumo de combustível ao usar ar pré-aquecido na combustão de gás com 10% de excesso de ar. Valores em percentual [%]. <b>Fonte:</b> Adaptado de [5] . . . . .	4
1.3	Funções de ativação mais utilizadas nos processos de redes neuronais artificiais. <b>Fonte:</b> [6] . . . . .	10
2.1	Valores típicos de albedo para diferentes tipos de coberturas/superfícies. <b>Fonte:</b> Adaptado de [7] . . . . .	22
3.1	Matriz de transição de estados de Markov do exemplo da Figura 3.1. . . . .	31
4.1	Dados referentes às coordenadas geográficas e altitude das estações utilizadas no presente trabalho. . . . .	42
4.2	Códigos, datas de início de operação, primeiro e último dia com registos e total de dias na base de dados do INMET para cada estação. . . . .	43
4.3	Padrão de códigos adotado para a validação dos dados de irradiação solar global utilizados no trabalho. . . . .	48
4.4	Inventário dos registos de irradiação solar global - Quantidades absolutas de dados após aplicação dos filtros de qualidade BSRN. . . . .	49
4.5	Inventário dos registos de irradiação solar global - Qualidade dos dados referentes ao período diurno após aplicação dos filtros de qualidade dos dados. . .	49
4.6	Tabela exemplo dos valores para as classes de irradiação para uma falha com limite máximo aceitável 3600 kJ/m <sup>2</sup> e 6 classes. Valores mínimos e máximos em kJ/m <sup>2</sup> . . . . .	54
4.7	Tabela exemplo dos valores para as classes de irradiação para uma falha com limite máximo aceitável 3600 kJ/m <sup>2</sup> e 6 classes após a divisão em subclasses. Valores em kJ/m <sup>2</sup> . . . . .	55

5.1	Tabela resumo com o número de ocorrências dos parâmetros de simulações que apresentaram os melhores ajustes considerando todos os períodos de análise de um dia. . . . .	58
5.2	Resumo dos indicadores estatísticos entre os valores medidos ( $I_m$ ) e estimados ( $I_e$ ) através da metodologia proposta no presente trabalho para todas as horas simuladas nas 6 estações ao considerar o modelo com o melhor ajuste dia a dia. 59	59
5.3	Comparativo dos indicadores estatísticos entre os valores medidos ( $I_m$ ) e os estimados ( $I_e$ ) entre os dias 1 e 28 de dezembro de 2009 para a estação A876 ao considerar os 4 espaços temporais de análise do melhor modelo. . . . .	60
A.1	Dias limite considerados para cada período semanal e quinzenal para as análises e geração dos gráficos. . . . .	75
B.1	Parâmetros de melhor ajuste por período para o mês de fevereiro de 2015 na estação A841. . . . .	78
B.2	Parâmetros de melhor ajuste por período para o mês de abril de 2015 na estação A841. . . . .	80
B.3	Parâmetros de melhor ajuste por período para o mês de junho de 2015 na estação A841. . . . .	82
B.4	Parâmetros de melhor ajuste por período para o mês de agosto de 2015 na estação A841. . . . .	84
B.5	Parâmetros de melhor ajuste por período para o mês de outubro de 2015 na estação A841. . . . .	86
B.6	Parâmetros de melhor ajuste por período para o mês de dezembro de 2015 na estação A841. . . . .	88
C.1	Parâmetros de melhor ajuste por período para o mês de fevereiro de 2012 na estação A858. . . . .	92
C.2	Parâmetros de melhor ajuste por período para o mês de abril de 2012 na estação A858. . . . .	94
C.3	Parâmetros de melhor ajuste por período para o mês de junho de 2012 na estação A858. . . . .	96
C.4	Parâmetros de melhor ajuste por período para o mês de agosto de 2012 na estação A858. . . . .	98
C.5	Parâmetros de melhor ajuste por período para o mês de outubro de 2012 na estação A858. . . . .	100

C.6	Parâmetros de melhor ajuste por período para o mês de fevereiro de 2012 na estação A858. . . . .	102
D.1	Parâmetros de melhor ajuste por período para o mês de fevereiro de 2013 na estação A859. . . . .	106
D.2	Parâmetros de melhor ajuste por período para o mês de abril de 2013 na estação A859. . . . .	108
D.3	Parâmetros de melhor ajuste por período para o mês de junho de 2013 na estação A859. . . . .	110
D.4	Parâmetros de melhor ajuste por período para o mês de agosto de 2013 na estação A859. . . . .	112
D.5	Parâmetros de melhor ajuste por período para o mês de outubro de 2013 na estação A859. . . . .	114
D.6	Parâmetros de melhor ajuste por período para o mês de dezembro de 2013 na estação A859. . . . .	116
E.1	Parâmetros de melhor ajuste por período para o mês de fevereiro de 2016 na estação A860. . . . .	120
E.2	Parâmetros de melhor ajuste por período para o mês de abril de 2016 na estação A860. . . . .	122
E.3	Parâmetros de melhor ajuste por período para o mês de junho de 2016 na estação A860. . . . .	124
E.4	Parâmetros de melhor ajuste por período para o mês de agosto de 2016 na estação A860. . . . .	126
E.5	Parâmetros de melhor ajuste por período para o mês de outubro de 2016 na estação A860. . . . .	128
E.6	Parâmetros de melhor ajuste por período para o mês de dezembro de 2016 na estação A860. . . . .	130
F.1	Parâmetros de melhor ajuste por período para o mês de fevereiro de 2012 na estação A875. . . . .	134
F.2	Parâmetros de melhor ajuste por período para o mês de abril de 2012 na estação A875. . . . .	136
F.3	Parâmetros de melhor ajuste por período para o mês de junho de 2012 na estação A875. . . . .	138
F.4	Parâmetros de melhor ajuste por período para o mês de agosto de 2012 na estação A875. . . . .	140

F.5	Parâmetros de melhor ajuste por período para o mês de outubro de 2012 na estação A875. . . . .	142
F.6	Parâmetros de melhor ajuste por período para o mês de dezembro de 2012 na estação A875. . . . .	144
G.1	Parâmetros de melhor ajuste por período para o mês de fevereiro de 2009 na estação A876. . . . .	148
G.2	Parâmetros de melhor ajuste por período para o mês de abril de 2009 na estação A876. . . . .	150
G.3	Parâmetros de melhor ajuste por período para o mês de junho de 2009 na estação A876. . . . .	152
G.4	Parâmetros de melhor ajuste por período para o mês de agosto de 2009 na estação A876. . . . .	154
G.5	Parâmetros de melhor ajuste por período para o mês de outubro de 2009 na estação A876. . . . .	156
G.6	Parâmetros de melhor ajuste por período para o mês de dezembro de 2009 na estação A876. . . . .	158



# Siglas

<b>ASTM</b>	<i>American Society for Testing and Materials</i>
<b>BSRN</b>	<i>Baseline Surface Radiation Network</i>
<b>DHI</b>	<i>Diffuse Horizontal Irradiation</i>
<b>DNI</b>	<i>Direct Normal Irradiation</i>
<b>erMAX</b>	Erro Relativo Máximo Absoluto ( <i>Maximum Absolute Relative Error</i> )
<b>ETR</b>	<i>Extraterrestrial Irradiation</i>
<b>GHI</b>	<i>Global Horizontal Irradiation</i>
<b>GPI</b>	Índice de Desempenho Global ( <i>Global Performance Index</i> )
<b>INMET</b>	Instituto Nacional de Meteorologia
<b>LER</b>	Limite extremamente raro de GHI
<b>LFP</b>	Limite fisicamente possível de GHI
<b>MAE</b>	Erro Absoluto Médio ( <i>Mean Absolute Error</i> )
<b>MARE</b>	Erro Absoluto Relativo Médio ( <i>Mean Absolute Relative Error</i> )
<b>MBE</b>	Erro Médio ( <i>Mean Bias Error</i> )
<b>NREL</b>	<i>National Renewable Energy Laboratory</i>
<b>R<sup>2</sup></b>	Coefficiente de correlação de Pearson
<b>RMSE</b>	Erro Quadrático Médio ( <i>Root Mean Square Error</i> )
<b>RMSRE</b>	Erro Quadrático Médio Relativo ( <i>Root Mean Squared Relative Error</i> )
<b>RNA</b>	Rede Neuronal Artificial
<b>RRMSE</b>	Raiz da Média dos Desvios Quadráticos Relativos ( <i>Relative Root Mean Square Error</i> )
<b>SGBD</b>	Sistema Gerenciador de Base de Dados
<b>SONDA</b>	Sistema de Organização Nacional de Dados Ambientais
<b>SPA</b>	<i>Sun Position Algorithm</i>
<b>t-stat</b>	Estatística-t ( <i>t-Statistic</i> )
<b>TSI</b>	<i>Total Solar Irradiance</i>
<b>U<sub>95%</sub></b>	Incerteza a 95% ( <i>Uncertainty at 95%</i> )
<b>UTC</b>	<i>Universal Time Coordinated</i>

# Nomenclatura

Símbolo	Descrição	Unidade
$c_j$	Soma dos elementos da coluna $j$ da matriz de conectividades $\mathbf{G}$	–
$\mathbf{D}$	Matriz diagonal do algoritmo Google PageRank	–
$e$	Ângulo de elevação solar	°
$\mathbf{e}$	Vector unitário	–
$erMAX$	Erro Relativo Máximo Absoluto ( <i>Maximum Absolute Relative Error</i> )	–
$F$	Energia incidente por unidade de área numa superfície horizontal	$\text{kJ/m}^2$
$g_{ij}$	Conectividade do estado $i$ para o estado $j$	–
$\mathbf{G}$	Matriz de conectividades do algoritmo Google <sup>TM</sup> PageRank <sup>TM</sup>	–
$G_{SC}$	Constante solar (1362.92)	$\text{W/m}^2$
$GPI$	Índice de Desempenho Global ( <i>Global Performance Index</i> )	–
$H$	Ângulo horário	°
$I_0$	Irradiação solar diária numa superfície horizontal no topo da atmosfera terrestre	$\text{kJ/m}^2$
$I_d$	Irradiação solar diária numa superfície horizontal	$\text{kJ/m}^2$
$I_t$	Irradiação solar (horária ou diária) incidente numa superfície horizontal	$\text{kJ/m}^2$
$K_t$	Índice de claridade	–
$L$	Latitude	°
$L_a$	Espessura da atmosfera	m
$m$	Massa de ar relativa	–
$MAE$	Erro Absoluto Médio ( <i>Mean Absolute Error</i> )	$\text{kJ/m}^2$

<b>Símbolo</b>	<b>Descrição</b>	<b>Unidade</b>
$MARE$	Erro Absoluto Relativo Médio ( <i>Mean Absolute Relative Error</i> )	–
$MBE$	Erro Médio ( <i>Mean Bias Error</i> )	$\text{kJ/m}^2$
$n$	Número de classes de irradiação	–
$p$	Coefficiente de amortização do algoritmo Google™ PageRank™	–
$p_{ij}$	Probabilidade de transição do estado $i$ para o estado $j$	–
$\mathbf{P}$	Matriz das probabilidades de transição de estados do processo de Markov	–
$PR(x)$	Probabilidade de ocorrência do valor $x$	–
$r_i$	Soma dos elementos da linha $i$ da matriz de conectividades $\mathbf{G}$	–
$R$	Afastamento instantâneo da Terra em relação ao Sol	m
$R_0$	Afastamento médio da Terra em relação ao Sol	m
$R_{Sol}$	Raio do Sol	m
$R_t$	Raio da Terra	m
$R^2$	Coefficiente de correlação de Pearson	–
$RMSE$	Erro Quadrático Médio ( <i>Root Mean Square Error</i> )	$\text{kJ/m}^2$
$RMSRE$	Erro Quadrático Médio Relativo ( <i>Root Mean Squared Relative Error</i> )	–
$RRMSE$	Raiz da Média dos Desvios Quadráticos Relativos ( <i>Relative Root Mean Square Error</i> )	–
$s$	Estado da Cadeia de Markov	–
$S$	Conjunto de todos os possíveis estados da Cadeia de Markov	–
$SD$	Desvio padrão	$\text{kJ/m}^2$
$T$	Temperatura absoluta	K
$t - stat$	Estatística-t ( <i>t-Statistic</i> )	–
$U_{95\%}$	Incerteza a 95%	$\text{kJ/m}^2$
$x$	Variável $x$	
$\mathbf{x}$	Vector normalizado do algoritmo Google™ PageRank™ com os pesos das classes de irradiação solar global	
$X$	Sequência de valores da variável $x$	–
$y$	Valor do indicador estatístico	
$Z$	Altitude local	m

## Símbolos Gregos

Símbolo	Descrição	Unidade
$\alpha$	Peso de um indicador estatístico no cálculo do GPI	—
$\delta$	Ângulo de declinação	°
$\varepsilon$	Emissividade	—
$\zeta$	Ângulo de incidência	°
$\theta$	Ângulo solar zenital	°
$\rho_G$	Albedo	—
$\sigma$	Constante de Stefan-Boltzmann ( $5.67 \times 10^{-8}$ )	W/m <sup>2</sup> K <sup>4</sup>
$\Phi$	Ângulo de azimute	°
$\omega$	Inclinação da superfície em relação ao plano horizontal	°

## Índices Inferiores

Símbolo	Descrição
$e$	Valor estimado
$i$	<i>i-ésimo</i> valor da variável
$ij$	Valor normalizado do indicador $j$ para o modelo $i$
$m$	Valor medido
$n$	Incidência normal

## Índices Superiores

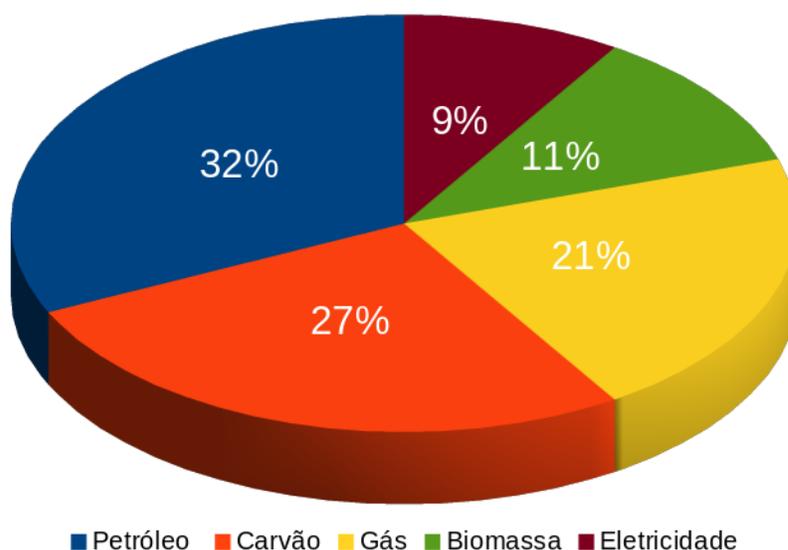
Símbolo	Descrição
$n$	<i>n-ésima</i> potência
$\sim$	Mediana
$\bar{\quad}$	Média



# Capítulo 1

## Introdução

Estima-se que o consumo energético mundial no ano de 2016 tenha sido de aproximadamente 13 509 Mtoe [8] incluindo os consumos em todos os sectores de atividade humana (residencial e de serviços, indústria, agricultura e transportes, etc). Esse valor representa um crescimento de 38.58% em relação ao ano de 2000. Todavia, mesmo com os constantes avanços tecnológicos, a humanidade ainda encontra-se fortemente dependente das fontes de energia de origem fóssil. Essa dependência pode ser vista no gráfico da Figura 1.1 onde mostra que cerca de 80% do consumo energético mundial está sobre o petróleo, carvão e gás.



**Figura 1.1:** Consumo energético mundial estimado para o ano de 2017.

Fonte: Adaptado de [8]

Muito do consumo de energia com origem no petróleo é na forma de combustível para veículos. Os novos veículos híbridos e elétricos representam uma revolução, no entanto, a eletricidade usada nesses veículos necessita ser gerada de alguma forma e a principal fonte

para a geração de eletricidade continua a ser através do ciclo de Rankine ou ciclo combinado tendo como fonte de calor o gás natural e o carvão.

A evolução tecnológica das últimas décadas permitiu a criação de equipamentos mais eficientes no consumo de energia. Provavelmente, um exemplo mais contundente dessa evolução pode ser visto nos computadores. O supercomputador Cray-1, lançado em 1975, pesava 5.5 t, custava 8.86 MUS\$<sup>1</sup> e apresentava um desempenho de 160 MFLOPS com um consumo de 115 kW. Nos dias atuais é possível adquirir um computador de secretária com capacidade de processamento na ordem dos 40 GFLOPS, menos de 100 W de consumo de energia, por algo em torno de 1.500 US\$. Graças a forte redução dos preços, houve uma elevada quantidade de equipamentos elétricos e/ou eletrônicos disponibilizados para a população. Devido a essa grande popularização dos equipamentos, mesmo eles sendo muito mais eficientes, o consumo global de energia aumentou devido ao número de equipamentos em funcionamento. Como exemplo disso, pode-se citar a mineração de criptomoedas (Bitcoin, Ethereum, Litecoin, etc). Esse processo de mineração demanda uma grande capacidade de processamento. Estima-se que esse processo de mineração apresente um consumo energético total equivalente ao de alguns países<sup>2</sup>.

Relembrando o gráfico do consumo energético mundial apresentado na Figura 1.1, aproximadamente metade é na forma de carvão e gás natural. Esses elementos são queimados para a produção de calor, geralmente na forma de vapor, quer para utilização directa quer para a produção de electricidade por via térmica, quer ainda em processos combinados (cogeração). Além disso, uma boa parte da energia consumida no setor industrial é para processos térmicos - tanto aquecimento quanto refrigeração. O gráfico da Figura 1.2 mostra que em torno de 30% dos processos industriais ocorrem a uma temperatura de até 100 °C [9].

Os dados da Figura 1.2 são corroborados pelos dados apresentados na Tabela 1.1, onde são apresentadas as faixas de temperaturas de alguns processos industriais.

Conforme pode ser visto na Tabela 1.1, uma vasta variedades de processos industriais ocorrem a baixas e médias temperaturas. Em alguns setores industriais, como no caso cerâmico, os processos térmicos podem representar até 92% do consumo de energia de uma empresa [11]. Uma parte dessa demanda térmica que hoje é suprida pela queima de carvão ou gás pode ser substituída por energia solar térmica.

Em muitos casos, suprir totalmente a demanda térmica (aquecimento e refrigeração) de uma empresa com a utilização de energia solar é quase impossível. Porém, pode-se utilizar energia térmica de origem solar para realizar uma parte do processo, como o pré-aquecimento

---

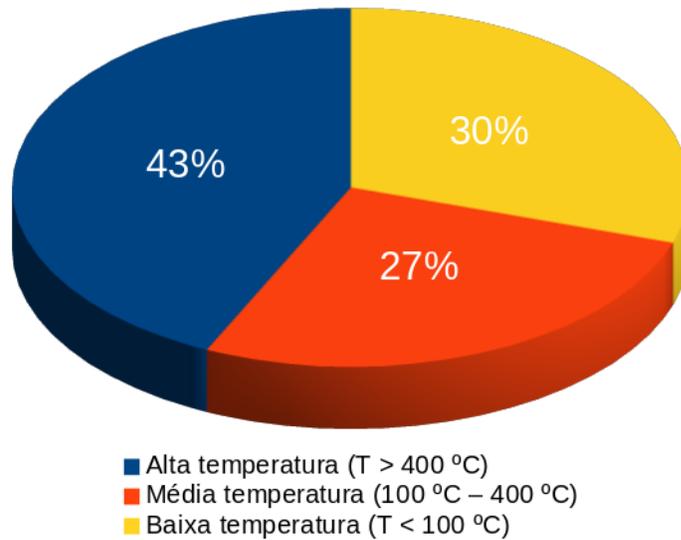
<sup>1</sup>Preço base de lançamento.

<sup>2</sup>Conforme apresentado na matéria <https://www.nytimes.com/es/2018/01/24/consumo-energia-bitcoin-tecnologia/?rref=collection%2Fsectioncollection%2Fnyt-es>, acessada em 30 de janeiro de 2018.

**Tabela 1.1:** Gamas de temperatura de alguns processos industriais.

Fonte: Adaptado de [10]

Setor industrial	Processo / unidade de produção	Gama de temperatura (°C)
Laticínios	Pressurização	60 – 80
	Esterilização	100 – 120
	Secagem	120 – 180
	Concentrados	60 – 80
	Água para alimentar as caldeiras	60 – 90
Enlatados	Esterilização	110 – 120
	Pasteurização	60 – 80
	Cozimento	60 – 90
	Branqueamento	60 – 90
Têxtil	Branqueamento e tingimento	60 – 90
	Secagem e desengorduramento	100 – 130
	Fixação	160 – 180
	Prensagem	80 – 100
Papel	Cozimento, secagem	60 – 80
	Água para alimentar as caldeiras	60 – 90
	Branqueamento	130 – 150
Química	Sabonetes	200 – 260
	Borracha sintética	150 – 200
	Tratamento térmico	120 – 180
	Água para pré-aquecimento	60 – 90
Carne	Lavar, esterilizar	60 – 90
	Cozimento	90 – 100
Bebidas	Lavar, esterilizar	60 – 80
	Pasteurização	60 – 70
Subprodutos de farinha	Esterilização	60 – 90
Subprodutos de madeira	Feixes de difusão térmica	80 – 100
	Secagem	60 – 100
	Água para pré-aquecimento	60 – 90
	Preparação de polpa	120 – 170
Tijolos e blocos	Tintura	60 – 140
Plástico	Preparação	120 – 140
	Destilação	140 – 150
	Separação	200 – 220
	Extensão	140 – 160
	Secagem	180 – 200
	Combinação	120 – 140



**Figura 1.2:** Proporção de demanda de calor industrial por gamas de temperatura.

Fonte: Adaptado de [9]

da água que irá entrar numa caldeira, ou do ar a ser utilizado na queima para alimentar um forno industrial, como pode ser visto em [12] e em [13].

O trabalho divulgado pelo U. S. Department of Energy em 2007 [5] mostra, através da Tabela 1.2, que realizar o aquecimento do ar antes da queima pode representar grandes reduções no consumo de combustível em fornos industriais.

**Tabela 1.2:** Redução do consumo de combustível ao usar ar pré-aquecido na combustão de gás com 10% de excesso de ar. Valores em percentual [%].

Fonte: Adaptado de [5]

Temperatura de exaustão do forno [°C]	Temp. do ar pré-aquecido [°C]					
	316	427	538	649	760	871
538	13	18				
649	14	19	23			
760	15	20	24	28		
871	17	22	26	30	34	
982	18	24	28	33	37	40
1 093	20	26	31	35	39	43
1 204	23	29	34	39	43	47
1 316	26	32	38	43	47	51

O Sol pode ser considerado uma fonte inesgotável de energia. Estima-se que menos de 90

minutos de radiação solar incidente no nosso planeta já seria suficiente para suprir a demanda anual de energia do globo terrestre (aproximadamente 900 EJ - ou  $9 \times 10^{20}$  J) [10].

Todavia, essa energia incidente não está igualmente distribuída, seja distribuição temporal ou espacial, sendo necessário estimar qual o recurso solar disponível numa determinada região de modo a dimensionar sistemas térmicos em função da aplicação desejada. Para a correta estimativa do recurso disponível, além de medições fiáveis, é necessário que as séries temporais dos dados sejam as mais completas possível. É nesse contexto que se insere a presente dissertação uma vez que, apesar dos avanços tecnológicos, sempre existem falhas ou lacunas nas séries de dados de radiação solar, as quais são necessárias preencher com métodos adequados de modo a garantir uma correcta avaliação do recurso solar. O trabalho desenvolvido nesta dissertação trata exactamente dessa questão, do preenchimento de lacunas e reconstrução de séries de dados de radiação solar global.

## 1.1 Objectivo

A presente dissertação tem por objectivo apresentar uma metodologia para reconstrução de séries de dados de radiação solar global no plano horizontal utilizando Processos de Markov.

Para atingir o objectivo proposto, foram utilizados os dados de estações meteorológicas automáticas localizadas na região Sul do Brasil, mais precisamente no meio-oeste do estado de Santa Catarina.

## 1.2 Estado da Arte

Desde o início dos estudos da aplicação da energia solar, um dos principais pontos estudados pelos investigadores é saber qual a disponibilidade do recurso solar para longo prazo com o objectivo de fazer o correcto dimensionamento de centrais solares e, não menos importante, saber também a curto prazo qual será a disponibilidade desse recurso de forma a operar essas centrais o mais próximo possível do ponto óptimo. Em ambos os casos, é essencial ter uma série de dados confiável e que represente o histórico das condições reais o mais fidedignamente. No entanto, muitas vezes é difícil ter longas séries temporais completas.

Com o objectivo de familiarizar o leitor às técnicas mais utilizadas na recuperação de falhas nas séries temporais dos dados de irradiação solar global, far-se-á uma breve apresentação das técnicas mais utilizadas. Conforme apresentado em [14], as técnicas de modelação da irradiação solar global podem ser classificadas em 4 grandes grupos:

- Modelos lineares;

- Modelos não-lineares;
- Lógica *fuzzy*; e
- Redes neuronais artificiais.

### 1.2.1 Modelos lineares

Essa família de modelos recebe esse nome por estes relacionarem os níveis de irradiação solar com as medições de alguma outra variável ambiental de medição mais fácil (ou barato), sendo a quantidade de horas de sol a variável mais utilizada na literatura [15], através de funções lineares simples [14].

Por utilizar o número médio diário de horas de sol ( $n$ ) e o número máximo de horas de sol diárias médio mensal ( $N$ ), essa família de métodos possui a característica de ser fortemente dependente do local e época do ano em análise. Exemplos de fórmulas de métodos lineares podem ser encontradas em [14] [16], sendo mais indicado para o cálculo de valores diários de irradiação solar. Por outro lado, é possível decompor os valores diários ( $I_d$ ) em horários ( $I_h$ ), através, por exemplo, da Equação (1.1) [17], onde  $H$  é o ângulo horário; e  $H_s$ , o ângulo horário ao pôr do sol<sup>3</sup>.

$$\frac{I_h}{I_d} = \frac{\pi (24/\pi) \sin(\pi/24) \cos H - \cos H_s}{24 \sin H_s - H_s \cos H_s} \quad (1.1)$$

### 1.2.2 Modelos não-lineares

Os modelos não-lineares são uma extensão dos modelos lineares e, assim como os lineares, são modelos empíricos. Eles recebem esse nome devido ao facto de utilizarem duas ou mais variáveis ou características do local de estudo e efectuarem o relacionamento destas através de equações não lineares. Conforme apresentado em [18], os modelos não-lineares podem ser expressos em função dos seguintes parâmetros:

- Número de horas de sol;
- Cobertura de nuvens;
- Parâmetros meteorológicos.

Além desses, ainda conforme [18], as entradas para os modelos podem incluir os seguintes tipos de parâmetros:

---

<sup>3</sup>Os ângulos solares e demais grandezas aqui apresentadas serão discutidos no Capítulo 2.

- Astronómicos: Constante solar, distância Terra-Sol, declinação solar, ângulo horário;
- Geográficos: Latitude, longitude e altitude;
- Geométricos: Azimute e/ou inclinação da superfície, altitude e/ou azimute solar;
- Físicos: Albedo, conteúdo de vapor d'água na atmosfera, *scattering*;
- Meteorológicos: Pressão, nebulosidade, insolação, temperatura do ar e/ou solo, humidade relativa, evaporação, precipitação, quantidade de dias com chuva, etc.

Para exemplificar a flexibilidade e quantidade de modelos empíricos lineares e não-lineares, um comparativo entre 78 modelos pode ser encontrado em [19]. Entre os modelos, pode-se citar alguns apresentados em [18]:

- Hargreaves e Samani:  $I/I_0 = K_r (T_{max} - T_{min})^{1/2}$ , onde  $K_r$  é um coeficiente empírico, sendo recomendado os valores 0.16 para regiões interiores e 0.19 para regiões costeiras.  $I$  e  $I_0$  em MJ/m<sup>2</sup>dia,  $T_{max}$  e  $T_{min}$  em °C e  $K_r$  em °C<sup>-1/2</sup>.
- Allen: Nesse modelo, o coeficiente  $K_r$  do modelo anterior assume o valor  $K_r = A (P/1013)^{1/2}$ , onde  $P$  é a pressão atmosférica local (hPa) e  $A$  é um coeficiente empírico (hPa<sup>-1/2</sup>°C<sup>-1/2</sup>) com valores recomendados de 0.17 para regiões interiores e 0.20 para regiões costeiras.
- Samani: Para Samani, o coeficiente  $K_r$  é uma função de segundo grau da amplitude térmica diária, ou seja,  $K_r = A (T_{max} - T_{min})^2 + B (T_{max} - T_{min}) + C$ , sendo  $A$  em (°C<sup>-2</sup>),  $B$  em (°C<sup>-1</sup>) e  $C$  adimensional. Com isso, esse modelo consegue minimizar o erro da estimativa da irradiação solar global diária.
- Regressão linear: Na regressão linear, é possível estimar a irradiação solar global diária por  $I = AT_{max} + BT_{min} + CI_0 + D$  onde  $D$  é um ajuste de *off-set* (MJ/m<sup>2</sup>dia).

### 1.2.3 Lógica *fuzzy*

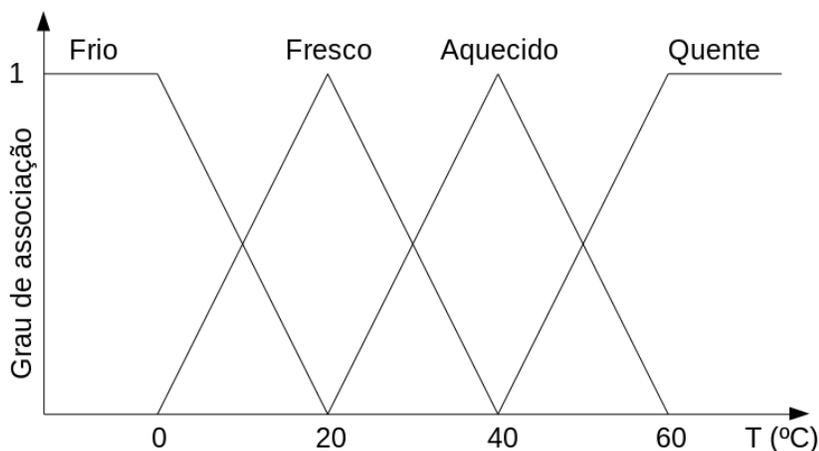
A lógica *fuzzy*<sup>4</sup> surgiu da necessidade de realizar uma melhor interpretação do mundo e que não era atendida pela lógica clássica de Aristóteles. Para essa melhor interpretação, principalmente de termos linguísticos como “*perto*”, “*longe*”, “*alto*” e “*baixo*”, o matemático Lofti Zadeh apresentou os primeiros conceitos da lógica *fuzzy* em 1967 [20]. Enquanto na lógica clássica um elemento quando referido a um conjunto pode assumir somente os valores 1

---

<sup>4</sup>Também conhecida por lógica difusa ou conjuntos *fuzzy*, nebulosos ou difusos.

e 0, ou seja, o elemento pertence ou não ao conjunto, na lógica *fuzzy* esse elemento irá assumir um valor no intervalo  $[0, 1]$  que dará o grau de aderência desse elemento ao conjunto.

Para mostrar de forma simplificada o procedimento realizado para o cálculo de uma estimativa, utilizar-se-á a explicação apresentada em [1] utilizando o conceito com temperatura, conforme a Figura 1.3.



**Figura 1.3:** Exemplo com escala de temperaturas para ilustrar a lógica *fuzzy*.

Fonte: Adaptado de [1]

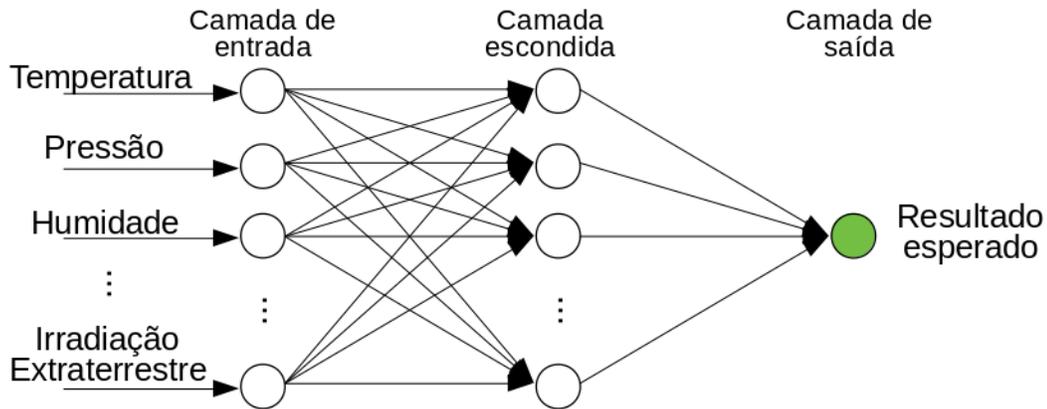
Na Figura 1.3, o valor médio de uma saída será a média ponderada das possíveis saídas  $Y_k$  (*frio*, *fresco*, *aquecido* e *quente*) pelos seus respectivos pesos  $W_k$  (grau de associação a variar entre 0 e 1), conforme visto na Equação (1.2). No exemplo da Figura 1.3 um exemplo do que é saída é a resposta para a seguinte pergunta: “15 °C é frio, fresco, aquecido ou quente?”

$$y = \frac{\sum_{k=1}^4 W_k Y_k}{\sum_{k=1}^4 W_k} \quad (1.2)$$

Conforme visto nos modelos lineares e não-lineares, a irradiação solar tem sido relacionada com as horas de sol do dia, temperatura e outras variáveis ambientais. Como a origem da lógica *fuzzy* está na interpretação linguística da semântica de palavras como “*muito*” e “*pouco*”, essa técnica tem sido utilizada para determinar o quão “*muito*” e “*pouco*” os níveis de irradiação solar estão associados aos números de horas de sol, à temperatura média do ar ou a qualquer outra variável ambiental tradicionalmente medida em estações meteorológicas e disponíveis na literatura, substituindo, assim, as técnicas de regressão linear para a determinação dos parâmetros nos modelos lineares e não-lineares.

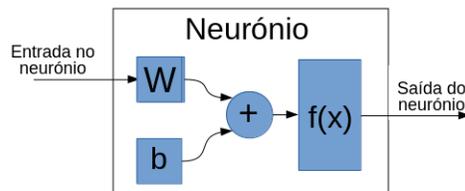
## 1.2.4 Redes neuronais artificiais

Os métodos baseados em redes neuronais artificiais (RNA) são exaustivamente utilizados na predição dos níveis de irradiação solar [6]. Esses métodos consistem em treinar uma rede de nós - os chamados neurónios - de forma a fazer o algoritmo “*aprender*” a pensar como um humano numa tarefa bem específica. O exemplo esquemático de uma RNA é apresentado na Figura 1.4.



**Figura 1.4:** Exemplo esquemático de uma rede neuronal artificial para predição de irradiação solar global.

Na Figura 1.4, a camada de entrada é a que recebe um conjunto de dados a serem analisados. Esse conjunto consiste, na verdade, numa combinação ponderada dos  $N$  parâmetros que fazem parte do modelo. Esse conjunto de entradas ativar­á os neurónios da(s) camada(s) escondida(s) que, por fim, ativar­á um neurónio específico na saída e que corresponderá ao valor de saída previsto para o conjunto de dados utilizados na entrada. Com relação à camada escondida - ou oculta, pode-se classificar as RNA como de camada simples ou multi-camadas. Esquemáticamente, os neurónios das camadas são representados conforme mostrado na Figura 1.5.



**Figura 1.5:** Representação esquemática dos neurónios presentes nas camadas de uma RNA.

Fonte: Adaptado de [2]

**Tabela 1.3:** Funções de ativação mais utilizadas nos processos de redes neurais artificiais.

Fonte: [6]

Função	Definição	Variação
Identidade / linear	$X$	$-\text{inf} < x < \text{inf}$
Logarítmica	$\frac{1}{1 - e^{-x}}$	$0 \leq x \leq 1$
Hiperbólica	$\frac{e^x - e^{-x}}{e^x + e^{-x}}$	$-1 \leq x \leq 1$
Exponencial	$e^{-x}$	$0 \leq x < \text{inf}$

Na Figura 1.5,  $W$  é o peso entre as conexões,  $b$  é o viés e  $f(x)$  é a função de ativação do neurónio e normalmente é uma das funções apresentadas na Tabela 1.3 [6].

De forma a utilizar a rede, é necessário realizar a calibração da mesma ou, como usualmente é dito, treinar a rede. Esse processo consiste em utilizar um conjunto de dados conhecidos - entrada e respetivas saídas - e, através do processo chamado *back propagation*, caminhar na rede da saída para as entradas de forma a encontrar os pesos das conexões  $W$  e os viés  $b$  de cada neurónio.

## 1.3 Motivação

Para uma estimativa fiável do recurso solar existente em uma determinada região, é essencial a existência de um histórico de medições radiométricas e meteorológicas que represente as reais características do local de interesse e das regiões próximas.

Todo equipamento, por melhor que seja, está sujeito a falhas. Essas falhas podem ter origens diversas, tais como:

- Falhas na alimentação elétrica;
- Faltas de manutenção;
- Desvios na calibração dos instrumentos de medição ou falha do sistema de aquisição de dados;
- Vandalismo e roubo;

- Acidentes diversos incluindo as consequências de condições atmosféricas muito adversas ou de eventos meteorológicos extremos;
- Perda de registos ou de base de dados por falhas dos sistemas informáticos de armazenamento ou devido a ataques informáticos.

Além da falta dos dados, outro problema que pode aparecer numa série são as leituras fora dos limites esperados, como - por exemplo - um valor de irradiação solar superior ao máximo aceitável, que podem ocorrer devido a diversos tipos de interferências e/ou às causas atrás mencionadas.

Diante das falhas que podem (e muito provavelmente irão) existir, aparece a pergunta: O que devemos fazer com elas?

Como uma série de dados completa e fiável é algo muito valioso, esses dados não podem ser simplesmente descartados. Por isso surgiu a ideia de elaborar um algoritmo que reconstrua essa informação perdida, de forma rápida, com um nível de certeza aceitável para a utilização em projetos de energia solar.

## 1.4 Organização da dissertação

O presente trabalho divide-se num total de 6 capítulos. No primeiro capítulo é realizada a introdução ao tema, principalmente no uso térmico da energia solar em processos industriais e uma breve introdução das famílias de técnicas utilizadas na reconstrução de séries de dados temporais de irradiação solar, essenciais para a avaliação do recurso e posterior dimensionamento dos referidos sistemas solares térmicos. O segundo capítulo tem por objetivo familiarizar o leitor com os termos e grandezas mais comuns da energia solar e mostrar os equipamentos utilizados nas medições de irradiação solar. No terceiro capítulo são abordados os conceitos matemáticos das cadeias de Markov, equações de Chapman-Kolmogorov e do algoritmo Google™ PageRank™. No quarto capítulo é apresentado o passo-a-passo de todo o trabalho realizado, descrevendo as dificuldades encontradas e quais soluções foram adoptadas. O quinto capítulo é reservado para a apresentação dos resultados obtidos com a técnica proposta neste trabalho e, também, realizada a discussão sobre os mesmos. Finalmente, no sexto capítulo são apresentadas as conclusões e as sugestões de trabalhos futuros.



# Capítulo 2

## Energia Solar: Fundamentos, medição e avaliação do recurso

Tendo em vista uma melhor compreensão deste trabalho, faz-se necessária a apresentação de alguns conceitos que foram utilizados para a realização do mesmo. Esses conceitos serão abordados de forma sucinta no presente capítulo.

### 2.1 Geometria Sol-Terra

De forma a ser possível a correta análise do recurso solar disponível num determinado local, faz-se necessário o conhecimento de como a Terra posiciona-se em relação ao Sol, bem como as implicações que isso tem nas respetivas séries temporais de radiação solar global à superfície da Terra, que são também fortemente influenciadas pelas condições climáticas do local. O presente trabalho utilizou os procedimentos de cálculo apresentados em [21]<sup>1</sup>, sendo possível a obtenção de todos os cálculos no referido trabalho. Devido a isso, a presente dissertação irá apresentar apenas os conceitos e definições dos ângulos solares e hora solar.

O procedimento de cálculo adotado em SPA [21] inclui, adicionalmente, o efeito da refração da luz na atmosfera. Assim, os valores finais encontrados referem-se à posição aparente do sol para um observador na superfície da Terra.

#### 2.1.1 Órbita terrestre: afélio, periélio, solstício e equinócio

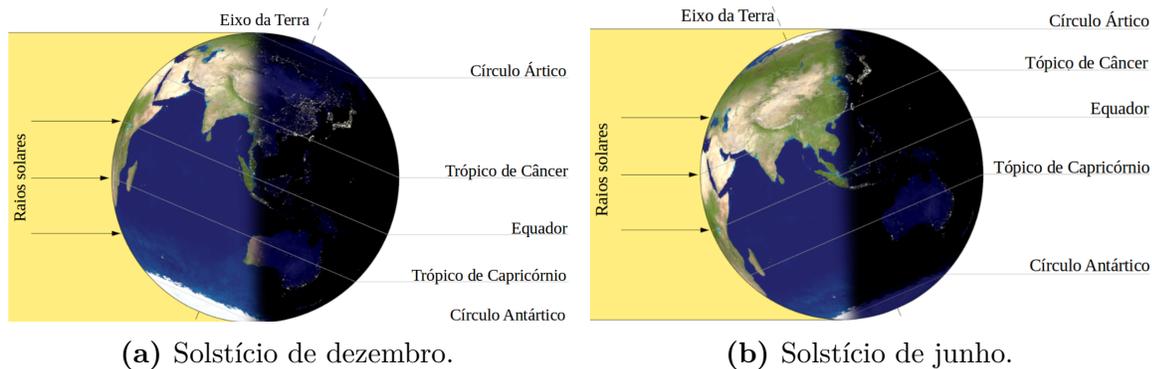
A Terra descreve uma órbita elíptica em torno do Sol (movimento de translação anual), com o Sol a ocupar um dos focos da elipse, e um movimento de rotação diária em torno de

---

<sup>1</sup>A metodologia apresentada no *Sun Position Algorithm* (SPA) do *National Renewable Energy Laboratory* (NREL) possui uma incerteza de  $0.0003^\circ$  nos cálculos dos ângulos de zénite e azimute solar no período compreendido entre os anos de 2000 *a.C.* até 6000 *d.C.*

um eixo que está inclinado em relação ao plano da órbita. Isto implica que existam vários pontos da órbita cujas particularidades são descritas de seguida. *Afélio* é um termo de origem latina que significa longínquo e designa o ponto da órbita de maior afastamento possível de um planeta em relação ao Sol. Para a órbita da Terra esse dia ocorre actualmente no início de julho<sup>2</sup>, coincidindo com o verão no hemisfério norte (inverno no hemisfério sul). Em oposição ao afélio há o *periélio*, que significa perto do sol e ocorre no início de janeiro. Devido a isso, o hemisfério sul apresenta maiores índices de irradiação solar no verão, e o hemisfério norte apresenta menores variações de irradiação entre o verão e o inverno.

O *solstício* ocorre no dia do ano em que o Sol, para um observador na Terra, atinge os extremos de altura angular ao meio dia solar, o que acontece duas vezes por ano, e está relacionado com a declinação solar (Secção 2.1.2). Esses dias ocorrem por volta dos dias 21 de dezembro (solstício de inverno no hemisfério norte e de verão no hemisfério sul - ver Figura 2.1a) e 21 de junho (solstício de verão no hemisfério norte e de inverno no hemisfério sul - ver Figura 2.1b). No solstício de verão ocorre o dia mais longo do ano; e no solstício de inverno, o dia mais curto do ano.



**Figura 2.1:** Posição da Terra em relação aos raios solares incidentes nos solstícios de dezembro e de junho.

Fonte: Disponível em <https://pt.wikipedia.org/wiki/Solstício>.

O *equinócio* é quando a superfície da Terra é igualmente iluminada tomando como referência o eixo de rotação da Terra. Nesses dias, que também ocorrem duas vezes por ano, o dia irá ter a aproximadamente a mesma duração da noite para qualquer ponto no planeta. Esses dias ocorrem por volta dos dias 21 de março (equinócio de primavera no hemisfério norte e de outono no hemisfério sul) e 21 de setembro (equinócio de outono no hemisfério norte e de primavera no hemisfério sul).

<sup>2</sup>Os dias para afélio e periélio - bem como o ângulo de declinação solar - podem ser considerados constantes para o período de tempo da vida de um ser humano; mas, ao se considerar escala de tempo de séculos ou milénios, esses valores podem variar consideravelmente.

### 2.1.2 Declinação solar

A *declinação solar* ( $\delta$ ) é o ângulo formado entre a linha Terra-Sol e o plano equatorial da Terra, a variar atualmente no intervalo de  $\pm 23.45^\circ$ , sendo o valor de  $23.45^\circ$  atingido no solstício junho; e o valor de  $-23.45^\circ$ , no solstício de dezembro. Esse ângulo deve-se ao facto de que o eixo de rotação da Terra está inclinado em  $23.45^\circ$  em relação ao plano da órbita de translação do planeta ao redor do Sol (*eclíptica*).

### 2.1.3 Ângulo solar zenital

O *ângulo solar zenital* ( $\theta$ ) é o ângulo formado entre os raios solares e a normal a uma superfície horizontal num determinado local da superfície terrestre. Esse ângulo é de suma importância, haja vista que a intensidade da irradiação solar útil num coletor está relacionada com o ângulo solar zenital devido ao facto de, em função desse ângulo, se ter maior ou menor espalhamento da irradiação. O espalhamento numa superfície horizontal é dado pela Equação (2.1)

$$F = F_n \cos(\theta) \quad (2.1)$$

onde  $F$  é a energia por unidade de área [ $\text{kJ}/\text{m}^2$ ] na superfície horizontal; e  $F_n$ , o equivalente caso a incidência fosse pela normal. Em outras palavras, quanto maior  $\theta$ , menor será a irradiação na superfície horizontal.

Além disso, através da definição do ângulo solar zenital e da Equação (2.1), é possível observar que quanto maior  $\theta$ , mais espessa é a camada de ar que a radiação solar terá que atravessar até atingir a superfície, o que provoca maior atenuação da sua intensidade. Uma forma simples para calcular a *massa de ar relativa* ( $m$ ) é considerar que a atmosfera do planeta é plana e utilizar a Equação (2.2) [10].

$$m = \frac{1}{\cos(\theta)} \quad (2.2)$$

A Equação (2.2) é uma aproximação. Para resultados mais exatos, deve-se utilizar a Equação (2.3).

$$m = \left[ (r' \cos \theta)^2 + 2r' + 1 \right]^{1/2} - r' \cos \theta \quad (2.3)$$

com  $r'$  a ser o rácio entre o raio da terra ( $R_t$ ) e a espessura média da atmosfera no zénite ( $L_a$ ) (Equação (2.4).)

$$r' = \frac{R_t}{L_a} \approx 708 \quad (2.4)$$

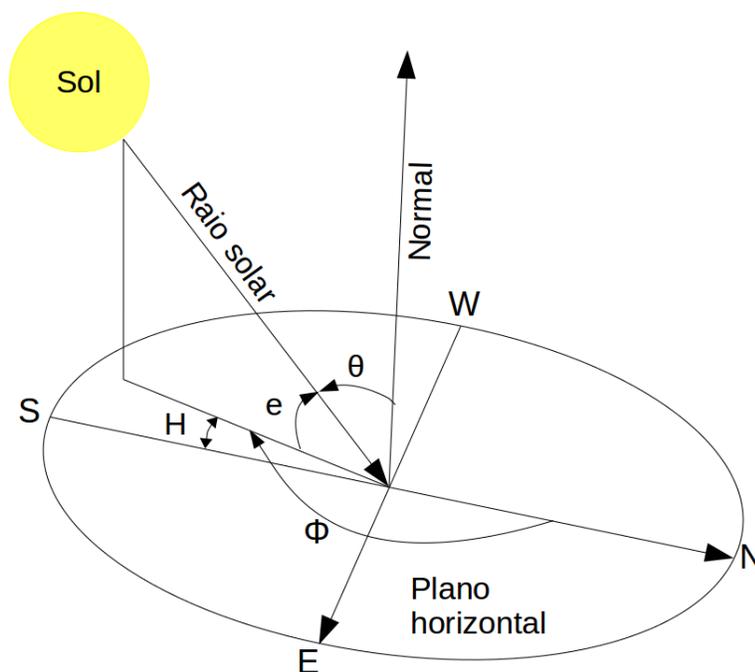
### 2.1.4 Ângulo de elevação

O *ângulo de elevação* ( $e$ ) é o ângulo formado entre os raios solares e o plano horizontal no local do observador, sendo este ângulo o complemento do ângulo zenital.

### 2.1.5 Ângulo de azimute

O *ângulo de azimute* ( $\Phi$ ) é o ângulo formado entre o meridiano local e a projeção dos raios solares no plano horizontal. Nas aplicações em energia solar e navegação, o ângulo de azimute é medido para *Este* tendo o *Norte* como referência ( $0^\circ$ ).

A Figura 2.2 apresenta os ângulos até agora discutidos.



**Figura 2.2:** Representação dos ângulos solar zenital ( $\theta$ ), de elevação ( $e$ ) e de azimute ( $\Phi$ )

### 2.1.6 Ângulo horário

O *ângulo horário* ( $H$ ) é o ângulo formado entre a projeção dos raios solares no plano equatorial e o meridiano local. O ângulo horário será 0 ao meio dia solar, com valores negativos no período da manhã e positivos no período da tarde. Nessa hora, a projeção da linha Terra-Sol no plano equatorial coincide com o meridiano local ( $H = 0$ ), sendo que o valor do ângulo solar zenital é mínimo. Devido ao facto da Terra demorar aproximadamente 24 horas para uma revolução, cada hora representa uma variação de cerca de 15 graus.

### 2.1.7 Ângulo de incidência

O resultado do contributo de todos os ângulos revela-se no *ângulo de incidência*  $\zeta$  dos raios solares sobre uma superfície inclinada de um ângulo  $\omega$  em relação ao plano horizontal e azimute <sup>3</sup>  $\Phi_s$ , de acordo com a Equação (2.5) [10]. Para o caso particular de uma superfície horizontal, o ângulo solar zenital é igual ao ângulo de incidência, e o  $\cos \theta$  da Equação (2.1) pode também ser obtido a partir da Equação (2.5).

$$\begin{aligned}\cos(\zeta) = & \sin(L) \sin(\delta) \cos(\omega) \\ & - \cos(L) \sin(\delta) \sin(\omega) \cos(\Phi_s) \\ & + \cos(L) \cos(\delta) \cos(H) \cos(\omega) \\ & + \sin(L) \cos(\delta) \cos(H) \sin(\omega) \cos(\Phi_s) \\ & + \cos(\delta) \sin(H) \sin(\omega) \sin(\Phi_s)\end{aligned}\tag{2.5}$$

## 2.2 Radiação solar

Conhecer o comportamento e os efeitos da atmosfera na radiação solar é de suma importância em qualquer projeto na área. Por isso, este tópico apresenta uma breve explicação sobre o tema.

### 2.2.1 O Sol como fonte de energia

O Sol é uma esfera gasosa quente, com diâmetro de  $1.39 \times 10^9$  m. A Terra possui diâmetro de  $1.27 \times 10^7$  m e com afastamento médio do Sol de  $1.496 \times 10^{11}$  m [10]. Com isso, para um observador na Terra, o Sol é visto como um disco com abertura de aproximadamente  $0.5333^\circ$ , conforme apresentado na Figura 2.3.

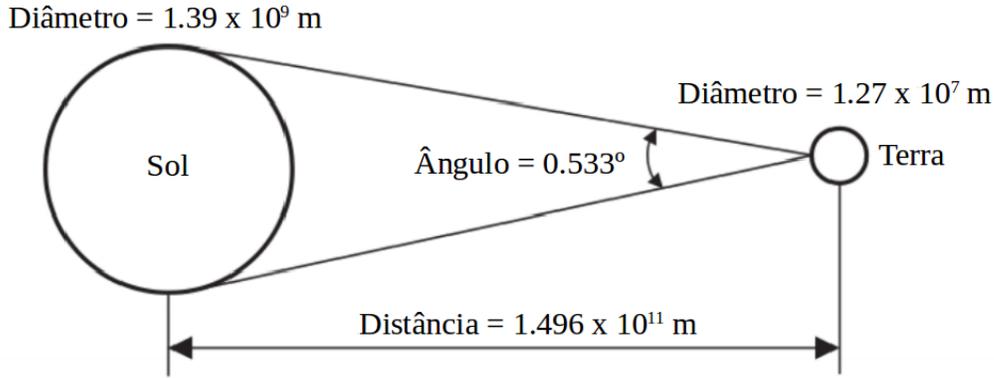
Numa primeira abordagem, o Sol pode ser modelado como um *corpo negro*, ou seja, um objecto que absorve toda energia eletromagnética que nele incide, com uma temperatura estimada <sup>4</sup> de aproximadamente 5777 K. Através da Lei de *Stefan-Boltzmann* (Equação (2.6)) é possível estimar a irradiância total emitida pelo Sol, sendo que para um corpo negro,  $\varepsilon = 1$ .

$$F_{Sol} = \varepsilon \sigma T^4\tag{2.6}$$

---

<sup>3</sup>O ângulo de rotação de azimute de uma superfícies é medido a partir do meridiano local (Sul) até à projecção da normal da superfície no plano horizontal sendo positivo se orientado para *Oeste*; e negativo, para *Este*.

<sup>4</sup>Temperatura para a qual um corpo negro emite a mesma energia que a emitida pelo Sol. Outra estimativa é considerar o comprimento de onda de máxima energia. Neste caso, a temperatura é na ordem de 6300 K [22].



**Figura 2.3:** Dimensões do Sol e da Terra e seu afastamento.

**Fonte:** Adaptado de [10]

Na Equação (2.6)  $\varepsilon$  representa a emissividade e  $\sigma$  é a constante de Stefan-Boltzman <sup>5</sup>. Ao substituir os valores na Equação (2.6) verifica-se que o Sol emite, aproximadamente,  $6.315 \times 10^7 \text{ W/m}^2$  à sua superfície.

Para saber a irradiância que efetivamente chega ao topo da atmosfera do nosso planeta é necessário considerar o afastamento do Sol. Sabe-se que a área de uma esfera é calculada pela Equação (2.7)

$$A = 4\pi r^2 \quad (2.7)$$

e que o fluxo de energia diminui com o aumento do raio da esfera imaginária centrada no sol. Assim, é possível saber qual a *irradiância* que chega até o topo da nossa atmosfera através da *Lei do Inverso do Quadrado* e que é dada pela Equação (2.8)

$$F_{Terra} = F_{Sol} \left( \frac{R_{Sol}}{R_0} \right)^2 \quad (2.8)$$

sendo  $R_0$  o raio médio da órbita terrestre. Dessa forma, é possível estimar a chamada *constante solar*<sup>6</sup>,  $G_{sc}$ , com um valor de  $1362.92 \text{ W/m}^2$ . Esse valor é muito próximo das medições mais recentes realizadas por satélites e que indicam um valor durante o mínimo solar para o ano de 2008 de  $(1360.8 \pm 0.5) \text{ W/m}^2$  <sup>7</sup>. Porém, para o presente trabalho, utilizou-se o valor adotado pela *American Society for Testing and Materials* (ASTM) em 2000 [10] de  $1366.1 \text{ W/m}^2$ .

<sup>5</sup>Constante de Stefan-Boltzman:  $\sigma \approx 5.67 \times 10^{-8} \text{ W/m}^2\text{K}^4$ .

<sup>6</sup>Devido à variação existente na distância Terra-Sol e os ciclos do próprio Sol, atualmente o termo mais correcto é o *Total Solar Irradiance* (TSI). [https://www.nasa.gov/mission\\_pages/Glory/solar\\_irradiance/total\\_solar\\_irradiance.html](https://www.nasa.gov/mission_pages/Glory/solar_irradiance/total_solar_irradiance.html), acessado em 15 de dezembro de 2017.

<sup>7</sup>Valor obtido no endereço <https://atmospheres.gsfc.nasa.gov/climate/?section=136>, acessado em 15 de dezembro de 2017.

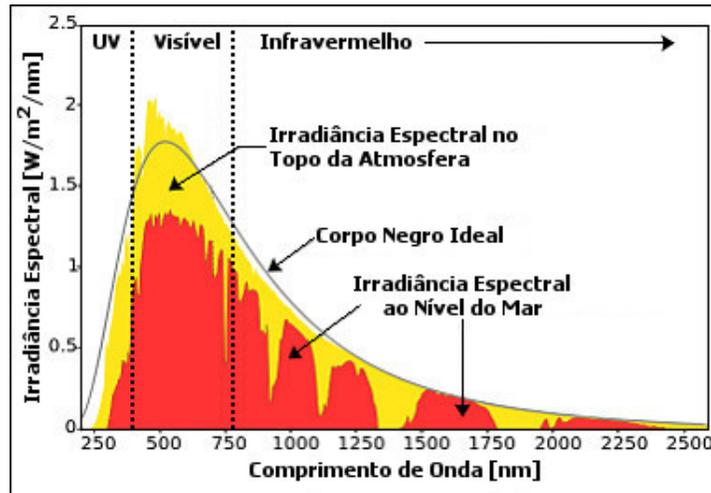
Em posse de  $G_{sc}$ , é possível calcular a quantidade de energia recebida por uma superfície horizontal no topo da atmosfera terrestre num determinado período de tempo. Para isso, faz-se o uso da Equação (2.9) [10]<sup>8</sup>.

$$I_0 = \frac{12 \times 3600 G_{sc}}{\pi} \left( \frac{R_0}{R} \right)^2 \times \left\{ \cos(L) \cos(\delta) [\sin(H_2) - \sin(H_1)] + \left[ \frac{\pi(H_2 - H_1)}{180} \right] \sin(L) \sin(\delta) \right\} \quad (2.9)$$

sendo  $R$  o real afastamento da Terra em relação ao Sol no momento da análise,  $H_1$  e  $H_2$  os ângulos horários - em graus - referentes ao início e fim do período de interesse. A fração  $R_0/R$  pode ser substituída pelo *Earth radius vector* -  $R$ , conforme apresentado no SPA do NREL [21], item 3.2.8, e medido em unidades astronômicas.

## 2.2.2 Espectro solar na superfície da Terra

Os raios solares que atingem o topo da atmosfera sofrem várias interferências até chegarem à superfície do planeta. Além disso, ao se modelar o Sol como um corpo negro, considera-se que o mesmo apresenta uma distribuição espectral contínua, o que não é verdade, como pode ser visto na Figura 2.4.



**Figura 2.4:** Comparativo do espectro de radiação de um corpo negro ideal com a radiação solar que chega ao topo da atmosfera e à superfície terrestre.

Fonte: Disponível em [http://recursosolar.geodesign.com.br/Graphics/Espectro\\_Solar1\\_RS.jpg](http://recursosolar.geodesign.com.br/Graphics/Espectro_Solar1_RS.jpg).

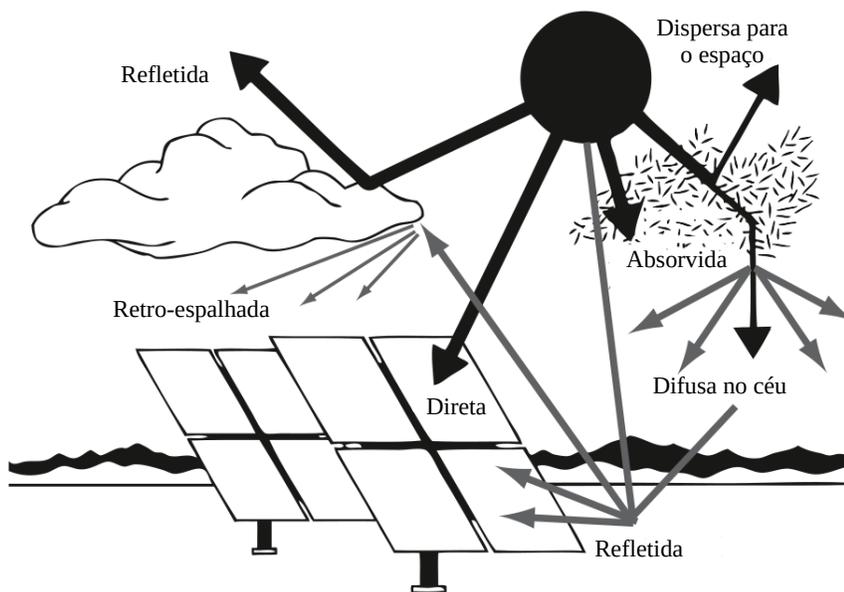
<sup>8</sup>No presente trabalho utilizou-se o valor para  $\pi$  de 3.141 592 653 589 8 por ser o valor utilizado no algoritmo do SPA [21]

## Interferência da atmosfera na radiação solar

É importante saber a quantidade de energia que chega ao topo da atmosfera, mas para as condições atmosféricas reais, incluindo a sua composição e tipo e concentração de aerossóis, o que realmente importa é a irradiação que chega ao local da aplicação. Para isso, faz-se necessário saber quais fenómenos de transferência da radiação na atmosfera e dos quais resulta a redução da energia útil para utilização.

A irradiação solar direta no topo da atmosfera - *Extraterrestrial Beam* (ETR) - sofre interações com os gases constituintes da atmosfera e aerossóis em suspensão. Essas interações provocam dispersão (*scattering*) e absorção da energia [3].

A Figura 2.5 apresenta - de forma esquemática - os fenómenos aos quais a radiação solar está sujeita ao penetrar e atravessar a atmosfera. Na perspectiva de aplicações da energia solar, da radiação que atinge o topo da atmosfera, parte é refletida pelas nuvens, parte sofre espalhamento devido aos aerossóis em suspensão na atmosfera, parte é refletida pelo meio e atinge os colectores solares e apenas uma parcela atinge de forma direta os coletores.



**Figura 2.5:** Representação dos fenómenos aos quais a radiação solar está sujeita ao atravessar a atmosfera terrestre.

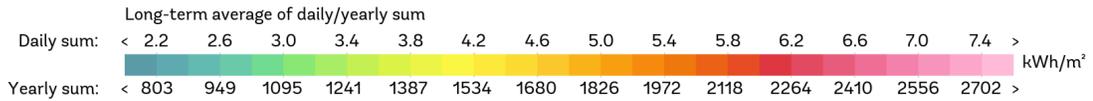
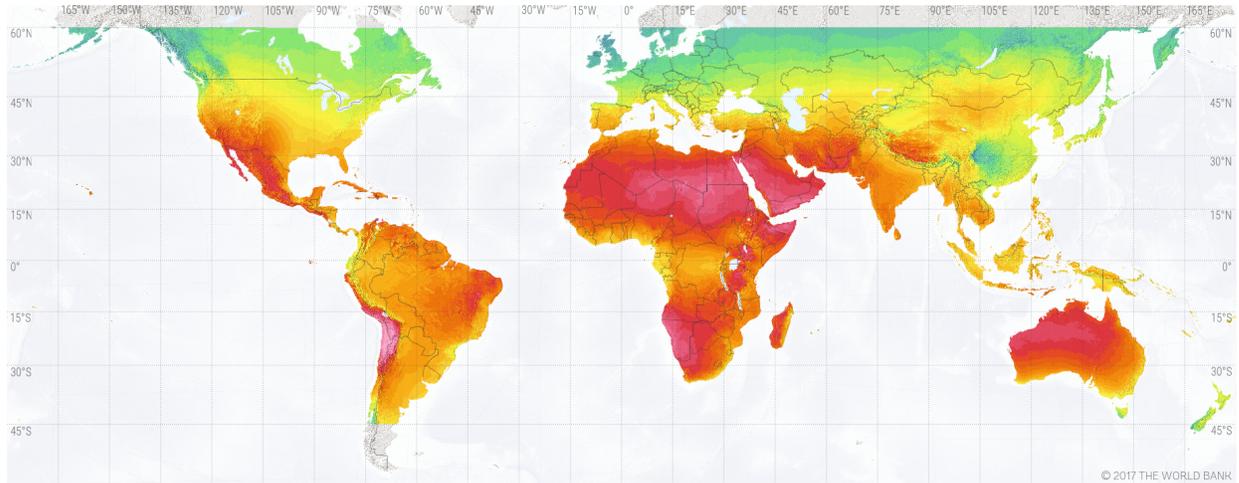
Fonte: Adaptado de [3]

Desta forma, cada ponto do planeta está sujeito a um nível de irradiação solar. A Figura 2.6 apresenta valores médios típicos de irradiação global no plano horizontal (GHI)<sup>9</sup>.

Ao analisar a Figura 2.6 cabe uma pergunta. Porque é que regiões com mesma latitude

<sup>9</sup>A Irradiação global no plano horizontal é tipicamente conhecida pelo termo em inglês *Global Horizontal Irradiation* (GHI).

SOLAR RESOURCE MAP  
GLOBAL HORIZONTAL IRRADIATION



This map is published by the World Bank Group, funded by ESMAP, and prepared by Solargis. For more information and terms of use, please visit <http://globalsolaratlas.info>.

**Figura 2.6:** Valores médios de longo prazo de GHI.

**Fonte:** Disponível em <https://solargis.com/maps-and-gis-data/download/world>.

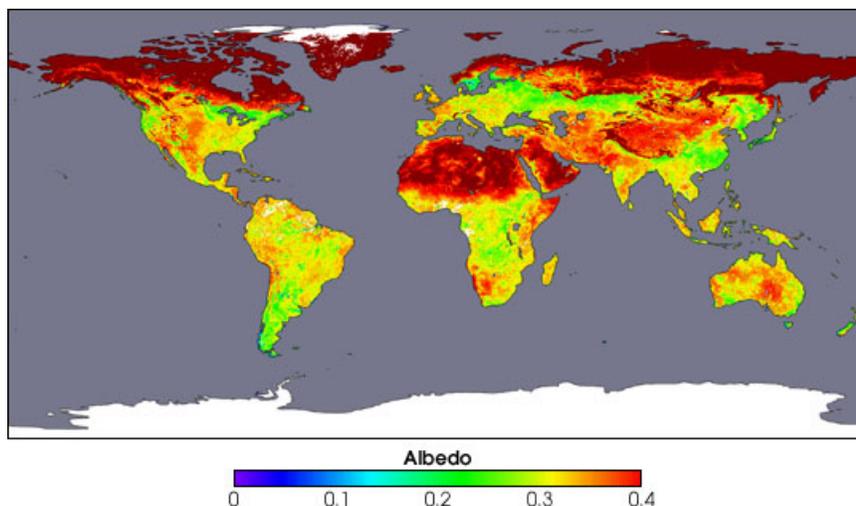
apresentam diferenças nos níveis de GHI? Essa diferença pode ser explicada devido a características climáticas locais/regionais e ser descrita com recurso a outros dois conceitos apresentados a seguir: o *albedo* da superfície terrestre ( $\rho_G$ ) e o *índice de claridade* ( $K_t$ ).

### Albedo

O albedo  $\rho_G$  de uma superfície representa a parcela de energia solar refletida em relação à incidente (Equação (2.10)).

$$\rho_G = \frac{\text{Luz refletida}}{\text{Luz incidente}} \quad (2.10)$$

Valores típicos de albedo na superfície da Terra são apresentados na Figura 2.7 e, na Tabela 2.1, para alguns tipos de cobertura mais comuns. O albedo da superfície terrestre tem importância não apenas na fração de energia que é refletida diretamente para os coletores solares, mas também nas reflexões múltiplas entre a superfície e atmosfera, as quais contribuem para o aumento da componente de radiação difusa.



**Figura 2.7:** Valores aproximados de albedo da superfície terrestre.

Fonte: Disponível em [https://eoimages.gsfc.nasa.gov/images/imagerecords/60000/60636/modis\\_albedo.jpg](https://eoimages.gsfc.nasa.gov/images/imagerecords/60000/60636/modis_albedo.jpg) acessado em 20 de dezembro de 2017.

**Tabela 2.1:** Valores típicos de albedo para diferentes tipos de coberturas/superfícies.

Fonte: Adaptado de [7]

Superfície	Albedo
Gramado	0.18 - 0.23
Gramma seca	0.20 - 0.32
Solo descampado	0.17
Asfalto	0.15
Betão novo (sem acção de intempéries)	0.55
Betão (construção urbana)	0.20
Neve recente	0.80 - 0.90
Água, para diferentes valores de altura solar	
$e > 45^\circ$	0.05
$e = 30^\circ$	0.08
$e = 20^\circ$	0.12
$e = 10^\circ$	0.22

## Índice de claridade

Ao analisar a Figura 2.5 e a Figura 2.4, é possível observar que a irradiação solar que incide em uma superfície horizontal é inferior à que chega ao topo da atmosfera devido às razões explicadas anteriormente. O índice de claridade  $K_t$  (Equação (2.11)) é o parâmetro que representa a proporção de quanto da ETR efectivamente chega à superfície, com a irradiação incidente no topo da atmosfera  $I_0$  a ser calculada através da Equação (2.9), e sendo  $I_t$  a

irradiação incidente no plano horizontal na superfície terrestre.

$$K_t = \frac{I_t}{I_0} \quad (2.11)$$

### 2.2.3 Medição do recurso solar disponível na superfície terrestre

Após os conceitos teóricos terem sido apresentados, faz-se necessário saber como é realizada a medição do recurso solar que efetivamente tem-se disponível na superfície terrestre.

Através dessas medições é que são geradas as séries temporais para posterior análise no presente trabalho, e que são essenciais para a estimativa da produção de energia de sistemas solares. Desta forma, o presente trabalho pretende garantir o melhor preenchimento das lacunas que as séries (muito provavelmente) irão apresentar.

#### Radiação solar direta normal

A *radiação solar direta normal* (DNI)<sup>10</sup> é a componente da energia solar global que corresponde à radiação proveniente do disco solar e da sua coroa (radiação circunsolar), ou seja, que sofreu poucas interferências após penetrar na atmosfera do planeta<sup>11</sup> e incide no ângulo normal à superfície. Essa parcela de energia é medida através de um pireliómetro (Figura 2.8).



**Figura 2.8:** Pireliómetros montados em um seguidor solar durante processo de medição da radiação solar direta.

**Fonte:** Disponível em [https://aim.nrel.gov/Calibrations/NPC/npc2011/DSC\\_3994.jpg](https://aim.nrel.gov/Calibrations/NPC/npc2011/DSC_3994.jpg) acessado em 21 de fevereiro de 2017.

<sup>10</sup>Na literatura é mais comum encontrar o termo em inglês *Direct Normal Irradiation* (DNI)

<sup>11</sup>Sofreu essencialmente fenômenos de absorção, refração e reflexão e apenas algum espalhamento, o qual é responsável pela radiação circunsolar. Por isso, na literatura é muito utilizado o termo em inglês *beam radiation* (feixe de radiação).

O pireliómetro apresenta um ângulo de aceitação estreito<sup>12</sup> [3] para a luz do sol entrar no aparelho e atingir os sensores. Durante o processo de medição, o pireliómetro deve permanecer diretamente apontado para o sol através de um seguidor solar.

Na Figura 2.8 é possível observar alguns modelos de pireliómetros montados em um seguidor solar durante um evento de comparação e calibração promovido pelo NREL.

Em dias de condição de céu limpo (elevado  $K_t$ ), a radiação direta representa a maior parcela da radiação solar global que chega à superfície.

A radiação direta é a parcela efetivamente utilizada nos sistemas de concentração solar devido ao seus ângulos de aceitação menores, de modo a se obter maiores densidades de energia solar a incidir nas células fotovoltaicas ou temperaturas mais elevadas nos sistemas térmicos.

## Radiação solar difusa

A *radiação difusa num plano horizontal* (DHI)<sup>13</sup> é toda a energia que chega à superfície e que sofreu algum fenômeno como dispersão, reflexão, etc. Para realizar a medição da radiação solar difusa é utilizado um piranómetro com uma banda para bloquear a radiação direta que de outra forma chegaria ao equipamento. Na Figura 2.9 é possível ver um piranómetro utilizado no projeto Sistema de Organização Nacional de Dados Ambientais (SONDA), instalado na cidade de São Luiz/MA - Brasil, com a sobra da banda projetada sobre o sensor.



**Figura 2.9:** Piranómetro sombreado por uma banda para medição da radiação difusa.

Fonte: Disponível em [http://sonda.ccst.inpe.br/fotos/SLZ/2007/saoluiz\\_02.html](http://sonda.ccst.inpe.br/fotos/SLZ/2007/saoluiz_02.html) acessado em 21 de fevereiro de 2017.

Em dias de céu muito nublado ou encoberto (baixos valores de  $K_t$ ), a DHI representa a maior parcela da energia solar global que chega à superfície, podendo chegar ao caso de ser igual à radiação solar global existente.

<sup>12</sup>Geralmente entre 5° e 6°.

<sup>13</sup>Na literatura é mais comum encontrar o termo em inglês *Diffuse Horizontal Irradiation* (DHI)

## Radiação solar global

A *radiação solar global no plano horizontal* (GHI)<sup>14</sup> é a soma da projeção da DNI no plano horizontal com a DHI e representa quanto de energia solar efetivamente atingiu a superfície.

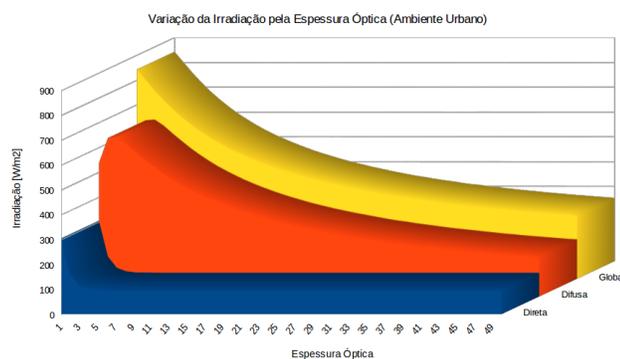
Para a medição da GHI pode-se - como já mencionado - somar os valores medidos das outras duas parcelas ou, como alternativa ou completamente, utilizar um piranómetro sem a banda de sombreamento, como pode ser visto na Figura 2.10.



**Figura 2.10:** Exemplo de piranómetro sem a banda de sombreamento, utilizado para medir a GHI.

**Fonte:** Disponível em [http://image.lufft.com/public/uploads/EV\\_AC\\_HU\\_Pecs\\_Viticultural\\_CMP\\_resampled\\_600.jpg](http://image.lufft.com/public/uploads/EV_AC_HU_Pecs_Viticultural_CMP_resampled_600.jpg) acessado em 21 de fevereiro de 2017.

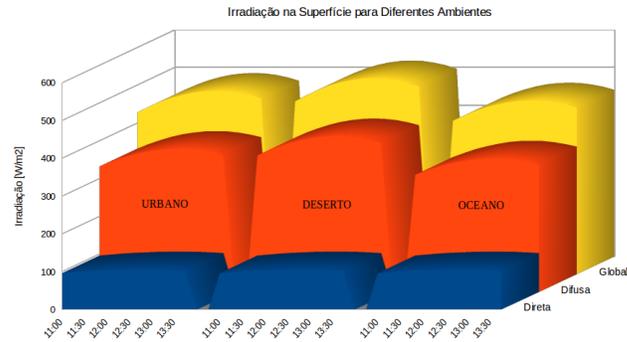
Na Figura 2.11 é possível observar o impacto que a variação da espessura da massa de ar provoca nos valores de irradiância solar direta normal, difusa e global no plano horizontal.



**Figura 2.11:** Impacto nos valores de irradiância solar direta normal, difusa e global no plano horizontal com a variação da espessura óptica.

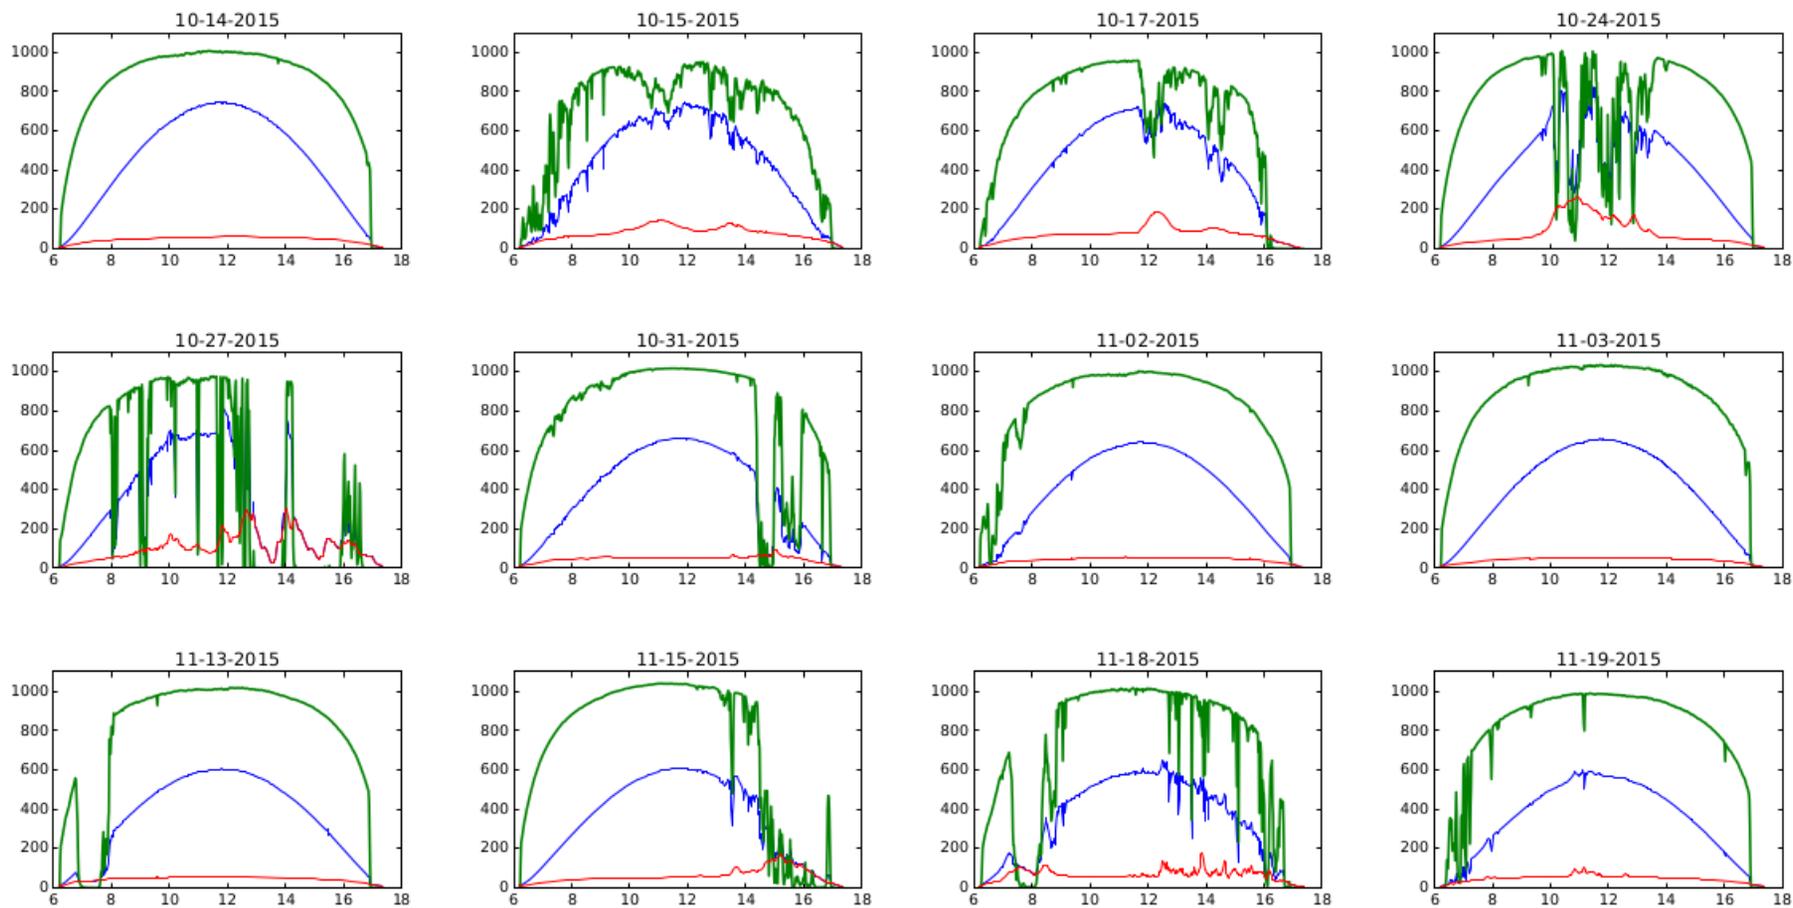
<sup>14</sup>Na literatura é mais comum encontrar o termo em inglês *Global Horizontal Irradiation* (GHI)

Já na Figura 2.12 é apresentado um gráfico ilustrativo do impacto nas três componentes de irradiância solar com a alteração do tipo de aerossóis.



**Figura 2.12:** Impacto nos níveis de DNI, DHI e GHI em função do tipo de aerossóis na atmosfera.

A Figura 2.13 apresenta o comportamento das 3 (três) parcelas de irradiância solar para variadas condições de cobertura de nuvens do céu. A presença de nuvens provoca a diminuição acentuada da componente direta normal com o correspondente aumento da componente difusa devido à dispersão na atmosfera e nas nuvens. Em caso de ocultação completa do sol, a irradiância global no plano horizontal é igual à componente difusa apenas, como por exemplo na parte da tarde do dia 10-27-2015 representado na figura. O dia 11-03-2015 também representado na Figura 2.13 é um exemplo de dia de céu limpo.



**Figura 2.13:** Comportamento das componente de irradiância direta normal (verde), difusa (vermelho) e global no plano horizontal (azul) para diferentes situações de cobertura de nuvens. Valores em  $\text{W}/\text{m}^2$  entre as 06 e 18 horas UTC.

Fonte: [4].



# Capítulo 3

## Fundamentos Matemáticos do Processamento Realizado

O presente capítulo tem por objectivo apresentar os fundamentos teóricos matemáticos que foram utilizados no processamento dos dados após a validação dos mesmos através dos conceitos apresentados no Capítulo 2

### 3.1 Fundamentos matemáticos das cadeias de Markov

As Cadeias de Markov (Processos de Markov ou Markovianos) recebem esse nome em homenagem ao matemático russo Andrey Markov. Markov apresentou seu primeiro trabalho nesta área em 1906.

Para um processo estocástico ser classificado como Processo de Markov, o mesmo deve ser sem memória, ou seja, o estado futuro depende exclusivamente do estado atual, não importando onde - ou como - o sistema encontrava-se no passado.

Conforme [23], uma cadeia de Markov é uma sequência de variáveis  $X_1, X_2, \dots, X_n, \dots$ . A probabilidade do sistema encontrar-se no estado  $X_{n+1}$  ao sair do estado  $X_n$  é dada por

$$Pr(X_{n+1} = x_{n+1} | X_1 = x_1, X_2 = x_2, \dots, X_n = x_n) = Pr(X_{n+1} = x_{n+1} | X_n = x_n). \quad (3.1)$$

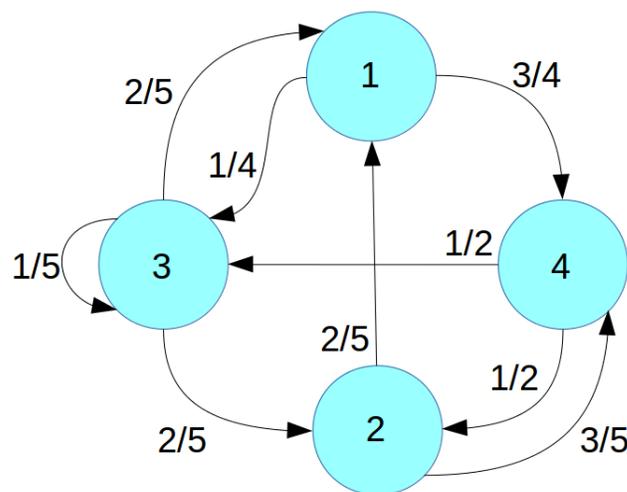
Cada um dos elementos da sequência  $X$  possui um conjunto finito de estados possíveis  $S = (s_1, s_2, \dots, s_n)$ . Assim, a probabilidade do sistema encontrar-se na posição (ou estado)  $j$  ao sair da posição  $i$  com apenas uma transição (*passo*) é dada por:

$$p_{ij} = Pr(X_1 = s_j | X_0 = s_i). \quad (3.2)$$

As cadeias de Markov são utilizadas num vasto leque de aplicações [24]. Algumas delas são:

- Sistemas de controle de cruzeiro em veículos;
- Teoria das filas;
- Economia;
- Modelos de armazenagem (volume em uma albufeira);
- Modelos de crescimento populacional;
- Teoria dos jogos;
- Reconhecimento da fala;
- Geradores de texto;
- Telecomunicações;
- Informática - aplicações em redes;

Para montar a Matriz de Markov é necessário conhecer a dinâmica (histórico) do sistema em análise. Para exemplificar o processo de construção da Matriz de Markov, apresenta-se o exemplo da Figura 3.1.



**Figura 3.1:** Exemplo de um processo estocástico para a construção da Cadeia de Markov.

Na Figura 3.1, cada círculo numerado é um dos 4 possíveis estados do sistema. As ligações entre os estados são as possíveis transições entre estados. As frações são as probabilidades de ocorrência de cada uma das transições. Com isso, a Matriz de Markov do sistema é apresentada na Tabela 3.1.

**Tabela 3.1:** Matriz de transição de estados de Markov do exemplo da Figura 3.1.

		Destino			
		1	2	3	4
Origem	1	0	0	1/4	3/4
	2	2/5	0	0	3/5
	3	2/5	2/5	1/5	0
	4	0	1/2	1/2	0

Pode-se observar na Tabela 3.1 que a soma das probabilidade em cada linha é sempre são igual a 1. Isso deve-se ao facto de que o sistema, independente do estado de origem, sempre terá que transitar para algum estado futuro pertencente à matriz (estado futuro do sistema).

### 3.1.1 Equações de Chapman-Kolmogorov

As equações de Chapman-Kolmogorov têm a função de descreverem a evolução de um Processo de Markov ao longo do tempo. Conforme mostrado em [25], um sistema classificado como de Markov apresenta a seguinte evolução:

$$PR_i(X_i = j) = \mathbf{P}_{ij}$$

$$PR_i(X_1 = j) = \sum_{i \in I} \lambda_i PR_i(X_1 = j) = \sum_{i \in I} \lambda_i \mathbf{P}_{ij} \quad (3.3)$$

$$PR_i(X_2 = j) = \sum_k \mathbf{P}_i(X_1 = k, X_2 = j) = \sum_k \mathbf{P}_{ik} \mathbf{P}_{kj} = (\mathbf{P}^2)_{ij}$$

Ao continuar o mesmo raciocínio, tem-se que na  $n$ -ésima transição, a probabilidade do sistema estar em um dos estados é dada por:

$$PR_i(X_n = j) = (\delta_i \mathbf{P}^n)_j = (\mathbf{P}^n)_{ij} = \mathbf{P}_{ij}^{(n)}$$

$$PR_i(X_n = j) = \sum_{i_0, \dots, i_{n-1}} \lambda_{i_0} \mathbf{P}_{i_0} \mathbf{P}_{i_1} \cdots \mathbf{P}_{i_{n-1}j} = (\lambda \mathbf{P}^n)_j. \quad (3.4)$$

Para qualquer estado  $i$  e  $j$ , sendo  $n, m > 0$ , pode-se reescrever a Equação (3.4) na forma das **Equações de Chapman-Kolmogorov** (Equação (3.5)).

$$PR_{ij}^{(n+m)} = \sum_{k \in I} \mathbf{P}_{ik}^{(n)} \mathbf{P}_{kj}^{(m)} \quad (3.5)$$

onde  $(PR_{ij}^{(n)}) = \mathbf{P}^n$  é a matriz de estados do sistema elevada à  $n$ -ésima potência.

Para o exemplo da Figura 3.1, a matriz  $\mathbf{P}^n$  é dada pela Equação (3.6):

$$\mathbf{P}^n = \begin{pmatrix} 0 & 0 & 1/4 & 3/4 \\ 2/5 & 0 & 0 & 3/5 \\ 2/5 & 2/5 & 1/5 & 0 \\ 0 & 1/2 & 1/2 & 0 \end{pmatrix}^n. \quad (3.6)$$

Caso o sistema do exemplo esteja no estado inicial 2, para saber qual a probabilidade do mesmo estar em algum dos estados do sistema após 3 transições será:

$$\mathbf{P}_{2j}^{(3)} = (0 \ 1 \ 0 \ 0) \begin{pmatrix} 0 & 0 & 1/4 & 3/4 \\ 2/5 & 0 & 0 & 3/5 \\ 2/5 & 2/5 & 1/5 & 0 \\ 0 & 1/2 & 1/2 & 0 \end{pmatrix}^3$$

$$= (0 \ 1 \ 0 \ 0) \begin{pmatrix} 0.36 & 0.17 & 0.11 & 0.36 \\ 0.28 & 0.31 & 0.23 & 0.18 \\ 0.088 & 0.326 & 0.358 & 0.228 \\ 0.12 & 0.19 & 0.27 & 0.42 \end{pmatrix} \quad (3.7)$$

$$= (0.28 \ 0.31 \ 0.23 \ 0.18)$$

### 3.1.2 Algoritmo Google™ PageRank™

O algoritmo Google™ PageRank™ foi proposto pelos fundadores do Google™ - Lawrence Page e Sergey Brin [26] - para a classificação e determinação da probabilidade de cada página da internet<sup>1</sup> ser escolhida para visualização. No presente trabalho, e uma vez que se pretende determinar a probabilidade de um determinado nível de irradiação ocorrer, o método será aplicado usando classes de irradiação em vez de páginas de internet, com as probabilidades representado os pesos para o cálculo da média ponderada nos níveis de irradiação. Ou seja, onde lê-se *página(s) da internet* deve-se ter em mente que para o presente trabalho corresponde a um determinado *nível de radiação solar global*. Esse algoritmo foi classificado como um dos 10 mais importantes algoritmos em mineração de dados [27]. A versão original do modelo é apresentada na Equação (3.8).

$$PR(P_x) = p \times \sum_{i=1}^n \frac{PR(P_i)}{c(P_i)} + \frac{1-p}{n} \quad (3.8)$$

Entretanto, em [26] os autores propuseram o formato apresentado na Equação (3.9).

$$PR(P_x) = p \times \sum_{i=1}^n \frac{PR(P_i)}{c(P_i)} + (1-p) \quad (3.9)$$

Nas Equações 3.8 e 3.9 tem-se:

- $PR(P_x)$ : Índice PageRank da página em análise
- $PR(P_i)$ : Índice PageRank da página  $i$  que tenha conexão (*link*) para a página em análise;
- $c(P_i)$ : Número de páginas para as quais a página  $i$  aponta <sup>2</sup>;
- $p$ : Factor de amortecimento <sup>3</sup>.

Conforme apresentado em [26], o factor de amortecimento varia entre 0 e 1, tendo sido proposto o valor de 0,85.

A diferença da Equação (3.8) para a Equação (3.9) é que no primeiro caso o algoritmo PageRank fornece um vector de dimensão  $n \times 1$  normalizado. Já o segundo caso, o índice PR é apresentado em valores absolutos. Com isso, a Equação (3.8) fornece as probabilidades de alguma página da Internet ser escolhida ao acaso.

---

<sup>1</sup>O termo *página da internet* foi mantido nesta secção apenas para efeito explicativo de forma a mater a mesma nomenclatura da bibliografia utilizada.

<sup>2</sup>Também chamado “*outbound links*” ou “*out-degree*”

<sup>3</sup>Mais usualmente chamado de factor de *damping*.

Todavia, esse formato de cálculo é pouco viável para o processamento computacional, haja vista tornar-se num processo iterativo e ser necessário atribuir valores iniciais para os  $n$   $PR(P_i)$ . Assim, a forma mais prática para o processamento é através da forma matricial.

Vários documentos descrevem o procedimento do algoritmo, como pode ser visto em [28] e [29]. Para o presente trabalho foi utilizado o algoritmo descrito em [29].

Seja  $\mathbf{G}$  a transposta da matriz de conectividade entre os estados do sistema com elementos da Equação (3.10).

$$g_{ij} = \begin{cases} 1 & \text{se há conectividade} \\ 0 & \text{se não há conectividade} \end{cases} \quad (3.10)$$

No caso original, links entre páginas na Internet, a matriz  $\mathbf{G}$  é uma matriz densa. Todavia, no presente trabalho, a matriz  $\mathbf{G}$  pode vir a ser uma matriz esparsa, a depender da quantidade de classes de irradiação<sup>4</sup> com que se trabalhe, ou seja, quanto maior a discretização da gama de valores de irradiação, maior a dimensão de  $\mathbf{G}$  e mais esparsa será essa matriz.

Seja, ainda,  $r_i$  e  $c_j$  a soma dos elementos da linha e da coluna da matriz  $\mathbf{G}$ , conforme visto na Equação (3.11)

$$r_i = \sum_j g_{ij} \quad c_j = \sum_i g_{ij} \quad (3.11)$$

Seja uma matriz diagonal com o elemento na diagonal principal da  $i$ -ésima coluna igual a  $1/c(i)$ , conforme Equação (3.12).

$$\mathbf{D} = \begin{pmatrix} 1 & 0 & \cdots & 0 \\ 0 & 1 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & 1 \end{pmatrix} \begin{pmatrix} 1/c_1 \\ 1/c_2 \\ \vdots \\ 1/c_n \end{pmatrix} \quad (3.12)$$

Assim, o vector  $\mathbf{x}$  com o *rank* de uma página de internet para um determinado instante é calculado através da Equação (3.13).

$$\mathbf{x} = p \mathbf{G} \mathbf{D} \mathbf{x} + \frac{1-p}{n} \mathbf{e} \quad (3.13)$$

Na Equação (3.13) tem-se que:

- $n$ : Número de páginas na Internet;
- $\mathbf{e}$ : Vector unitário com dimensão  $n \times 1$

---

<sup>4</sup>Buscou-se no presente trabalho desenvolver uma técnica para as séries de dados de radiação solar global se auto-regenerarem e, por isso, não foram consideradas outras variáveis. A utilização de outras variáveis para o aperfeiçoamento da técnica pode ser considerado para um trabalho futuro.

Ao isolar a variável  $\mathbf{x}$  da Equação (3.13), tem-se que o vector PageRank  $\mathbf{x}$  é calculado através da Equação (3.14)

$$\mathbf{x} = (\mathbf{I} - p \mathbf{G} \mathbf{D})^{-1} * \left( \frac{1-p}{n} \mathbf{e} \right) \quad (3.14)$$

com  $\mathbf{I}$  sendo a matriz identidade.

Na Equação (3.14),  $(1-p)/n$  é a probabilidade de uma página arbitrária ser escolhida<sup>5</sup>.

Caso o vector  $\mathbf{x}$  seja dividido pela sua soma, ter-se-á o vector das probabilidades de seleção de todas as páginas ou, no caso do presente trabalho, das classes de irradiação solar ocorrerem para uma determinada hora.

Com a variação dos parâmetros nas cadeias de Markov, bem como na forma de seleção dos dados, é possível gerar diferentes modelos e estimativas. Todo processo de estimativa de valores possui um erro associado. Com o intuito de saber qual o modelo gera as estimativas com os menores erros faz-se o uso de vários indicadores estatísticos, sendo essas as ferramentas que têm por objetivo dizer quão boa (ou ruim) é a estimativa.

## 3.2 Indicadores estatísticos para avaliação de modelos

Nesta secção serão apresentados os indicadores estatísticos mais utilizados na literatura com o objetivo de mensurar a qualidade de um modelo. A utilização desses indicadores pode ser visto em [30, 31, 32, 33, 34].

Os nomes dos indicadores nos tópicos de apresentação foram traduzidos. Todavia, quando forem referidos ao longo do texto, sempre serão utilizados suas siglas no idioma inglês de forma a se manter uma padronização com a literatura.

### 3.2.1 Erro relativo máximo absoluto

O erro relativo máximo absoluto - em inglês *Maximum Absolute Relative Error* (*erMAX*) - como o próprio nome indica, é o erro relativo máximo absoluto que um determinado modelo em análise (as estimativas de valores  $I_{i,e}$ ) teve em relação aos valores reais (valores registados  $I_{i,m}$ ), e é calculado através da Equação (3.15).

$$erMAX = \max \left( \left| \frac{I_{i,m} - I_{i,e}}{I_{i,m}} \right| \right) \quad (3.15)$$

---

<sup>5</sup>No presente trabalho, um nível de irradiação arbitrário ocorrer.

### 3.2.2 Erro médio

O erro médio, usualmente designado em inglês por *Mean Bias Error (MBE)*, dá a indicação do comportamento do modelo ( $I_{i,e}$ ) com relação ao mesmo estar a subestimar (valor negativo) ou superestimar (valor positivo) os valores de referência ( $I_{i,m}$ ). O *MBE* é calculado através da Equação (3.16).

$$MBE = \frac{1}{n} \sum_{i=1}^n (I_{i,e} - I_{i,m}) \quad (3.16)$$

### 3.2.3 Erro absoluto médio

O erro absoluto médio, em inglês *Mean Absolute Error (MAE)*, tem a função de dizer quão afastados os resultados obtidos com o modelo ( $I_{i,e}$ ) estão dos valores de referência ( $I_{i,m}$ ). O *MAE* é calculado com a Equação (3.17).

$$MAE = \frac{1}{n} \sum_{i=1}^n |I_{i,m} - I_{i,e}| \quad (3.17)$$

### 3.2.4 Erro absoluto relativo médio

O erro absoluto relativo médio, em inglês *Mean Absolute Relative Error (MARE)*, indica a distância relativa das estimativas para os valores reais e é calculado com a Equação (3.18).

$$MARE = \frac{1}{n} \sum_{i=1}^n \left| \frac{I_{i,m} - I_{i,e}}{I_{i,m}} \right| \quad (3.18)$$

### 3.2.5 Erro quadrático médio

O erro quadrático médio - em inglês *Root Mean Square Error (RMSE)* - é utilizada para comparar a performance entre modelos de previsão. Todavia, esse indicador é extremamente sensível às grandes variações, haja vista o desvio ser elevado ao quadrado. Com isso, poucos valores discrepantes podem ser o suficiente para provocarem um elevado valor do indicador. O *RMSE* é calculado através da Equação (3.19).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (I_{i,m} - I_{i,e})^2} \quad (3.19)$$

### 3.2.6 Erro quadrático médio relativo

O erro quadrático médio relativo - em inglês *Root Mean Squared Relative Error (RRMSE)* - é a divisão do *RMSE* pela média dos valores medidos. O valor é dado em percentual. Conforme [32], a exatidão de um modelo de previsão pode ser classificada como:

- Excelente, para  $RRMSE < 10\%$ ;
- Boa, para  $10\% \leq RRMSE < 20\%$ ;
- Razoável, para  $20\% \leq RRMSE < 30\%$ ;
- Má, para  $RRMSE \geq 30\%$ .

O  $RRMSE$  é calculado através da Equação (3.20).

$$RRMSE = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (I_{i,m} - I_{i,e})^2}}{\frac{1}{n} \sum_{i=1}^n I_{i,m}} \times 100 \quad (3.20)$$

### 3.2.7 Raiz da média dos desvios quadráticos relativos

A raiz da média dos desvios quadráticos relativos - em inglês *Relative Root Mean Square Error* ( $RMSRE$ ) - está para o  $RMSE$  assim como o  $MARE$  (Equação (3.18)) está para o  $MAE$  (Equação (3.17)) e é calculado através da Equação (3.21).

$$RMSRE = \sqrt{\frac{1}{n} \sum_{i=1}^n \left( \frac{I_{i,m} - I_{i,e}}{I_{i,m}} \right)^2} \quad (3.21)$$

### 3.2.8 Erro estatística-t

A estatística-t, do inglês *t-Statistic* (*t-stat*), faz uso dos indicadores  $MBE$  e  $RMSE$  e “indica se as estimativas de radiação solar não são significativamente diferentes de suas contrapartes medidas” [31]. “O modelo com valor mais próximo de zero é o de melhor desempenho” [30] para este indicador que é calculado por meio da Equação (3.22).

$$t = \sqrt{\frac{(n-1)MBE^2}{RMSE^2 - MBE^2}} \quad (3.22)$$

### 3.2.9 Coeficiente de correlação

O coeficiente de correlação de Pearson ( $R^2$ ) indica qual o grau de correlação dos valores estimados em relação aos valores medidos.  $OR^2$  pode variar entre os seguintes valores:

- -1: Correlação inversamente perfeita;
- 0: Totalmente sem correlação;
- 1: Correlação perfeita

e utiliza a Equação (3.23).

$$R^2 = \frac{\sum_{i=1}^n (I_{i,e} - I_{e,avg})(I_{i,m} - I_{m,avg})}{\sqrt{\sum_{i=1}^n (I_{i,e} - I_{e,avg})^2 \sum_{i=1}^n (I_{i,m} - I_{m,avg})^2}} \quad (3.23)$$

### 3.2.10 Incerteza a 95%

A incerteza a 95% tem por base a distribuição normal. Na distribuição normal, 95% da área da curva está contido no intervalo de  $\pm 1.96$  desvio padrão em torno da média. Esse indicador é calculado através da Equação (3.24).

$$U_{95\%} = 1.96\sqrt{SD^2 + RMSE^2} \quad (3.24)$$

Na Equação (3.24),  $SD$  é o desvio padrão das<sup>6</sup> diferenças e é dado pela Equação (3.25).

$$SD = \sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (3.25)$$

com:

- $x_i$ : o  $i$ -ésimo valor de  $x$ ;
- $\bar{x}$ : a média aritmética dos valores de  $x$ .

### 3.2.11 Índice de desempenho global

O índice de desempenho global, em inglês *Global Performance Index (GPI)*, tem por objetivo realizar uma avaliação conjunta dos indicadores apresentados entre a Secção 3.2.1 até a Secção 3.2.10 e é calculado com o uso da Equação (3.26).

$$GPI = \sum_{j=1}^{10} \alpha(\tilde{y}_j - y_{ij}) \quad (3.26)$$

Na Equação (3.26) tem-se que:

- $\alpha$ : Peso do  $j$ -ésimo indicador estatístico no cálculo do  $GPI$  com valor:

$$\alpha = \begin{cases} -1 & \text{para o indicador } R^2 \\ 1 & \text{para todos os outros indicadores} \end{cases}$$

---

<sup>6</sup>SD do termo em inglês *Standard Deviation*.

- $\tilde{y}_j$ : Mediana dos valores normalizados do  $j$ -ésimo indicador
- $y_{ij}$ : Valor normalizado do indicador  $j$  para o modelo  $i$

Conforme apresentado em [31], o modelo a que corresponder o maior valor de  $GPI$  é o que apresenta os melhores resultados, de uma forma global, entre os modelos analisados.



# Capítulo 4

## Aplicação de Processos de Markov na Reconstrução de séries de Radiação Solar Global

Neste capítulo são apresentadas as etapas que foram realizadas no desenvolvimento deste trabalho. De forma resumida:

- Obtenção dos dados;
- Montagem da base de dados
- Filtragem e tratamento dos dados;
- O processamento realizado.

### 4.1 Obtenção dos dados

Os dados utilizados neste trabalho foram fornecidos pelo Instituto Nacional de Meteorologia - INMET (Brasil). Conforme descrito na página do INMET na Internet<sup>1</sup>: “*A missão do Instituto Nacional de Meteorologia (INMET), órgão do Ministério da Agricultura, Pecuária e Abastecimento, é prover informações meteorológicas à sociedade brasileira*”<sup>2</sup>, além de representar o Brasil junto à Organização Meteorológica Mundial.

Foram selecionadas quatro estações meteorológicas automáticas localizadas na região Meio Oeste e Oeste do estado brasileiro de Santa Catarina e duas na parte sul do estado do Paraná. A Figura 4.1 apresenta a localização das seis estações utilizadas neste trabalho. A Tabela 4.1

---

<sup>1</sup>Endereço do INMET na Internet: [www.inmet.org.br](http://www.inmet.org.br).

<sup>2</sup>Texto extraído da página do INMET.

apresenta mais informações sobre as estações, nomeadamente as coordenadas geográficas e altitude.



**Figura 4.1:** Localização das estações meteorológicas automáticas da rede INMET utilizadas no presente trabalho.

**Fonte:** Imagem gerada através da ferramenta Google Earth.

**Tabela 4.1:** Dados referentes às coordenadas geográficas e altitude das estações utilizadas no presente trabalho.

Município	Altitude [m]	Latitude [°]	Longitude [°]
Caçador	944	-26.819 156	-50.985 520
Clelândia	966	-26.417 200	-52.348 741
Curitibanos	978	-27.288 624	-50.604 283
General Carneiro	1009	-26.398 473	-51.353 670
Joaçaba	768	-27.169 268	-51.558 963
Xanxerê	879	-26.938 666	-52.398 090

Os dados armazenados pelo sistema de aquisição de dados das estações fornecem a irradiação solar global horária no plano horizontal em  $\text{kJ}/\text{m}^2$ . É importante frisar que os

dados fornecidos pelo INMET não possuem qualquer tipo de tratamento ou filtragem, pelo que se tornou necessário fazer esse tratamento prévio neste trabalho.

O INMET fornece na sua página na *Internet* os dados dos últimos 12 meses para cada estação. De modo a ter acesso ao histórico dos registos, foram solicitados os dados desde o início de operação das estações utilizadas. Na Tabela 4.2 são apresentados o código, início de operação e outras informações referentes a cada estação.

**Tabela 4.2:** Códigos, datas de início de operação, primeiro e último dia com registos e total de dias na base de dados do INMET para cada estação.

Município	Código da estação	Entrada em operação	Primeiro dia com registo	Último dia com registo	Total de dias com registo
Caçador	A859	2008-03-19	2008-03-19	2017-03-31	3 300
Clevelândia	A876	2008-05-16	2008-05-15	2017-03-31	3 243
Curitibanos	A860	2008-03-03	2008-02-29	2017-03-31	3 319
General Carneiro	A875	2008-04-10	2008-04-30	2017-03-31	3 258
Joaçaba	A841	2007-09-19	2007-09-20	2017-03-31	3 481
Xanxerê	A858	2008-03-15	2008-03-15	2017-03-31	3 304

É importante ressaltar que na Tabela 4.2 o último dia com registos refere-se à última data presente nos ficheiros recebidos. Todavia, as estações continuam em operação.

## 4.2 Montagem da base de dados

Os dados foram recebidos em ficheiros no formato *xls*. Cada linha dos ficheiros representava um dia de medição, ou seja, uma linha compreendia as 24h de medição para cada uma das variáveis armazenadas. Um exemplo do formato original dos dados nos ficheiros pode ser visto na Figura 4.2.

Como pode ser visto na Figura 4.2, o formato é muito útil para a observação de alguns dados. Porém, torna-se complicado trabalhar com os mesmos para períodos longos e com muitas variáveis. Para solucionar esse problema, foi realizada a conversão de formato para a inserção dos mesmos em um Sistema Gerenciador de Base de Dados (SGBD).

Durante a fase inicial do trabalho foi utilizado o *SQLite* que, mesmo sem ser um SGBD no seu conceito mais amplo, é muito útil para testes simples e permite armazenar um volume satisfatório de informação<sup>3</sup>. Entretanto, com o objetivo de poder trabalhar com processamento

<sup>3</sup>Conforme pode ser visto em <https://sqlite.org/about.html>, o SQLite permite trabalhar com bases de dados de até 140 TiB e linhas com até 1 GiB.

	A	B	C	D	E	F	G	H	I	J	K	L
1	MINISTERIO DA AGRICULTURA, PECUÁRIA E ABASTECIMENTO-MAPA											
2	INSTITUTO NACIONAL DE METEOROLOGIA - INMET											
3	ESTAÇÃO METEOROLÓGICA AUTOMÁTICA DE XANXERÊ/SC											
4												
5												
6	Alt.	889m										
7	Lat.	26° 56' S										
8	Lon.	52° 24' W										
9												
10		PRESSÃO ATMOSFÉRICA (hPa)										
11	HORA UTC	0000	0100	0200	0300	0400	0500	0600	0700	0800	0900	1000
12	15-mar-2008	NULL										
13	16-mar-2008	NULL										
14	17-mar-2008	918,9	919,3	919,6	919,4	919,3	919,1	918,5	918,1	918,2	918,5	919,1
15	18-mar-2008	918,2	918,6	918,7	918,6	918,6	918,5	918,1	917,8	917,9	918,5	918,7
16	19-mar-2008	916,3	916,6	916,3	916,3	916,3	915,9	915,9	915,9	915,9	916,5	917,0
17	20-mar-2008	916,2	916,4	916,4	916,1	916,0	916,1	916,0	915,6	916,3	917,2	917,9
18	21-mar-2008	916,7	917,2	917,4	917,3	916,9	916,4	915,9	915,5	915,3	915,8	916,3
19	22-mar-2008	915,0	915,7	916,0	915,3	914,2	914,1	913,7	913,4	913,9	914,5	915,1
20	23-mar-2008	915,7	916,0	915,8	915,3	915,6	914,9	914,2	914,0	914,7	914,9	915,2

**Figura 4.2:** Exemplo da distribuição dos dados nos ficheiros recebidos do INMET.

paralelo e garantir maior velocidade global, os dados foram migrados para *MySQL*.

A seguir serão apresentados os procedimentos realizados para a construção da base de dados do trabalho, bem como os problemas encontrados para a inserção dos dados no SGBD e a explicação de como foram resolvidos.

#### 4.2.1 Nomes dos ficheiros

Foram recebidos oito ficheiros para cada estação. Com isso, os nomes dos ficheiros não podiam ser iguais e apresentavam caracteres diferenciadores. Esses caracteres eram:

- Um *underscore* (`_`) no início do nome ficheiro;
- Dois *underscores* (`__`) no início do nome do ficheiro;
- O número “2017” ao final do nome do ficheiro;
- Um *underscore* (`_`) no final do nome ficheiro precedido - ou não - do número “2017”;

De forma a ser possível fazer leitura sequencial dos ficheiros, foi necessário padronizar os nomes. Esse ponto apresentava, ainda, o agravante de que o código de identificação de cada estação estava no nome do ficheiro.

#### 4.2.2 Nomes das variáveis

Após a padronização dos nomes dos ficheiros, foi possível realizar a leitura sequencial dos mesmos e a conversão do formato para a inserção dos dados no SGBD. Porém, após a inserção, verificou-se uma perda considerável de dados.

Ao ser feita a análise do que estava a causar a perda, constatou-se que o nome de uma mesma variável ambiental podia ter até quatro formas de escrita. Como exemplo, para a variável “temperatura máxima do ar” foram encontrados os seguintes formatos de escrita:

- Temperatura Máxima do Ar;
- Temperatura Máxima do Ar (°C);
- Temperatura Maxima do Ar;
- Temperatura Maxima do Ar (°C).

Devidos às diferenças na forma de escrita - uma vez que “á” é diferente de “a” - foi necessário fazer uma varredura nos ficheiros para encontrar todas as formas de escritas das variáveis ambientais.

Como o número de vezes que cada variável aparecia escrita nos ficheiros era muito elevada, optou-se por fazer comparação via código dos possíveis nomes, associado com o corte no tamanho do *string* dos nomes lidos para que as unidades referentes às grandezas físicas fossem removidas.

### 4.2.3 Número de colunas dos ficheiros

Devido ao facto de cada estação possuir oito ficheiros, e o número de colunas não ser igual em todos eles, optou-se inicialmente por determinar, via programação, o número de colunas que cada ficheiro tinha quando estava ser lido. Porém isso causava erro durante a leitura dos dados, uma vez que - por serem ficheiros em formato “xls” - os mesmos poderem apresentar - ou não - colunas vazias.

Para solucionar estes problemas, optou-se por fazer uma leitura inicial da linha referente à hora de cada leitura. Como pode ser visto na Figura 4.2, a linha referente às horas era obrigatoriamente do mesmo tamanho do tamanho real do ficheiro. Assim, essa linha era lida coluna a coluna até encontrar a primeira célula vazia.

## 4.3 Tratamento e filtragem dos dados

Após solucionar os problemas enfrentados para a inserir os dados dos ficheiros recebidos na base de dados, passou-se para a fase de tratamento e filtragem dos dados. Essa é uma fase fundamental para um bom resultado final, haja vista que não basta estar em posse de dados, é necessário saber qual a qualidade desses dados.

Nesta fase do trabalho foi realizada a implementação do procedimento apresentado no *Solar Position Algorithm* (SPA) do NREL, conforme descrito em [21], em linguagem Python. Assim, foram realizados os tratamentos e filtragens apresentados a seguir.

### 4.3.1 Verificação da sincronização dos dados

Ao se trabalhar com o armazenamento de variáveis em *data loggers* há duas formas de se armazenar a hora de referência das medições. A primeira forma é armazenar a hora referente ao término do período de registo<sup>4</sup>. A segunda forma é armazenar a hora referente ao início do período de registo.

Essas duas formas, quando se trabalha com dados vindos de diferentes fontes, podem provocar um grande erro no resultado final se não houver uma uniformização. Para exemplificar, suponhamos que tem-se os dados das 16 horas *Universal Time Coordinated* (UTC)<sup>5</sup> de duas estações geograficamente próximas, porém, de responsabilidades de organismos diferentes, e que cada organismo adote uma das metodologias acima descritas. Assim, ter-se-á os seguintes casos:

- Para a estação *a*, o valor de irradiação registado às 16 horas são relativos à energia solar recebida entre as 15 horas e as 16 horas do dia em análise.
- Para a estação *b*, o valor de irradiação registado às 16 horas são relativos à energia solar recebida entre as 16 horas e as 17 horas do dia em análise.

Como é possível observar, apesar de que os dados apresentem o mesmo registo de hora no armazenamento, na verdade referem-se a períodos diferentes. Isso acarretará erros de estimação.

Para verificar se os dados estavam corretamente "sincronizados", foram realizados os seguintes passos:

1. Selecionaram-se os dias de maiores  $K_t$  (dias de céu limpo) para todos os meses com registos na base;
2. Para os dias selecionados, foi calculada através do SPA a hora UTC do menor ângulo solar zenital  $\theta$  (meio dia solar);

---

<sup>4</sup>Período durante o qual se fazem as medições e depois se determinam os correspondentes valores médios ou totais das variáveis.

<sup>5</sup>A hora UTC refere-se ao tempo em relação ao meridiano de referência. Se uma localidade está 3 fusos horários a *Este* do meridiano de referência, quando for 17h13 nessa localidade, sua hora UTC será 14h13.

3. Se a hora com o registo de irradiação mais elevado no dia selecionado fosse após o meio dia solar, é porque o valor da hora referia-se ao horário do término do período armazenado. Se fosse antes, é porque o valor da hora referia-se ao início do período.

Nem todas as estações tinham o registo de tempo sincronizado, sendo esse um dos motivos por se utilizarem os dados somente de seis estações. Entre as estações solicitadas ao INMET, havia estações em que a hora de registo referia-se ao início do período e, em uma estação, após um longo período de falha, a metodologia alterou de um caso para o outro.

### 4.3.2 Dados nulos de irradiação solar global

Para os dados referentes à irradiação solar global<sup>6</sup>, nos ficheiros fornecidos pelo INMET, há registo de valores somente entre o período compreendido entre as 9 horas UTC e as 22 horas UTC. Todavia, devido às variações entre os períodos de verão e inverno, os períodos com sol variam ao longo do ano. Assim, muitos dias possuíam registos ausentes (*NULL*) tanto do início como no fim do dia. Para verificar se esses dados eram falhas de registo ou se eram referentes ao período noturno (antes do nascer do sol ou após o pôr do sol), foi necessário calcular as horas do nascer e pôr do sol para todos os dias de todas as estações.

Após o cálculo exato das horas, os registos de todos os dias de cada estação foram cruzados com as horas de nascer e pôr do sol do referido dia para a localização da estação. Com isso, foi possível separar os valores nulos (*NULL*) que eram referentes a falhas de medição e/ou de registo dos casos em que os valores eram nulos devido ao facto da hora de registo ser anterior ao nascer do sol ou posterior ao pôr do sol.

### 4.3.3 Validação dos dados

Para a validação dos dados de radiação solar foram utilizados os procedimentos e limites adotados pelo *Baseline Surface Radiation Network* (BSRN) e que podem ser consultados em [35].

O BSRN apresenta dois níveis de limites (algoritmos) para os valores de irradiação solar global. O algoritmo BSRN 1 refere-se aos *limites fisicamente possíveis* (LFP) e apresenta maiores tolerâncias do que algoritmo BSRN 2 que, por sua vez, refere-se aos *limites extremamente raros* (LER). Os valores para o LFP e LER são:

- Limites fisicamente possíveis (LFP):

- Valor mínimo:  $-4 \text{ W/m}^2$

---

<sup>6</sup>Referente aos dados de irradiação, os ficheiros fornecidos pelo INMET continham somente os dados de irradiação solar global horária no plano horizontal.

- Valor máximo:  $S_a \times 1.5 \times \mu_0^{1.2} + 100 \text{ W/m}^2$
- Limites extremamente raros (LER):
  - Valor mínimo:  $-2 \text{ W/m}^2$
  - Valor máximo:  $S_a \times 1.2 \times \mu_0^{1.2} + 50 \text{ W/m}^2$

com  $S_a$  sendo a constante solar corrigida para o real afastamento Terra - Sol ( $G_{sc} / R$ ); e  $\mu_0$ , o cosseno do ângulo solar zenital ( $\cos(\theta)$ ). É possível observar que são admitidos valores nos limites superiores ao valor de  $S_a$ . Isso é possível porque as nuvens podem provocar um efeito de lente na radiação devido à reflexão da radiação solar nas nuvens, ocasionando uma concentração solar natural.

Para poder validar os valores horários de irradiação solar global utilizando os algoritmos BSRN, que são referentes à irradiação, os limites físicos e extremamente raros de cada hora foram calculados com passo de discretização de 1 segundo e depois integrados numericamente para o período de dados de irradiação utilizados no presente trabalho. O passo de discretização de tempo de um segundo foi adoptado com o objectivo de ter a melhor discretização possível. Todavia, os procedimentos de cálculos do SPA exigem maior capacidade de processamento. Logo, a etapa de validação foi a que demandou o maior tempo de processamento no presente trabalho.

Após a verificação e filtragem dos dados foi gerado um código para indicar o estado de cada registo. O padrão adoptado para esse código de validação foi o utilizado no projeto Sistema de Organização Nacional de Dados Ambientais (SONDA) - Brasil, mas com pequenas modificações. Com isso, o padrão ficou conforme apresentado na Tabela 4.3.

**Tabela 4.3:** Padrão de códigos adotado para a validação dos dados de irradiação solar global utilizados no trabalho.

Código	Projeto SONDA	Presente trabalho
0	Nenhum procedimento foi adotado	Valor no período noturno
2	Valor suspeito de ser incorreto	Valor suspeito de ser incorreto
5	Procedimento não pode ser executado	Valor ausente (Falha)
9	Valor de boa qualidade ou não suspeito	Valor de boa qualidade ou não suspeito

Os códigos de validação da Tabela 4.3 foram utilizados para facilitar o processo de seleção dos dados para o cálculo dos valores de irradiação solar global na reconstrução das séries com o modelo proposto no trabalho.

## Qualidade dos dados

Após a criação da base de dados e filtragem/tratamento dos valores, foi possível saber qual o volume real de informação útil disponível para trabalhar. Essa quantidade é apresentada na Tabela 4.4<sup>7</sup>.

**Tabela 4.4:** Inventário dos registos de irradiação solar global - Quantidades absolutas de dados após aplicação dos filtros de qualidade BSRN.

Estação	Dias	Registos		Nulos	Suspeitos LFP	Suspeitos LER	Válidos
		Noturnos	Diurnos				
A841	3 481	38 787	44 757	2 573	0	1	42 183
A858	3 304	37 006	42 290	3 236	155	47	38 852
A859	3 300	36 847	42 353	1 023	4	18	41 308
A860	3 319	37 054	42 602	836	2	3	41 761
A875	3 258	36 380	41 812	2 216	1	1	39 594
A876	3 243	36 280	41 552	8 670	46	11	32 825
<b>Totais</b>		<b>222 354</b>	<b>255 366</b>	<b>18 554</b>	<b>208</b>	<b>81</b>	<b>236 523</b>

A Tabela 4.5 apresenta a qualidade dos dados com relação aos valores percentuais de dados em cada categoria na Tabela 4.4.

**Tabela 4.5:** Inventário dos registos de irradiação solar global - Qualidade dos dados referentes ao período diurno após aplicação dos filtros de qualidade dos dados.

Estação	Registos nulos	Suspeitos LFP	Suspeitos LER	Registos válidos
A841	5.749%	0.000%	0.002%	94.249%
A858	7.652%	0.367%	0.111%	91.870%
A859	2.415%	0.009%	0.042%	97.533%
A860	1.962%	0.005%	0.007%	98.026%
A875	5.300%	0.002%	0.002%	94.695%
A876	20.865%	0.111%	0.026%	78.997%
<b>Totais</b>	<b>7.266%</b>	<b>0.081%</b>	<b>0.032%</b>	<b>92.621%</b>

Nesta parte do trabalho é importante referir que, nos ficheiros recebidos, a máxima hora UTC com registo de energia solar são as 22 horas. Contudo, no período do verão, o pôr do sol

<sup>7</sup>Os algoritmos 1 e 2 da Tabela 4.4 e da Tabela 4.5 referem-se, respetivamente, aos limites “físicos” e “extremamente raros” do BSRN.

ocorre após essa hora em algumas estações. Como exemplo pode-se citar o caso da estação localizada no município de Xanxerê (estação A858) que, no dia 2012-01-11 apresentou pôr do sol por volta das 22 horas e 28 minutos UTC. Porém, na base de dados, o último registo de irradiação é às 22 horas UTC.

## **4.4 Processamento realizado**

Após os processos de criação da base de dados e validação dos dados, foi realizado o processamento dos dados para testar a metodologia proposta neste trabalho.

O procedimento proposto consiste em aproximar o comportamento aleatório da irradiação solar global horária ao comportamento de uma pessoa ao navegar entre páginas na Internet. Para isso, utilizou-se o algoritmo de busca apresentado na Secção 3.1.2. O algoritmo da Secção 3.1.2 tem por objetivo fazer a indexação das páginas da Internet, ou seja, dizer qual página possui maior probabilidade de ser a que o usuário esteja a procurar. No caso do presente trabalho, o objetivo é encontrar o nível de irradiação solar que melhor se enquadra numa falha de dados de modo a se preencher essa lacuna com uma boa estimativa. O procedimento adotado segue os passos descritos nas secções seguintes.

### **4.4.1 Identificação das falhas**

Para a identificação da falha - registo nulo ou que tenha falhado no processo de validação dos algoritmos da BSRN - é realizada uma consulta na base de dados. Nessa consulta, os dados referentes ao código da estação, dia e hora da falha são localizados e selecionados para serem tratados.

### **4.4.2 Seleção dos dados para geração da simulação**

Com o objectivo de testar o método, foram geradas falhas artificiais compreendidas entre as 13h UTC e 20h UTC. Assim, os dados selecionados para a geração da simulação estavam entre as 12h UTC e 20h UTC. Esse intervalo de horas para a geração das falhas artificiais foi escolhido para que todos os dados selecionados estivessem compreendidos em horas de sol, excluindo dessa forma as horas com nascer ou pôr do sol.

Além do intervalo de horas anteriormente citado, foram escolhidos os dados nos meses de fevereiro, abril, junho, agosto, outubro e dezembro com o objectivo de abranger todas as 4 estações do ano, haja vista as estações estarem em região subtropical e com as 4 estações do ano bem definidas.

Além disso, de forma a garantir o melhor estudo de qualidade dos dados gerados, para cada estação foi escolhido o ano com a maior quantidade possível de dados válidos. Assim, o ano seleccionado para cada estação foi:

- A841: 2015
- A859: 2013
- A875: 2012
- A858: 2012
- A860: 2016
- A876: 2009

No estudos das ciências atmosféricas, as condições podem ser consideradas aproximadamente constantes para um intervalo de 5 dias para trás ou para frente [36]. Com isso em mente, os dados seleccionados para a hora da falha artificial e a hora anterior foram seleccionados dentro de um intervalo de datas. Esse intervalo de datas variou de mais ou menos 1 dia até mais ou menos 10 dias em torno do dia que estava a ser analisado.

De forma a exemplificar, suponha-se que para uma estação em análise existe uma falha de medição (ou esta foi criada artificialmente com o objectivo de verificação do modelo) às 15 horas do dia 2016-08-24. Com o objectivo de testar todas as combinações possíveis de parâmetros a serem variados no modelo proposto e, assim, encontrar a configuração que proporciona o melhor resultado, serão seleccionados os dados das 14 horas e das 15 horas para os seguintes intervalos de datas:

- $\pm 1$  dia: Dados das 14h UTC e 15h UTC de 2016-08-23 a 2016-08-25;
- $\pm 2$  dias: Dados das 14h UTC e 15h UTC de 2016-08-22 a 2016-08-26;
- $\pm 5$  dias: Dados das 14h UTC e 15h UTC de 2016-08-19 a 2016-08-29;
- $\pm 10$  dias: Dados das 14h UTC e 15h UTC de 2016-08-14 a 2016-09-03;

Os dados seleccionados retornam em duas matrizes de iguais dimensões  $n \times 2$ , sendo  $n$  o número de dias do intervalo de interesse; e 2, as duas horas seleccionadas. Uma matriz retorna os valores de irradiação registados no período. A outra matriz, os códigos de validação para cada valor registado.

#### 4.4.3 Filtragem e tratamento dos dados seleccionados

A filtragem dos dados seleccionados consiste na remoção das possíveis falhas existentes nesses dados, bem como valores erróneos, e segue o procedimento descrito na Secção 4.3.3. Conforme visto na Secção 4.4.2, uma das matrizes retornadas contém os códigos de validação<sup>8</sup>. Esses códigos podem ser:

---

<sup>8</sup>Códigos de validação conforme modelo adoptado pelo projecto SONDA para os limites (fisicamente possível e extremamente raro) do BSRN para a irradiação solar global.

- 0: Nenhum procedimento realizado (dado referente a um período noturno.)
- 5: falha
- 2: valor suspeito no algoritmo 1 do BSRN (LFP)
- 29: valor suspeito no algoritmo 2 do BSRN (LER)

Assim, a matriz com os códigos de validação é percorrida e caso algum dos códigos de erros apareça na linha analisada, a linha equivalente na matriz com os dados de irradiação é removida. Após essa filtragem, os dados estão prontos para o início do processamento.

A partir dos dados já limpos de erros ou valores suspeitos oriundos da Secção 4.4.3 é realizado o processamento que passa a ser descrito.

#### 4.4.4 Cálculo dos limites de irradiação utilizados nos modelos

O primeiro passo a ser realizado é o calculo dos limites inferior e superior dos valores de irradiação. Inicialmente pensou-se em manter os limites fixos nos seguintes valores:

- Para o limite inferior, 95% do menor valor de irradiação presente na matriz de dados válidos;
- Para o limite superior, 105% do maior valor de irradiação presente na matriz de dados válidos, limitado ao valor calculado com o algoritmo 2 do BSRN - *Valor extremamente raro* - para o dia e hora da falha.

Entretanto, com o objetivo de gerar outras configurações do modelo através da combinação de vários parâmetros, os valores de tolerância foram variados. Assim, foram gerados modelos com as seguintes tolerâncias:

- $\pm 0\%$  (limites estritamente dentro do mínimo e máximo registados)
- $\pm 5\%$
- $\pm 10\%$

#### 4.4.5 Geração das classes de irradiação

Após estabelecidos os limites de irradiação, são geradas as classes - ou níveis - de energia. Para gerar as classes, verifica-se a amplitude dos valores de irradiação para a hora e dia da falha com base nos registos correspondentes dos dias adjacentes para a mesma hora. Essa amplitude é dividida em um número inteiro de classes de forma a manter os intervalos iguais.

As classes de irradiação assumem, no presente trabalho, a função de estados na Cadeia de Markov. Sendo assim, a quantidade de classes - ou níveis - de irradiação para a hora anterior à da falha bem como da própria hora da falha em análise devem ser iguais. Todavia, devido aos diferentes limites de irradiação calculados em ambas as horas - conforme explicado na Secção 4.4.4 - os intervalos das classes para cada hora diferem entre si.

Inicialmente utilizou-se a abordagem de variar esse número de classes de forma a ser suficientemente grande para garantir um intervalo máximo entre as classes de irradiação na hora da falha em análise de apenas  $1.0 \text{ kJ/m}^2$ . No entanto, ao realizar essa abordagem foi possível verificar que o número de classes geradas era tão grande que a matriz de conexão tornava-se extremamente esparsa, sendo que algumas situações a matriz possuía 99.999% de elementos nulos, devido ao facto de não se verificarem ocorrências em muitas das classes. Além disso, essas matrizes de ordem tão elevadas exigem um grande esforço computacional para o processamento.

Após essa abordagem inicial, os dados foram reanalisados com a geração de quantidades fixas e menores de classes de irradiação, variando entre 25 e 100 classes. Com essa redução foi possível observar que os melhores resultados eram obtidos com os menores números de classes e, assim, promoveu-se uma segunda redução. Por fim, verificou-se que os melhores resultados eram obtidos quando se trabalhava gerando modelos com 5, 6, 7, 8, 9, 10, 15 e 20 classes de irradiação. Essa drástica redução no número de classes de irradiação acabou por se apresentar duplamente vantajosa. Além de prevenir a quebra do sistema pelo facto da matriz de conexões ser extremamente esparsa, matrizes de menor dimensão exigem menos esforço computacional, o que terminou por deixar o processo muito mais rápido do que a abordagem inicial.

#### 4.4.6 Geração da matriz de transição de estados

A etapa seguinte é a conversão dos dados de irradiação já limpos de erros obtidos após a etapa apresentada na Secção 4.4.3 em uma matriz  $n \times n$ , onde  $n$  é o número de classes de irradiação. Para essa conversão, percorre-se a matriz de dados da etapa descrita na Secção 4.4.3 e verifica-se em quais classes obtidas na Secção 4.4.5 a hora anterior e a hora em análise se enquadram, sendo a classe da hora anterior o número da linha (*índice  $i$* ); e da hora em análise, o número da coluna (*índice  $j$* ) da matriz de transição de estados de Markov. Após essa identificação, o elemento  $g_{i,j}$  da matriz de *zeros* inicial é acrescido em uma unidade, representando mais uma transição naquela mudança específica de estado.

A matriz resultante após essa etapa é a matriz final da transição de estados de Markov que será utilizada no processamento do algoritmo Google™ PageRank™ apresentado na Secção 3.1.2. Todavia, ao invés de manter o índice de amortecimento  $p$  constante em 0.85, o mesmo

foi variado entre os valores de 0.65, 0.75, 0.85 e 0.95 de modo a analisar várias configurações do modelo.

Vale destacar que a matriz de transição de estados para o cálculo da estimativa de irradiação solar foi gerada para cada hora simulada de cada mês em todas as estações.

#### 4.4.7 Obtenção do valor final da estimativa

Conforme descrito na Secção 3.1.2, o vector normalizado obtido após o processamento é um vector de probabilidades. Com esse conhecimento, o cálculo da estimativa é realizado através do producto vetorial entre o vector  $\mathbf{x}$  do algoritmo Google™ PageRank™ com os valores de irradiação das classes descritas na Secção 4.4.5. Todavia, como o processamento fez uso de poucas classes por simulação, conforme já explicado na Secção 4.4.5, o valor que resulta desse producto pode estar ainda longe da melhor estimativa. Com o objectivo de melhorar a estimativa, através da geração de mais modelos, as classes foram subdivididas.

Para exemplificar a subdivisão das classes, suponhamos que para uma falha qualquer o limite máximo aceitável de irradiação horária, conforme exposto na Secção 4.4.4, seja de 3600 kJ/m<sup>2</sup> e sejam analisadas 6 classes, dessa forma, as classes são as apresentadas na Tabela 4.6.

**Tabela 4.6:** Tabela exemplo dos valores para as classes de irradiação para uma falha com limite máximo aceitável 3600 kJ/m<sup>2</sup> e 6 classes. Valores mínimos e máximos em kJ/m<sup>2</sup>.

Classe	Irradiação mínima	Irradiação máxima
1	0	600
2	600	1200
3	1200	1800
4	1800	2400
5	2400	3000
6	3000	3600

Como pode ser visto na Tabela 4.6, as classes possuem grande amplitude, o que pode resultar num grande desvio em relação ao valor correcto. Outra questão é determinar qual o valor dentro de cada classe deve ser utilizado, o limite inferior, o valor médio ou o limite superior. Subdividindo as classes da Tabela 4.6 é possível gerar a Tabela 4.7

Conforme o apresentado na Tabela 4.7, para cada conjunto de parâmetros são gerados 3 modelos. Essa abordagem de dividir as classes em subclasses apresenta duas vantagens.

A principal vantagem é a de reduzir o salto entre os níveis de energia, o que promove uma

**Tabela 4.7:** Tabela exemplo dos valores para as classes de irradiação para uma falha com limite máximo aceitável  $3600 \text{ kJ/m}^2$  e 6 classes após a divisão em subclasses. Valores em  $\text{kJ/m}^2$ .

Classe	Nível ou Subclasse		
	1	2	3
1	0	300	600
2	600	900	1200
3	1200	1500	1800
4	1800	2100	2400
5	2400	2700	3000
6	3000	3300	3600

melhor discretização sem correr o risco de instabilidade do modelo - conforme descrito na Secção 4.4.5.

A segunda vantagem é que a multiplicação de vetores possui um custo computacional muito inferior ao da resolução de um sistema linear de igual dimensão. Dessa forma é possível obter uma melhor discretização do modelo - menores saltos entre as classes - sem substancial aumento no tempo de processamento.

Assim, o vector  $\mathbf{x}$  normalizado das probabilidades é multiplicado pelos 3 diferentes níveis de irradiação e, posteriormente, a seleção do melhor modelo é realizada conforme apresentado na Secção 4.4.8.

#### 4.4.8 Seleção da melhor combinação de parâmetros

Após a realização de todo o processamento, faz-se necessário escolher a combinação de parâmetros ou factores que definem o modelo que melhor se adapta aos valores efetivamente registados pelos equipamentos de medição. Para realizar a seleção, utilizaram-se os indicadores estatísticos apresentados na Secção 3.2.

Para cada hora estimada foram gerados 1200 modelos através da variação dos seguintes parâmetros:

- Número de dias para a selecção dos dados ( $\pm 1$  dia,  $\pm 2$  dias,  $\pm 5$  dias e  $\pm 10$  dias);
- Variação dos limites admissíveis de irradiação ( $\pm 0\%$ ,  $\pm 5\%$  e  $\pm 10\%$ );
- Número de classes de irradiação geradas (5, 6, 7, 8, 9, 10, 15 e 20 classes);
- Coeficiente de amortização  $p$  do algoritmo (0.65, 0.75, 0.85 e 0.95)

Conforme já apresentado na Secção 3.2.11, o GPI realiza uma análise agregada de todos os indicadores estatísticos. Dessa forma, foi selecionado o modelo com maior GPI para cada hora entre as 1200 estimativas, considerando diferentes períodos de análise de dados. Os períodos de análise foram escolhidos de forma a encontrar o melhor modelo global tomando como base os seguintes intervalos de dias:

- Melhor ajuste mensal: Modelo de maior GPI para o período compreendido entre o início e fim do mês
- Melhor ajuste quinzenal: Modelo de maior GPI para cada uma das duas quinzenas do mês
  - Quinzena 1: Período compreendido entre o dia 1 e o dia 14 do mês
  - Quinzena 2: Período compreendido entre o dia 15 e o dia 28 do mês
- Melhor ajuste semanal: Modelo de maior GPI para cada semana do mês
  - Semana 1: Período compreendido entre o dia 1 e o dia 7 do mês
  - Semana 2: Período compreendido entre o dia 8 e o dia 14 do mês
  - Semana 3: Período compreendido entre o dia 15 e o dia 21 do mês
  - Semana 4: Período compreendido entre o dia 22 e o dia 28 do mês
- Melhor ajuste diário: Modelo de maior GPI para cada dia do mês

# Capítulo 5

## Análise e discussão dos resultados

Com o objectivo de realizar uma avaliação global, foi gerada a Tabela 5.1 que apresenta o resumo dos resultados obtidos no processamento. Os gráficos e tabelas completas para todos os meses e período em análise correspondentes ao melhor ajuste em cada estação são apresentados nos apêndices do presente trabalho.

Na Tabela 5.1 cada ocorrência equivale a uma hora simulada, que pode variar entre 222 e 223 para cada estação. Para título explicativo, ao verificar-se que 132 ocorrências apresentaram melhor resultado utilizando os dados com 1 dia de variação em torno do dia em análise na estação A841, significa que esse parâmetro foi mantido fixo enquanto os demais parâmetros (número de classes, variação dos limites e coeficiente de amortização  $p$ ) foram variados.

É possível observar na Tabela 5.1 que os melhores resultados são obtidos quando são utilizados os dados registados dentro de uma variação de mais ou menos um dia em torno do dia em análise. Esse resultado já era esperado, haja vista que um dia qualquer apresenta condições meteorológicas semelhantes aos dias mais próximos numa percentagem elevada de dias no ano (modelo de persistência), o que vai ao encontro do apresentado em [36] e já abordado na Secção 4.4.2.

No que diz respeito à quantidade de classes de irradiação (estados do sistema nas cadeias de Markov) é possível observar que os melhores resultados são conseguidos - na grande maioria dos casos - com apenas 5 a 10 classes, com um valor máximo global de ocorrências para o caso de 5 classes, o que é um facto extremamente importante. Quando o sistema é processado com poucas classes de irradiação, o processamento torna-se muito mais rápido em virtude das menores dimensões do sistema, o que exige menor esforço computacional. O factor negativo de possuir poucas classes é que o salto entre elas torna-se grande. A solução adoptada para minimizar estes saltos foi criar subdivisões dentro das classes quando se faz a multiplicação dos pesos de cada classe, conforme apresentado na Secção 4.4.7. Assim sendo, cada conjunto

**Tabela 5.1:** Tabela resumo com o número de ocorrências dos parâmetros de simulações que apresentaram os melhores ajustes considerando todos os períodos de análise de um dia.

Dias	A841	A858	A859	A860	A875	A876
<b>1</b>	<b>132</b>	<b>145</b>	<b>144</b>	<b>128</b>	<b>122</b>	<b>134</b>
2	46	33	41	42	40	50
5	29	23	16	24	31	16
10	16	22	22	29	29	23
Classes	A841	A858	A859	A860	A875	A876
<b>5</b>	<b>97</b>	<b>74</b>	<b>89</b>	<b>86</b>	<b>101</b>	<b>97</b>
6	39	58	34	40	36	34
7	24	27	29	33	26	28
8	21	23	22	14	19	27
9	7	15	23	12	16	17
10	15	11	9	14	9	8
15	7	6	9	12	6	6
20	13	9	8	12	9	6
Variação	A841	A858	A859	A860	A875	A876
-0.10	27	30	32	31	30	24
-0.05	23	19	15	22	24	25
<b>0</b>	<b>76</b>	<b>84</b>	<b>76</b>	<b>60</b>	<b>61</b>	<b>77</b>
0.05	42	48	61	58	48	47
0.10	55	42	39	52	59	50
Factor $p$	A841	A858	A859	A860	A875	A876
0.65	24	15	14	19	17	16
0.75	8	11	20	18	12	14
0.85	53	53	46	58	49	43
<b>0.95</b>	<b>138</b>	<b>144</b>	<b>143</b>	<b>128</b>	<b>144</b>	<b>150</b>

de parâmetros resultava, na verdade, em 3 estimativas distintas, uma vez que o vector  $\mathbf{x}$  normalizado era multiplicado pelos níveis inferiores, médios e superiores das classes. Ou seja, com o mesmo tempo de processamento foi possível estimar 3 valores de irradiação distintos.

No que respeita aos limites de tolerância para os valores mínimos e máximos de irradiação, observou-se que considerar nula a tolerância, ou seja, que os valores aceitáveis fiquem entre o mínimo e máximo registados no período seleccionado, apresenta uma frequência de ocorrência ligeiramente maior. Todavia, é menos clara a existência de um valor que possua uma frequência de ocorrência de "*melhores resultados*" muito superior à dos outros valores.

Por fim, tem-se o factor de amortecimento  $p$  do algoritmo Google™ PageRank™. Foi possível observar que valores elevados de  $p$  ( $0.85 \leq p \leq 0.95$ ) concentraram os melhores resul-

tados. Uma explicação plausível para isso é o próprio significado do factor de amortecimento conforme apresentado na Equação (3.14) onde é exposto que  $(1 - p)/n$  é a probabilidade de um nível de irradiação arbitrário ocorrer, o que vai ao encontro do proposto no algoritmo PageRank original ( $p = 0.85$ ).

A Tabela 5.2 apresenta o resumo dos indicadores estatísticos entre os valores medidos ( $I_m$ ) e estimados ( $I_e$ ) através da metodologia proposta no presente trabalho para todas as horas simuladas nas 6 estações ao considerar o modelo com o melhor ajuste dia a dia.

**Tabela 5.2:** Resumo dos indicadores estatísticos entre os valores medidos ( $I_m$ ) e estimados ( $I_e$ ) através da metodologia proposta no presente trabalho para todas as horas simuladas nas 6 estações ao considerar o modelo com o melhor ajuste dia a dia.

Indicadores	Estações						Unidades
	A841	A858	A859	A860	A875	A876	
erMAX	97.60	68.15	74.23	12.32	45.91	45.50	kJ/(m <sup>2</sup> h)
MBE	36.55	33.58	61.45	33.68	33.93	49.57	kJ/(m <sup>2</sup> h)
MAE	307.84	303.07	262.64	228.42	269.11	230.15	kJ/(m <sup>2</sup> h)
RMSE	436.10	435.12	383.99	316.42	381.96	350.69	kJ/(m <sup>2</sup> h)
RRMSE	25.75	24.90	22.27	18.53	23.83	18.83	
RMSRE	3.99	2.93	3.16	0.79	2.65	2.73	
T-Stat	3.182	2.943	6.162	4.071	3.379	5.428	
$R^2$	0.888	0.905	0.936	0.944	0.923	0.934	
$U_{95\%}$	1777.61	1933.82	1979.19	1754.01	1844.58	1772.41	kJ/(m <sup>2</sup> h)
$\bar{I}_m$	1693.35	1747.80	1724.19	1707.80	1602.69	1862.75	kJ/(m <sup>2</sup> h)
$\bar{I}_e$	1729.90	1781.39	1785.64	1741.91	1636.62	1912.32	kJ/(m <sup>2</sup> h)
$SD_m$	940.18	1018.41	1060.95	939.76	983.65	958.17	kJ/(m <sup>2</sup> h)
$SD_e$	795.21	885.52	933.93	837.10	860.11	833.52	kJ/(m <sup>2</sup> h)
$\tilde{I}_m$	1701.95	1766.94	1696.07	1701.52	1560.21	1924.70	kJ/(m <sup>2</sup> h)
$\tilde{I}_e$	1686.66	1688.35	1744.73	1691.66	1576.14	1889.78	kJ/(m <sup>2</sup> h)

Com o objectivo de analisar estatisticamente o impacto ao modificar-se o intervalo de tempo (análise diária, semana, quinzenal ou mensal) para a escolha do modelo de melhor ajuste, elaborou-se a Tabela 5.3. A Tabela 5.3 apresenta os indicadores estatísticos para o mês de dezembro de 2009 na estação A876. A escolha do mês e estação foram aleatórias. Vale lembrar que os valores gerados correspondem aos valores de irradiação solar global entre as 13 horas UTC e 20 horas UTC. Essa gama de horas foi escolhida para garantir que todos os valores selecionados correspondiam a horas completas com o Sol acima do horizonte.

No caso específico da Tabela 5.3 foi considerado apenas até o dia 28 para o mês de dezembro de forma a todos os 4 períodos de tempo para análise do modelo de melhor ajuste possuírem iguais quantidade de dados gerados.

Através da Tabela 5.3 é possível observar que os valores estimados ao se considerar o modelo

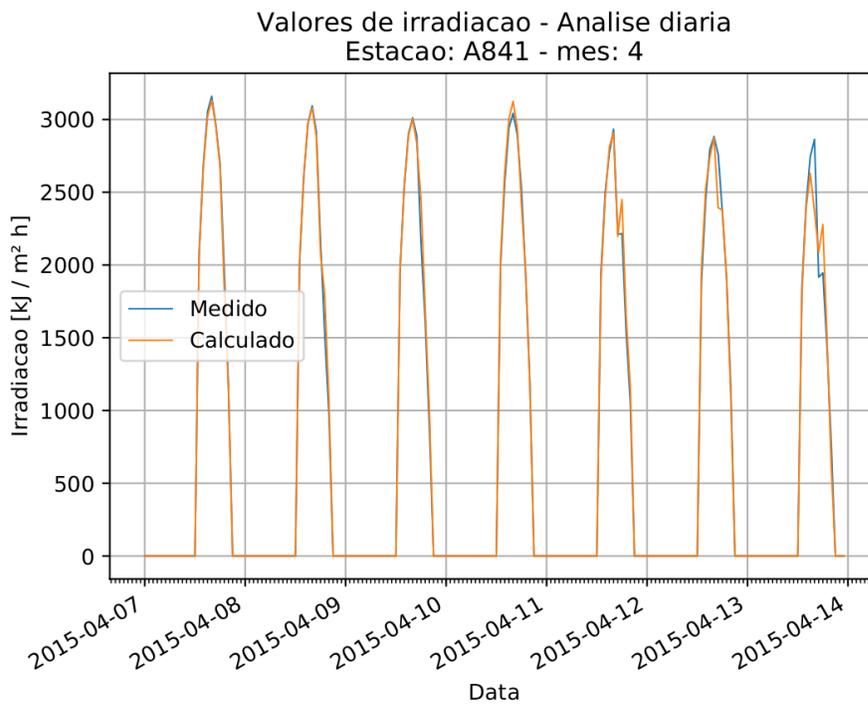
**Tabela 5.3:** Comparativo dos indicadores estatísticos entre os valores medidos ( $I_m$ ) e os estimados ( $I_e$ ) entre os dias 1 e 28 de dezembro de 2009 para a estação A876 ao considerar os 4 espaços temporais de análise do melhor modelo.

Indicadores	Tipo de análise				Unidades
	Diária	Semanal	Quinzenal	Mensal	
erMAX	45.50	58.11	66.58	58.22	$\text{kJ}/(\text{m}^2 \text{ h})$
MBE	18.84	42.25	0.67	-56.10	$\text{kJ}/(\text{m}^2 \text{ h})$
MAE	288.43	514.55	543.36	555.23	$\text{kJ}/(\text{m}^2 \text{ h})$
RMSE	403.60	696.20	730.37	766.15	$\text{kJ}/(\text{m}^2 \text{ h})$
RRMSE	17.56	30.29	31.78	33.34	
RMSRE	3.73	4.84	5.36	4.78	
T-Stat	0.698	0.908	0.014	1.096	
$R^2$	0.920	0.727	0.692	0.663	
$U_{95\%}$	1855.11	1986.54	1995.63	2131.16	$\text{kJ}/(\text{m}^2 \text{ h})$
$\bar{I}_m$		2298.30			$\text{kJ}/(\text{m}^2 \text{ h})$
$\bar{I}_e$	2317.14	2340.56	2298.98	2242.20	$\text{kJ}/(\text{m}^2 \text{ h})$
$SD_m$		1014.40			$\text{kJ}/(\text{m}^2 \text{ h})$
$SD_e$	856.12	736.60	709.40	771.55	$\text{kJ}/(\text{m}^2 \text{ h})$
$\tilde{I}_m$		2514.91			$\text{kJ}/(\text{m}^2 \text{ h})$
$\tilde{I}_e$	2337.38	2463.52	2444.94	2384.18	$\text{kJ}/(\text{m}^2 \text{ h})$

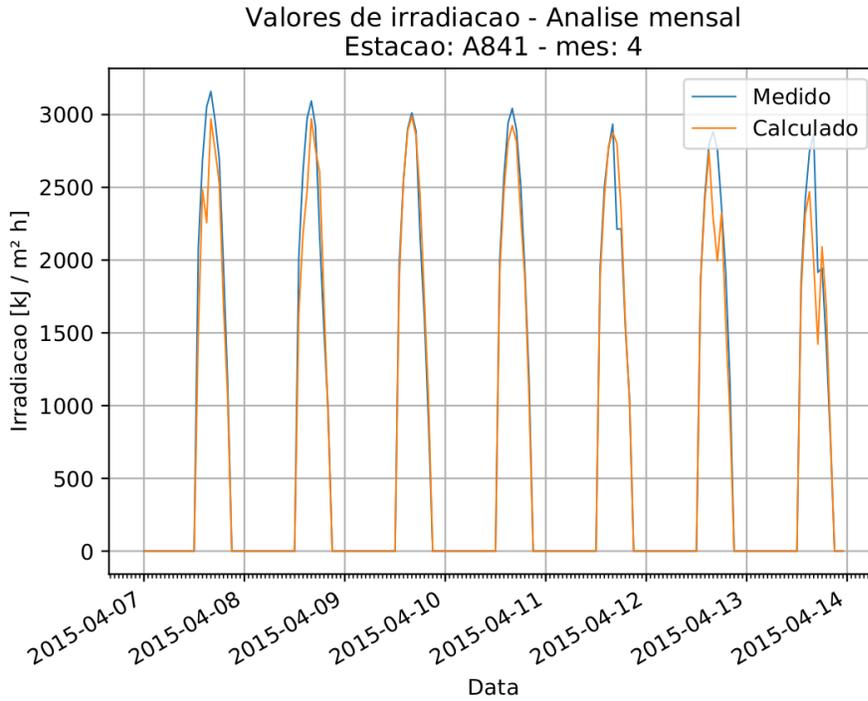
de melhor ajuste dia a dia apresenta menor dispersão em relação aos valores efectivamente registados. Esse comportamento já era esperado, haja vista estar a ser feita a escolha da configuração do modelo que melhor descreve cada dia. Todavia, caso o interesse seja uma simulação rápida de valores, a escolha dados modelos com melhores ajustes para cada quinzena do mês já pode resultar numa boa aproximação, uma vez que a média dos valores estimados está muito próxima da dos medidos, além de possuir o menor desvio padrão.

Os gráficos das Figuras 5.1 até 5.5 apresentam comparativos detalhados para dias de céu limpo, período de transição entre céu limpo e dias de céu encoberto e períodos de dias com tempo instável<sup>1</sup>. As escolhas dos dias e estações dos gráficos das Figuras 5.1 até 5.5 foram feitas com o objectivo de encontrar os períodos que fossem possíveis observar da melhor forma cada um dos exemplos.

<sup>1</sup>Nos apêndices do presente trabalho são fornecidos os gráficos comparativos para todos os meses simulados, bem como as tabelas com os parâmetros que garantiram os melhores ajustes para as análises mensais, quinzenais, semanais e diárias.

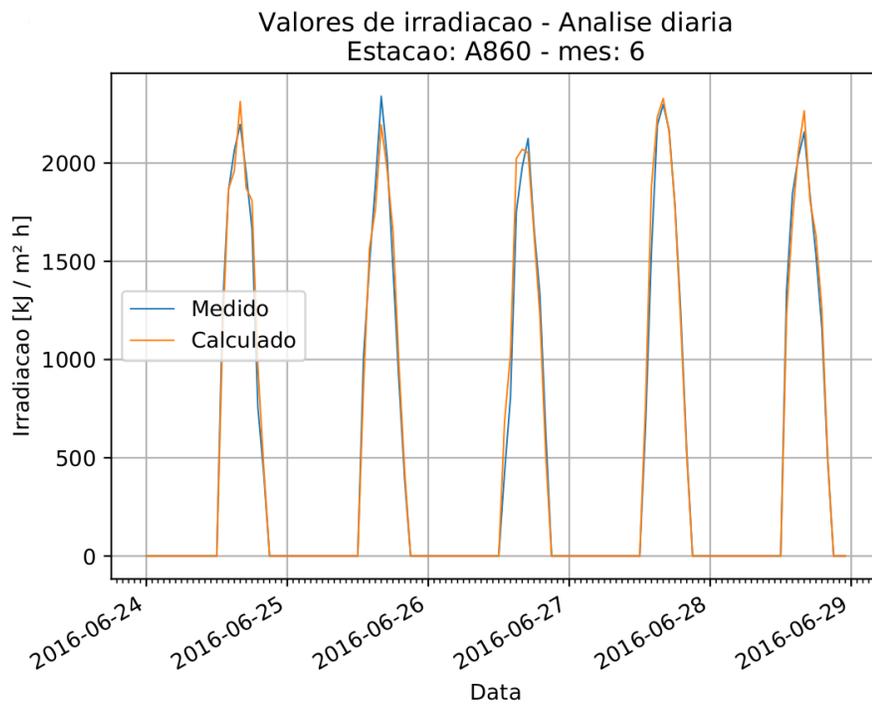


(a) Melhores ajustes diários.

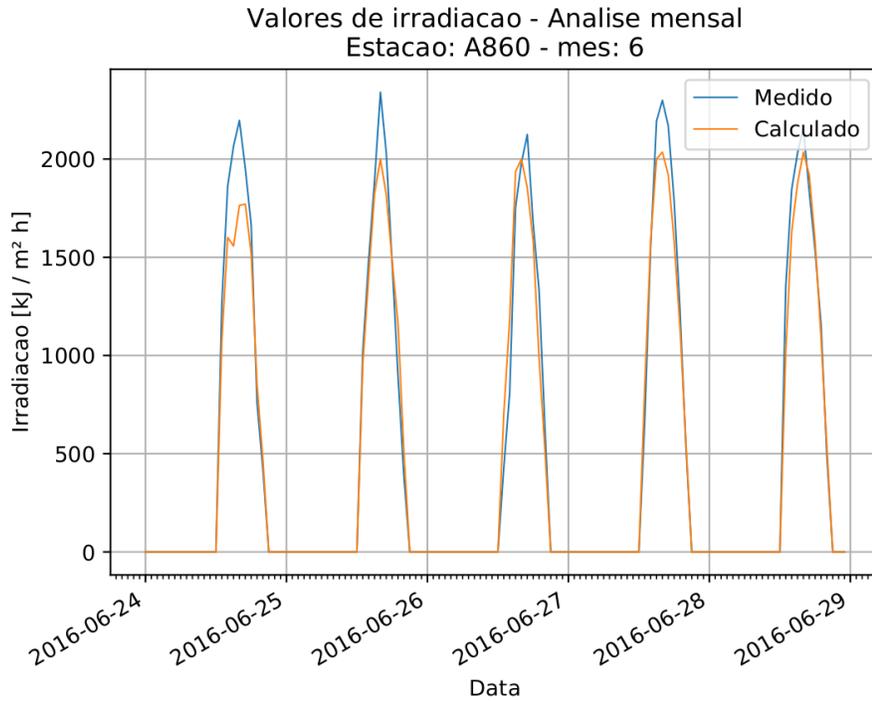


(b) Melhor ajuste mensal.

**Figura 5.1:** Comparativo entre os valores medidos e estimados através dos parâmetros de melhor ajuste para a análise diária e mensal numa situação de céu limpo na estação A841 durante o mês de abril de 2015.

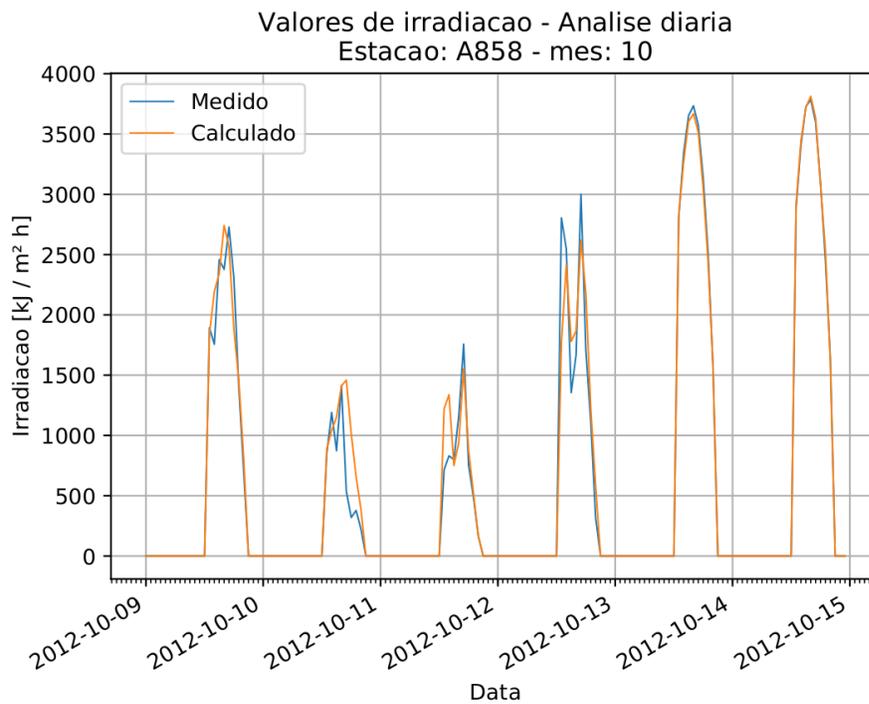


(a) Melhores ajustes diários.

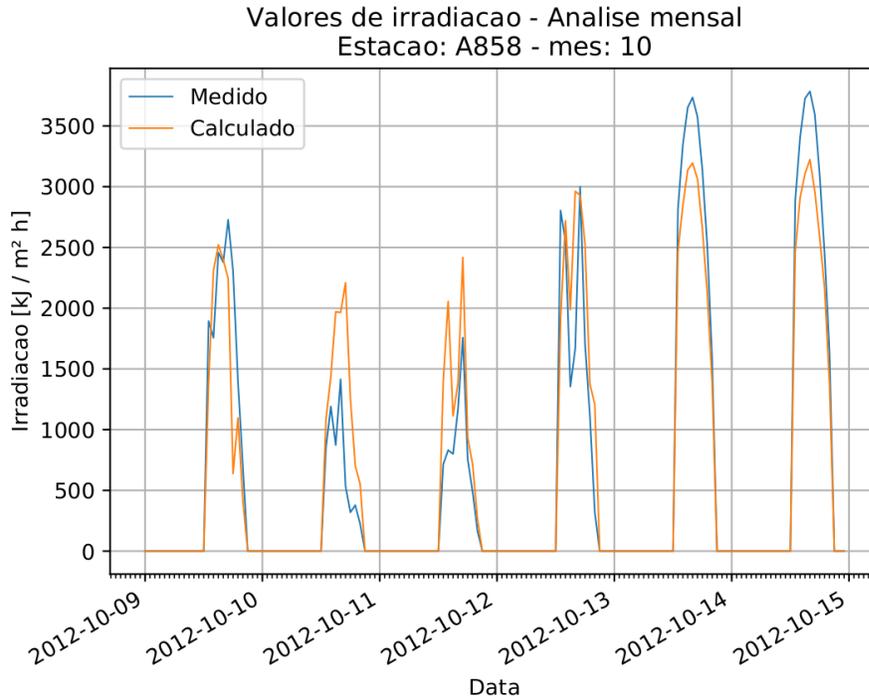


(b) Melhor ajuste mensal.

**Figura 5.2:** Comparativo entre os valores medidos e estimados através dos parâmetros de melhor ajuste para a análise diária e mensal numa situação de céu limpo na estação A860 durante o mês de junho de 2016.

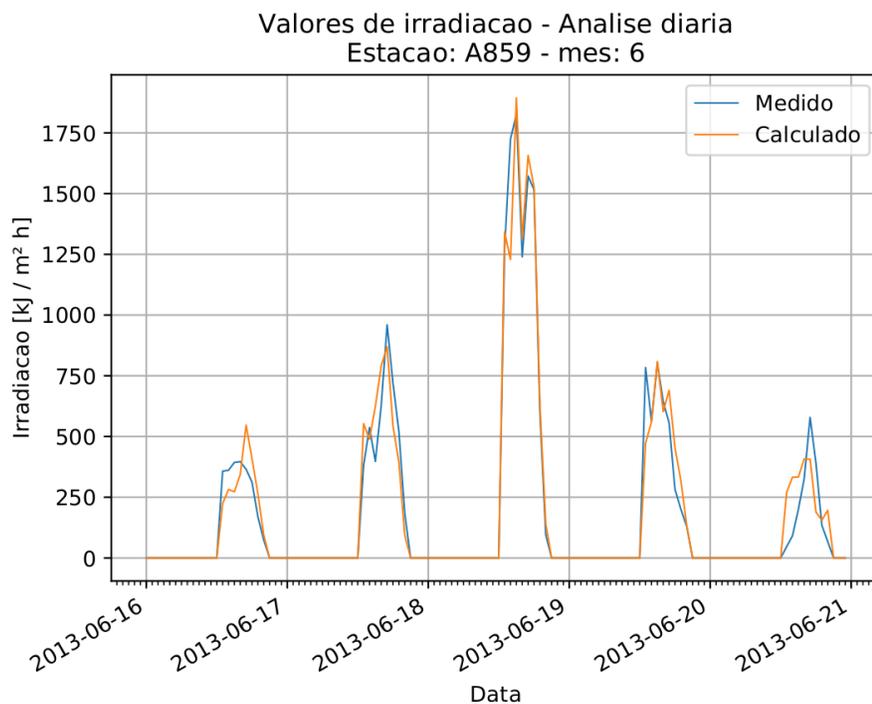


(a) Melhores ajustes diários.

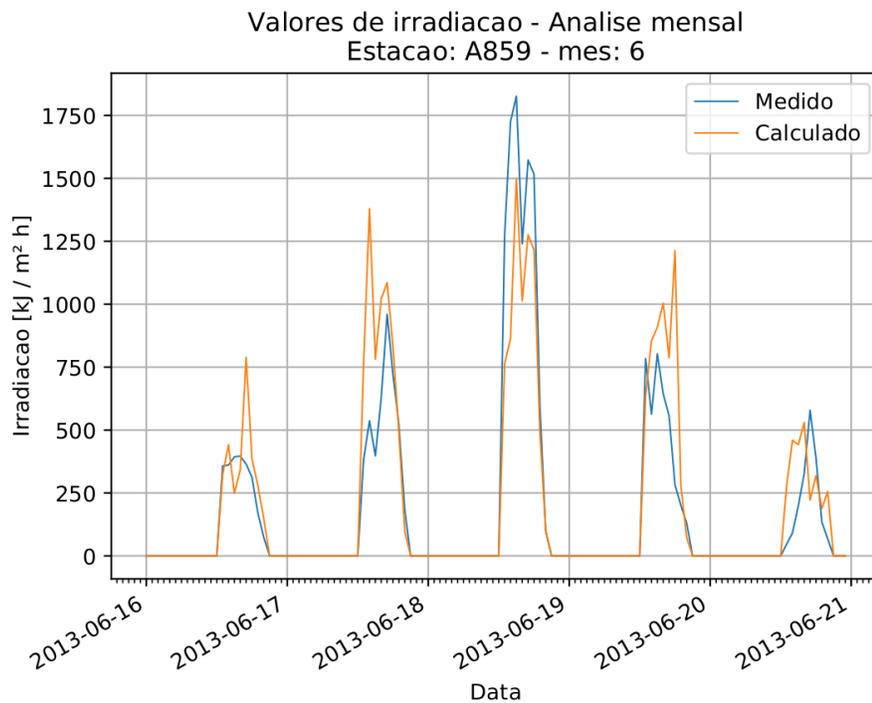


(b) Melhor ajuste mensal.

**Figura 5.3:** Comparativo entre os valores medidos e estimados através dos parâmetros de melhor ajuste para a análise diária e mensal numa situação de céu em transição na estação A858 durante o mês de outubro de 2012.

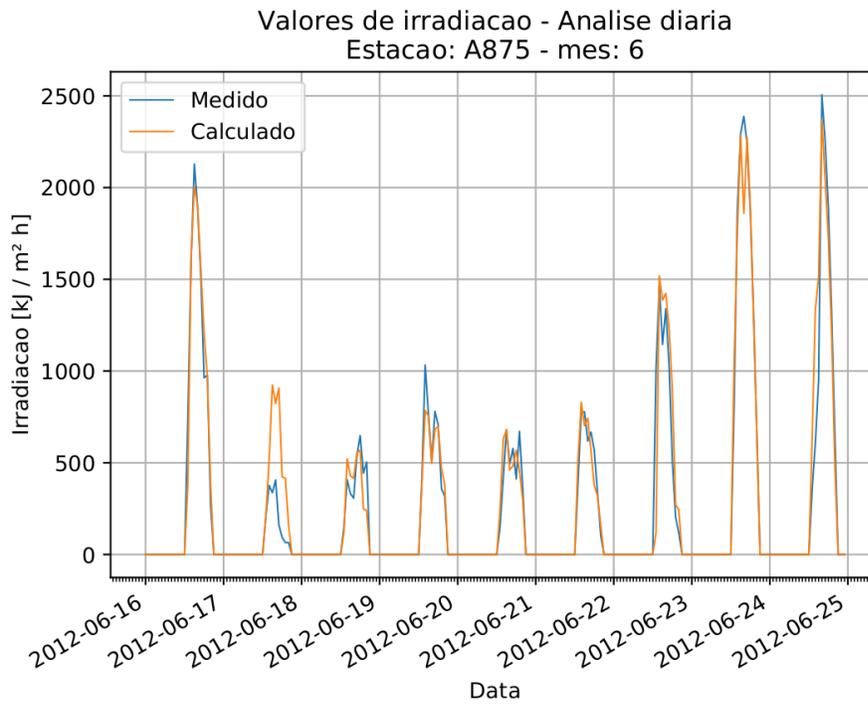


(a) Melhores ajustes diários.

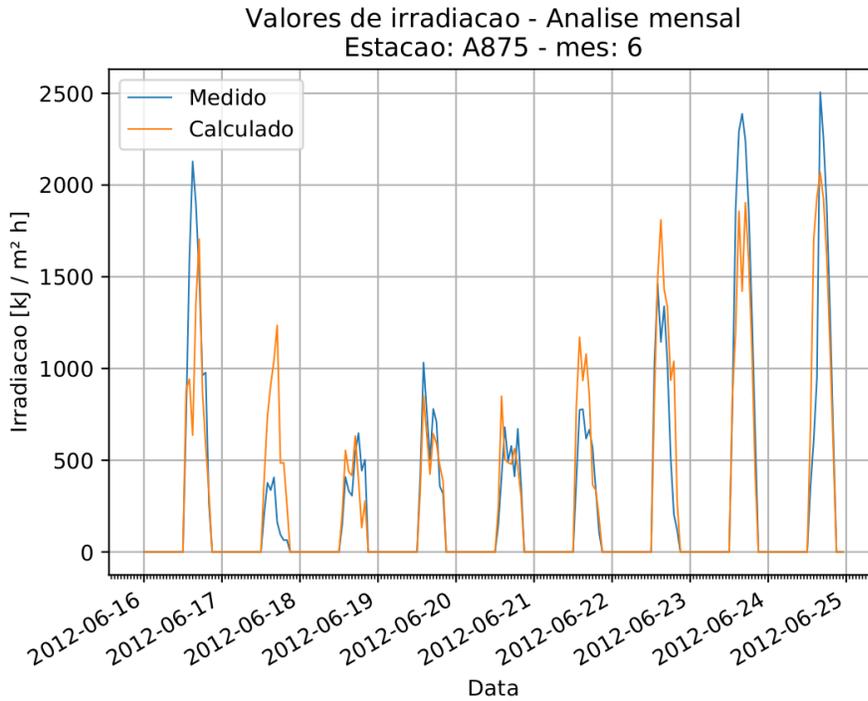


(b) Melhor ajuste mensal.

**Figura 5.4:** Comparativo entre os valores medidos e estimados através dos parâmetros de melhor ajuste para a análise diária e mensal numa situação de céu em transição na estação A859 durante o mês de junho de 2013.



(a) Melhores ajustes diários.



(b) Melhor ajuste mensal.

**Figura 5.5:** Comparativo entre os valores medidos e estimados através dos parâmetros de melhor ajuste para a análise diária e mensal numa situação de céu instável na estação A875 durante o mês de junho de 2012.

Ao comparar os gráficos com melhor ajuste em análise dia a dia (sub-índices (*a*) das Figuras 5.1 a 5.5) com os de melhor ajuste em análise mensal (sub-índices (*b*) das Figuras 5.1 a 5.5) verifica-se - como esperado - que as análises dia a dia apresentam resultados muito mais próximos do real (valores medidos) do que ao serem utilizados os melhores ajustes mensais. No entanto, para uma rápida avaliação, os resultados ao utilizar o conjunto de parâmetros que fornece o melhor ajuste global para um mês apresenta resultados satisfatórios, além de ser um processo muito mais rápido. Para efeito de comparação, com as variações de parâmetros utilizadas no presente trabalho, eram gerados 1200 modelos em cada simulação de valor. Ao verificar o melhor ajuste dia a dia, esse volume de simulações era analisado para cada dia, aumentando muito a quantidade de acessos à base de dados e o tempo de processamento.

Os gráficos das Figuras 5.1 e 5.2 (referentes à condição de céu limpo) demonstram que os valores estimados através da metodologia proposta conseguem acompanhar com uma proximidade bastante aceitável os valores efectivamente registados após a estabilização das condições meteorológicas. Casos de oscilações repentinas, como verificada no período após o meio dia solar dos dias 2015-04-13 e 2015-04-14 na estação A841 (Figura 5.1), tornam-se pontos problemáticos devido ao facto do modelo utilizar dados dos dias próximos.

A dificuldade de acompanhar os valores registados durante os períodos de transições atmosféricas torna-se mais evidente quando analisamos os gráficos das Figuras 5.3 a 5.5 (condições de céu em transição ou instável). Todavia, mesmo nesses casos, os valores estimados voltam a seguir com certa proximidade os valores registados após a estabilização das condições meteorológicas.

## Capítulo 6

# Conclusões e sugestões para trabalhos futuros

Após analisar os resultados do presente trabalho, é possível concluir que a metodologia proposta de utilização de Processos de Markov e do algoritmo Google™PageRank™ para a indexação de níveis de irradiação solar aparenta possuir um bom potencial, sendo uma técnica de fácil implementação e, com as adequações propostas, de rápido processamento.

A aplicação do método proposto foi avaliada através de um índice de desempenho global baseado em vários indicadores estatísticos a partir da geração de falhas sintéticas nas séries de dados disponíveis para o período 2008-2016, para seis estações meteorológicas localizadas no estado brasileiro de Santa Catarina.

Os vários parâmetros do modelo foram variados de forma a avaliar o desempenho e robustez do modelo, quer ao nível da estimativa de valores quer também ao nível do desempenho computacional do modelo (tempo de cálculo), nomeadamente: o número de dias em torno do dia/hora da falha; o número de classes de irradiação; a tolerância dos limites de irradiação; e o coeficiente de amortização do algoritmo Google™PageRank™. Além disso, foi testada a divisão das classes de irradiação em vários níveis com o objectivo a melhorar a estimativa dos valores.

A análise de resultados foi feita para diferentes escalas de tempo, através da utilização de diferentes janelas temporais na determinação do índice global de performance, de modo a aferir o impacto dessas janelas temporais na avaliação da qualidade dos resultados gerados.

Os melhores ajustes foram obtidos para os casos em que se utilizam entre 5 a 10 classes de irradiação e coeficientes de amortização do algoritmo Google™PageRank™ entre 0,85 e 0,95 para uma análise de base diária. Além disso, verificou-se ser mais vantajoso a utilização dos limites reais de irradiação registados no período (variação nula dos limites) e com os dados de um a dois dias em torno do dia/hora em análise.

Numa perspectiva de trabalho futuro, e de forma a obter melhores resultados na auto-regeneração das séries dos dados de irradiação solar global, considera-se que a utilização de outras variáveis ambientais medidas nas estações pode ser um fator de correção dos resultados gerados. Na perspectiva de se ter acesso a dados de outras estações, esses dados também poderiam ser utilizados de forma a refinar os resultados obtidos.

Com a utilização desses outros dados, os níveis de irradiação estimados para as falhas poderiam ser corrigidos com base no estabelecimento de correlações com as leituras de temperatura, humidade relativa do ar, ou outra variável que apresente uma boa correlação, de forma a estimar um valor mais próximo do real. Esta análise em conjunto com outras variáveis será tanto mais útil quanto maior for o número de situações meteorológicas/climáticas distintas que sejam consideradas e, em particular, se for feita uma divisão por períodos típicos ou por estações do ano.

Além disso, e uma vez que no presente trabalho a multiplicação dos vectores normalizados com os resultados dos pesos de cada classe foi realizado apenas pelos valores mínimos, médios e de topo das classes, uma sugestão para trabalho futuro é considerar uma maior quantidade de intervalos nas classes. Com essa maior discretização é possível reduzir os saltos entre os níveis e, assim, ter um maior grau de refinamento dos valores estimados.

# Referências

- [1] O. Kisi, “Modeling solar radiation of Mediterranean region in Turkey by using fuzzy genetic approach,” *Energy*, vol. 64, pp. 429 – 436, 2014. xiii, 8
- [2] M. Bou-Rabee, S. A. Sulaiman, M. S. Saleh, and S. Marafi, “Using artificial neural networks to estimate solar radiation in Kuwait,” *Renewable and Sustainable Energy Reviews*, vol. 72, pp. 434 – 438, 2017. xiii, 9
- [3] C. A. Gueymard and D. R. Myers, “Solar Radiation Measurement: Progress in Radiometry for Improved Modeling,” in *Modeling Solar Radiation at the Earth Surface* (V. Badescu, ed.), ch. 1, Springer, 2008. xiii, 20, 24
- [4] W. Richardson, H. Krishnaswami, R. Vega, and M. Cervantes, “A low cost, edge computing, all-sky imager for cloud tracking and intra-hour irradiance forecasting,” *Sustainability*, vol. 9, no. 4, 2017. xiv, 27
- [5] “Preheated Combustion Air - Process Heating Tip Sheet #1.” [https://www.energy.gov/sites/prod/files/2014/05/f16/et\\_preheated.pdf](https://www.energy.gov/sites/prod/files/2014/05/f16/et_preheated.pdf), 11 2007. BestPractices Program tip sheet discussing process heating system efficiency. xvii, 4
- [6] A. Qazi, H. Fayaz, A. Wadi, R. G. Raj, N. Rahim, and W. A. Khan, “The artificial neural network for solar radiation prediction and designing solar systems: a systematic literature review,” *Journal of Cleaner Production*, vol. 104, pp. 1 – 12, 2015. xvii, 9, 10
- [7] J. T. Pinheiro and M. A. Galdino, *Manual de engenharia para sistemas fotovoltaicos*. CEPTEL - CRESESB, Rio de Janeiro, 3 2014. xvii, 22
- [8] Enerdata, “Global Energy Statistical Yearbook 2017.” <https://yearbook.enerdata.net>, 6 2017. 1
- [9] C. Vannoni, R. Battisti, and S. Drigo, *Potential for Solar Heat in Industrial Processes*. CIEMAT, 2008. 2, 4

- [10] S. A. Kalogirou, *Solar Energy Engineering*. Boston: Academic Press, 2 ed., 2014. 3, 5, 15, 17, 18, 19
- [11] E. Monfort, A. Mezquita, E. Vaquer, H. J. Alves, and F. G. M. and. O. Boschi, “Brasil × Espanha: Consumo de Energia Térmica e Emissões de  $CO_2$  Envolvidos na Fabricação de Revestimentos Cerâmicos,” *Cerâmica Industrial*, vol. 16, pp. 13 – 20, 7 2011. 2
- [12] V. Mallikarjuna, N. Jashuva, and B. R. B. Reddy, “Improving boiler efficiency by using air preheater,” *International Journal of Advanced Research in Engineering and Applied Sciences*, vol. 3, pp. 11 – 24, 2 2014. 4
- [13] “BestPractices Technical Brief - Waste Heat Reduction and Recovery for Improving Furnace Efficiency, Productivity, and Emissions Performance,” tech. rep., U.S. Department of Energy, 11 2004. 4
- [14] A. Teke, H. B. Yildirim, and Özgür Çelik, “Evaluation and performance comparison of different models for the estimation of solar radiation,” *Renewable and Sustainable Energy Reviews*, vol. 50, pp. 1097 – 1107, 2015. 5, 6
- [15] J. Almorox and C. Hontoria, “Global solar radiation estimation using sunshine duration in Spain,” *Energy Conversion and Management*, vol. 45, no. 9, pp. 1529 – 1535, 2004. 6
- [16] J. Zhang, L. Zhao, S. Deng, W. Xu, and Y. Zhang, “A critical review of the models used to estimate solar radiation,” *Renewable and Sustainable Energy Reviews*, vol. 70, pp. 314 – 329, 2017. 6
- [17] O. T. Ogunsola and L. Song, “Restoration of long-term missing gaps in solar radiation,” *Energy and Buildings*, vol. 82, pp. 580 – 591, 2014. 6
- [18] J. Almorox, M. Bocco, and E. Willington, “Estimation of daily global solar radiation from measured temperatures at Cañada de Luque, Córdoba, Argentina,” *Renewable Energy*, vol. 60, pp. 382 – 387, 2013. 6, 7
- [19] F. Besharat, A. A. Dehghan, and A. R. Faghieh, “Empirical models for estimating global solar radiation: A review and case study,” *Renewable and Sustainable Energy Reviews*, vol. 21, pp. 798 – 821, 2013. 7
- [20] Z. Şen, “Fuzzy algorithm for estimation of solar irradiation from sunshine duration,” *Solar Energy*, vol. 63, no. 1, pp. 39 – 49, 1998. 7

- [21] I. Reda and A. Andreas, “Solar Position Algorithm for Solar Radiation Application,” tech. rep., National Renewable Energy Laboratory, 1 2008. <https://www.nrel.gov/docs/fy08osti/34302.pdf>. 13, 19, 46
- [22] J. A. Duffie and W. A. Beckman, *Solar Engineering of Thermal Processes*. WILEY, 4 ed., 2013. 17
- [23] G. A. Spedicato, T. S. Kang, S. B. Yalamanchi, and D. Yadav, “The markovchain Package: A Package for Easily Handling Discrete Markov Chains in R.” [https://cran.r-project.org/web/packages/markovchain/vignettes/an\\_introduction\\_to\\_markovchain\\_package.pdf](https://cran.r-project.org/web/packages/markovchain/vignettes/an_introduction_to_markovchain_package.pdf). 29
- [24] S. P. Meyn and R. L. Tweedie, *Markov Chains and Stochastic Stability*. Springer-Verlag, 2 ed., 2005. 30
- [25] R. Weber, “Markov Chains.” <http://www.statslab.cam.ac.uk/~rrw1/markov/M.pdf>, 2011. 31
- [26] S. Brin and L. Page, “The Anatomy of a Large-Scale Hypertextual Web Search Engine,” *Computer Networks and ISDN Systems*, vol. 30, pp. 107–117, Apr. 1998. 33
- [27] X. Wu, V. Kumar, J. Ross, Q. Joydeep, G. Q. Yang, H. Motoda, G. J. Mclachlan, A. Ng, B. Liu, P. S. Yu, D. Steinberg, X. W. (b, V. Kumar, J. R. Quinlan, J. Ghosh, Q. Yang, and H. Motoda, “Top 10 algorithms in data mining,” 2007. 33
- [28] J. Leskovec, A. Rajaraman, and J. D. Ullman, *Mining of Massive Datasets*. Cambridge University Press, 2 ed., 3 2014. <http://infolab.stanford.edu/~ullman/mmds/book.pdf>. 34
- [29] C. Moler, *Experiments with MATLAB*. MathWorks, Inc, 10 2011. <https://www.mathworks.com/content/dam/mathworks/mathworks-dot-com/moler/exm/book.pdf>. 34
- [30] B. Jamil and N. Akhtar, “Comparative analysis of diffuse solar radiation models based on sky-clearness index and sunshine period for humid-subtropical climatic region of india: A case study,” *Renewable and Sustainable Energy Reviews*, vol. 78, pp. 329 – 355, 2017. 35, 37
- [31] M. Despotovic, V. Nedic, D. Despotovic, and S. Cvetanovic, “Review and statistical analysis of different global solar radiation sunshine models,” *Renewable and Sustainable Energy Reviews*, vol. 52, pp. 1869 – 1880, 2015. 35, 37, 39

- [32] M.-F. Li, X.-P. Tang, W. Wu, and H.-B. Liu, “General models for estimating daily global solar radiation for different solar radiation zones in mainland China,” *Energy Conversion and Management*, vol. 70, pp. 139 – 148, 2013. 35, 36
- [33] M. Despotovic, V. Nedic, D. Despotovic, and S. Cvetanovic, “Evaluation of empirical models for predicting monthly mean horizontal diffuse solar radiation,” *Renewable and Sustainable Energy Reviews*, vol. 56, pp. 246 – 260, 2016. 35
- [34] S. S. Sharifi, V. Rezaverdinejad, and V. Nourani, “Estimation of daily global solar radiation using wavelet regression, ann, gep and empirical models: A comparative study of selected temperature-based approaches,” *Journal of Atmospheric and Solar-Terrestrial Physics*, vol. 149, pp. 131 – 145, 2016. 35
- [35] C. N. Long and E. G. Dutton, “BSRN Global Network recommended QC tests, V2.0.” [http://bsrn.awi.de/fileadmin/user\\_upload/bsrn.awi.de/Publications/BSRN\\_recommended\\_QC\\_tests\\_V2.pdf](http://bsrn.awi.de/fileadmin/user_upload/bsrn.awi.de/Publications/BSRN_recommended_QC_tests_V2.pdf). Acessado em 25 de agosto de 2017. 47
- [36] M. Schwandt, K. Chhatbar, R. Meyer, K. Fross, I. Mitra, R. Vashistha, G. Giridhar, S. Gomathinayagam, and A. Kumar, “Development and Test of Gap Filling Procedures for Solar Radiation Data of the Indian SRRA Measurement Network,” *Energy Procedia*, vol. 57, pp. 1100 – 1109, 2014. 2013 ISES Solar World Congress. 51, 57

# APÊNDICES



# Apêndice A

## Explicações sobre as tabelas e gráficos dos apêndices

Os gráficos dos melhores ajustes semanais e quinzenais referentes aos meses com mais de 28 dias possuem representação somente até o dia 28 do mês devido ao facto dos dias limites para cada período terem sido considerados conforme o apresentado na Tabela A.1.

**Tabela A.1:** Dias limite considerados para cada período semanal e quinzenal para as análises e geração dos gráficos.

Período	Dia de início	Dia de término
Quinzenal		
1	1	14
2	15	28
Semanal		
1	1	7
2	8	14
3	15	21
4	22	28

Para a análise mensal, o código  $\theta$  é referente ao parâmetro interno do programa que informa que a análise é mensal. Com relação aos períodos para as análises diárias, cada período é o próprio dia do mês. Os níveis  $1$ ,  $2$  e  $3$  são, respetivamente, os níveis mínimos, médios e máximos de irradiação dentro das classes, conforme explicado na Secção 4.4.7 (ver Tabela 4.7 na Página 55).



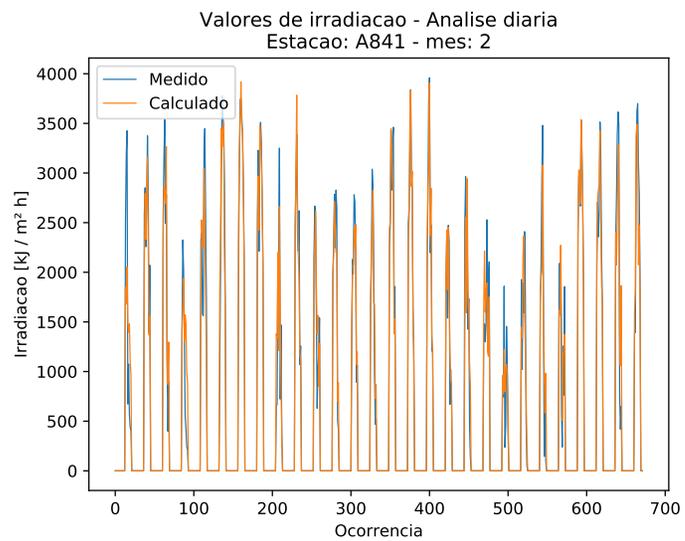
# Apêndice B

## Resultados para a estação A841

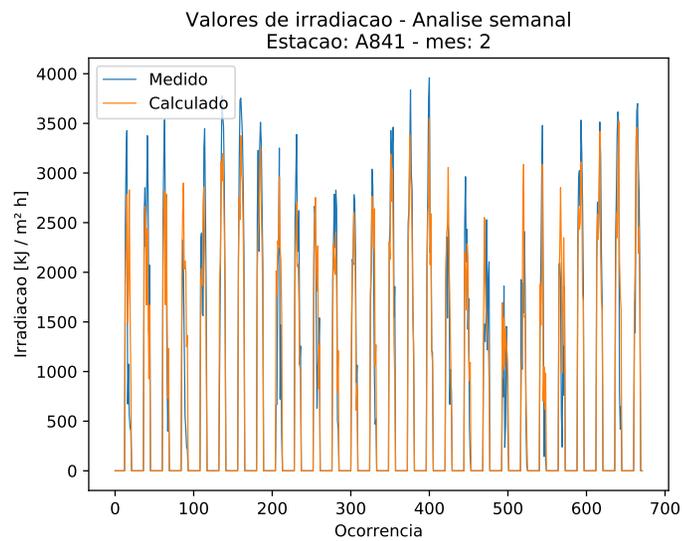
Tabelas com os parâmetros de melhor ajuste dos dados estimados aos dados efetivamente registrados, bem como os gráficos com os referidos valores para a estação A841 para os meses de fevereiro, abril, junho, agosto, outubro e dezembro do ano de 2015. Para os gráficos referentes aos meses com mais de 28 dias valem as explicações do Apêndice A na Página 75.

**Tabela B.1:** Parâmetros de melhor ajuste por período para o mês de fevereiro de 2015 na estação A841.

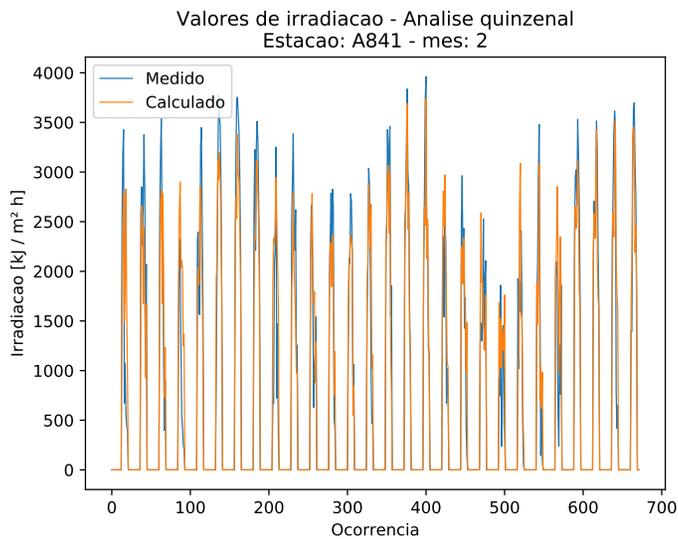
Período	Dias	Classes	Tolerância nos limites [%]	Coef. $p$ PageRank	Nível	GPI ( $\times 10^{-4}$ )
Mensal						
0	1	7	10	0.95	2	888.281
Quinzenal						
1	1	6	0	0.85	2	589.759
2	1	7	10	0.95	2	1001.561
Semanal						
1	1	6	0	0.85	2	689.5
2	1	9	5	0.85	3	416.384
3	1	5	10	0.95	2	843.862
4	1	7	10	0.95	2	1044.86
Diário						
1	2	9	-10	0.95	1	617.186
2	5	5	-5	0.75	3	1269.741
3	1	5	5	0.95	3	1122.585
4	1	6	-10	0.65	1	663.217
5	2	20	0	0.95	3	1008.295
6	1	10	10	0.95	3	1263.111
7	1	5	0	0.85	3	1774.118
8	1	10	0	0.95	3	1759.059
9	5	5	5	0.95	1	601.104
10	1	5	0	0.95	3	1173.928
11	1	6	0	0.95	1	980.282
12	2	9	10	0.95	1	845.508
13	2	8	-10	0.95	1	799.453
14	5	20	-5	0.95	1	681.5
15	2	5	10	0.85	3	1328.281
16	1	6	0	0.95	2	1589.605
17	1	5	5	0.95	3	1395.497
18	1	8	-10	0.95	1	870.367
19	2	5	5	0.95	2	590.451
20	1	8	10	0.95	2	810.36
21	1	5	5	0.95	1	2174.659
22	1	7	-5	0.65	3	955.77
23	1	8	10	0.95	2	608.481
24	1	5	5	0.95	1	1631.798
25	1	7	0	0.95	3	1991.725
26	1	5	5	0.85	3	1411.438
27	5	10	10	0.95	3	793.075
28	1	5	-10	0.95	2	1181.119



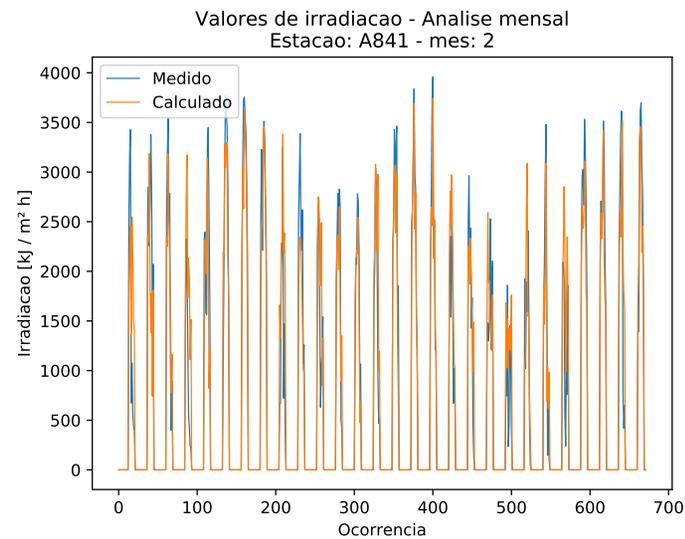
(a) Melhores ajustes diários.



(b) Melhores ajustes semanais.



(c) Melhores ajustes quinzenais.

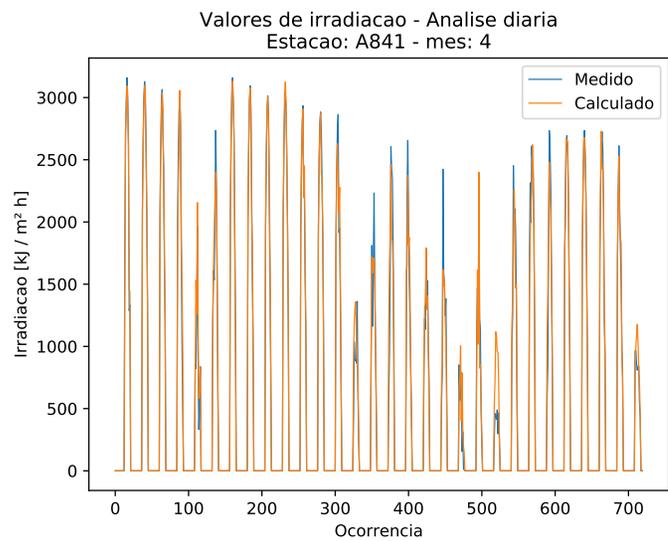


(d) Melhor ajuste mensal

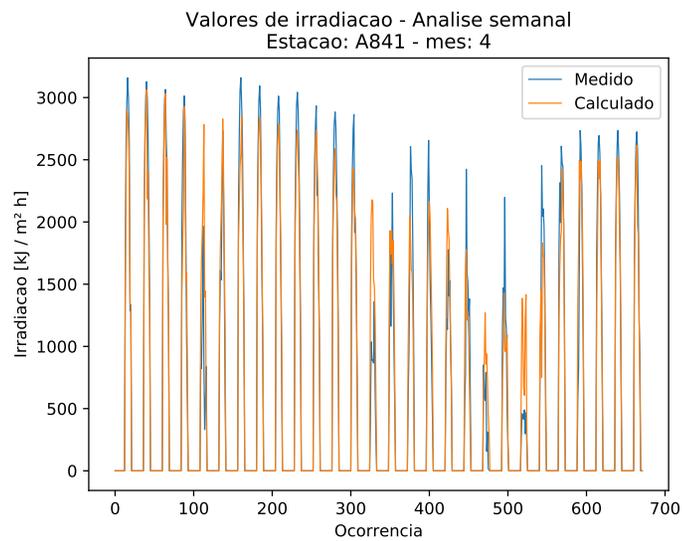
**Figura B.1:** Análises para a estação A841 para o mês de fevereiro de 2015.

**Tabela B.2:** Parâmetros de melhor ajuste por período para o mês de abril de 2015 na estação A841.

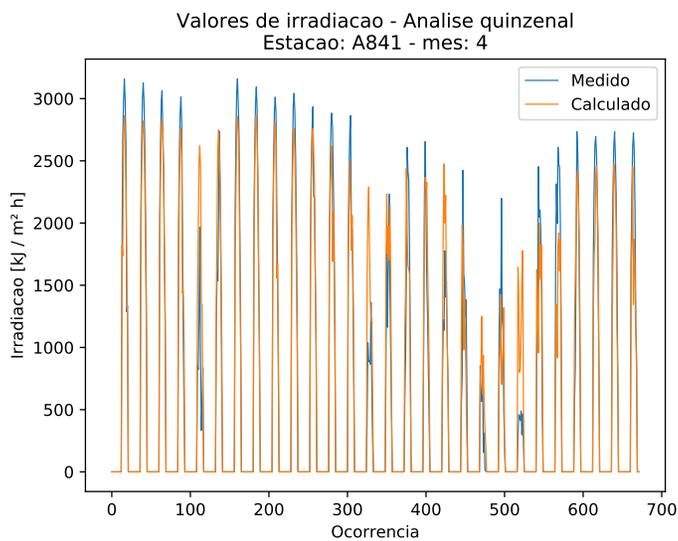
Período	Dias	Classes	Tolerância nos limites [%]	Coef. $p$ PageRank	Nível	GPI ( $\times 10^{-4}$ )
Mensal						
0	2	6	0	0.95	2	864.84
Quinzenal						
1	1	10	0	0.95	2	874.135
2	2	6	0	0.95	2	789.125
Semanal						
1	1	5	-5	0.95	2	871.931
2	1	6	0	0.75	3	850.352
3	2	6	0	0.85	2	492.703
4	1	5	0	0.95	2	1021.27
Diário						
1	2	7	-5	0.95	3	1663.646
2	1	5	0	0.85	3	1954.498
3	1	5	10	0.85	3	1762.702
4	1	5	0	0.85	3	1013.57
5	10	5	10	0.85	1	1091.178
6	2	5	0	0.95	1	1162.26
7	1	8	0	0.95	3	1826.637
8	1	6	5	0.95	3	1586.8
9	1	5	10	0.85	3	1597.935
10	2	5	0	0.85	3	1886.362
11	2	7	5	0.95	3	1575.75
12	1	5	0	0.85	3	1659.777
13	5	6	-10	0.95	3	1246.705
14	1	20	-10	0.65	1	800.028
15	5	8	0	0.75	1	704.92
16	10	20	10	0.95	2	712.235
17	5	9	5	0.95	3	986.882
18	10	15	-10	0.65	1	980.017
19	1	5	-5	0.95	3	784.556
20	2	6	0	0.95	1	927.087
21	1	5	0	0.95	3	909.053
22	1	20	-10	0.65	1	695.261
23	5	20	10	0.95	3	831.554
24	1	5	0	0.85	3	1484.943
25	2	6	-10	0.95	2	983.565
26	1	7	0	0.95	3	1741.462
27	1	5	0	0.85	3	1946.89
28	1	5	10	0.95	3	1697.53
29	1	9	0	0.95	3	1478.131
30	5	5	5	0.95	1	943.484



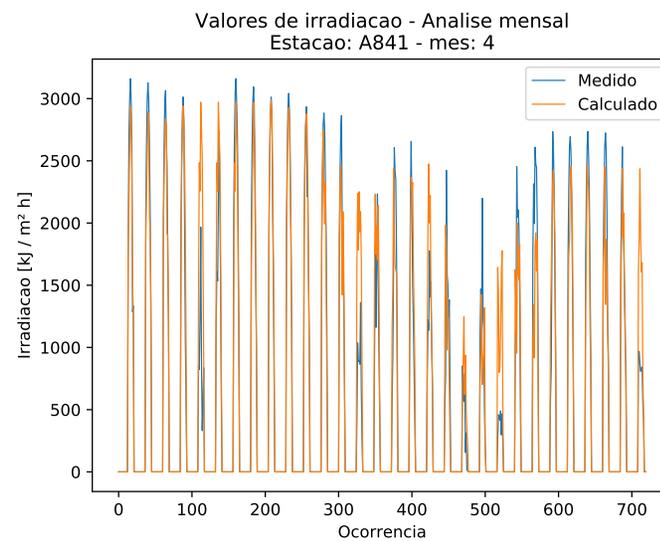
(a) Melhores ajustes diários.



(b) Melhores ajustes semanais.



(c) Melhores ajustes quinzenais.

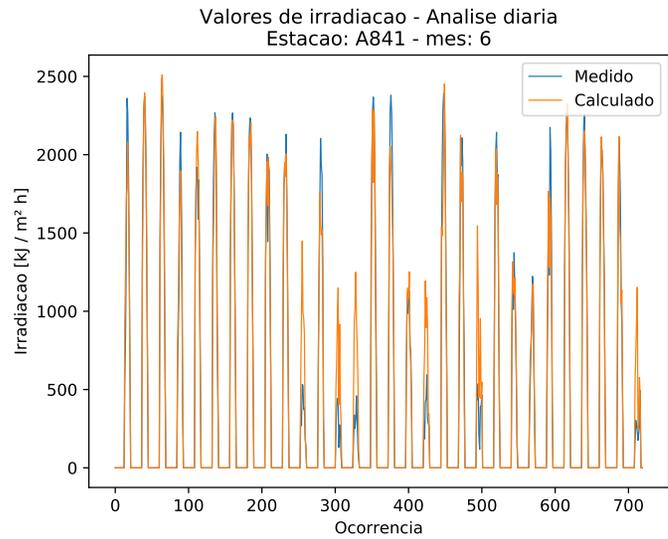


(d) Melhor ajuste mensal

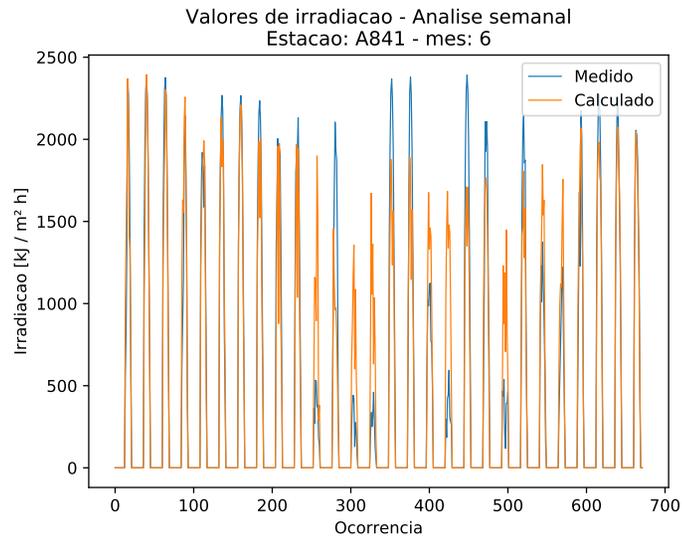
**Figura B.2:** Análises para a estação A841 para o mês de abril de 2015.

**Tabela B.3:** Parâmetros de melhor ajuste por período para o mês de junho de 2015 na estação A841.

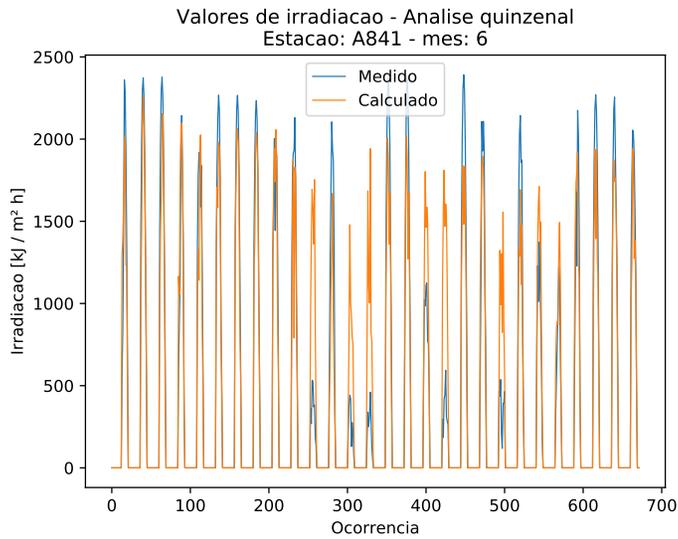
Período	Dias	Classes	Tolerância nos limites [%]	Coef. $p$ PageRank	Nível	GPI ( $\times 10^{-4}$ )
Mensal						
0	1	7	10	0.95	2	597.347
Quinzenal						
1	1	7	10	0.95	2	679.842
2	1	20	5	0.95	3	721.194
Semanal						
1	1	6	5	0.95	3	988.566
2	2	7	5	0.95	2	436.515
3	1	20	5	0.95	1	702.206
4	1	6	-5	0.85	3	1049.908
Diário						
1	1	8	0	0.95	2	894.764
2	1	5	0	0.85	3	1685.407
3	1	5	0	0.95	3	1600.477
4	1	5	-10	0.95	1	905.224
5	5	5	10	0.65	3	1168.623
6	2	5	-5	0.85	3	1298.752
7	1	5	0	0.85	3	1871.565
8	2	5	10	0.85	3	1743.672
9	1	5	10	0.95	2	1519.394
10	2	6	0	0.85	3	1650.467
11	2	5	-10	0.95	1	625.482
12	2	5	0	0.85	3	941.605
13	2	7	5	0.95	1	838.67
14	2	5	5	0.95	1	580.405
15	1	7	0	0.95	3	1263.905
16	1	7	10	0.95	3	1128.487
17	5	6	5	0.65	1	967.186
18	5	6	-10	0.95	1	697.905
19	1	5	0	0.95	3	1255.233
20	5	15	0	0.95	3	808.85
21	2	5	10	0.95	1	1219.309
22	5	20	10	0.95	3	1366.361
23	10	10	5	0.85	1	695.206
24	1	5	5	0.65	1	1254.914
25	5	10	0	0.95	3	866.725
26	1	5	10	0.95	3	1695.987
27	1	10	0	0.95	3	1724.541
28	1	8	-5	0.95	3	1798.524
29	1	7	0	0.95	3	1106.593
30	1	5	-10	0.95	1	943.51



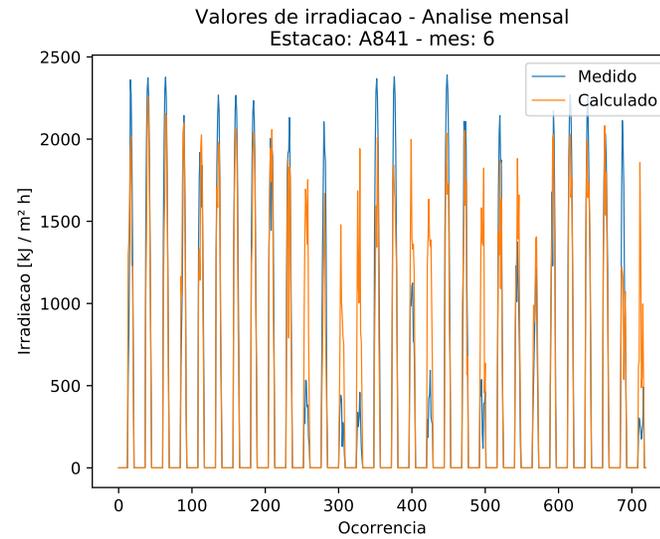
(a) Melhores ajustes diários.



(b) Melhores ajustes semanais.



(c) Melhores ajustes quinzenais.

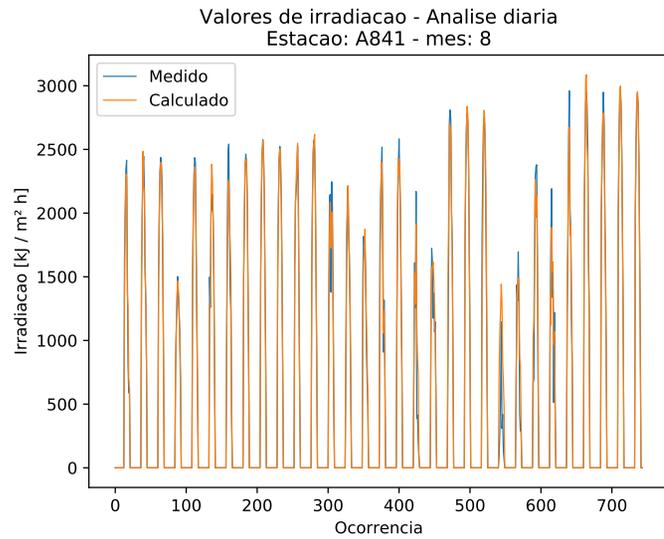


(d) Melhor ajuste mensal

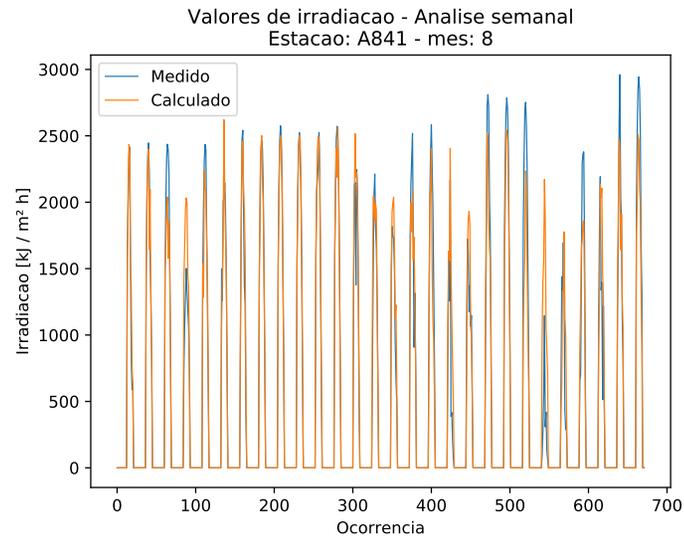
**Figura B.3:** Análises para a estação A841 para o mês de junho de 2015.

**Tabela B.4:** Parâmetros de melhor ajuste por período para o mês de agosto de 2015 na estação A841.

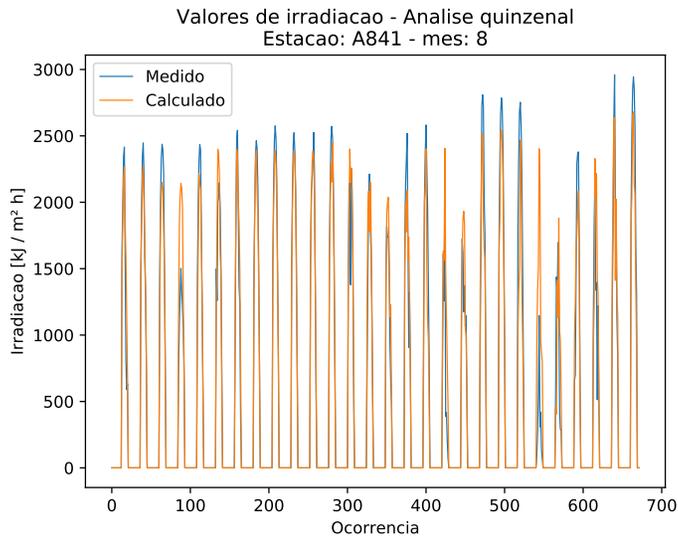
Período	Dias	Classes	Tolerância nos limites [%]	Coef. $p$ PageRank	Nível	GPI ( $\times 10^{-4}$ )
Mensal						
0	1	6	5	0.85	3	716.212
Quinzenal						
1	1	5	5	0.85	3	846.721
2	1	5	10	0.95	2	559.392
Semanal						
1	1	7	-5	0.95	3	689.861
2	1	5	10	0.85	3	1143.092
3	1	5	10	0.95	2	734.595
4	1	5	10	0.85	2	440.975
Diário						
1	1	6	-5	0.95	2	1097.785
2	5	6	10	0.95	3	1630.924
3	1	5	0	0.95	3	1682.43
4	2	15	5	0.65	1	1000.65
5	10	6	5	0.85	3	1508.409
6	2	10	0	0.95	3	1316.666
7	1	7	-5	0.95	2	935.578
8	2	8	0	0.95	3	1791.377
9	1	8	0	0.95	3	1730.368
10	2	5	10	0.85	3	1793.429
11	2	10	10	0.95	3	1453.111
12	1	5	0	0.85	3	1788.763
13	2	5	5	0.95	2	834.559
14	10	7	-10	0.95	2	1033.833
15	1	6	0	0.65	2	694.651
16	5	10	5	0.95	2	1105.752
17	5	15	0	0.95	3	1501.563
18	1	5	5	0.95	1	876.613
19	10	10	-10	0.65	1	751.17
20	1	6	5	0.95	3	1286.706
21	1	5	0	0.85	3	1917.812
22	1	7	0	0.95	3	1330.125
23	1	5	-10	0.65	1	570.325
24	2	6	-10	0.65	1	782.327
25	2	7	5	0.95	3	1109.09
26	5	5	10	0.85	1	710.535
27	10	6	-5	0.85	3	1048.504
28	1	5	10	0.95	3	1586.907
29	1	8	5	0.95	3	1684.194
30	1	5	0	0.85	3	1960.64
31	1	5	5	0.95	3	1774.607



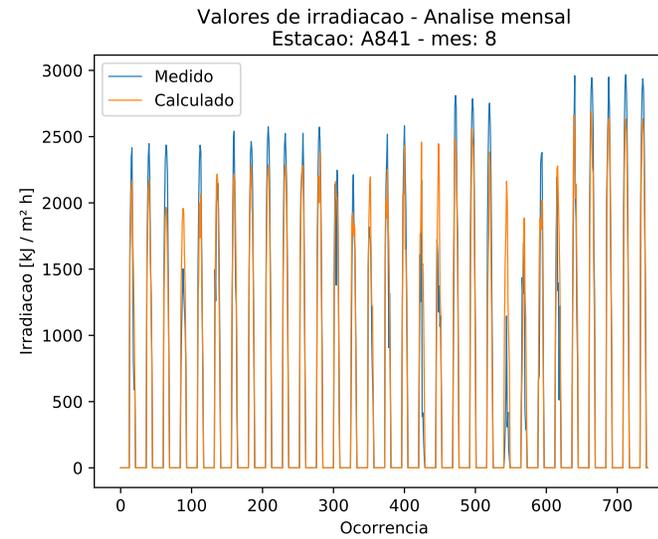
(a) Melhores ajustes diários.



(b) Melhores ajustes semanais.



(c) Melhores ajustes quinzenais.

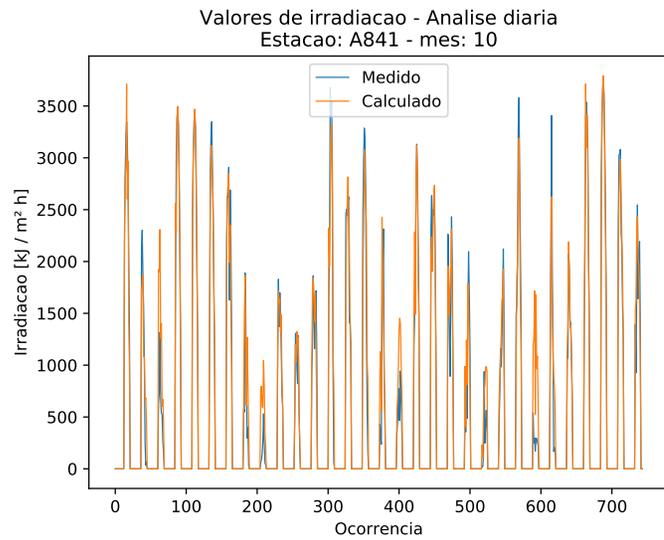


(d) Melhor ajuste mensal

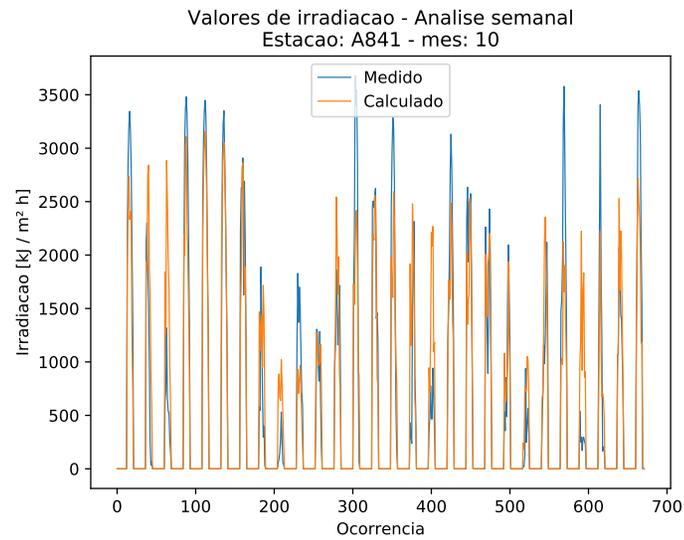
**Figura B.4:** Análises para a estação A841 para o mês de agosto de 2015.

**Tabela B.5:** Parâmetros de melhor ajuste por período para o mês de outubro de 2015 na estação A841.

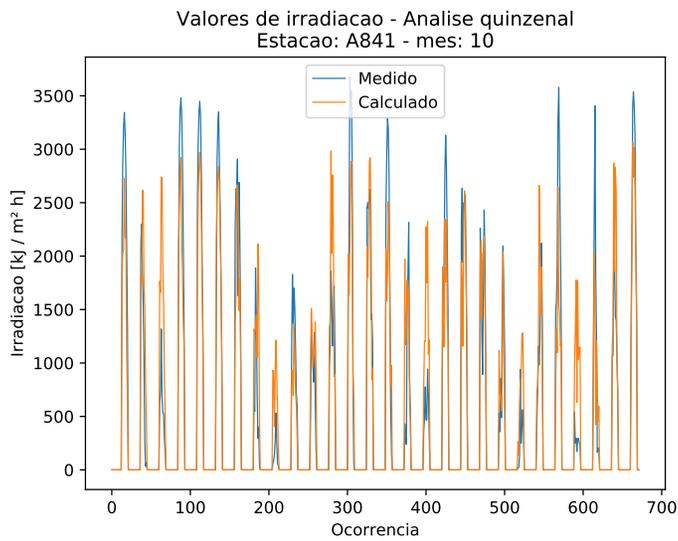
Período	Dias	Classes	Tolerância nos limites [%]	Coef. $p$ PageRank	Nível	GPI ( $\times 10^{-4}$ )
Mensal						
0	1	8	0	0.95	1	884.639
Quinzenal						
1	1	9	0	0.95	1	823.99
2	1	8	0	0.95	1	790.9
Semanal						
1	1	10	0	0.95	2	882.467
2	1	7	0	0.85	1	657.917
3	1	8	10	0.95	1	554.217
4	1	20	-10	0.95	1	789.947
Diário						
1	1	5	0	0.95	3	1352.41
2	10	15	-10	0.95	1	797.355
3	10	20	0	0.95	1	578.347
4	1	7	0	0.95	3	1424.052
5	1	8	0	0.95	3	1915.007
6	2	10	0	0.95	2	1523.273
7	10	5	10	0.75	3	1130.281
8	2	5	5	0.85	1	555.653
9	1	5	0	0.85	1	989.865
10	5	5	5	0.65	1	1150.698
11	2	5	5	0.85	1	1013.805
12	10	5	0	0.85	1	676.657
13	1	9	0	0.95	3	758.072
14	5	5	0	0.65	3	984.11
15	2	6	0	0.75	3	806.757
16	2	5	10	0.95	1	804.362
17	1	20	-10	0.65	1	755.957
18	1	7	0	0.95	3	1112.307
19	1	5	10	0.75	3	1430.993
20	1	5	-10	0.65	3	997.269
21	2	5	10	0.95	1	799.187
22	1	5	10	0.95	1	1271.718
23	2	8	0	0.95	2	1114.459
24	10	20	10	0.95	3	1040.251
25	1	6	-5	0.95	1	1003.721
26	1	5	10	0.65	3	902.221
27	5	8	-10	0.65	1	977.539
28	1	6	5	0.95	3	1561.298
29	1	5	0	0.85	3	1687.396
30	1	7	-5	0.85	2	1218.634
31	2	10	-5	0.85	1	879.967



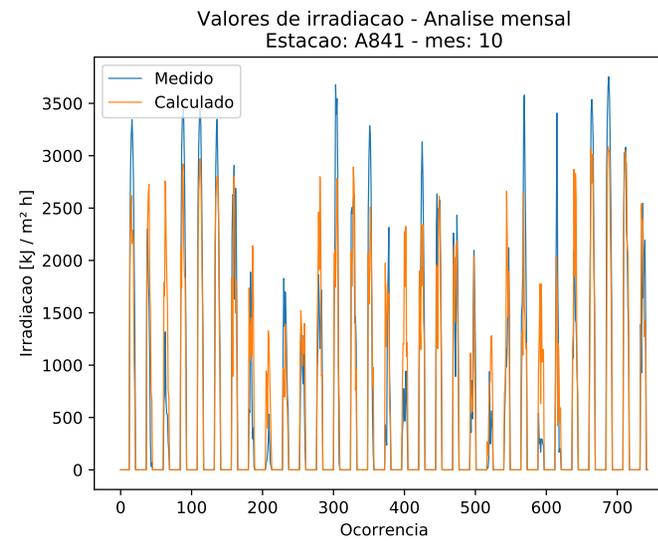
(a) Melhores ajustes diários.



(b) Melhores ajustes semanais.



(c) Melhores ajustes quinzenais.

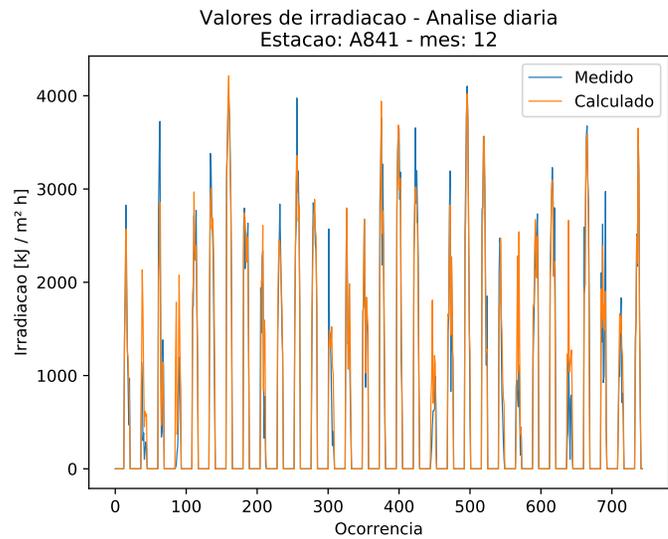


(d) Melhor ajuste mensal

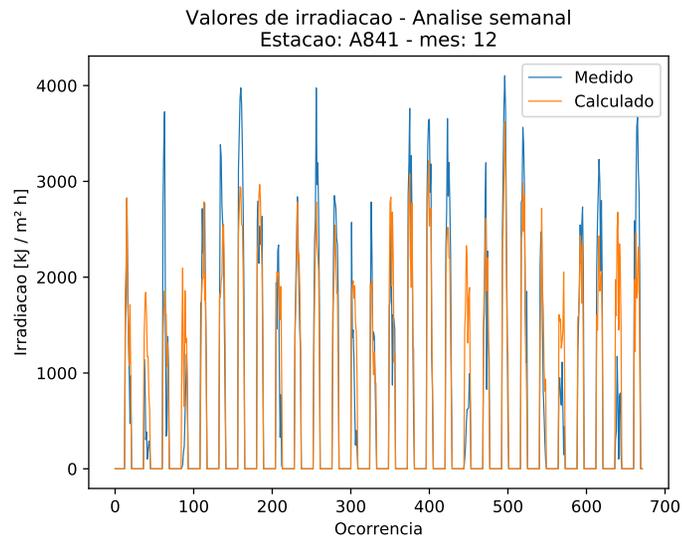
**Figura B.5:** Análises para a estação A841 para o mês de outubro de 2015.

**Tabela B.6:** Parâmetros de melhor ajuste por período para o mês de dezembro de 2015 na estação A841.

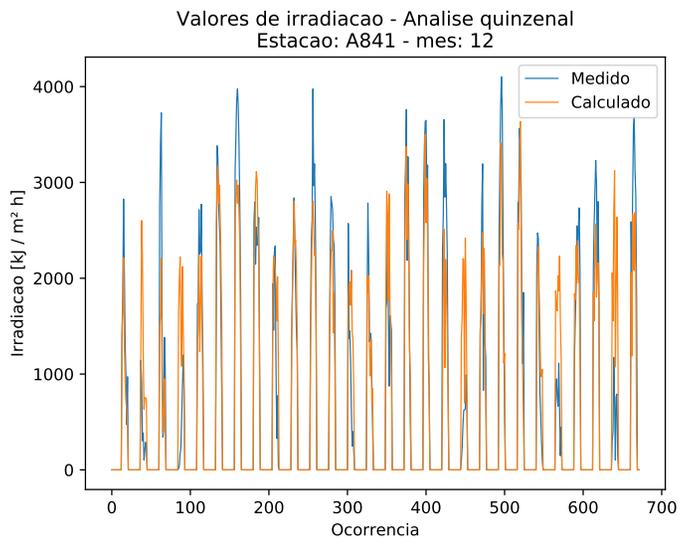
Período	Dias	Classes	Tolerância nos limites [%]	Coef. $p$ PageRank	Nível	GPI ( $\times 10^{-4}$ )
Mensal						
0	1	6	5	0.95	2	516.35
Quinzenal						
1	1	5	10	0.85	2	474.751
2	1	5	10	0.95	2	661.965
Semanal						
1	2	15	5	0.95	1	549.564
2	1	5	10	0.65	2	520.584
3	1	5	0	0.85	2	752.198
4	1	5	-10	0.85	2	577.517
Diário						
1	1	5	0	0.75	3	957.268
2	1	5	10	0.85	1	752.862
3	1	5	10	0.65	3	778.583
4	2	5	-5	0.95	1	819.267
5	5	5	10	0.85	3	1269.498
6	1	6	5	0.85	2	932.554
7	1	6	0	0.95	3	1808.285
8	5	5	-5	0.65	3	1074.327
9	5	8	10	0.95	1	673.573
10	5	15	0	0.85	1	862.149
11	1	5	10	0.95	3	1503.706
12	2	8	0	0.95	3	1309.398
13	1	5	5	0.75	1	763.282
14	10	6	-5	0.95	2	757.403
15	5	8	-10	0.95	3	1090.264
16	2	6	10	0.95	3	1330.565
17	1	5	0	0.85	3	1372.518
18	1	5	0	0.95	3	1329.945
19	5	5	5	0.95	1	980.905
20	2	8	-5	0.95	1	1003.913
21	1	6	-5	0.95	3	1147.45
22	1	5	10	0.65	3	1443.832
23	1	5	0	0.85	1	764.175
24	10	6	-10	0.95	1	1013.586
25	1	10	5	0.95	2	1374.343
26	5	5	10	0.65	3	1338.858
27	10	5	10	0.95	1	792.613
28	1	6	-5	0.95	3	1313.521
29	1	6	-10	0.95	1	1138.326
30	2	5	10	0.85	1	879.683
31	1	6	-5	0.95	3	1485.56



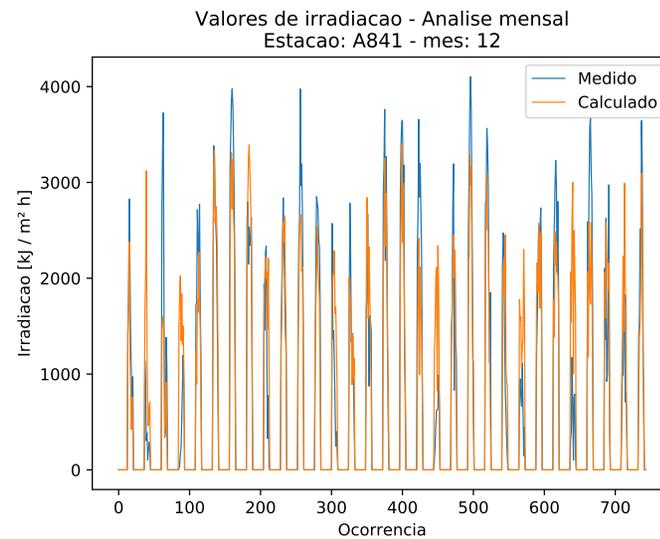
(a) Melhores ajustes diários.



(b) Melhores ajustes semanais.



(c) Melhores ajustes quinzenais.



(d) Melhor ajuste mensal

**Figura B.6:** Análises para a estação A841 para o mês de dezembro de 2015.



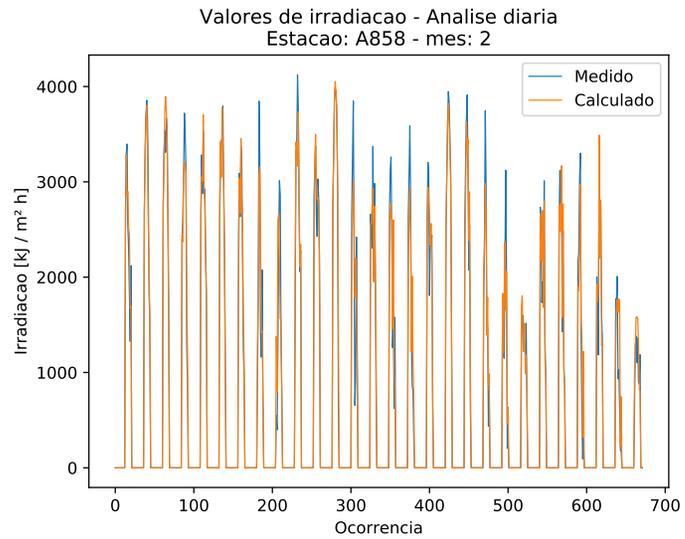
# Apêndice C

## Resultados para a estação A858

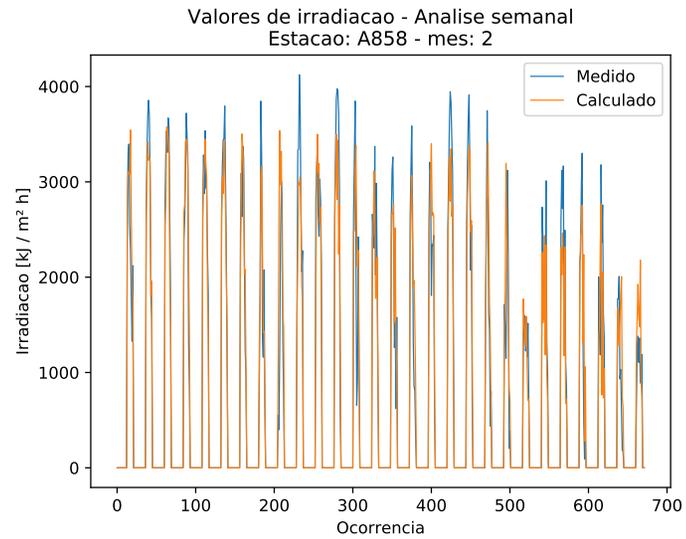
Tabelas com os parâmetros de melhor ajuste dos dados estimados aos dados efetivamente registrados, bem como os gráficos com os referidos valores para a estação A858 para os meses de fevereiro, abril, junho, agosto outubro e dezembro do ano de 2012. Para os gráficos referentes aos meses com mais de 28 dias valem as explicações do Apêndice A na Página 75.

**Tabela C.1:** Parâmetros de melhor ajuste por período para o mês de fevereiro de 2012 na estação A858.

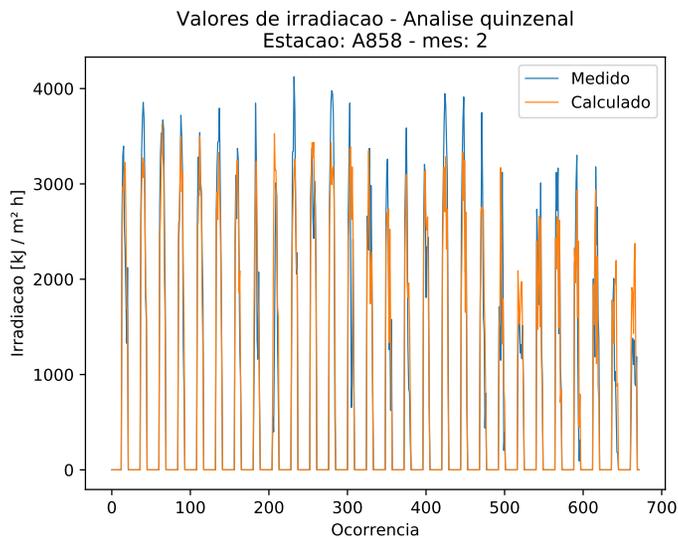
Período	Dias	Classes	Tolerância nos limites [%]	Coef. $p$ PageRank	Nível	GPI ( $\times 10^{-4}$ )
Mensal						
0	1	5	10	0.95	2	718.702
Quinzenal						
1	1	6	5	0.85	3	612.071
2	1	5	5	0.95	2	723.759
Semanal						
1	1	5	5	0.85	3	890.413
2	1	5	10	0.95	2	532.81
3	1	5	0	0.85	2	896.704
4	1	6	10	0.95	1	454.92
Diário						
1	5	6	-10	0.95	2	974.78
2	1	8	0	0.95	3	1405.394
3	1	5	0	0.85	3	1540.827
4	1	5	5	0.95	2	1066.233
5	2	7	5	0.95	3	1573.129
6	1	5	10	0.95	3	1517.048
7	2	8	-5	0.95	3	1009.967
8	1	5	10	0.95	2	781.546
9	5	5	10	0.95	1	615.993
10	1	7	10	0.95	3	1244.977
11	2	9	10	0.95	3	1338.332
12	1	7	0	0.95	3	1188.095
13	10	9	10	0.95	2	1001.283
14	10	20	10	0.95	3	1156.581
15	10	7	10	0.95	2	902.644
16	1	6	0	0.95	1	766.622
17	2	6	10	0.95	2	922.145
18	1	9	0	0.95	3	1755.712
19	1	5	5	0.85	3	1106.238
20	10	10	5	0.95	2	1005.139
21	5	5	5	0.85	1	732.886
22	1	6	5	0.95	1	1020.683
23	1	8	5	0.95	3	979.879
24	1	5	-5	0.85	3	1499.956
25	5	7	5	0.95	2	742.628
26	5	6	0	0.95	2	1189.616
27	2	6	-5	0.95	1	713.274
28	2	6	-10	0.65	1	1088.526



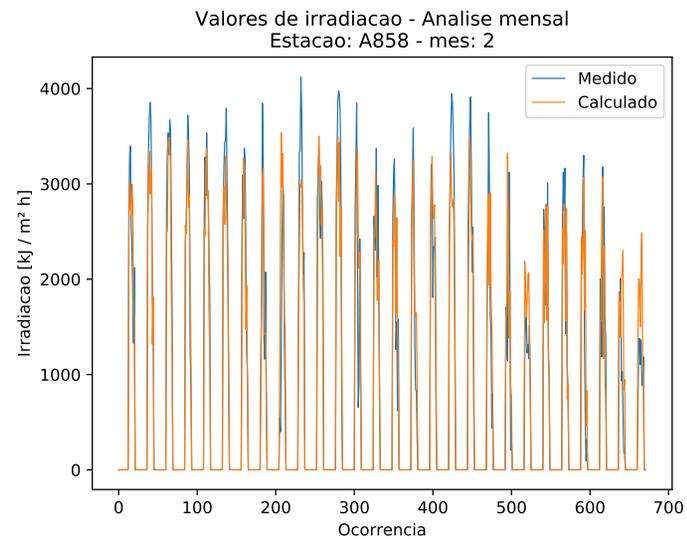
(a) Melhores ajustes diários.



(b) Melhores ajustes semanais.



(c) Melhores ajustes quinzenais.

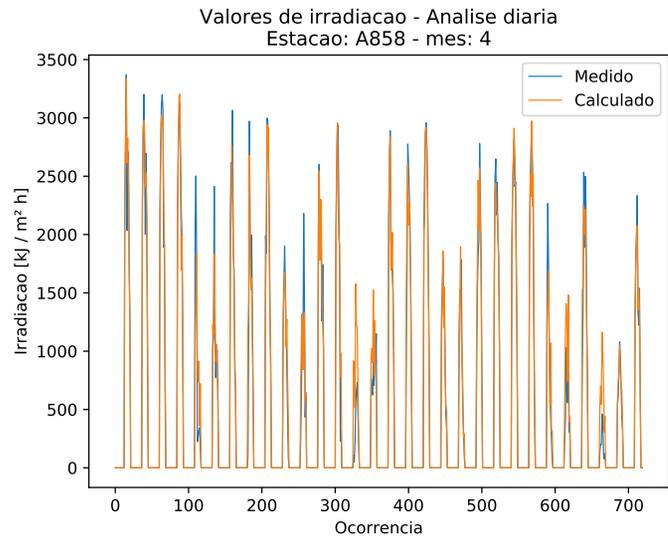


(d) Melhor ajuste mensal

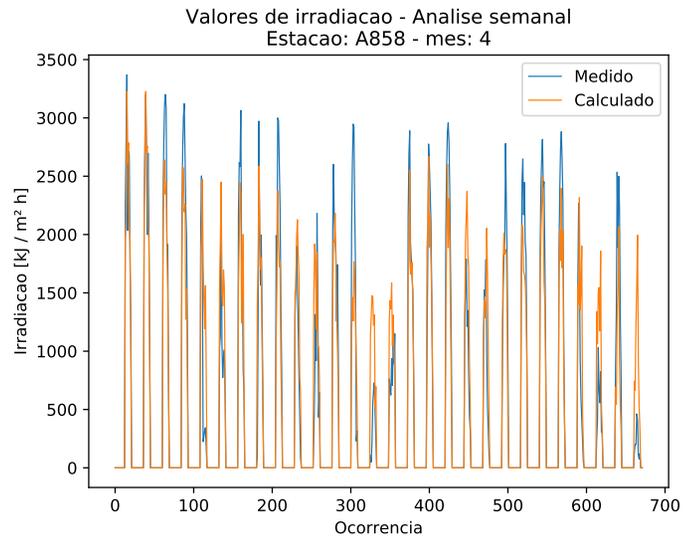
**Figura C.1:** Análises para a estação A858 para o mês de fevereiro de 2012.

**Tabela C.2:** Parâmetros de melhor ajuste por período para o mês de abril de 2012 na estação A858.

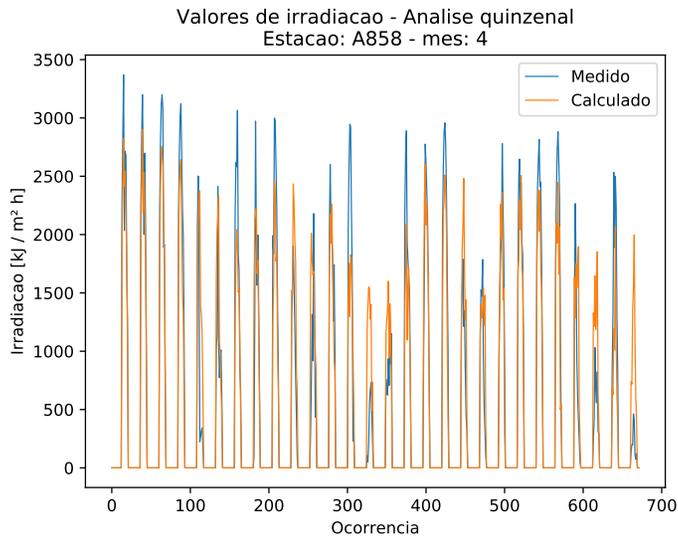
Período	Dias	Classes	Tolerância nos limites [%]	Coef. $p$ PageRank	Nível	GPI ( $\times 10^{-4}$ )
Mensal						
0	1	5	10	0.85	2	601.949
Quinzenal						
1	1	6	0	0.85	2	549.473
2	1	6	5	0.95	2	697.736
Semanal						
1	5	8	-5	0.95	3	697.675
2	1	6	5	0.85	2	400.344
3	1	5	-5	0.85	2	692.651
4	1	6	0	0.95	1	675.144
Diário						
1	1	8	0	0.95	3	1431.213
2	2	6	10	0.95	3	1493.369
3	1	6	0	0.95	2	1467.67
4	1	7	0	0.95	3	1526.987
5	10	6	10	0.95	1	871.829
6	2	6	-5	0.95	1	881.754
7	5	10	0	0.95	3	1155.708
8	2	5	5	0.95	2	600.28
9	1	5	0	0.95	3	1365.198
10	5	15	-5	0.85	1	585.068
11	5	7	5	0.85	1	864.956
12	1	5	5	0.95	3	1162.28
13	10	5	0	0.95	3	1066.123
14	2	5	10	0.95	1	1290.012
15	1	5	-10	0.95	1	1116.743
16	1	5	0	0.95	2	1370.162
17	1	6	5	0.95	2	983.267
18	1	8	0	0.95	3	1664.889
19	10	6	0	0.85	1	1038.49
20	10	6	-10	0.95	1	882.526
21	1	7	0	0.95	2	1178.457
22	1	6	0	0.85	3	1567.617
23	1	5	0	0.85	3	1747.122
24	1	6	0	0.95	3	1201.22
25	5	6	-10	0.95	1	811.524
26	5	10	-10	0.95	1	700.629
27	10	20	5	0.95	3	912.217
28	2	7	10	0.95	1	812.275
29	1	5	-10	0.75	1	1143.807
30	1	5	5	0.85	2	1218.714



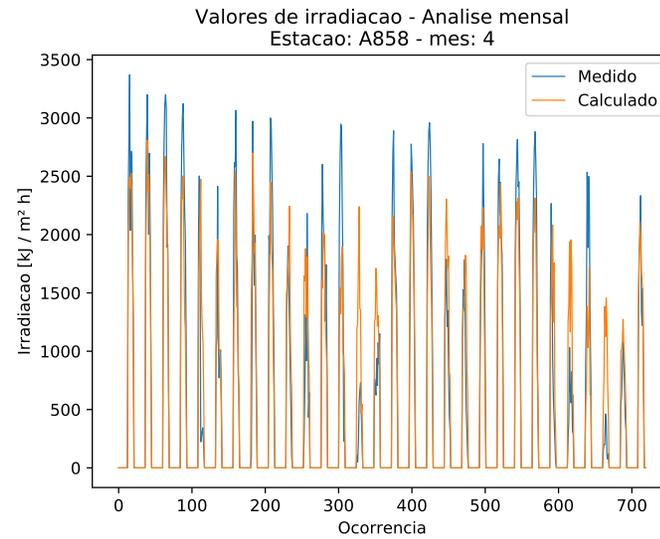
(a) Melhores ajustes diários.



(b) Melhores ajustes semanais.



(c) Melhores ajustes quinzenais.

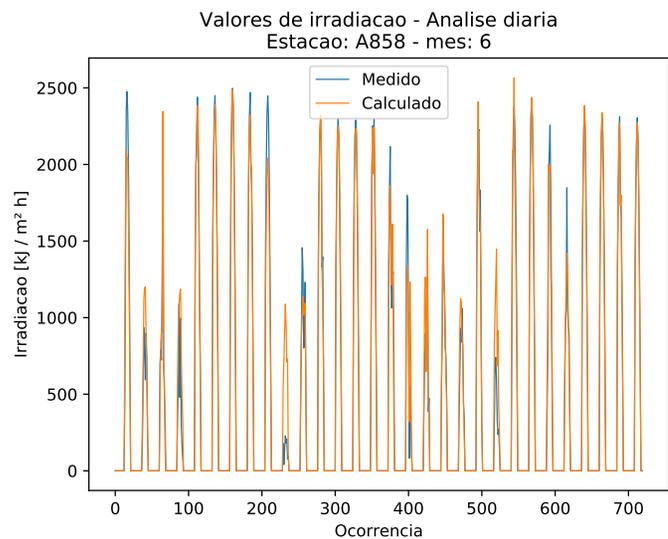


(d) Melhor ajuste mensal

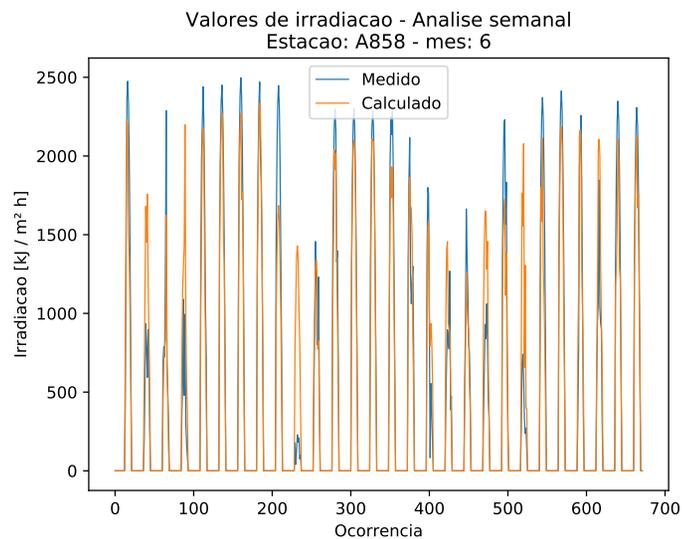
**Figura C.2:** Análises para a estação A858 para o mês de abril de 2012.

**Tabela C.3:** Parâmetros de melhor ajuste por período para o mês de junho de 2012 na estação A858.

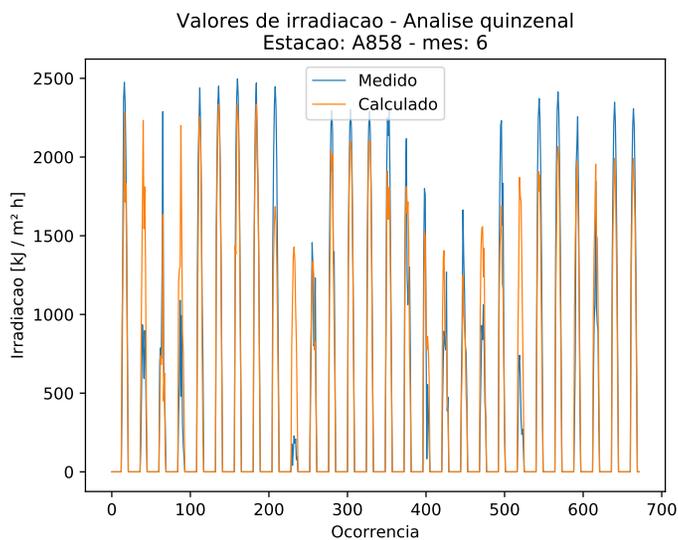
Período	Dias	Classes	Tolerância nos limites [%]	Coef. $p$ PageRank	Nível	GPI ( $\times 10^{-4}$ )
Mensal						
0	1	5	0	0.85	2	792.751
Quinzenal						
1	1	7	0	0.95	2	883.675
2	1	10	0	0.85	3	701.049
Semanal						
1	1	7	10	0.95	2	840.971
2	1	7	0	0.95	2	981.891
3	1	7	0	0.75	3	670.883
4	1	5	10	0.95	2	647.499
Diário						
1	1	5	10	0.75	3	869.506
2	1	20	-10	0.65	1	925.866
3	1	6	0	0.95	3	868.172
4	1	20	-10	0.65	1	612.255
5	1	5	0	0.85	3	1619.939
6	1	5	0	0.95	2	1813.376
7	2	8	0	0.95	3	1827.93
8	1	6	10	0.85	3	1749.056
9	1	5	0	0.95	3	1026.333
10	1	5	5	0.95	1	714.084
11	1	8	-5	0.95	1	724.545
12	1	6	-5	0.95	3	1680.7
13	1	8	0	0.95	3	1952.459
14	1	5	10	0.85	3	1731.883
15	1	5	5	0.95	3	1458.416
16	10	5	-5	0.85	3	980.081
17	10	5	-5	0.95	1	969.557
18	5	7	5	0.95	1	647.976
19	1	6	10	0.95	3	1038.745
20	2	5	-10	0.65	1	883.623
21	10	5	-5	0.95	3	1303.392
22	2	5	5	0.85	1	580.94
23	1	5	0	0.95	3	1375.846
24	1	5	0	0.85	3	1953.305
25	1	5	0	0.95	1	1050.698
26	1	7	-10	0.65	1	767.854
27	1	7	0	0.95	3	1753.125
28	1	5	5	0.95	3	1864.568
29	1	8	10	0.95	3	1649.873
30	2	10	0	0.95	3	1874.752



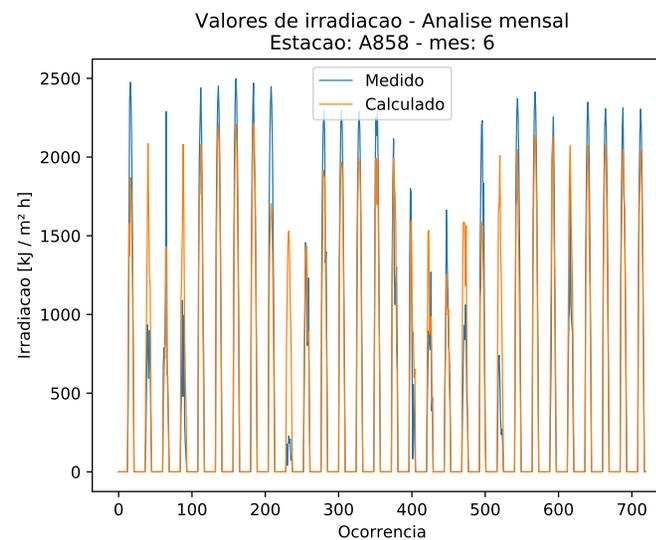
(a) Melhores ajustes diários.



(b) Melhores ajustes semanais.



(c) Melhores ajustes quinzenais.

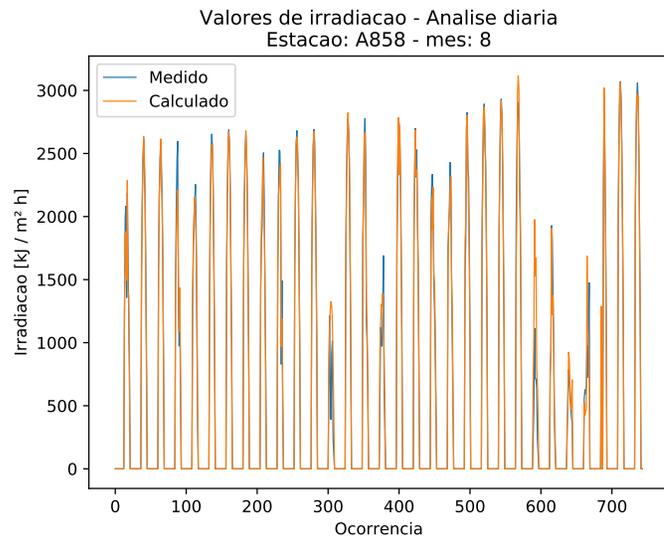


(d) Melhor ajuste mensal

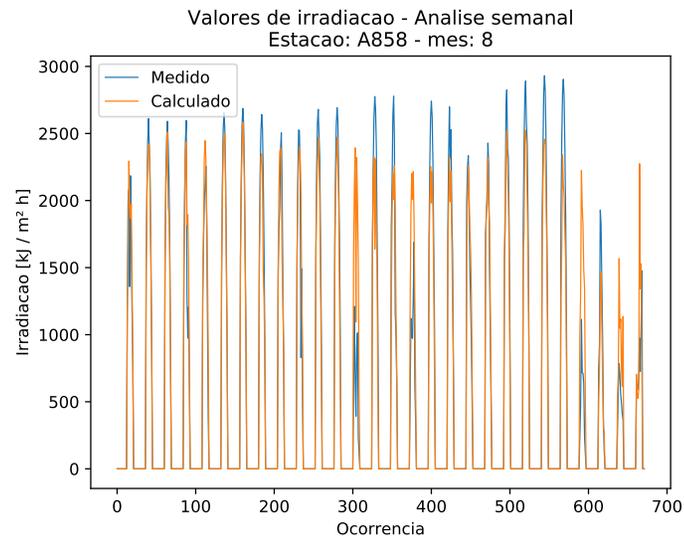
**Figura C.3:** Análises para a estação A858 para o mês de junho de 2012.

**Tabela C.4:** Parâmetros de melhor ajuste por período para o mês de agosto de 2012 na estação A858.

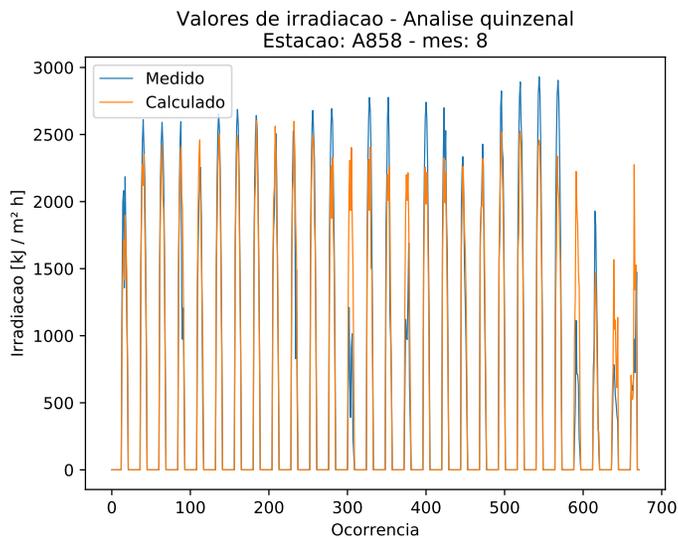
Período	Dias	Classes	Tolerância nos limites [%]	Coef. $p$ PageRank	Nível	GPI ( $\times 10^{-4}$ )
Mensal						
0	1	8	0	0.85	3	812.949
Quinzenal						
1	1	5	5	0.85	3	744.683
2	1	6	0	0.85	2	794.794
Semanal						
1	1	6	0	0.85	3	1031.006
2	5	9	0	0.95	2	559.73
3	1	6	0	0.85	2	671.449
4	1	6	0	0.85	2	726.297
Diário						
1	2	5	10	0.75	3	1440.417
2	1	6	-5	0.95	3	1909.028
3	2	5	0	0.85	3	1859.451
4	1	6	-10	0.95	2	1081.53
5	2	15	5	0.95	1	1045.616
6	1	8	0	0.95	3	1759.228
7	1	5	5	0.95	3	1892.072
8	1	8	0	0.95	3	1918.209
9	1	6	0	0.75	3	1356.674
10	5	5	-10	0.95	2	1316.27
11	1	8	0	0.95	3	1826.552
12	2	9	0	0.95	3	1809.507
13	1	20	-10	0.65	1	666.626
14	2	6	0	0.95	3	1610.479
15	10	7	-10	0.95	3	1540.422
16	2	20	-10	0.65	1	823.408
17	1	6	0	0.95	3	1528.833
18	1	5	5	0.95	3	1597.249
19	1	8	-5	0.95	2	897.142
20	2	9	5	0.95	2	1146.496
21	1	5	5	0.85	3	1509.211
22	1	9	0	0.95	3	1896.22
23	1	5	5	0.95	3	1884.726
24	1	5	0	0.95	3	1511.924
25	2	6	5	0.95	1	656.313
26	1	6	10	0.95	3	963.19
27	1	20	-10	0.65	1	1098.324
28	1	6	10	0.65	1	1337.59
29	1	7	-5	0.95	3	1466.961
30	1	8	0	0.95	3	1905.61
31	1	5	0	0.85	3	1898.695



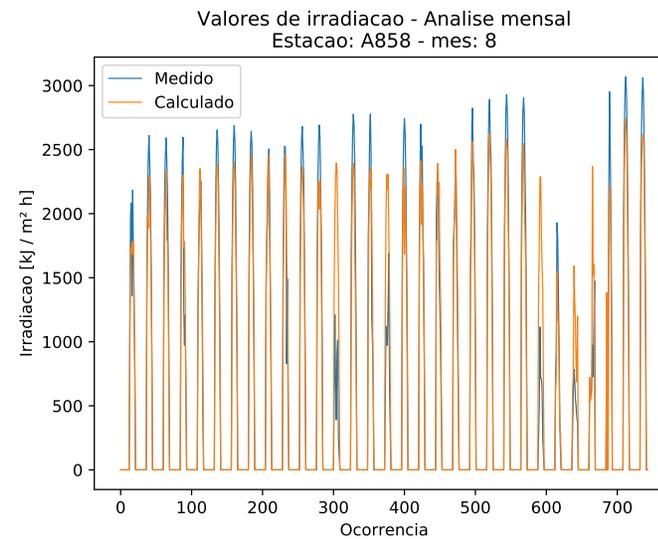
(a) Melhores ajustes diários.



(b) Melhores ajustes semanais.



(c) Melhores ajustes quinzenais.

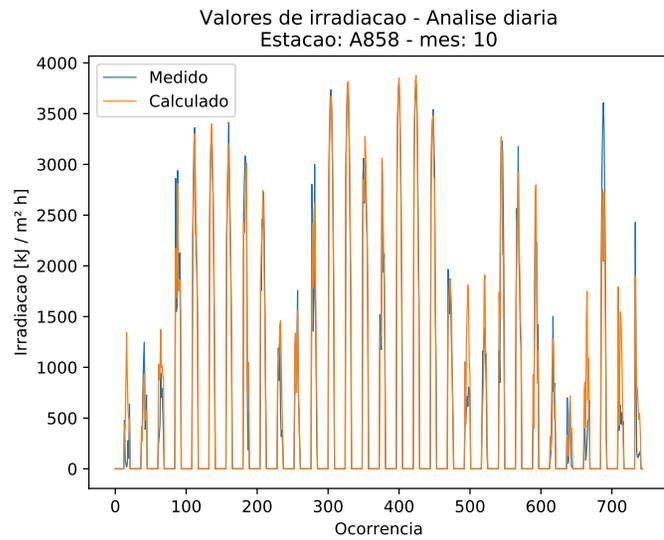


(d) Melhor ajuste mensal

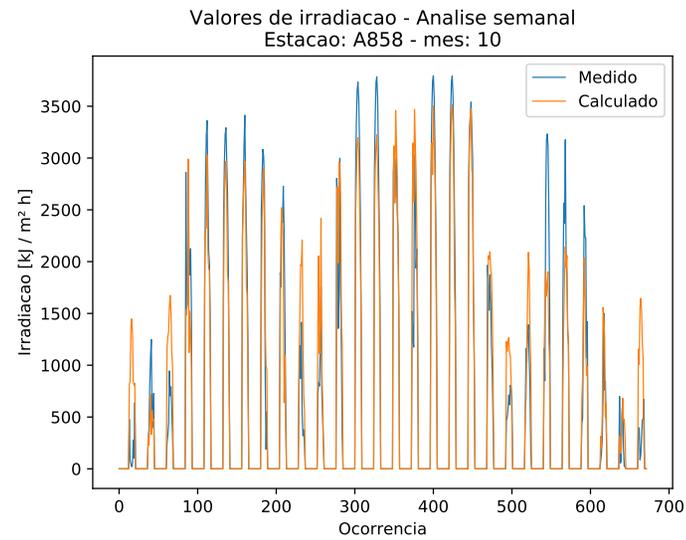
**Figura C.4:** Análises para a estação A858 para o mês de agosto de 2012.

**Tabela C.5:** Parâmetros de melhor ajuste por período para o mês de outubro de 2012 na estação A858.

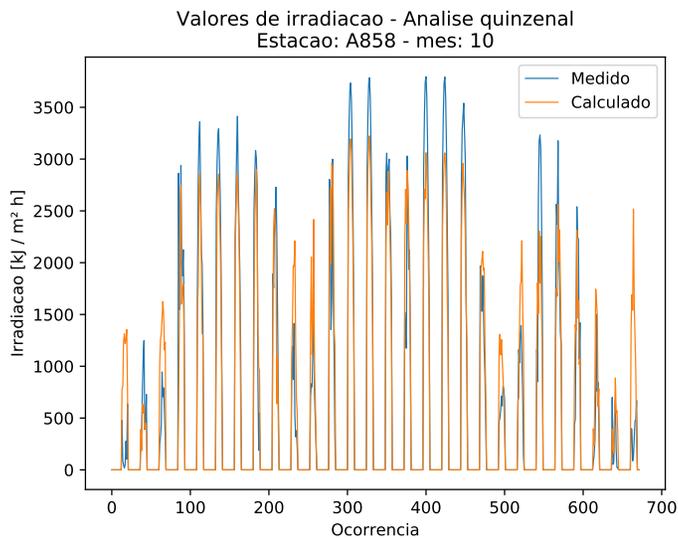
Período	Dias	Classes	Tolerância nos limites [%]	Coef. $p$ PageRank	Nível	GPI ( $\times 10^{-4}$ )
Mensal						
0	1	9	0	0.95	1	831.718
Quinzenal						
1	1	9	0	0.95	1	872.729
2	1	9	0	0.85	2	875.194
Semanal						
1	1	6	5	0.95	2	805.484
2	1	9	0	0.95	1	873.622
3	1	8	0	0.95	2	1189.806
4	1	6	5	0.85	1	755.174
Diário						
1	2	5	5	0.95	1	693.972
2	1	5	0	0.65	3	1216.948
3	1	6	-10	0.75	1	714.398
4	1	15	10	0.95	3	1373.481
5	1	8	10	0.95	3	1351.148
6	1	5	5	0.95	3	1612.91
7	1	6	0	0.85	3	1769.949
8	2	5	5	0.95	3	1139.939
9	5	7	10	0.65	2	1094.479
10	1	5	5	0.75	1	716.853
11	1	6	-10	0.65	1	1150.499
12	1	5	0	0.85	1	851.639
13	1	9	0	0.95	3	1877.88
14	1	5	0	0.85	3	1949.56
15	1	7	5	0.85	3	1461.171
16	5	9	-10	0.95	3	1238.53
17	1	7	0	0.95	3	1754.235
18	1	6	10	0.95	3	1800.66
19	1	8	0	0.95	2	1656.621
20	1	20	-10	0.65	3	904.738
21	10	10	-10	0.95	1	892.269
22	10	6	5	0.95	1	869.148
23	10	5	10	0.95	3	991.929
24	5	5	5	0.85	3	1615.988
25	10	15	0	0.95	1	882.528
26	1	6	-10	0.75	1	1044.878
27	1	20	-10	0.65	1	1213.362
28	5	10	-10	0.95	1	842.642
29	1	15	10	0.95	3	858.226
30	1	5	10	0.95	1	849.74
31	1	6	5	0.95	1	1300.8



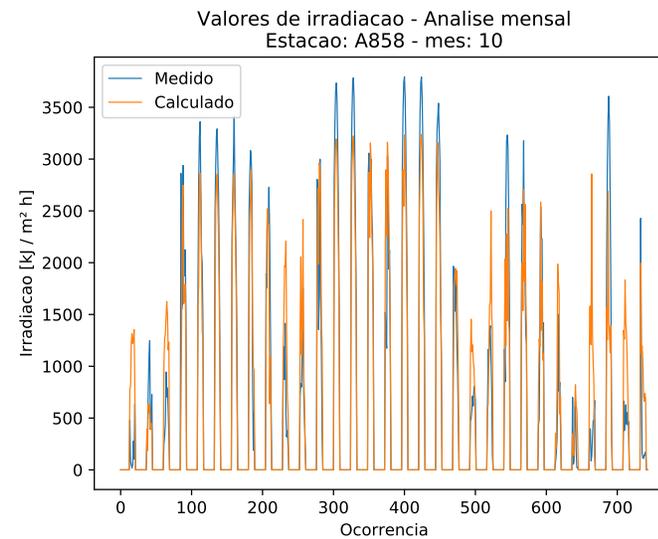
(a) Melhores ajustes diários.



(b) Melhores ajustes semanais.



(c) Melhores ajustes quinzenais.

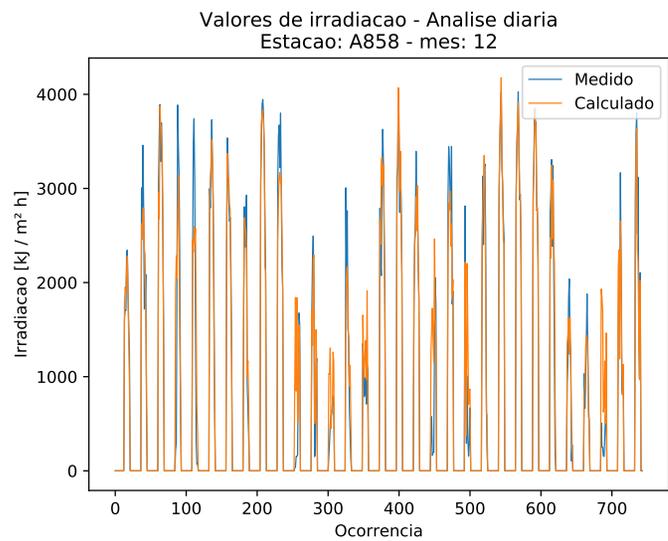


(d) Melhor ajuste mensal

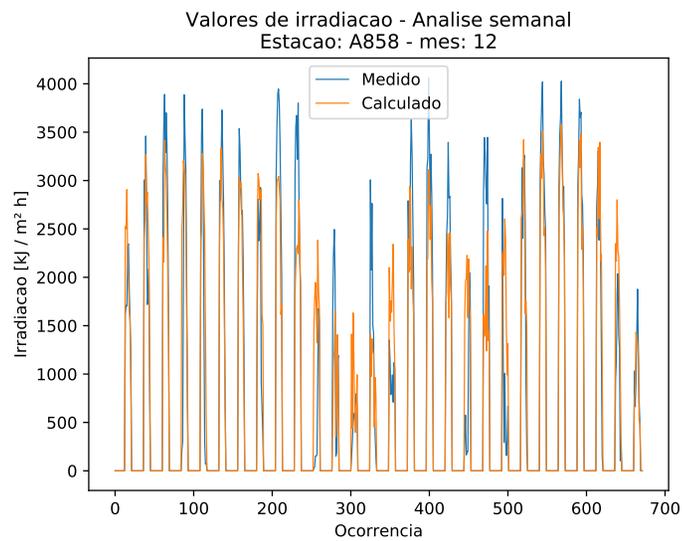
**Figura C.5:** Análises para a estação A858 para o mês de outubro de 2012.

**Tabela C.6:** Parâmetros de melhor ajuste por período para o mês de fevereiro de 2012 na estação A858.

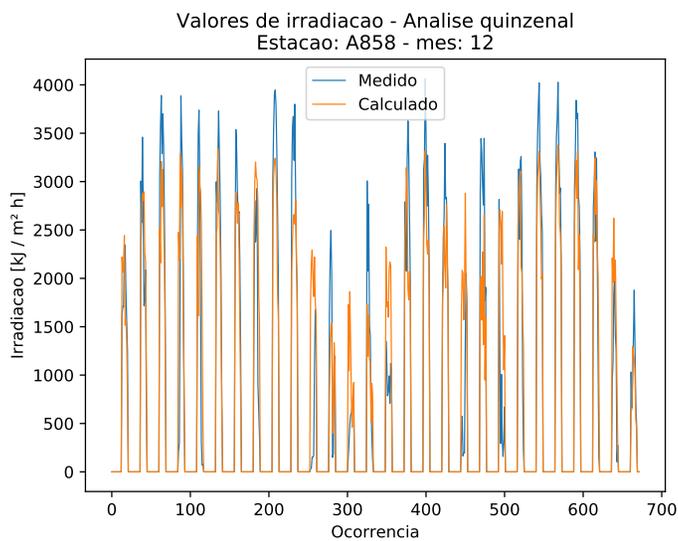
Período	Dias	Classes	Tolerância nos limites [%]	Coef. $p$ PageRank	Nível	GPI ( $\times 10^{-4}$ )
Mensal						
0	1	6	0	0.85	2	701.101
Quinzenal						
1	1	6	0	0.85	2	597.972
2	1	6	0	0.85	2	853.135
Semanal						
1	1	6	5	0.75	3	617.161
2	1	6	0	0.95	1	640.02
3	1	6	5	0.85	2	719.897
4	1	6	5	0.85	3	1105.992
Diário						
1	2	8	-10	0.85	1	991.926
2	5	7	-5	0.95	2	854.873
3	1	5	0	0.85	3	1531.667
4	5	7	0	0.95	1	352.481
5	5	7	-10	0.95	1	632.328
6	2	5	0	0.85	3	1568.338
7	2	7	10	0.85	3	1450.598
8	5	7	-10	0.95	2	847.624
9	1	6	0	0.95	3	1737.37
10	1	5	0	0.75	3	1381.371
11	10	5	10	0.95	1	779.176
12	10	6	5	0.95	1	1056.387
13	2	10	-5	0.95	1	750.944
14	10	9	0	0.95	1	770.256
15	1	5	10	0.95	1	1418.533
16	2	5	-5	0.85	3	1394.442
17	1	6	-5	0.95	3	1801.863
18	2	7	10	0.75	3	1599.928
19	1	5	5	0.95	1	738.068
20	5	8	0	0.95	3	1235.746
21	10	5	10	0.95	1	1368.469
22	2	10	0	0.95	1	1262.927
23	1	5	0	0.85	3	1869.11
24	1	5	10	0.85	3	1810.239
25	1	10	0	0.95	3	1806.453
26	1	8	0	0.95	1	961.221
27	1	15	-10	0.65	1	810.938
28	1	5	10	0.95	3	1094.642
29	2	9	-10	0.95	1	730.834
30	10	10	5	0.95	1	930.952
31	1	8	10	0.95	3	1095.631



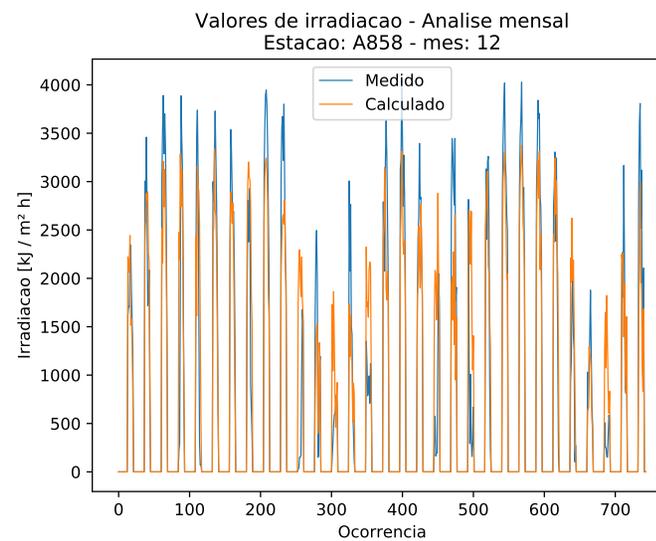
(a) Melhores ajustes diários.



(b) Melhores ajustes semanais.



(c) Melhores ajustes quinzenais.



(d) Melhor ajuste mensal

**Figura C.6:** Análises para a estação A858 para o mês de dezembro de 2012.



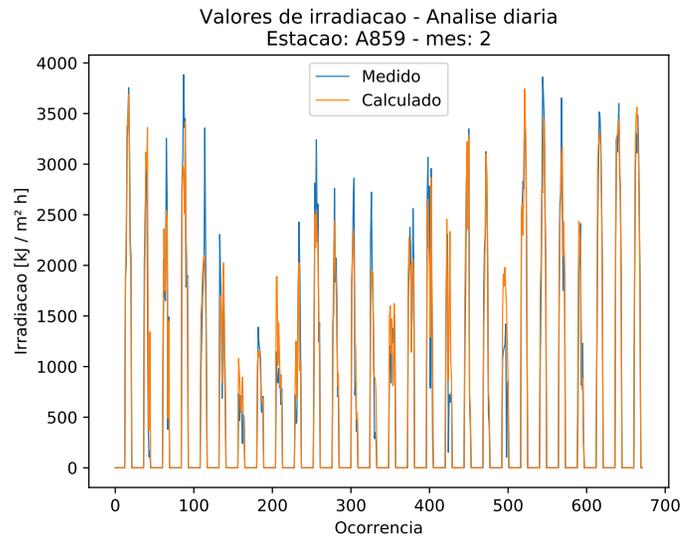
# Apêndice D

## Resultados para a estação A859

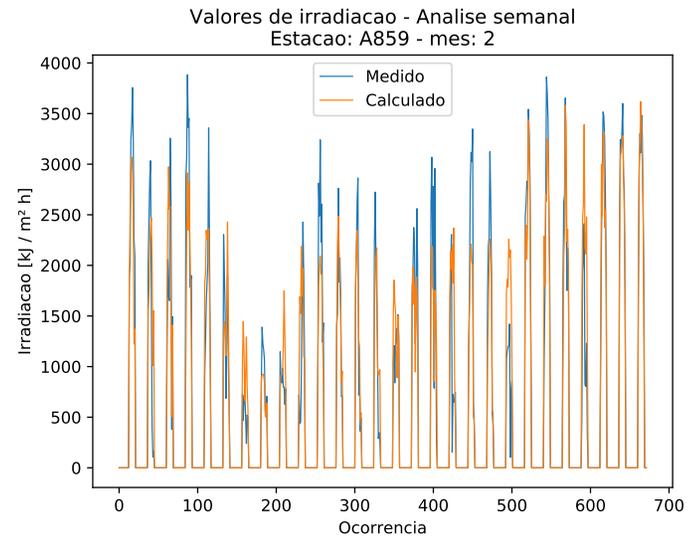
Tabelas com os parâmetros de melhor ajuste dos dados estimados aos dados efetivamente registrados, bem como os gráficos com os referidos valores para a estação A859 para os meses de fevereiro, abril, junho, agosto outubro e dezembro do ano de 2013. Para os gráficos referentes aos meses com mais de 28 dias valem as explicações do Apêndice A na Página 75.

**Tabela D.1:** Parâmetros de melhor ajuste por período para o mês de fevereiro de 2013 na estação A859.

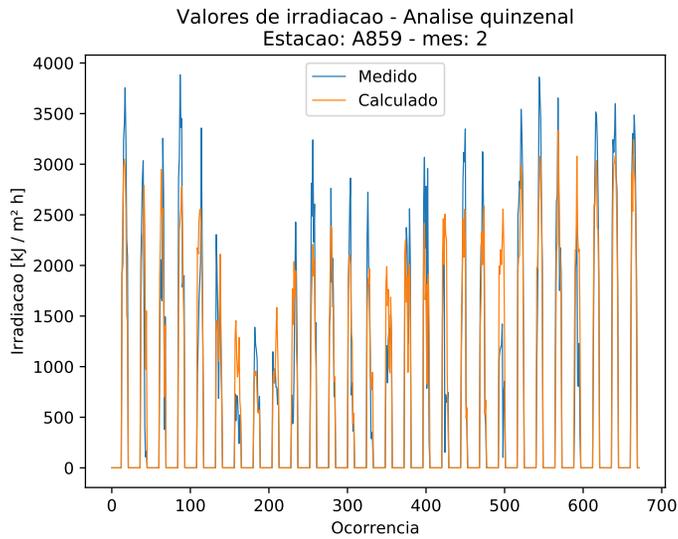
Período	Dias	Classes	Tolerância nos limites [%]	Coef. $p$ PageRank	Nível	GPI ( $\times 10^{-4}$ )
Mensal						
0	1	8	0	0.75	3	504.073
Quinzenal						
1	1	5	10	0.75	2	553.869
2	1	9	0	0.85	3	553.348
Semanal						
1	1	6	5	0.85	2	462.759
2	1	6	-10	0.75	3	796.258
3	1	6	5	0.65	2	341
4	1	7	0	0.95	2	873.532
Diário						
1	5	20	0	0.95	3	1546.921
2	5	7	10	0.95	1	592.033
3	10	9	-10	0.95	1	1060.195
4	1	8	0	0.95	3	1048.557
5	1	6	5	0.95	1	708.63
6	1	5	10	0.95	2	1023.779
7	1	20	-10	0.65	1	970.825
8	1	5	10	0.85	3	1026.644
9	5	7	-10	0.95	1	775.083
10	2	8	10	0.95	1	1333.884
11	1	5	5	0.95	3	1253.227
12	1	8	-10	0.85	3	1014.823
13	1	6	-10	0.75	3	948.939
14	1	5	-5	0.85	2	703.065
15	1	7	-5	0.85	1	847.208
16	1	8	5	0.95	3	1554.794
17	2	5	5	0.95	3	950.787
18	10	5	0	0.95	1	949.337
19	1	6	10	0.95	3	1202.453
20	1	6	5	0.95	3	1242.821
21	10	6	-10	0.65	1	839.934
22	1	7	0	0.95	3	1638.911
23	1	5	0	0.95	2	1075.254
24	2	7	5	0.95	2	1186.193
25	5	5	5	0.95	1	743.888
26	2	10	10	0.95	3	1481.764
27	1	7	5	0.95	3	1742.254
28	2	5	5	0.85	3	1542.299



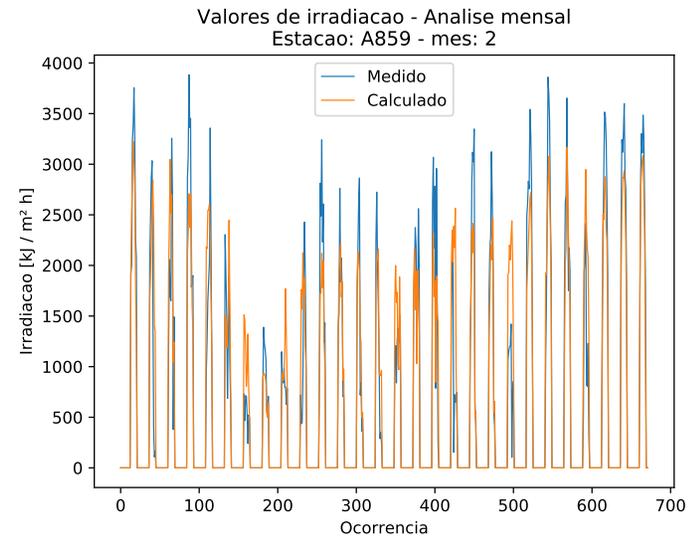
(a) Melhores ajustes diários.



(b) Melhores ajustes semanais.



(c) Melhores ajustes quinzenais.

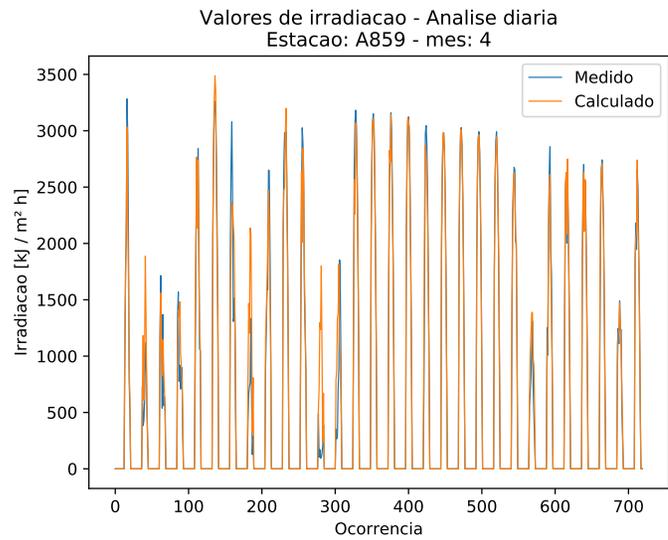


(d) Melhor ajuste mensal

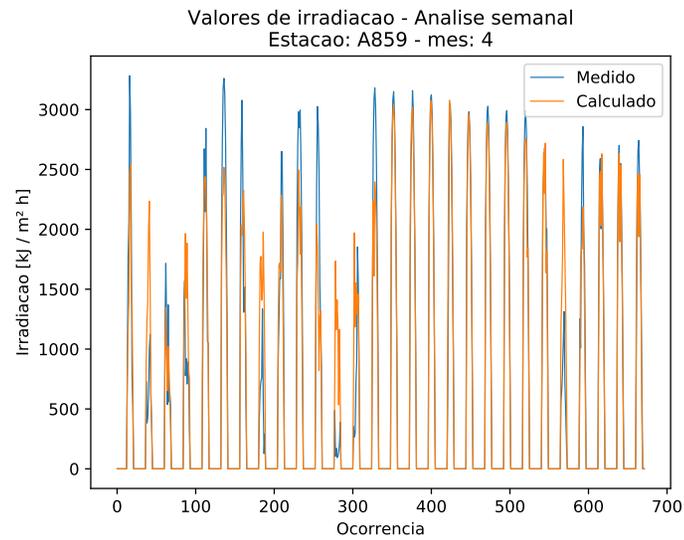
**Figura D.1:** Análises para a estação A859 para o mês de fevereiro de 2013.

**Tabela D.2:** Parâmetros de melhor ajuste por período para o mês de abril de 2013 na estação A859.

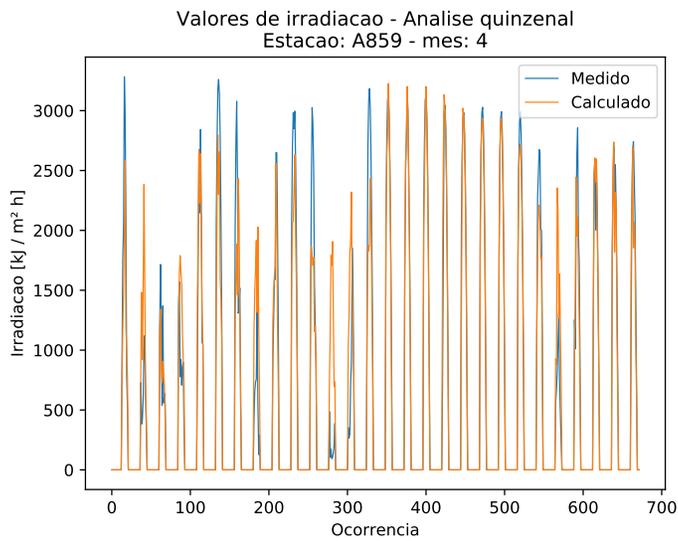
Período	Dias	Classes	Tolerância nos limites [%]	Coef. $p$ PageRank	Nível	GPI ( $\times 10^{-4}$ )
Mensal						
0	1	15	10	0.95	3	680.143
Quinzenal						
1	1	5	10	0.85	2	533.009
2	1	5	-5	0.95	2	1010.092
Semanal						
1	1	10	10	0.75	3	679.697
2	1	15	10	0.95	1	544.528
3	1	7	5	0.95	3	1388.585
4	1	9	5	0.95	3	720.384
Diário						
1	2	7	5	0.95	3	982.349
2	1	5	5	0.85	1	863.84
3	1	5	0	0.75	3	1206.274
4	1	5	5	0.95	1	1062.211
5	1	5	5	0.95	2	1197.547
6	1	6	0	0.95	3	1675.376
7	10	5	-10	0.65	3	793.36
8	10	5	5	0.95	1	703.842
9	1	9	0	0.95	1	1258.934
10	1	5	10	0.95	3	1608.519
11	10	9	0	0.95	3	1112.998
12	1	5	10	0.95	1	553.783
13	1	5	5	0.85	1	856.061
14	1	9	0	0.95	3	1408.128
15	1	8	0	0.95	3	1918.647
16	2	5	-10	0.85	3	1607.411
17	1	5	0	0.85	3	1943.693
18	1	6	-10	0.95	2	1058.8
19	2	5	0	0.75	3	1768.844
20	1	5	5	0.95	3	1936.663
21	1	9	0	0.95	3	1830.455
22	1	9	0	0.95	3	1663.775
23	1	5	0	0.85	3	1316.911
24	1	20	-10	0.65	1	837.354
25	2	7	0	0.95	3	1163.25
26	1	7	-5	0.95	3	1578.762
27	1	6	5	0.95	3	1750.047
28	1	5	5	0.95	3	1417.19
29	1	15	-10	0.65	1	1077.837
30	2	5	-10	0.95	3	1555.333



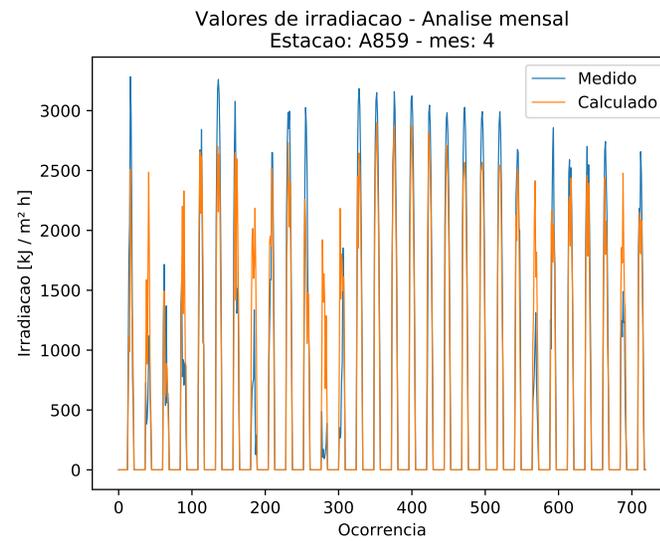
(a) Melhores ajustes diários.



(b) Melhores ajustes semanais.



(c) Melhores ajustes quinzenais.

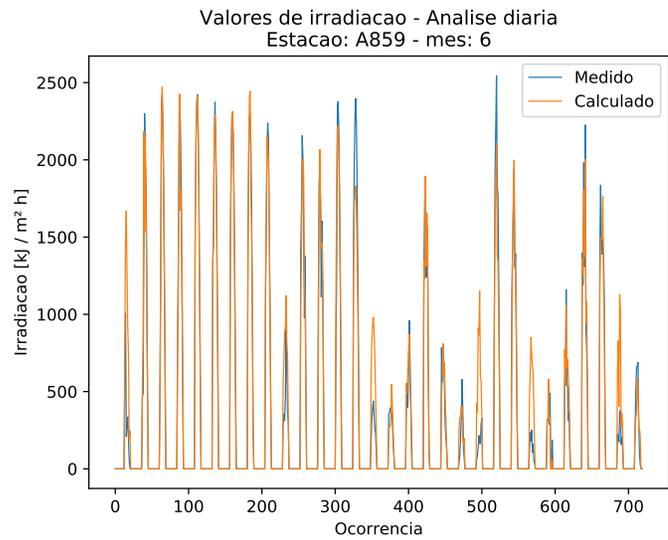


(d) Melhor ajuste mensal

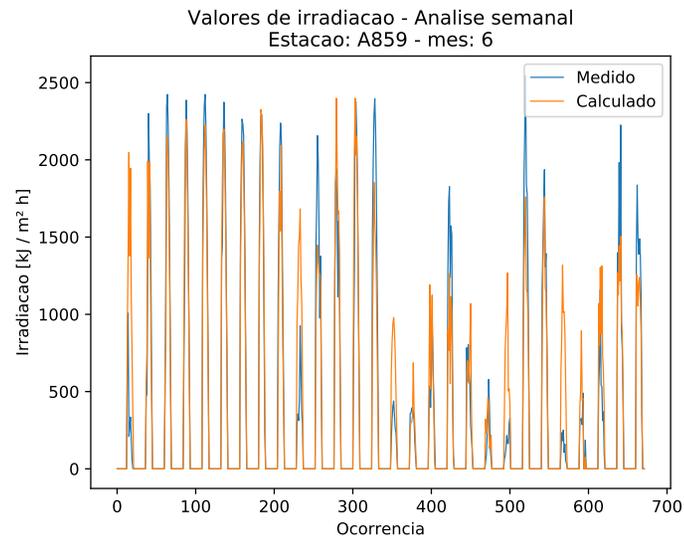
**Figura D.2:** Análises para a estação A859 para o mês de abril de 2013.

**Tabela D.3:** Parâmetros de melhor ajuste por período para o mês de junho de 2013 na estação A859.

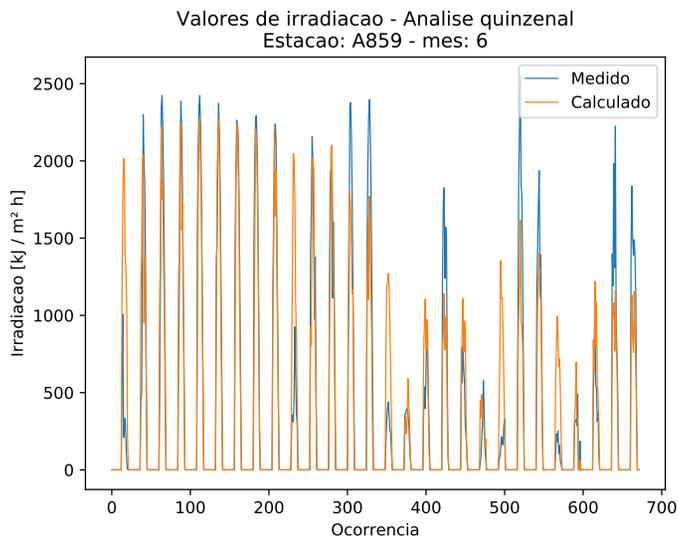
Período	Dias	Classes	Tolerância nos limites [%]	Coef. $p$ PageRank	Nível	GPI ( $\times 10^{-4}$ )
Mensal						
0	1	6	5	0.95	2	507.546
Quinzenal						
1	2	15	5	0.95	3	667.332
2	1	15	0	0.85	1	576.743
Semanal						
1	1	10	0	0.95	2	724.065
2	1	5	5	0.95	3	700.096
3	1	5	5	0.95	1	686.071
4	1	8	5	0.85	3	851.15
Diário						
1	1	5	5	0.95	1	537.636
2	1	9	0	0.95	3	1004.777
3	1	5	5	0.95	3	1787.155
4	2	7	-10	0.95	3	1271.34
5	1	8	0	0.95	3	1901.763
6	2	6	0	0.95	2	1656.478
7	2	5	0	0.75	3	1846.582
8	10	5	0	0.95	3	1365.496
9	5	7	0	0.85	3	1565.333
10	1	5	5	0.95	1	816.803
11	2	8	10	0.85	3	1161.838
12	1	5	10	0.85	2	1240.39
13	1	6	-5	0.95	2	1145.598
14	10	5	0	0.65	3	957.154
15	1	5	5	0.95	1	551.7
16	1	6	5	0.65	1	1276.282
17	2	5	-10	0.85	1	991.039
18	1	5	-5	0.95	3	1250.481
19	2	6	-10	0.95	1	1042.682
20	1	7	-10	0.85	1	1123.243
21	2	5	5	0.95	1	724.366
22	1	5	0	0.95	3	1067.348
23	1	5	-5	0.95	3	1351.344
24	1	7	-10	0.65	1	630.157
25	1	6	-10	0.75	1	1154.89
26	2	6	-5	0.75	1	783.626
27	10	5	0	0.95	3	1393.185
28	10	5	10	0.75	3	1277.735
29	2	6	10	0.95	1	723.971
30	1	5	5	0.95	2	857.743



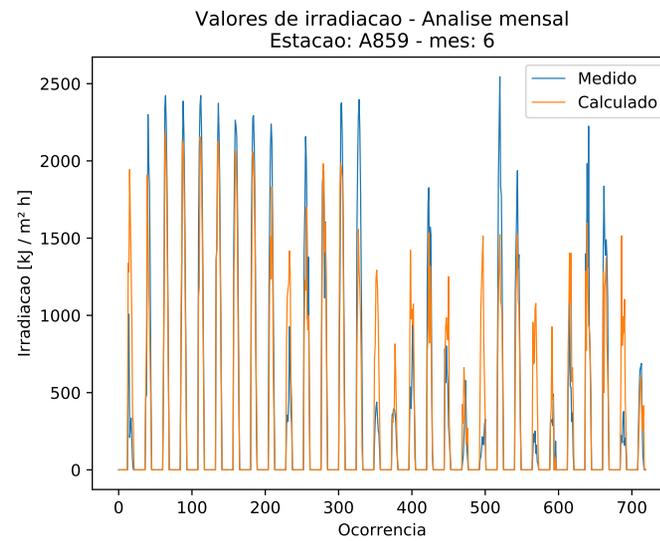
(a) Melhores ajustes diários.



(b) Melhores ajustes semanais.



(c) Melhores ajustes quinzenais.

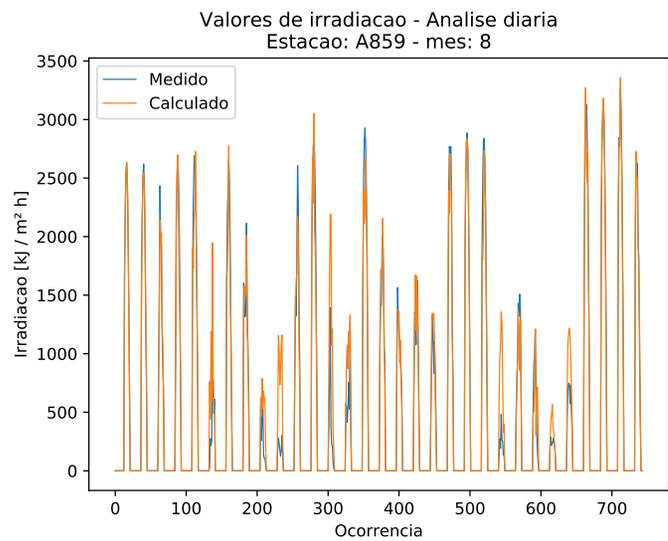


(d) Melhor ajuste mensal

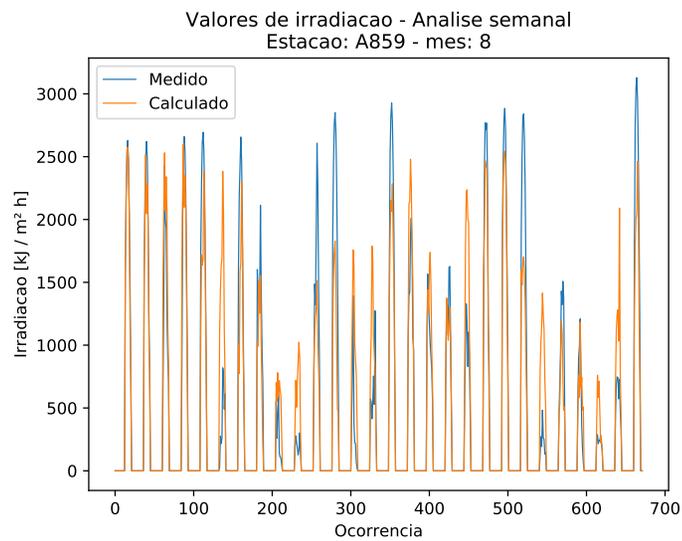
**Figura D.3:** Análises para a estação A859 para o mês de junho de 2013.

**Tabela D.4:** Parâmetros de melhor ajuste por período para o mês de agosto de 2013 na estação A859.

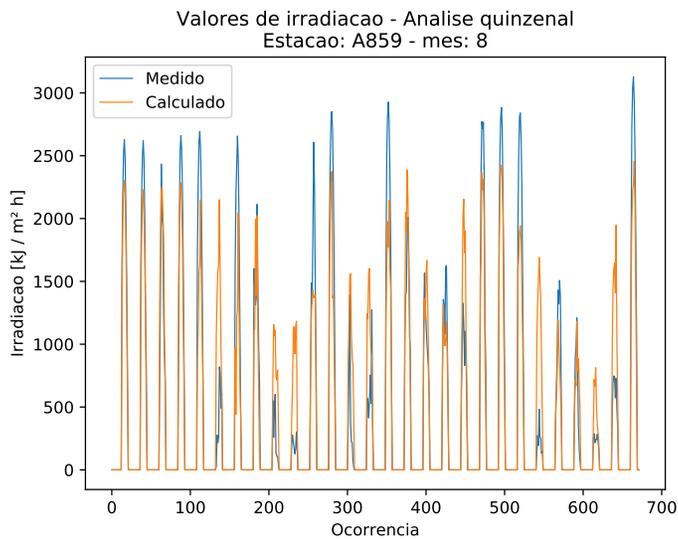
Período	Dias	Classes	Tolerância nos limites [%]	Coef. $p$ PageRank	Nível	GPI ( $\times 10^{-4}$ )
Mensal						
0	1	5	-10	0.95	2	701.811
Quinzenal						
1	1	8	0	0.95	1	589.264
2	1	6	0	0.85	2	777.104
Semanal						
1	1	7	5	0.95	3	577.448
2	1	6	-10	0.85	1	672.309
3	1	6	0	0.75	3	729.061
4	1	6	0	0.95	1	732.581
Diário						
1	1	9	0	0.95	3	1869.094
2	2	6	0	0.85	3	1805.474
3	10	20	10	0.85	3	818.678
4	1	5	0	0.95	2	1354.352
5	1	5	0	0.95	3	1272.126
6	5	5	5	0.95	1	1271.368
7	10	6	0	0.95	3	1245.505
8	10	5	5	0.75	2	1176.361
9	1	5	5	0.85	1	878.561
10	1	6	-5	0.95	1	1523.353
11	1	20	10	0.95	3	936.991
12	1	5	0	0.95	3	1343.027
13	2	7	-5	0.95	1	533.698
14	1	5	10	0.95	1	1843.541
15	1	5	0	0.95	3	1312.106
16	10	8	-5	0.85	3	796.268
17	10	7	-10	0.85	1	927.059
18	10	8	-10	0.85	2	832.845
19	1	20	-10	0.65	1	898.126
20	2	10	0	0.95	3	1175.74
21	1	5	0	0.85	3	1797.235
22	1	10	0	0.95	3	1133.038
23	2	7	10	0.95	1	704.556
24	1	9	10	0.95	3	1088.86
25	2	5	10	0.95	2	458.619
26	1	20	-10	0.65	1	1290.059
27	1	6	-5	0.95	1	751.71
28	1	5	0	0.95	3	1559.406
29	1	6	5	0.95	3	1949.251
30	1	8	10	0.95	3	1896.633
31	2	7	-5	0.95	3	1334.121



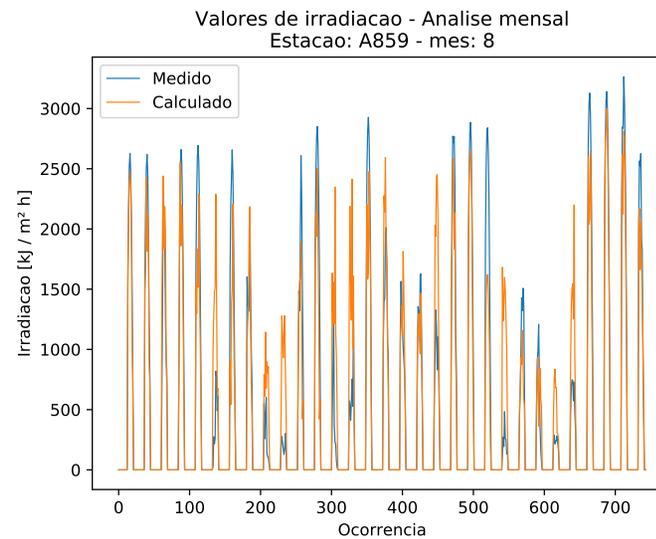
(a) Melhores ajustes diários.



(b) Melhores ajustes semanais.



(c) Melhores ajustes quinzenais.

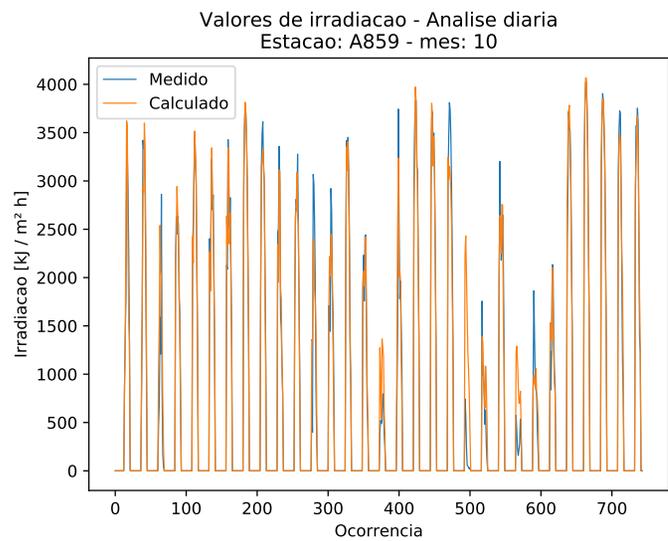


(d) Melhor ajuste mensal

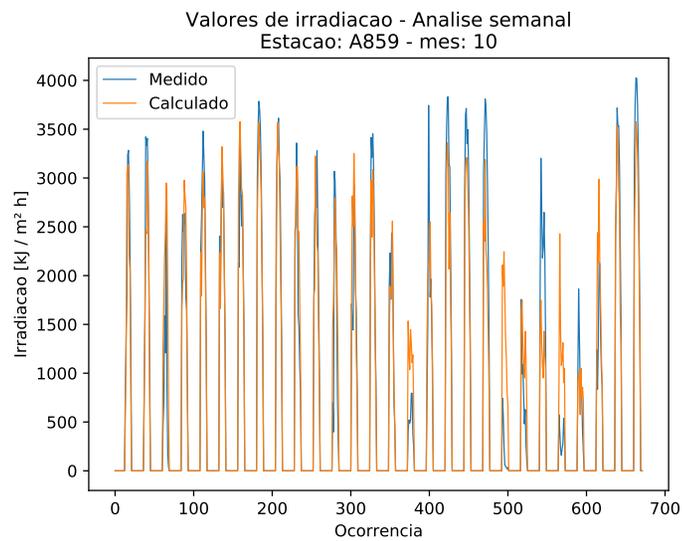
**Figura D.4:** Análises para a estação A859 para o mês de agosto de 2013.

**Tabela D.5:** Parâmetros de melhor ajuste por período para o mês de outubro de 2013 na estação A859.

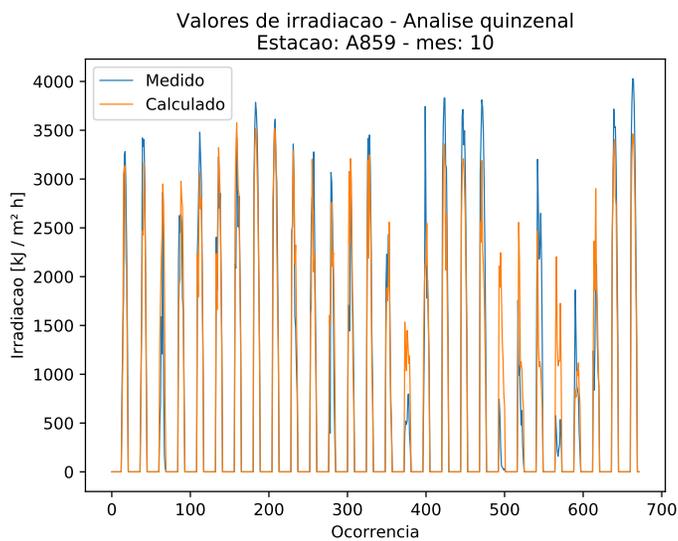
Período	Dias	Classes	Tolerância nos limites [%]	Coef. $p$ PageRank	Nível	GPI ( $\times 10^{-4}$ )
Mensal						
0	1	9	0	0.95	2	816.965
Quinzenal						
1	1	7	0	0.95	2	693.293
2	1	9	0	0.95	1	796.002
Semanal						
1	1	7	0	0.95	2	648.056
2	1	7	0	0.85	3	795.789
3	1	9	0	0.95	1	894.373
4	1	5	5	0.95	2	702.978
Diário						
1	2	5	0	0.95	3	1234.818
2	1	5	0	0.95	3	1498.897
3	5	8	-10	0.95	1	641.646
4	10	8	10	0.65	3	1117.797
5	1	5	0	0.85	3	1614.846
6	1	7	0	0.85	3	1599.629
7	1	5	5	0.95	2	1109.876
8	1	5	0	0.85	3	1834.647
9	5	10	10	0.95	3	1462.838
10	10	5	0	0.85	2	939.915
11	1	7	10	0.95	3	1240.258
12	1	5	10	0.95	1	463.622
13	2	10	10	0.85	1	666.638
14	1	8	0	0.95	3	1450.655
15	1	6	0	0.85	2	946.27
16	1	5	5	0.95	1	955.923
17	2	9	5	0.95	1	744.454
18	1	5	0	0.85	3	1709.896
19	1	5	-5	0.85	3	1891.298
20	1	5	0	0.95	3	1298.024
21	1	9	-10	0.95	1	575.604
22	1	5	5	0.95	1	896.759
23	5	5	-10	0.75	3	1246.527
24	2	6	5	0.95	1	1032.293
25	1	6	5	0.85	2	756.189
26	5	6	-10	0.85	1	973.304
27	1	5	0	0.75	3	1547.173
28	1	5	0	0.85	3	1947.679
29	1	5	0	0.95	2	1921.396
30	1	8	0	0.85	3	881.419
31	1	5	5	0.85	3	1311.11



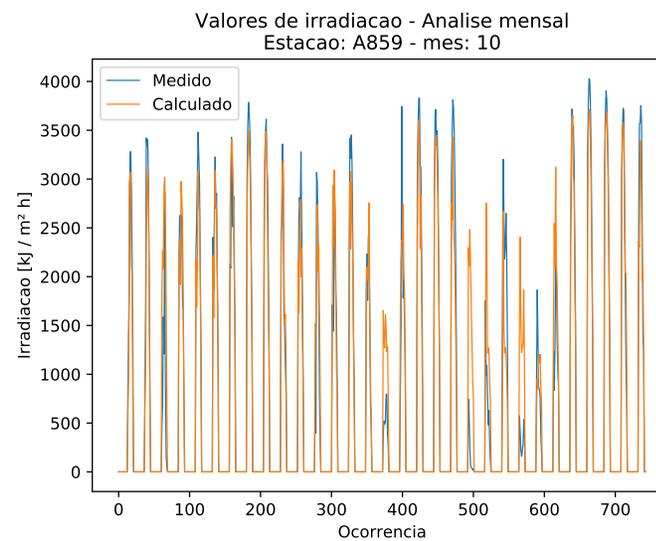
(a) Melhores ajustes diários.



(b) Melhores ajustes semanais.



(c) Melhores ajustes quinzenais.

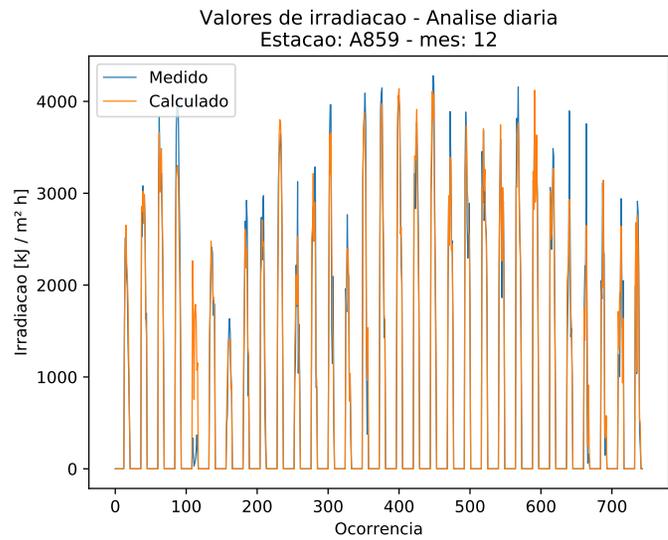


(d) Melhor ajuste mensal

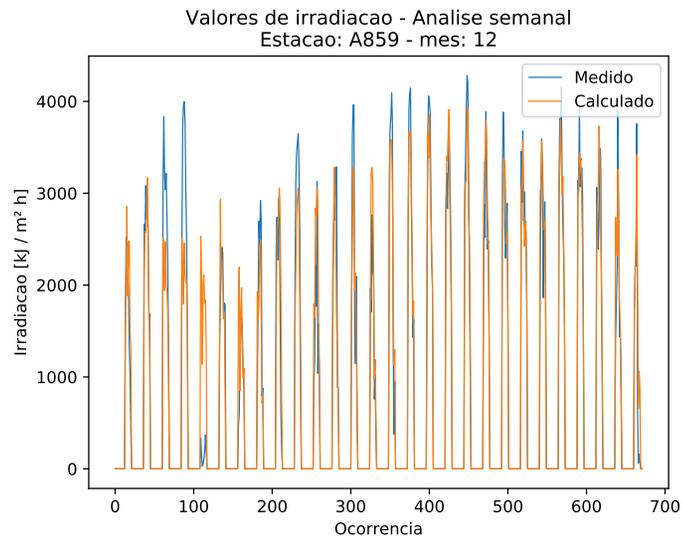
**Figura D.5:** Análises para a estação A859 para o mês de outubro de 2013.

**Tabela D.6:** Parâmetros de melhor ajuste por período para o mês de dezembro de 2013 na estação A859.

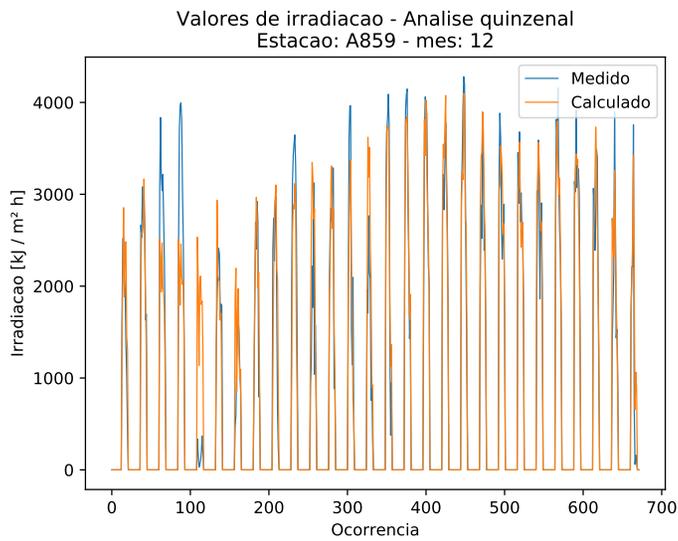
Período	Dias	Classes	Tolerância nos limites [%]	Coef. $p$ PageRank	Nível	GPI ( $\times 10^{-4}$ )
Mensal						
0	2	9	10	0.95	2	544.614
Quinzenal						
1	2	9	5	0.95	2	497.282
2	1	5	5	0.85	3	1215.809
Semanal						
1	2	9	5	0.95	2	549.53
2	1	5	-5	0.85	2	409.379
3	1	5	5	0.75	3	1079.111
4	1	5	5	0.85	3	1201.353
Diário						
1	10	9	5	0.95	1	832.737
2	1	7	0	0.95	2	1547.352
3	1	9	5	0.95	3	1684.738
4	1	5	0	0.95	3	1190.465
5	2	8	-10	0.95	1	810.593
6	5	10	0	0.95	2	1109.609
7	1	15	-10	0.75	1	1373.235
8	2	8	5	0.95	1	727.958
9	5	8	5	0.95	3	884.364
10	1	6	0	0.95	3	1619.89
11	1	5	5	0.75	1	754.586
12	10	8	10	0.95	3	962.06
13	2	8	5	0.95	3	1001.296
14	1	15	0	0.65	1	1028.568
15	1	5	0	0.95	2	1257.536
16	2	9	10	0.95	3	1434.653
17	1	7	10	0.95	3	1420.939
18	1	5	5	0.75	3	1279.623
19	5	7	0	0.95	3	1127.73
20	2	20	0	0.95	3	1235.666
21	5	15	10	0.95	3	1263.5
22	2	9	10	0.95	3	1482.175
23	2	10	0	0.95	3	1313.403
24	5	5	10	0.65	3	1367.667
25	1	5	-10	0.95	3	1674.349
26	1	6	5	0.95	3	1235.522
27	10	5	5	0.75	2	732.816
28	5	5	10	0.95	1	935.046
29	2	5	10	0.95	2	898.207
30	1	15	10	0.95	3	990.494
31	10	7	0	0.95	1	1187.198



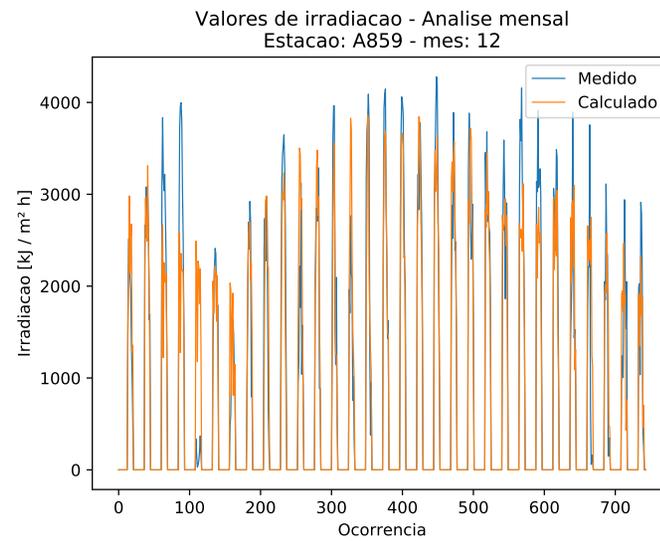
(a) Melhores ajustes diários.



(b) Melhores ajustes semanais.



(c) Melhores ajustes quinzenais.



(d) Melhor ajuste mensal

**Figura D.6:** Análises para a estação A859 para o mês de dezembro de 2013.



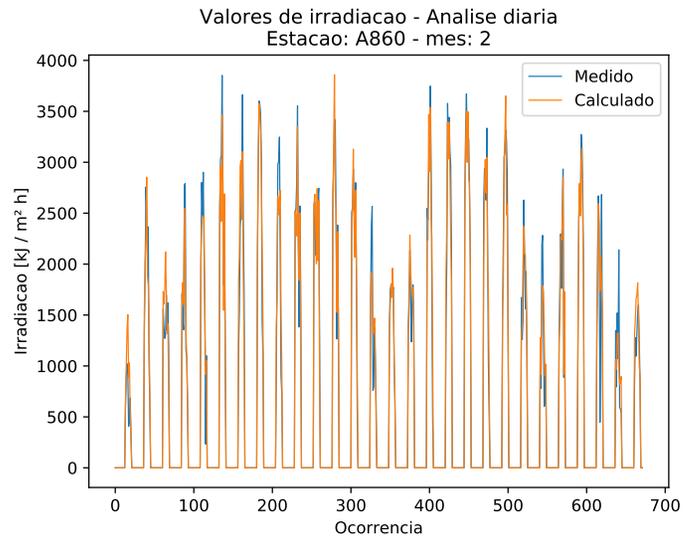
# Apêndice E

## Resultados para a estação A860

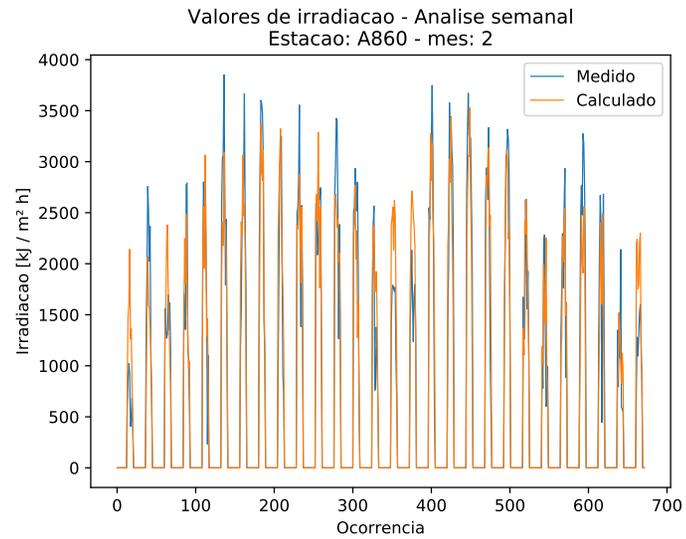
Tabelas com os parâmetros de melhor ajuste dos dados estimados aos dados efetivamente registrados, bem como os gráficos com os referidos valores para a estação A860 para os meses de fevereiro, abril, junho, agosto outubro e dezembro do ano de 2016. Para os gráficos referentes aos meses com mais de 28 dias valem as explicações do Apêndice A na Página 75.

**Tabela E.1:** Parâmetros de melhor ajuste por período para o mês de fevereiro de 2016 na estação A860.

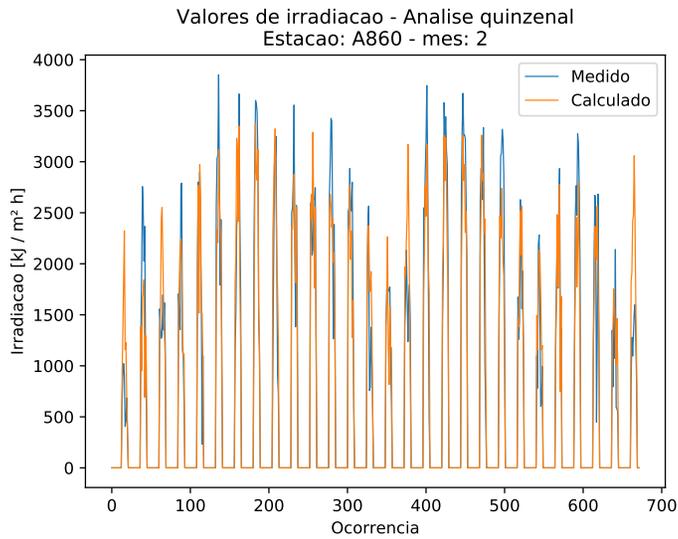
Período	Dias	Classes	Tolerância nos limites [%]	Coef. $p$ PageRank	Nível	GPI ( $\times 10^{-4}$ )
Mensal						
0	1	5	10	0.95	2	569.975
Quinzenal						
1	1	5	10	0.95	2	602.857
2	1	5	5	0.95	2	605.603
Semanal						
1	1	6	10	0.85	2	464.07
2	1	5	10	0.95	2	746.25
3	2	6	5	0.85	3	665.241
4	1	7	-5	0.95	1	493.455
Diário						
1	1	6	-10	0.65	1	846.933
2	5	20	10	0.85	3	978.882
3	10	6	-10	0.65	1	782.897
4	2	9	5	0.85	1	889.074
5	10	15	10	0.95	3	1064.922
6	5	6	5	0.95	3	1295.253
7	1	5	10	0.85	2	873.826
8	2	5	0	0.85	3	1217.791
9	2	20	0	0.95	1	558.685
10	1	8	-5	0.95	3	1234.947
11	10	8	0	0.95	3	1221.888
12	2	5	0	0.95	3	1428.039
13	5	7	5	0.95	2	1082.119
14	1	5	5	0.95	1	828.49
15	2	20	0	0.75	1	1117.909
16	2	20	0	0.85	1	901.612
17	2	6	5	0.95	3	984.185
18	1	5	10	0.95	2	1285.892
19	1	5	10	0.85	3	1633.473
20	1	10	10	0.95	1	1141.143
21	5	6	5	0.95	3	1289.297
22	1	5	5	0.75	2	713.556
23	1	5	5	0.95	1	843.583
24	1	7	5	0.95	2	1056.002
25	1	5	0	0.85	3	1645.621
26	10	15	-5	0.95	1	1105.539
27	1	6	5	0.95	1	799.977
28	1	7	-10	0.65	1	859.648



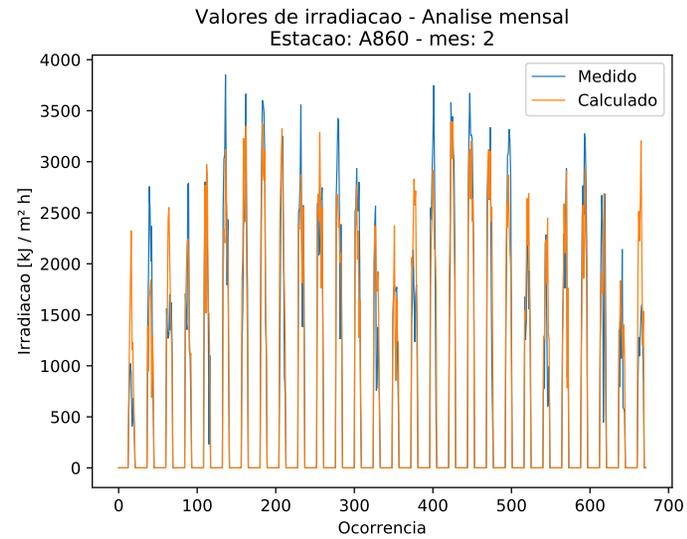
(a) Melhores ajustes diários.



(b) Melhores ajustes semanais.



(c) Melhores ajustes quinzenais.

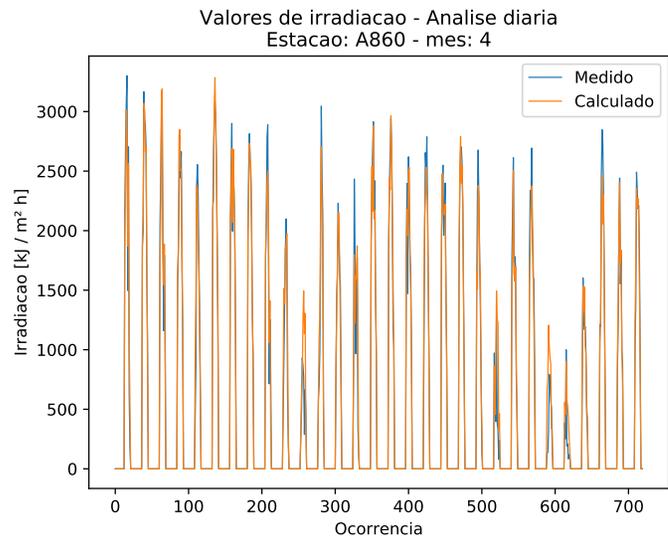


(d) Melhor ajuste mensal

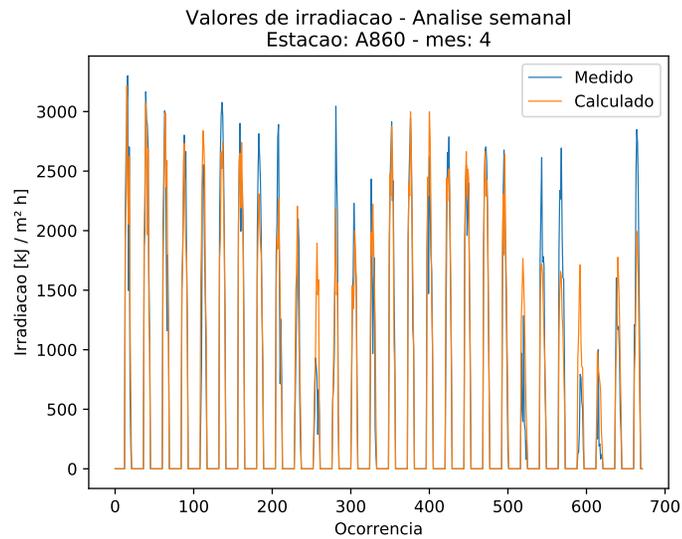
**Figura E.1:** Análises para a estação A860 para o mês de fevereiro de 2016.

**Tabela E.2:** Parâmetros de melhor ajuste por período para o mês de abril de 2016 na estação A860.

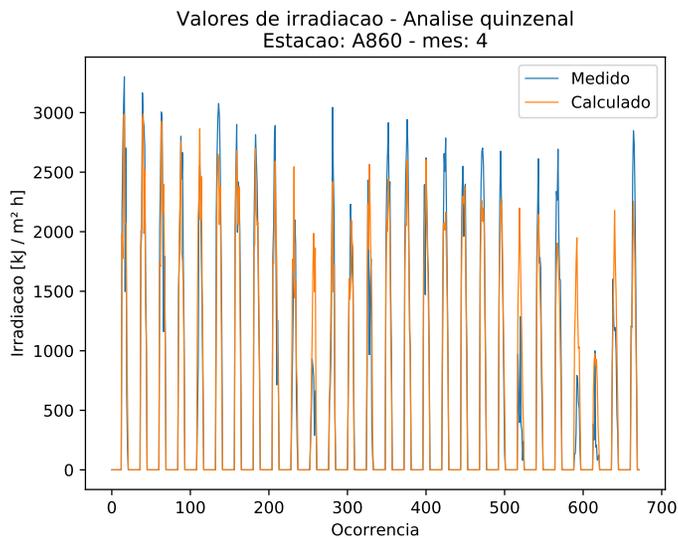
Período	Dias	Classes	Tolerância nos limites [%]	Coef. $p$ PageRank	Nível	GPI ( $\times 10^{-4}$ )
Mensal						
0	1	5	10	0.95	2	808.995
Quinzenal						
1	1	5	10	0.95	2	666.919
2	1	7	0	0.75	3	899.511
Semanal						
1	1	6	-5	0.85	3	789.213
2	1	5	5	0.85	2	502.203
3	1	5	5	0.95	3	1165.515
4	1	8	0	0.75	2	674.913
Diário						
1	1	9	10	0.95	2	1089.639
2	5	7	10	0.85	3	1592.264
3	10	5	5	0.95	3	1335.513
4	2	7	0	0.95	2	1113.519
5	5	5	5	0.95	1	658.413
6	1	6	0	0.95	3	1618.887
7	1	10	5	0.95	3	1567.804
8	2	15	0	0.95	3	1463.365
9	10	5	5	0.95	2	1006.172
10	5	6	5	0.95	1	733.886
11	1	5	5	0.85	1	828.843
12	1	7	-5	0.95	3	1145.557
13	5	6	5	0.85	2	1058.715
14	2	5	5	0.95	1	649.182
15	1	7	10	0.95	3	1445.982
16	1	5	0	0.85	3	1490.081
17	2	15	0	0.95	3	1229.583
18	2	6	5	0.85	3	1128.95
19	2	6	-10	0.95	3	1537.588
20	1	5	10	0.95	3	1738.589
21	10	8	5	0.95	3	921.196
22	5	9	-10	0.95	1	786.647
23	5	7	0	0.95	3	1214.107
24	10	5	10	0.65	3	1313.681
25	2	7	-10	0.95	1	670.028
26	1	5	5	0.95	1	1334.091
27	10	6	5	0.95	1	869.23
28	1	6	-5	0.95	3	1245.675
29	5	20	5	0.95	2	1211.124
30	1	8	5	0.95	2	1343.677



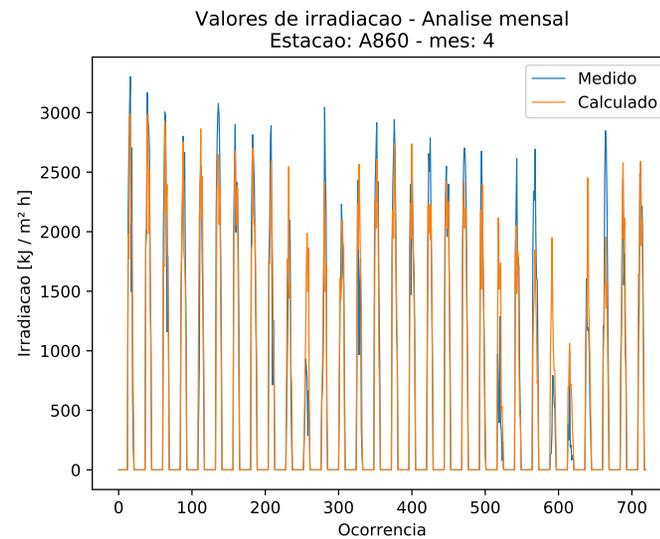
(a) Melhores ajustes diários.



(b) Melhores ajustes semanais.



(c) Melhores ajustes quinzenais.

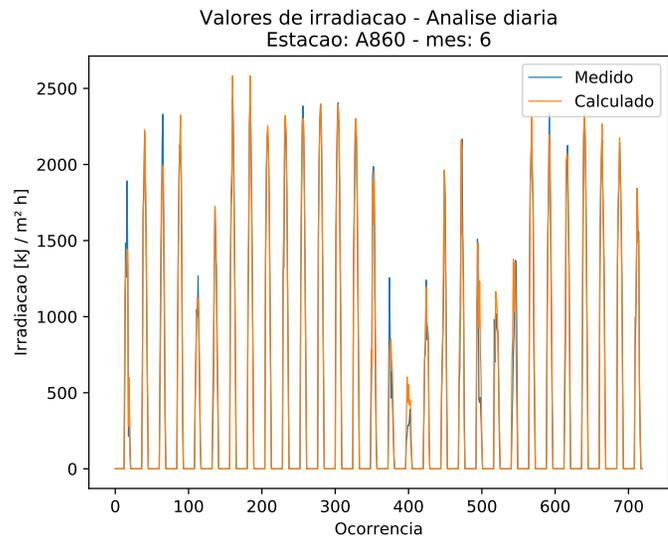


(d) Melhor ajuste mensal

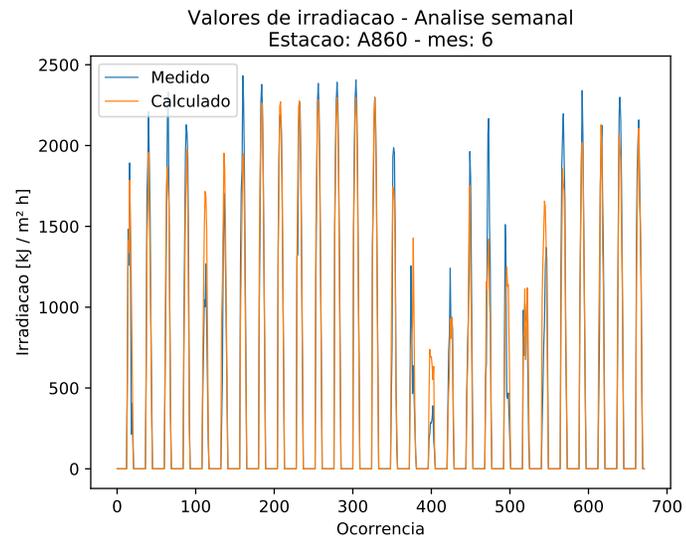
**Figura E.2:** Análises para a estação A860 para o mês de abril de 2016.

**Tabela E.3:** Parâmetros de melhor ajuste por período para o mês de junho de 2016 na estação A860.

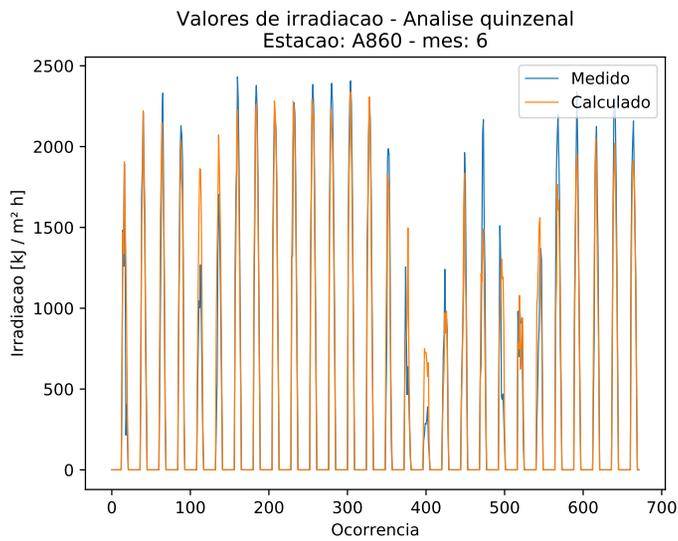
Período	Dias	Classes	Tolerância nos limites [%]	Coef. $p$ PageRank	Nível	GPI ( $\times 10^{-4}$ )
Mensal						
0	1	5	0	0.85	2	801.791
Quinzenal						
1	1	5	-5	0.75	3	889.256
2	1	5	10	0.85	2	718.285
Semanal						
1	1	7	0	0.75	3	650.778
2	1	5	0	0.75	3	1509.412
3	1	5	5	0.85	2	636.203
4	1	7	5	0.85	3	730.825
Diário						
1	10	7	0	0.95	1	827.66
2	1	5	0	0.85	3	1661.791
3	1	5	0	0.85	2	1263.926
4	1	5	0	0.85	3	1649.563
5	1	10	-10	0.65	1	1157.416
6	1	5	5	0.95	1	915.582
7	1	5	10	0.95	3	1684.823
8	2	5	10	0.95	3	1645.783
9	2	5	5	0.85	3	1718.699
10	1	6	5	0.95	3	1427.24
11	1	10	0	0.95	3	1624.334
12	1	8	0	0.95	3	1947.255
13	1	5	5	0.95	3	1944.981
14	1	5	0	0.75	3	1798.385
15	2	8	-10	0.95	3	866.866
16	1	6	5	0.95	1	919.926
17	1	20	-10	0.65	1	937.376
18	2	7	10	0.75	1	1009.39
19	1	6	5	0.85	3	1317.682
20	2	6	0	0.95	3	904.003
21	10	5	5	0.85	1	726.853
22	2	7	-10	0.75	1	772.361
23	1	6	10	0.85	1	576.838
24	5	5	0	0.95	3	1455.93
25	2	7	10	0.95	2	1376.898
26	1	8	0	0.95	2	1227.131
27	2	5	5	0.95	3	1475.973
28	1	6	10	0.85	3	1613.291
29	1	5	0	0.85	3	1760.946
30	10	10	0	0.95	2	900.421



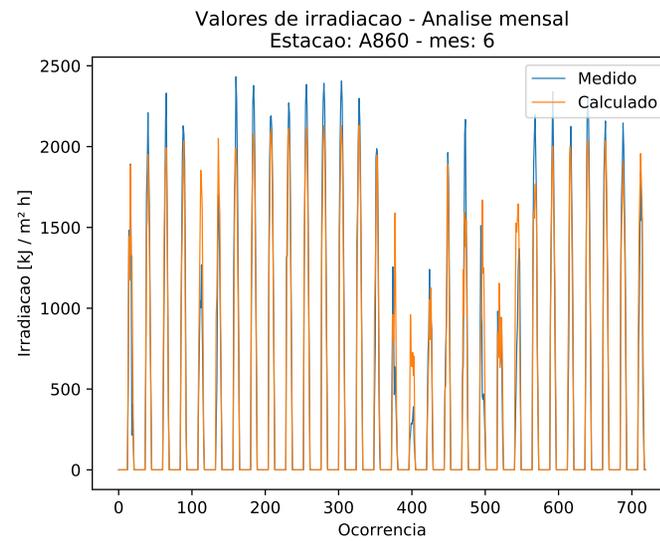
(a) Melhores ajustes diários.



(b) Melhores ajustes semanais.



(c) Melhores ajustes quinzenais.

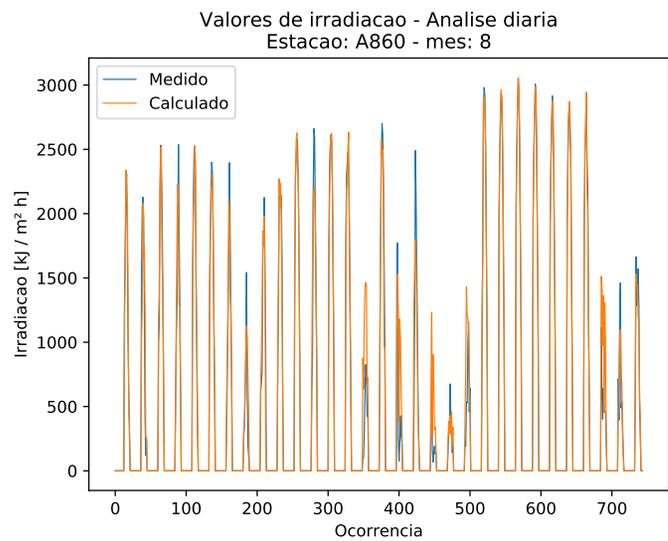


(d) Melhor ajuste mensal

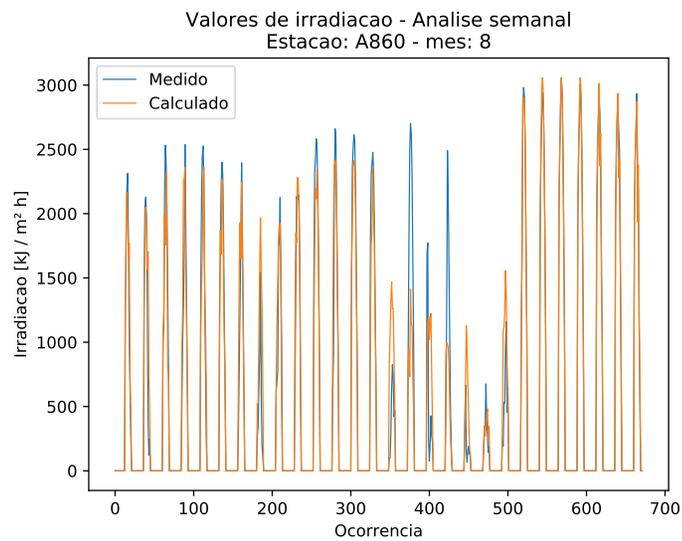
**Figura E.3:** Análises para a estação A860 para o mês de junho de 2016.

**Tabela E.4:** Parâmetros de melhor ajuste por período para o mês de agosto de 2016 na estação A860.

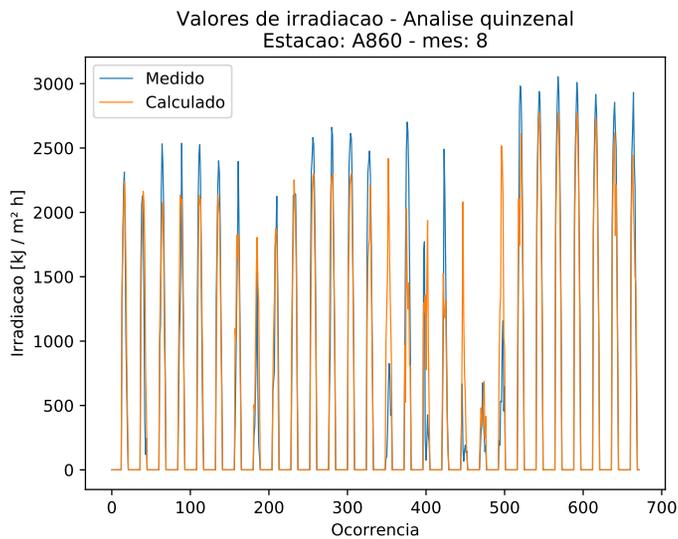
Período	Dias	Classes	Tolerância nos limites [%]	Coef. $p$ PageRank	Nível	GPI ( $\times 10^{-4}$ )
Mensal						
0	1	10	5	0.95	2	748.114
Quinzenal						
1	1	5	0	0.85	2	742.259
2	1	10	0	0.95	2	861.119
Semanal						
1	1	5	10	0.95	2	640.727
2	1	7	0	0.85	3	839.903
3	1	8	-10	0.75	1	510.597
4	1	7	10	0.95	3	1611.791
Diário						
1	10	5	-10	0.95	2	920.625
2	10	5	-10	0.95	1	620.741
3	10	10	10	0.95	2	1307.199
4	5	10	0	0.95	2	773.392
5	10	8	0	0.95	3	1266.761
6	10	5	10	0.65	3	1577.806
7	2	9	0	0.95	1	903.811
8	1	20	-10	0.65	1	831.058
9	1	6	10	0.95	2	993.393
10	2	6	5	0.85	3	1402.242
11	2	5	5	0.95	3	1758.347
12	1	8	0	0.95	1	973.509
13	1	5	0	0.85	3	1760.302
14	10	5	0	0.75	3	1494.901
15	2	9	5	0.95	1	718.68
16	10	20	5	0.95	3	1363.28
17	1	5	-10	0.95	1	1405.758
18	1	5	10	0.65	3	474.479
19	2	6	5	0.95	1	1275.498
20	1	6	5	0.85	1	1353.22
21	1	6	-10	0.65	1	905.392
22	1	7	10	0.95	3	1611.951
23	1	5	-5	0.95	2	1928.646
24	1	7	10	0.95	3	1944.927
25	1	9	0	0.95	3	1917.329
26	1	7	5	0.95	3	1899.22
27	1	5	0	0.85	3	1804.595
28	1	7	0	0.95	3	1392.899
29	2	5	-5	0.85	1	896.343
30	1	6	5	0.95	1	1203.621
31	5	5	10	0.85	1	867.519



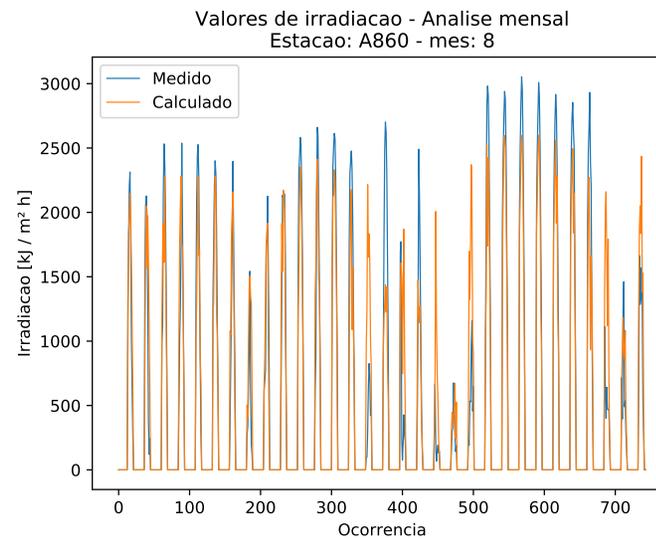
(a) Melhores ajustes diários.



(b) Melhores ajustes semanais.



(c) Melhores ajustes quinzenais.

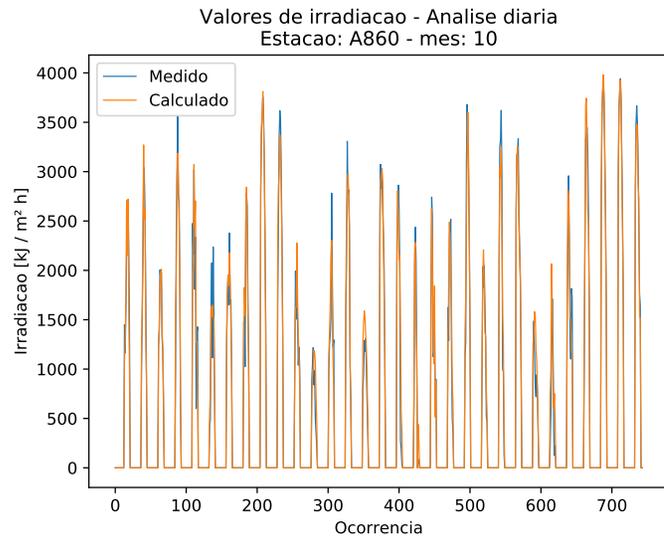


(d) Melhor ajuste mensal

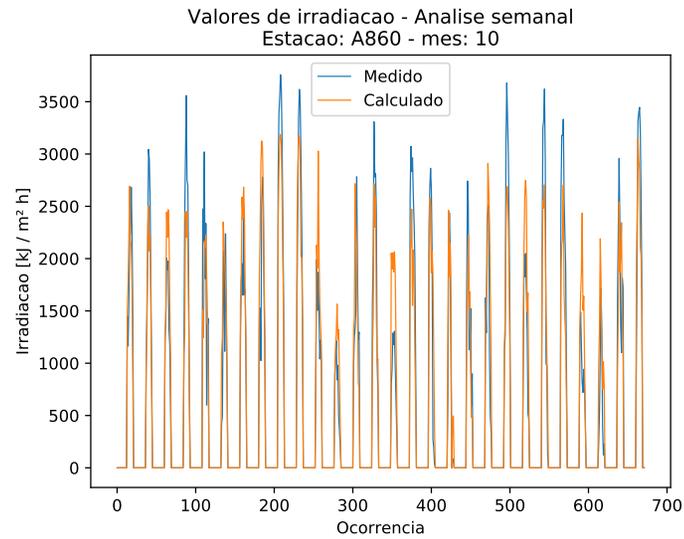
**Figura E.4:** Análises para a estação A860 para o mês de agosto de 2016.

**Tabela E.5:** Parâmetros de melhor ajuste por período para o mês de outubro de 2016 na estação A860.

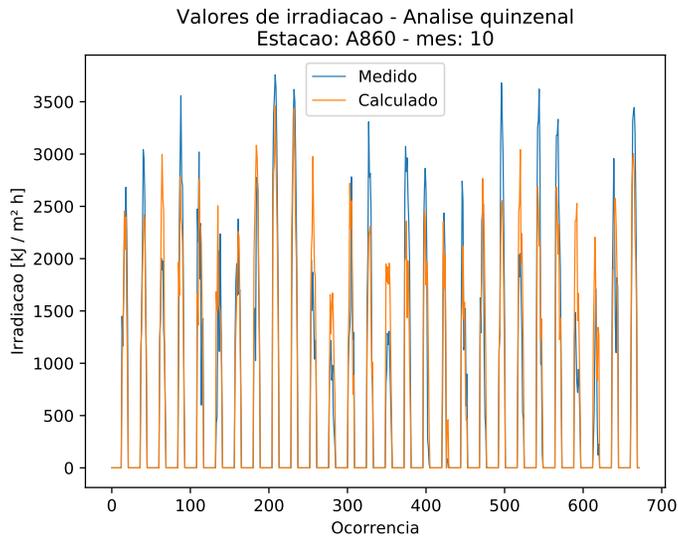
Período	Dias	Classes	Tolerância nos limites [%]	Coef. $p$ PageRank	Nível	GPI ( $\times 10^{-4}$ )
Mensal						
0	1	15	10	0.95	2	591.779
Quinzenal						
1	1	7	-5	0.85	3	546.186
2	1	15	10	0.95	1	450.855
Semanal						
1	2	7	0	0.85	2	449.863
2	1	7	-10	0.95	2	912.28
3	1	15	10	0.95	2	494.462
4	1	5	5	0.85	2	565.65
Diário						
1	1	8	10	0.95	3	1034.285
2	2	7	5	0.95	3	1113.408
3	5	6	10	0.65	1	960.926
4	5	15	-5	0.95	3	1100.654
5	10	7	5	0.95	2	1158.982
6	2	5	0	0.95	1	1080.957
7	2	7	-10	0.75	1	964.081
8	5	10	10	0.95	1	976.023
9	1	7	0	0.95	3	1948.322
10	1	15	0	0.95	3	1240.484
11	1	7	-10	0.85	1	926.316
12	1	7	-10	0.85	1	957.525
13	2	5	10	0.85	2	758.413
14	5	15	10	0.95	3	1147.758
15	1	20	-10	0.65	1	810.652
16	10	5	0	0.75	3	1543.911
17	10	10	-5	0.95	1	681.663
18	1	6	5	0.95	1	909.328
19	5	5	-10	0.95	1	1169.873
20	10	20	-10	0.85	1	547.195
21	1	5	-5	0.95	3	1511.452
22	5	9	-10	0.75	1	886.284
23	1	5	10	0.95	2	1116.263
24	10	5	5	0.65	3	1335.246
25	1	6	-10	0.65	1	966.943
26	1	5	5	0.95	1	963.663
27	10	5	-5	0.85	1	811.975
28	1	5	-5	0.95	2	1495.136
29	1	5	0	0.85	3	1883.984
30	1	8	0	0.95	3	1895.558
31	5	9	10	0.85	3	1319.286



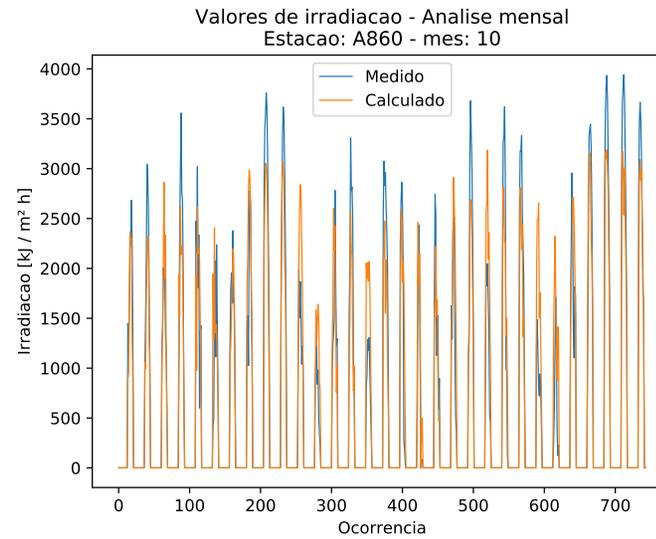
(a) Melhores ajustes diários.



(b) Melhores ajustes semanais.



(c) Melhores ajustes quinzenais.

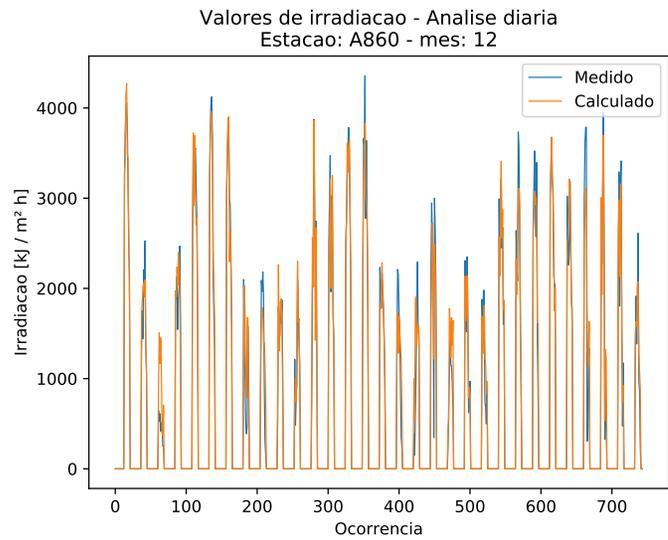


(d) Melhor ajuste mensal

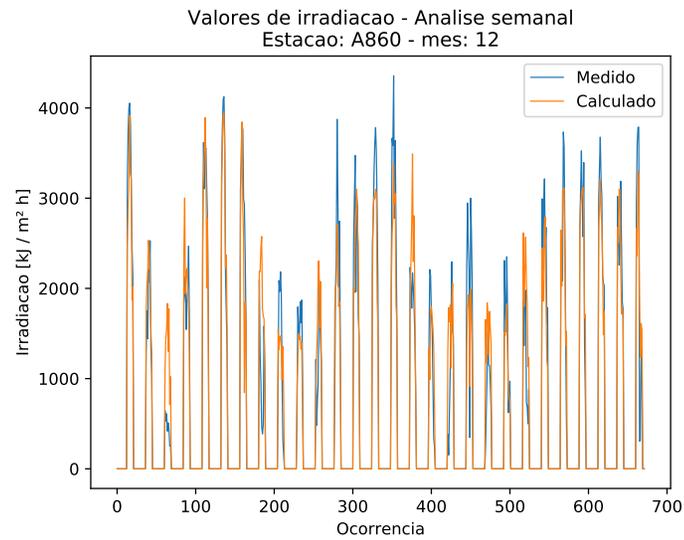
**Figura E.5:** Análises para a estação A860 para o mês de outubro de 2016.

**Tabela E.6:** Parâmetros de melhor ajuste por período para o mês de dezembro de 2016 na estação A860.

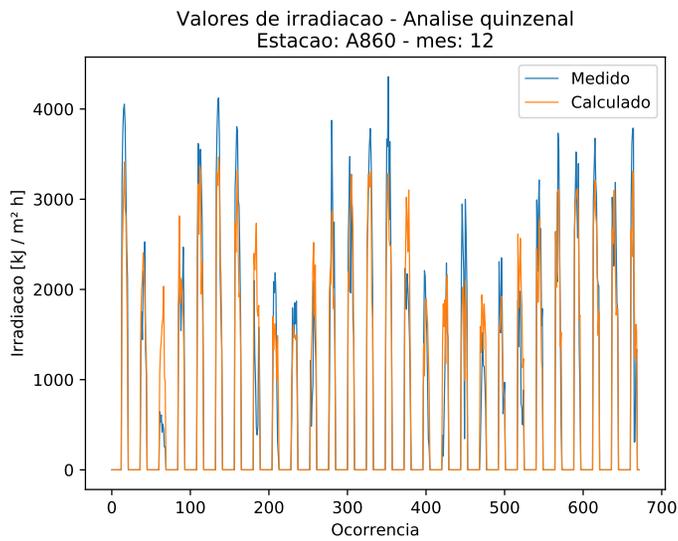
Período	Dias	Classes	Tolerância nos limites [%]	Coef. $p$ PageRank	Nível	GPI ( $\times 10^{-4}$ )
Mensal						
0	1	5	-5	0.85	2	743.634
Quinzenal						
1	1	5	-5	0.85	2	930.454
2	1	5	0	0.85	2	679.766
Semanal						
1	1	5	0	0.95	2	1207.734
2	1	5	-5	0.75	2	661.22
3	1	5	-5	0.85	2	505.563
4	1	5	0	0.85	2	793.366
Diário						
1	1	6	0	0.95	3	1728.351
2	2	5	0	0.75	1	839.654
3	1	5	10	0.95	1	939.622
4	5	7	5	0.95	2	1220.972
5	1	5	10	0.85	3	1530.148
6	1	6	-10	0.95	3	1500.434
7	1	10	10	0.95	3	1492.379
8	5	6	5	0.95	1	1160.097
9	2	20	-10	0.65	1	497.262
10	10	5	5	0.85	1	882.885
11	1	6	5	0.95	1	1512.745
12	10	10	10	0.95	3	1393.219
13	2	15	10	0.95	3	1356.731
14	1	6	5	0.95	3	1712.905
15	1	5	0	0.85	3	1468.91
16	10	20	-5	0.65	1	803.186
17	1	9	-10	0.85	3	620.44
18	2	9	-5	0.95	1	1287.04
19	1	5	0	0.95	3	1125.433
20	2	8	0	0.95	1	850.904
21	1	10	10	0.95	3	1095.838
22	1	6	-10	0.65	1	966.184
23	5	5	10	0.85	3	1582.144
24	1	6	-10	0.95	2	956.778
25	1	6	0	0.65	3	896.873
26	1	5	0	0.85	3	1586.882
27	10	5	10	0.75	3	1376.991
28	2	9	0	0.95	1	749.41
29	2	6	-5	0.95	2	1110.519
30	1	9	10	0.95	3	1324.985
31	2	15	-10	0.65	1	701.311



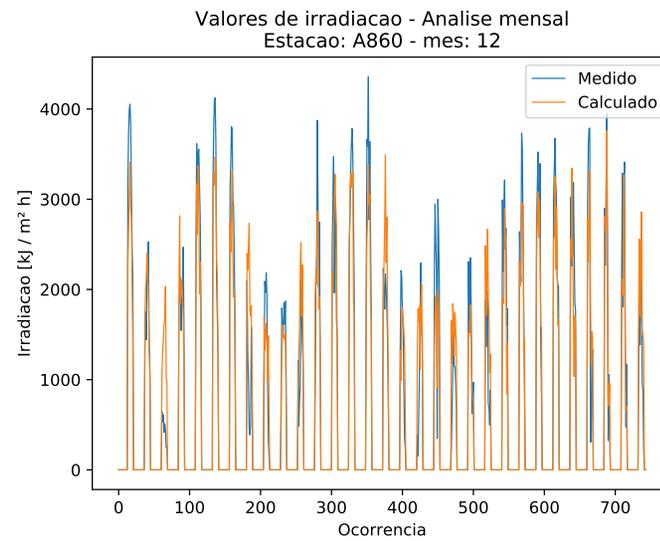
(a) Melhores ajustes diários.



(b) Melhores ajustes semanais.



(c) Melhores ajustes quinzenais.



(d) Melhor ajuste mensal

**Figura E.6:** Análises para a estação A860 para o mês de dezembro de 2016.



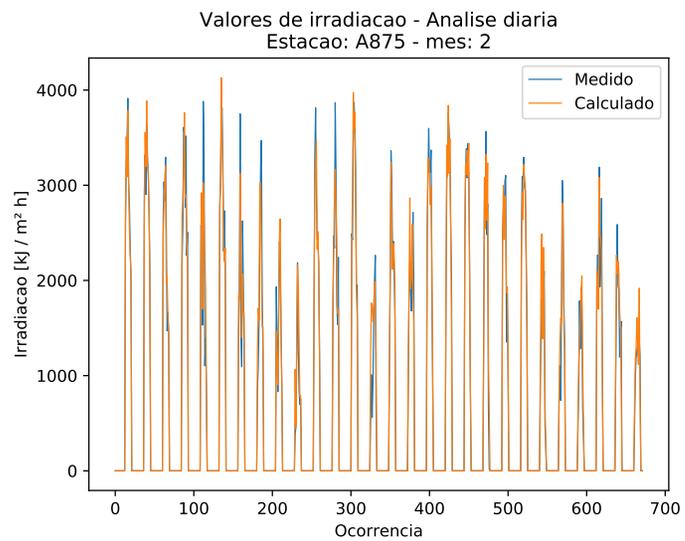
# Apêndice F

## Resultados para a estação A875

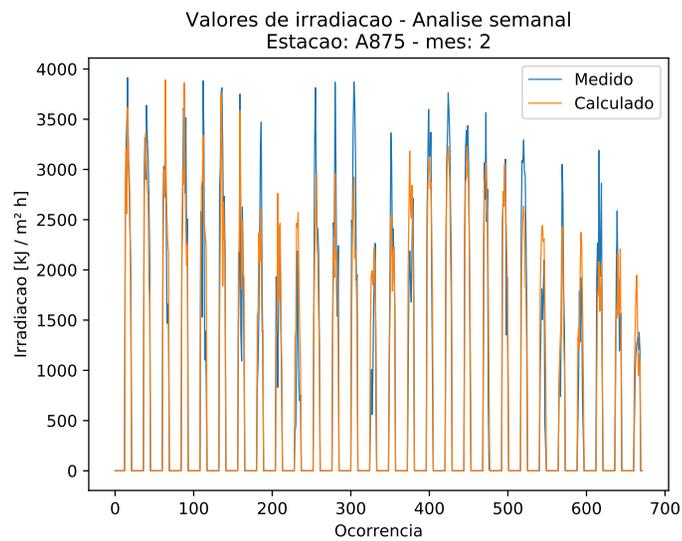
Tabelas com os parâmetros de melhor ajuste dos dados estimados aos dado efetivamente registados, bem como os gráficos com os referidos valores para a estação A875 para os meses de fevereiro, abril, junho, agosto outubro e dezembro do ano de 2012. Para os gráficos referentes aos meses com mais de 28 dias valem as explicações do Apêncide A na Página 75.

**Tabela F.1:** Parâmetros de melhor ajuste por período para o mês de fevereiro de 2012 na estação A875.

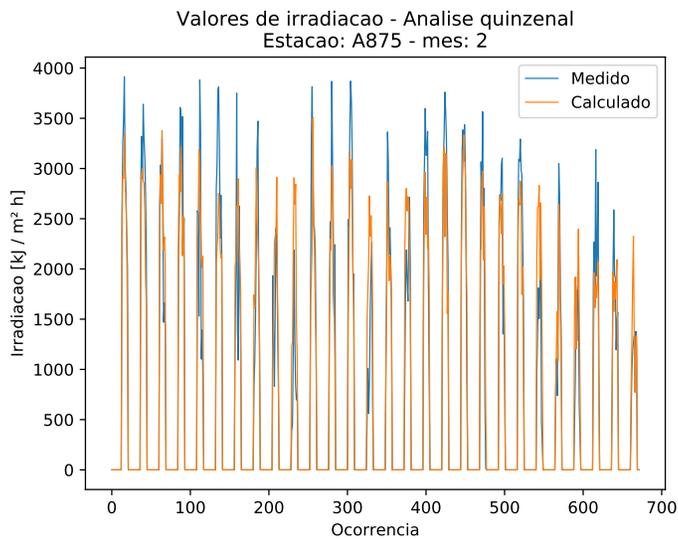
Período	Dias	Classes	Tolerância nos limites [%]	Coef. $p$ PageRank	Nível	GPI ( $\times 10^{-4}$ )
Mensal						
0	1	6	5	0.65	3	763.048
Quinzenal						
1	2	5	0	0.85	2	607.494
2	1	10	0	0.95	2	773.02
Semanal						
1	2	10	10	0.95	3	666.136
2	2	7	-10	0.85	2	474.633
3	1	5	5	0.65	3	932.414
4	1	5	0	0.75	2	363.078
Diário						
1	5	7	10	0.95	3	1579.126
2	1	6	-5	0.95	3	1659.464
3	1	10	-5	0.95	2	966.633
4	2	5	10	0.65	3	1395.223
5	10	10	-5	0.95	3	704.451
6	1	5	0	0.95	3	1550.611
7	2	10	10	0.95	1	1048.655
8	5	6	5	0.95	2	762.487
9	1	9	5	0.95	1	1302.691
10	1	5	10	0.95	1	943.55
11	5	5	-5	0.95	3	1328.885
12	1	5	0	0.65	2	888.103
13	2	6	0	0.95	3	1389.901
14	2	7	-10	0.85	1	916.586
15	1	8	0	0.95	3	1309.953
16	2	7	5	0.95	1	958.82
17	5	5	0	0.95	3	1326.003
18	2	6	0	0.95	3	1413.319
19	5	6	10	0.95	3	1590.121
20	10	5	-10	0.95	3	871.137
21	10	9	10	0.95	3	1116.857
22	5	5	10	0.75	3	1423.551
23	10	6	10	0.95	1	862.332
24	1	5	0	0.75	3	1195.931
25	2	5	0	0.85	1	851.781
26	5	7	-5	0.95	2	1166.995
27	10	10	-10	0.75	1	753.506
28	2	15	-10	0.95	1	1001.338



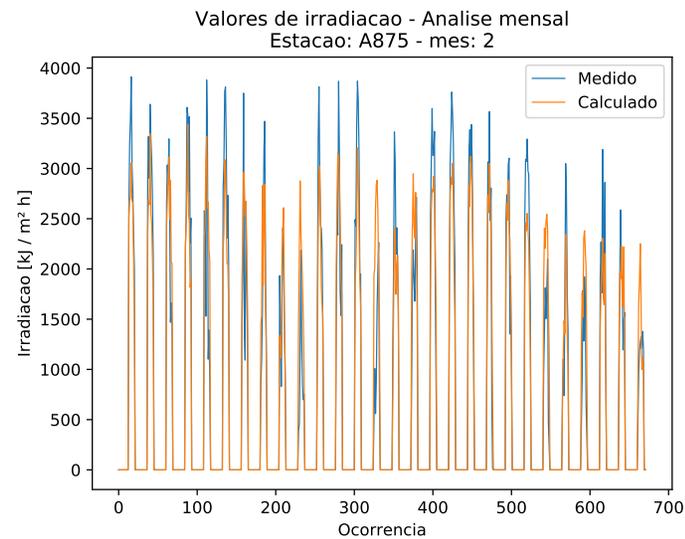
(a) Melhores ajustes diários.



(b) Melhores ajustes semanais.



(c) Melhores ajustes quinzenais.

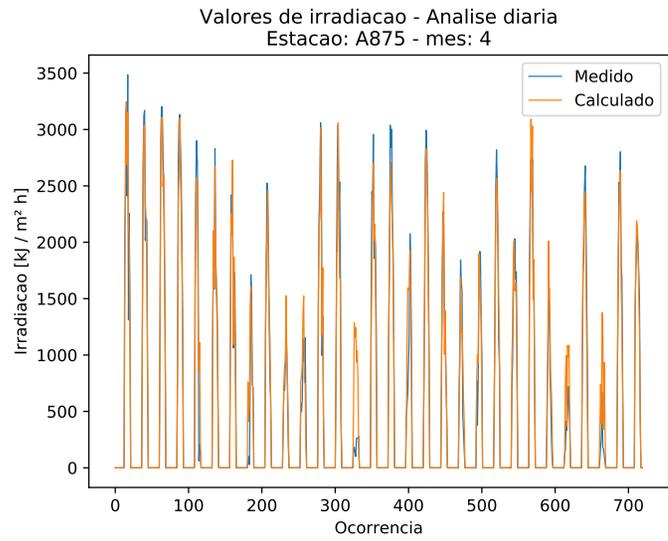


(d) Melhor ajuste mensal

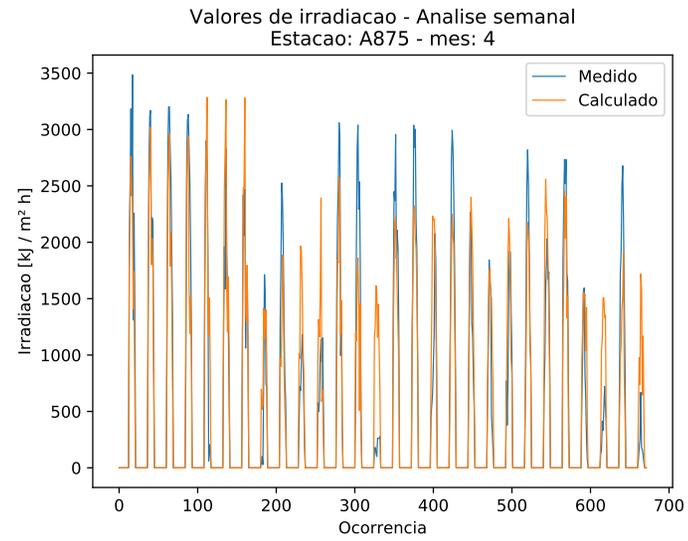
**Figura F.1:** Análises para a estação A875 para o mês de fevereiro de 2012.

**Tabela F.2:** Parâmetros de melhor ajuste por período para o mês de abril de 2012 na estação A875.

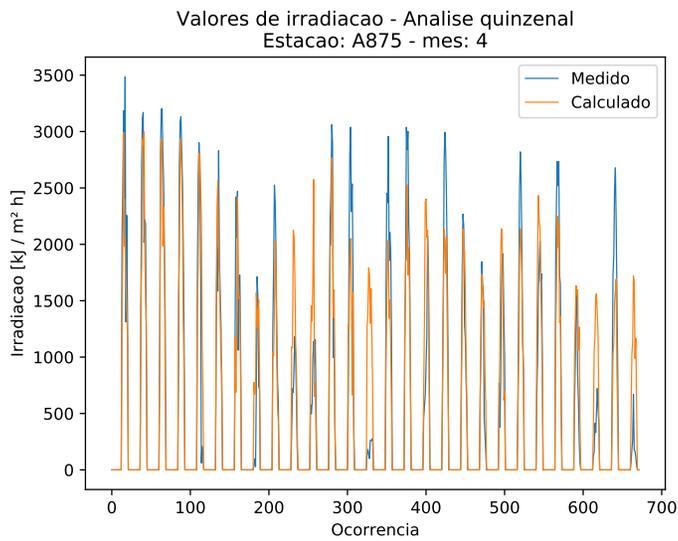
Período	Dias	Classes	Tolerância nos limites [%]	Coef. $p$ PageRank	Nível	GPI ( $\times 10^{-4}$ )
Mensal						
0	1	15	5	0.95	3	517.3
Quinzenal						
1	1	9	0	0.95	2	526.126
2	1	5	10	0.85	2	552.31
Semanal						
1	10	9	-5	0.95	3	627.082
2	1	9	0	0.95	1	514.201
3	1	6	5	0.65	3	579.079
4	1	5	10	0.95	2	406.28
Diário						
1	1	5	5	0.95	3	963.561
2	5	8	-10	0.85	3	1292.812
3	1	5	10	0.85	3	1609.645
4	5	6	0	0.95	3	1256.494
5	10	5	-10	0.95	1	781.238
6	5	5	0	0.85	2	1253.876
7	10	9	-10	0.95	2	1223.69
8	2	5	-10	0.95	1	1376.63
9	5	7	10	0.85	3	1085.896
10	2	5	5	0.95	1	1018.78
11	1	5	5	0.95	1	912.527
12	1	8	0	0.95	3	1294.421
13	5	5	10	0.95	3	969.242
14	1	5	5	0.95	1	603.461
15	2	5	10	0.65	3	1201.536
16	1	5	10	0.65	3	1324.415
17	1	6	5	0.95	1	1175.898
18	1	9	10	0.95	3	1431.808
19	10	6	5	0.95	2	1129.668
20	1	5	5	0.95	1	633.601
21	5	8	-5	0.95	2	746.269
22	1	5	10	0.95	3	1259.97
23	10	20	5	0.85	3	794.903
24	1	5	0	0.95	3	1547.214
25	5	5	5	0.95	1	729.381
26	1	5	5	0.95	1	1450.029
27	5	15	0	0.95	3	1003.089
28	1	5	10	0.95	1	652.249
29	2	6	10	0.85	3	1313.45
30	5	6	0	0.85	3	1175.028



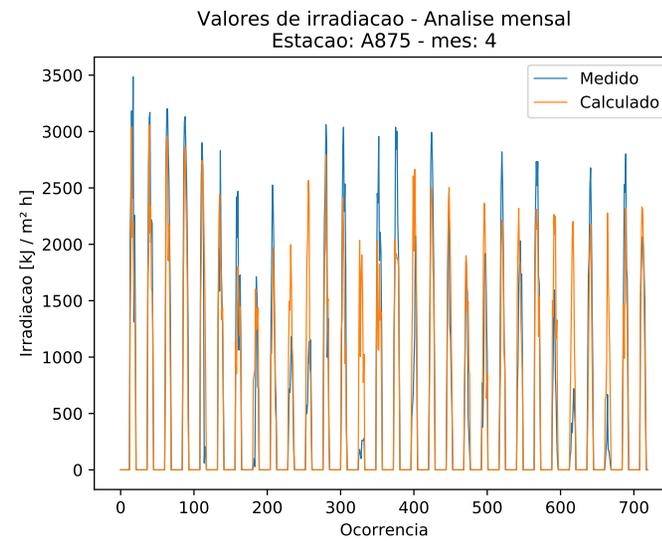
(a) Melhores ajustes diários.



(b) Melhores ajustes semanais.



(c) Melhores ajustes quinzenais.

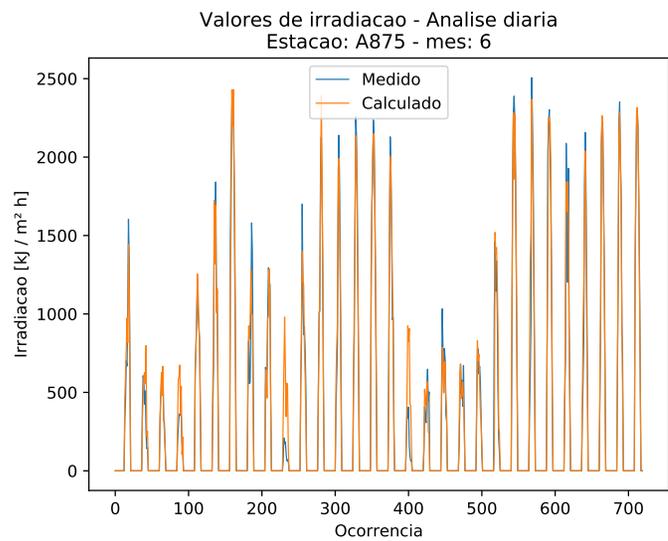


(d) Melhor ajuste mensal

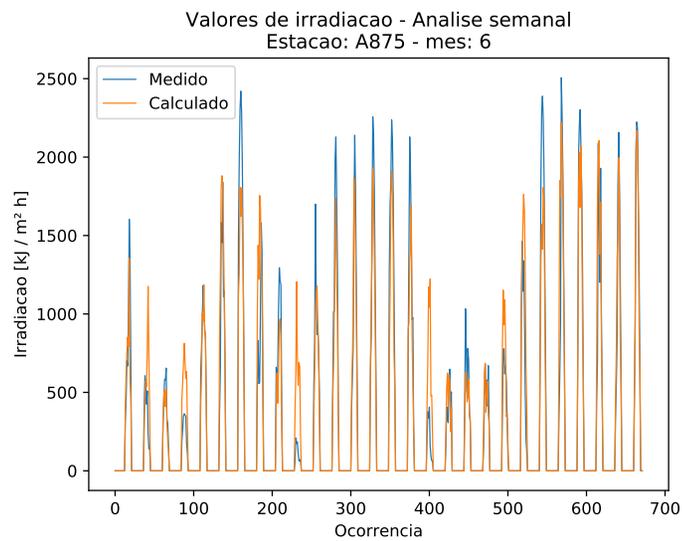
**Figura F.2:** Análises para a estação A875 para o mês de abril de 2012.

**Tabela F.3:** Parâmetros de melhor ajuste por período para o mês de junho de 2012 na estação A875.

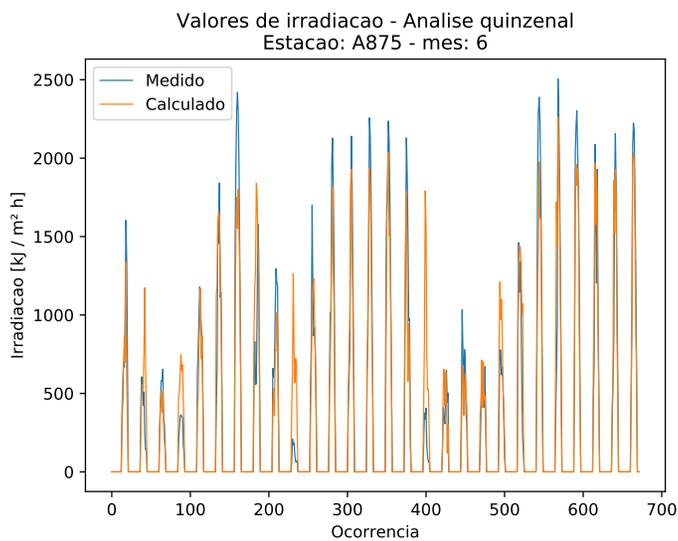
Período	Dias	Classes	Tolerância nos limites [%]	Coef. $p$ PageRank	Nível	GPI ( $\times 10^{-4}$ )
Mensal						
0	1	6	0	0.85	2	764.007
Quinzenal						
1	1	7	10	0.85	2	694.66
2	1	6	5	0.95	2	758.331
Semanal						
1	1	7	-10	0.85	3	627.299
2	1	7	5	0.85	2	668.171
3	1	9	10	0.95	1	805.905
4	1	8	0	0.95	2	721.487
Diário						
1	1	8	0	0.95	2	1427.09
2	2	6	-10	0.85	1	874.36
3	1	5	10	0.95	3	1263.018
4	2	5	5	0.95	1	928.045
5	2	7	-10	0.85	1	958.031
6	2	8	5	0.95	1	1253.257
7	1	5	-5	0.95	3	1558.485
8	5	20	5	0.95	1	1110.239
9	1	5	0	0.85	3	826.068
10	1	5	-10	0.85	1	760.968
11	10	20	-10	0.85	1	821.044
12	1	5	-5	0.95	3	1444.946
13	1	9	5	0.95	2	1182.182
14	1	8	-10	0.95	3	1430.236
15	1	5	0	0.85	3	1625.852
16	5	6	0	0.95	3	1135.457
17	1	5	5	0.85	1	678.159
18	1	6	-5	0.95	1	1704.446
19	1	8	0	0.95	3	917.027
20	1	7	-5	0.95	1	1114.152
21	1	5	-10	0.75	1	1189.153
22	10	6	0	0.95	1	548.78
23	1	7	0	0.95	3	1464.668
24	1	6	10	0.95	2	834.315
25	2	5	10	0.85	3	1557.611
26	2	6	10	0.95	1	816.559
27	1	6	0	0.95	2	1163.355
28	1	9	10	0.95	3	1654.907
29	2	7	10	0.95	2	1363.313
30	1	9	0	0.95	3	1805.971



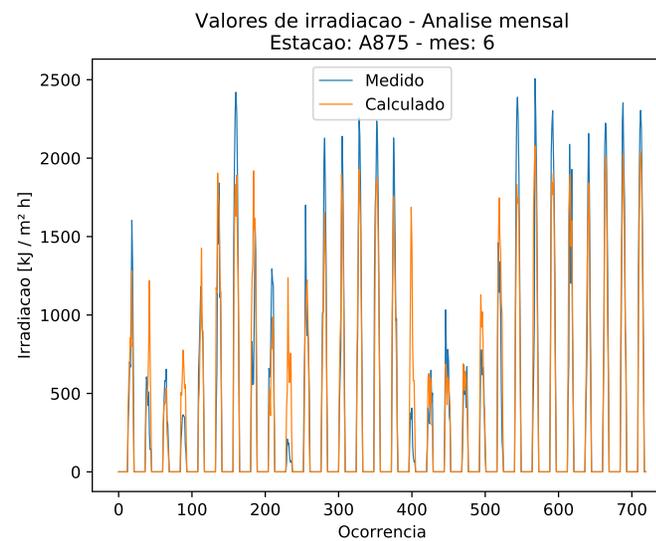
(a) Melhores ajustes diários.



(b) Melhores ajustes semanais.



(c) Melhores ajustes quinzenais.

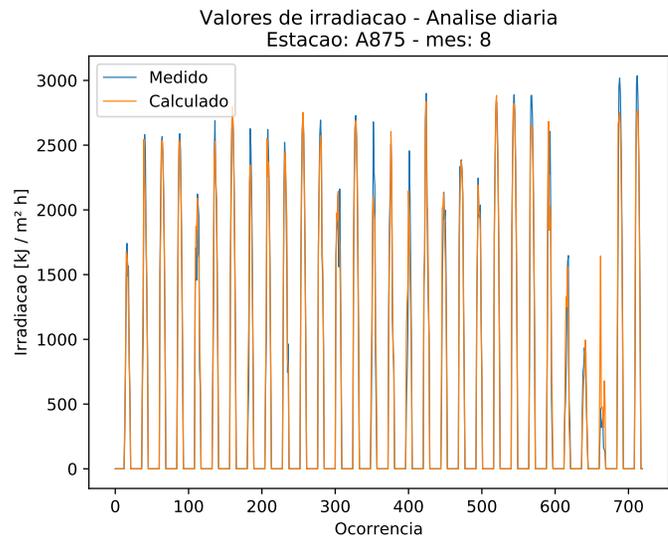


(d) Melhor ajuste mensal

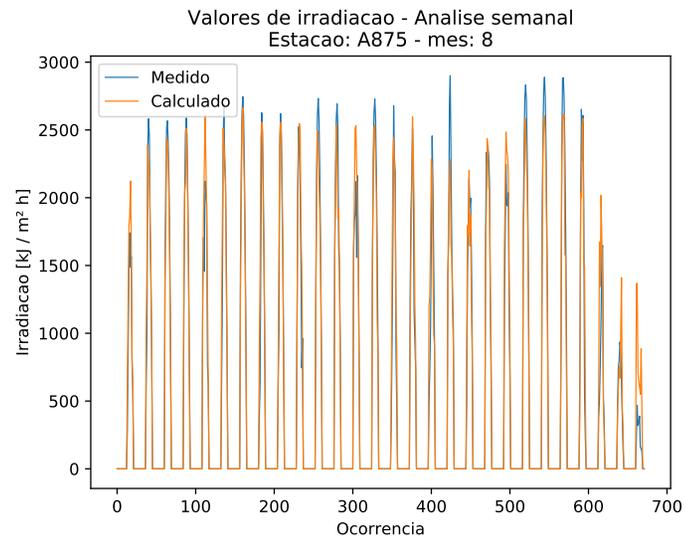
**Figura F.3:** Análises para a estação A875 para o mês de junho de 2012.

**Tabela F.4:** Parâmetros de melhor ajuste por período para o mês de agosto de 2012 na estação A875.

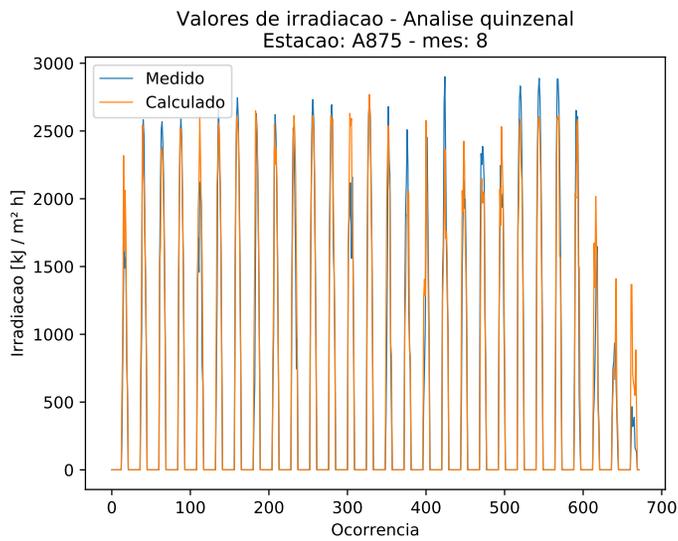
Período	Dias	Classes	Tolerância nos limites [%]	Coef. $p$ PageRank	Nível	GPI ( $\times 10^{-4}$ )
Mensal						
0	1	7	0	0.95	2	955.879
Quinzenal						
1	1	5	0	0.95	2	984.542
2	1	7	-5	0.95	2	832.983
Semanal						
1	1	5	5	0.85	3	1191.965
2	2	6	0	0.95	2	901.889
3	2	9	0	0.95	2	616.686
4	1	7	-5	0.95	2	949.354
Diário						
1	1	5	10	0.65	2	1045.787
2	1	5	0	0.95	2	1338.031
3	1	5	0	0.85	3	1776.918
4	2	8	5	0.95	3	1633.348
5	10	7	10	0.75	3	814.641
6	2	9	0	0.95	2	1314.469
7	1	5	5	0.95	3	1879.183
8	2	8	0	0.95	1	1035.091
9	1	5	0	0.95	2	1364.306
10	10	15	-5	0.95	3	1102.173
11	2	5	0	0.85	3	1640.44
12	1	6	-10	0.95	3	1602.702
13	10	5	-5	0.95	1	935.603
14	10	5	0	0.85	3	1654.71
15	2	20	10	0.95	1	777.753
16	1	5	-10	0.95	2	934.476
17	1	8	-5	0.85	2	475.872
18	1	8	0	0.95	3	1261.37
19	10	15	-5	0.95	1	846.291
20	1	5	5	0.95	3	1357.487
21	1	5	5	0.75	2	1102.361
22	1	5	0	0.85	3	1850.511
23	1	8	0	0.95	3	1933.394
24	1	5	0	0.95	2	1263.501
25	5	7	-10	0.95	3	928.538
26	1	5	10	0.65	1	874.343
27	1	5	5	0.95	2	1208.067
28	1	5	-10	0.75	1	771.955
30	1	5	10	0.95	2	1359.088
31	1	5	-5	0.95	2	1519.518



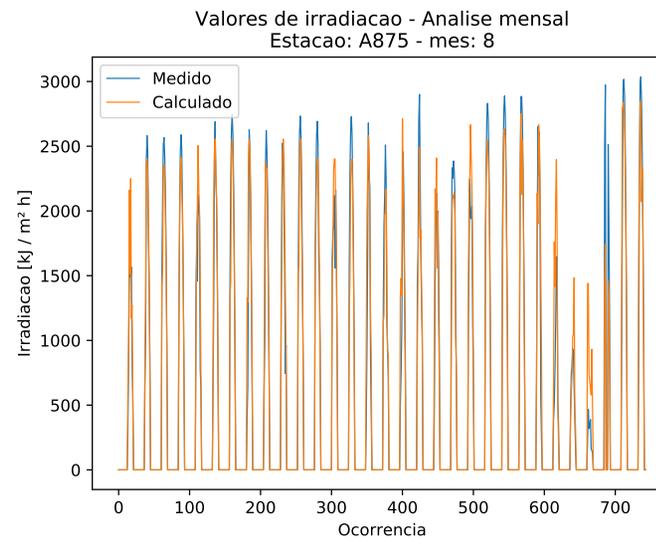
(a) Melhores ajustes diários.



(b) Melhores ajustes semanais.



(c) Melhores ajustes quinzenais.

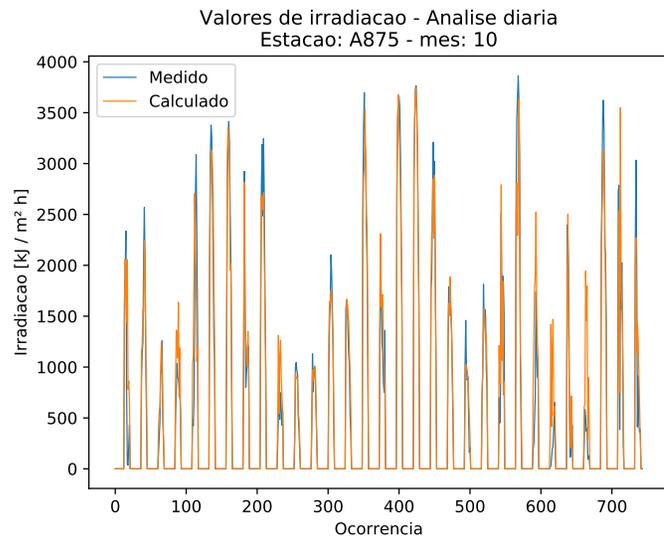


(d) Melhor ajuste mensal

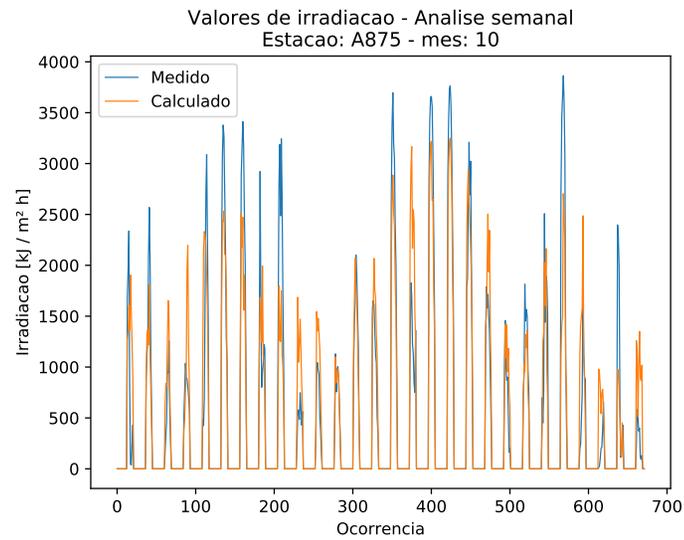
**Figura F.4:** Análises para a estação A875 para o mês de agosto de 2012.

**Tabela F.5:** Parâmetros de melhor ajuste por período para o mês de outubro de 2012 na estação A875.

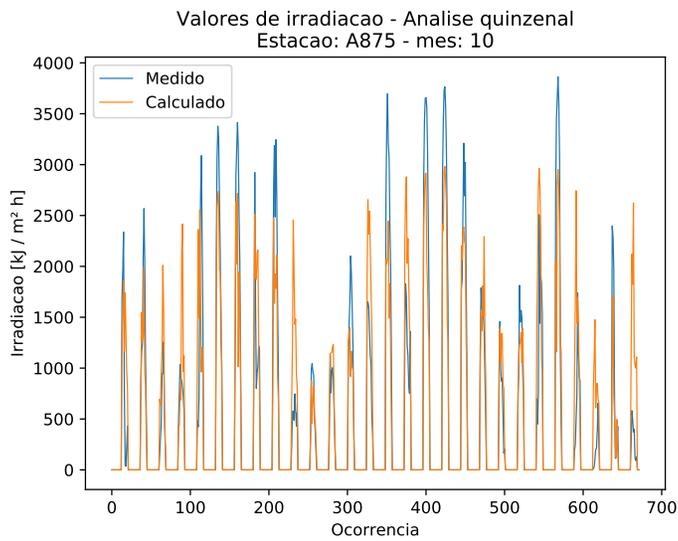
Período	Dias	Classes	Tolerância nos limites [%]	Coef. $p$ PageRank	Nível	GPI ( $\times 10^{-4}$ )
Mensal						
0	1	10	5	0.95	1	525.833
Quinzenal						
1	1	7	10	0.95	1	409.172
2	1	9	5	0.95	1	612.135
Semanal						
1	1	8	5	0.85	2	493.686
2	2	5	10	0.65	1	583.457
3	1	20	0	0.95	3	943.498
4	1	5	5	0.95	1	725.198
Diário						
1	10	5	5	0.85	1	758.66
2	2	6	10	0.95	3	857.054
3	1	20	-10	0.65	1	1261.33
4	5	7	-10	0.95	1	673.561
5	2	6	0	0.95	1	928.914
6	1	8	0	0.95	2	1279.846
7	1	5	0	0.95	2	1391.538
8	2	10	5	0.95	2	1390.812
9	10	6	0	0.65	3	1180.225
10	2	5	5	0.85	1	890.02
11	1	6	-10	0.95	2	1328.966
12	1	5	5	0.85	1	1048.042
13	1	5	0	0.85	3	897.731
14	2	6	-10	0.65	1	892.66
15	2	5	0	0.85	3	1364.292
16	10	6	5	0.85	1	825.842
17	1	5	0	0.85	3	1616.795
18	1	8	0	0.95	3	1876.252
19	5	9	0	0.95	3	1174.731
20	10	20	-5	0.85	1	960.894
21	1	7	-10	0.65	1	1042.426
22	1	6	-10	0.75	3	852.621
23	5	5	10	0.95	1	1404.971
24	10	5	-5	0.95	3	899.355
25	2	20	0	0.95	1	1256.628
26	5	5	10	0.95	1	878.789
27	1	5	0	0.95	3	1487.042
28	5	6	-10	0.95	1	583.492
29	10	5	10	0.65	3	1300.381
30	5	7	10	0.95	2	822.014
31	1	5	10	0.95	1	1169.659



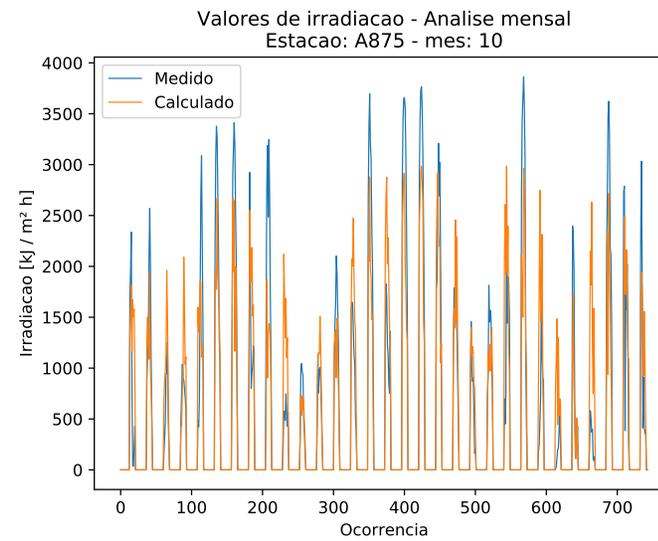
(a) Melhores ajustes diários.



(b) Melhores ajustes semanais.



(c) Melhores ajustes quinzenais.

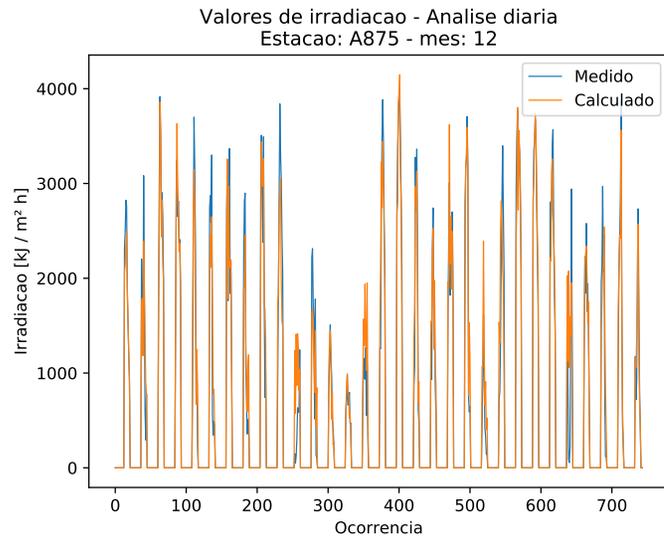


(d) Melhor ajuste mensal

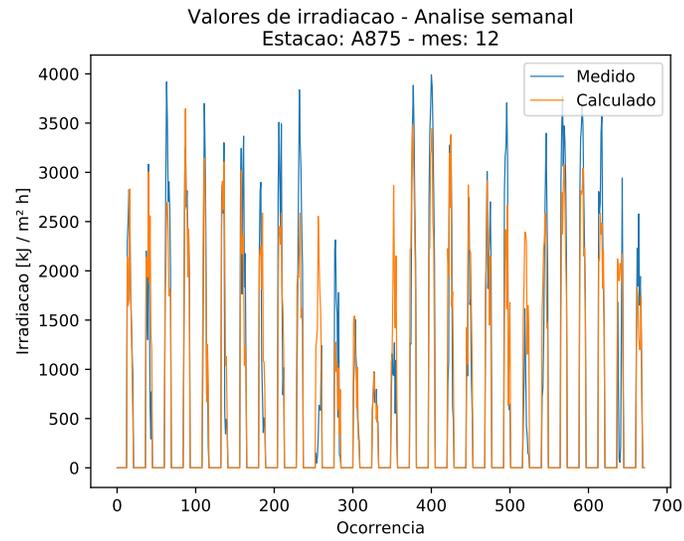
**Figura F.5:** Análises para a estação A875 para o mês de outubro de 2012.

**Tabela F.6:** Parâmetros de melhor ajuste por período para o mês de dezembro de 2012 na estação A875.

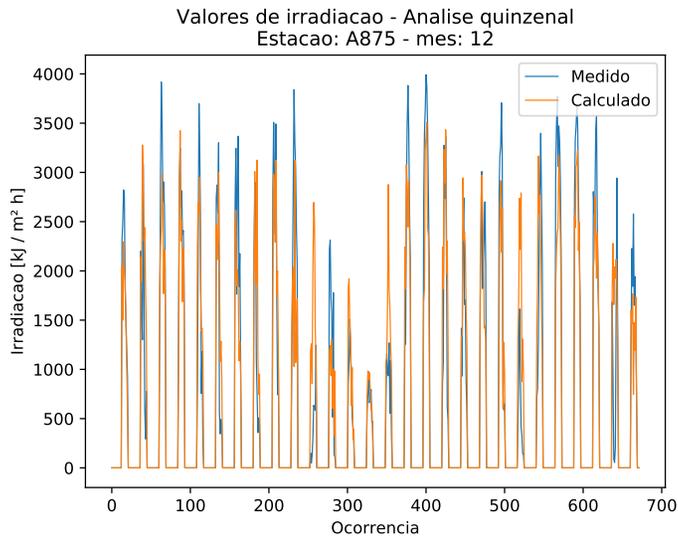
Período	Dias	Classes	Tolerância nos limites [%]	Coef. $p$ PageRank	Nível	GPI ( $\times 10^{-4}$ )
Mensal						
0	1	5	10	0.85	2	625.108
Quinzenal						
1	1	9	5	0.95	2	556.039
2	1	6	5	0.95	2	668.76
Semanal						
1	1	5	10	0.95	2	608.254
2	1	15	10	0.85	2	601.098
3	1	5	5	0.95	2	766.433
4	1	5	-5	0.75	2	743.756
Diário						
1	5	6	10	0.85	1	810.165
2	2	5	5	0.95	1	822.834
3	1	5	0	0.85	3	1494.593
4	1	5	5	0.85	3	1730.951
5	1	5	10	0.95	2	700.882
6	1	5	10	0.95	1	563.607
7	10	5	0	0.95	3	1144.847
8	10	6	10	0.95	1	865.69
9	1	5	5	0.85	3	931.444
10	10	20	10	0.95	3	969.917
11	2	5	5	0.95	1	1037.954
12	1	5	10	0.65	3	823.672
13	1	5	-5	0.95	1	746.433
14	1	7	-5	0.75	2	1405.692
15	2	5	10	0.95	1	864.162
16	1	5	10	0.95	2	1130.054
17	1	5	10	0.95	3	1495.871
18	5	10	10	0.95	1	818.254
19	5	6	10	0.85	1	657.971
20	10	5	10	0.95	3	1609.262
21	1	7	0	0.95	3	1099.053
22	10	5	-10	0.95	1	1051.35
23	5	8	-10	0.95	3	977.03
24	1	7	0	0.95	3	1548.169
25	1	5	10	0.85	3	1761.637
26	5	5	10	0.65	3	1193.049
27	10	8	-10	0.95	1	766.268
28	5	5	-5	0.85	2	946.271
29	1	5	5	0.75	2	828.888
30	1	5	10	0.85	3	1394.501
31	1	7	5	0.95	2	757.366



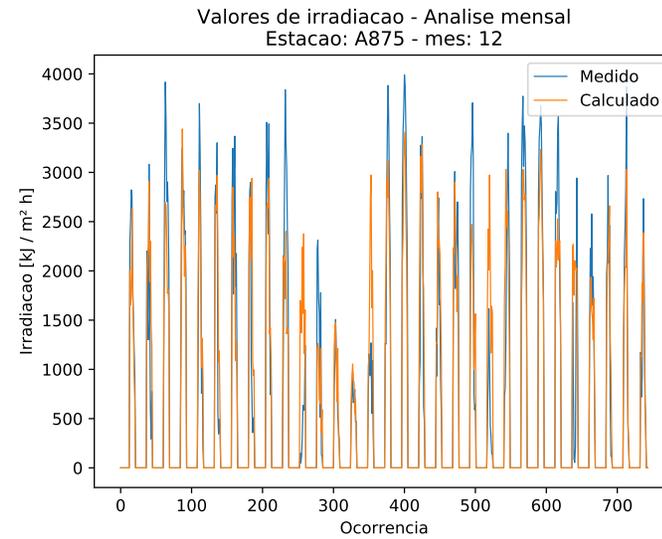
(a) Melhores ajustes diários.



(b) Melhores ajustes semanais.



(c) Melhores ajustes quinzenais.



(d) Melhor ajuste mensal

**Figura F.6:** Análises para a estação A875 para o mês de dezembro de 2012.



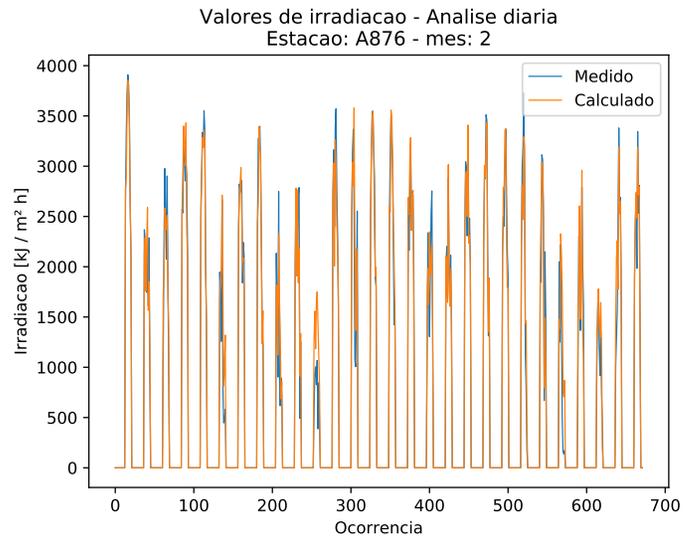
# Apêndice G

## Resultados para a estação A876

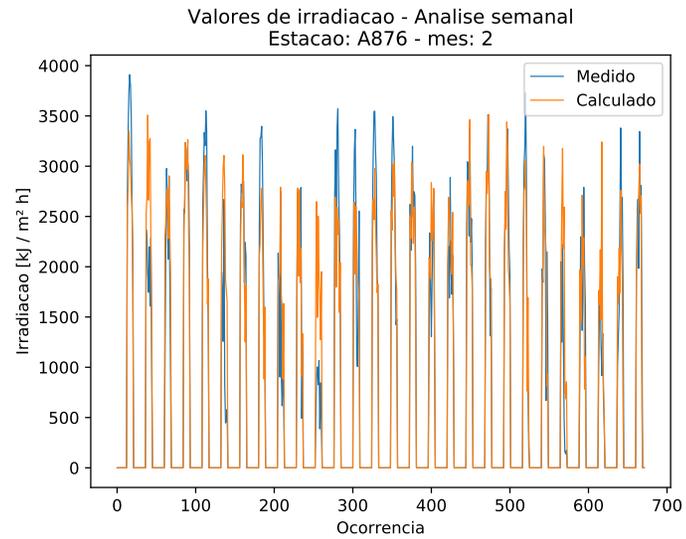
Tabelas com os parâmetros de melhor ajuste dos dados estimados aos dados efetivamente registrados, bem como os gráficos com os referidos valores para a estação A876 para os meses de fevereiro, abril, junho, agosto outubro e dezembro do ano de 2009. Para os gráficos referentes aos meses com mais de 28 dias valem as explicações do Apêndice A na Página 75.

**Tabela G.1:** Parâmetros de melhor ajuste por período para o mês de fevereiro de 2009 na estação A876.

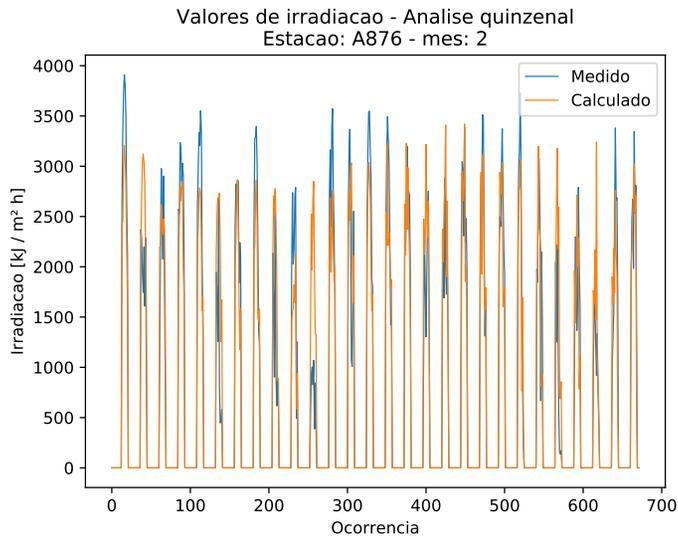
Período	Dias	Classes	Tolerância nos limites [%]	Coef. $p$ PageRank	Nível	GPI ( $\times 10^{-4}$ )
Mensal						
0	1	8	0	0.85	3	567.429
Quinzenal						
1	1	9	0	0.85	3	506.352
2	2	6	-5	0.95	2	740.229
Semanal						
1	1	5	5	0.85	3	562.402
2	2	6	0	0.85	2	581.919
3	1	6	-5	0.85	3	883.451
4	2	6	-5	0.95	2	550.785
Diário						
1	1	5	0	0.85	3	1676.279
2	10	10	0	0.95	1	999.514
3	2	9	-5	0.65	2	637.737
4	1	5	5	0.95	3	1378.318
5	1	8	0	0.95	3	1677.34
6	2	5	10	0.95	1	931.752
7	5	5	10	0.75	3	1466.079
8	2	5	-5	0.95	3	1332.981
9	1	5	5	0.95	1	801.808
10	2	6	0	0.85	2	756.108
11	1	20	-10	0.65	1	713.198
12	10	5	-10	0.95	3	1344.953
13	10	5	10	0.95	3	1169.525
14	1	5	0	0.85	3	1679.541
15	2	6	0	0.95	3	1110.868
16	1	5	-5	0.85	3	1476.156
17	1	9	5	0.85	2	892.959
18	10	8	10	0.95	3	1066.167
19	1	8	0	0.95	3	1792.897
20	2	9	10	0.95	3	1598.252
21	1	5	10	0.75	3	1317.061
22	2	8	-5	0.95	3	1228.209
23	1	5	10	0.65	3	1185.819
24	1	5	-5	0.85	1	706.092
25	1	5	0	0.95	3	1127.481
26	10	5	5	0.95	1	1017.8
27	1	5	0	0.95	2	919.863
28	1	5	5	0.95	3	1440.204



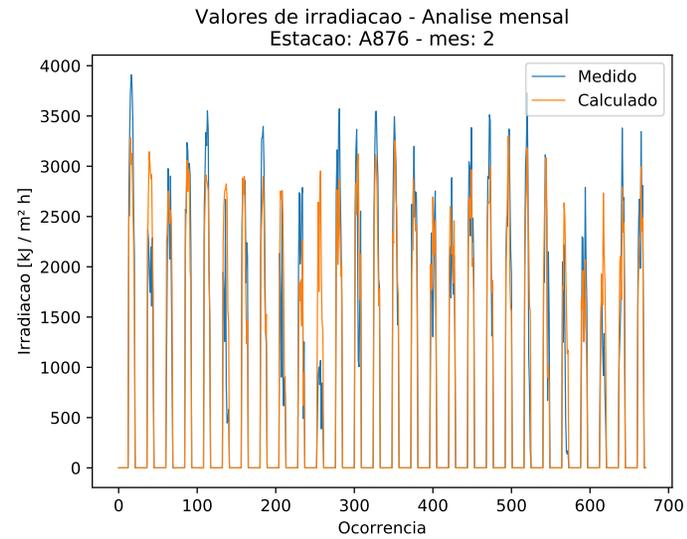
(a) Melhores ajustes diários.



(b) Melhores ajustes semanais.



(c) Melhores ajustes quinzenais.

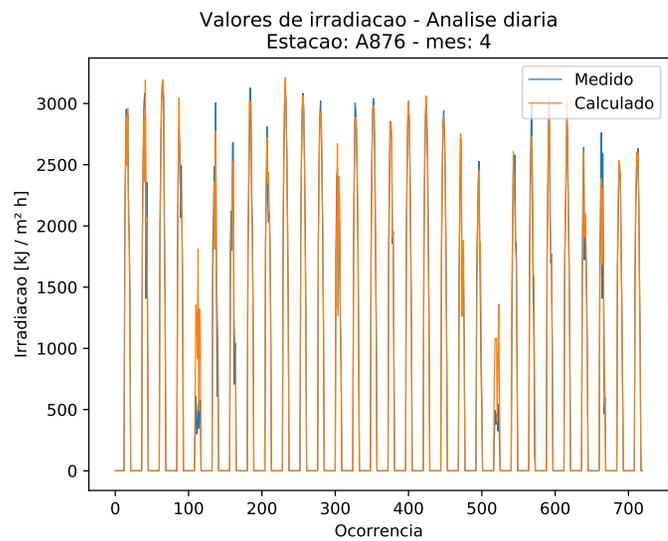


(d) Melhor ajuste mensal

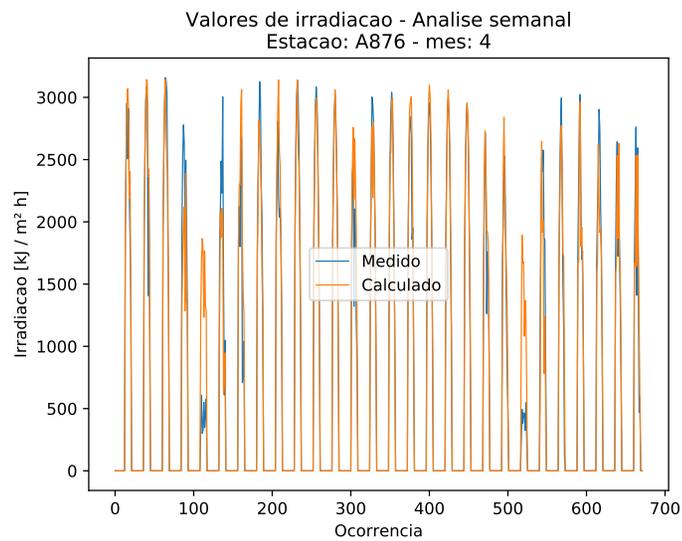
**Figura G.1:** Análises para a estação A876 para o mês de fevereiro de 2009.

**Tabela G.2:** Parâmetros de melhor ajuste por período para o mês de abril de 2009 na estação A876.

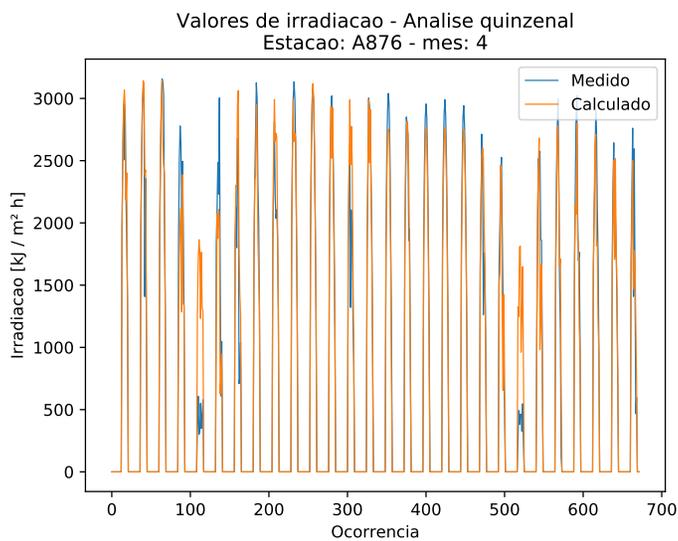
Período	Dias	Classes	Tolerância nos limites [%]	Coef. $p$ PageRank	Nível	GPI ( $\times 10^{-4}$ )
Mensal						
0	1	5	5	0.85	3	834.909
Quinzenal						
1	1	5	5	0.95	3	925.492
2	1	8	0	0.95	2	802.78
Semanal						
1	1	5	5	0.95	3	785.562
2	1	5	0	0.95	2	1171.979
3	2	7	0	0.95	3	1295.176
4	1	7	-10	0.95	3	683.643
Diário						
1	1	6	5	0.95	3	1693.629
2	1	6	-10	0.95	3	1126.796
3	1	7	0	0.95	3	1883.041
4	1	6	0	0.95	3	1409.149
5	10	5	10	0.95	1	1265.112
6	2	9	10	0.85	3	737.121
7	1	15	5	0.95	1	1043.59
8	2	5	10	0.85	3	1658.535
9	1	5	10	0.95	2	1350.582
10	1	7	0	0.95	3	1887.509
11	1	9	0	0.95	3	1873.124
12	2	6	0	0.85	3	1878.161
13	10	20	5	0.95	3	1255.371
14	5	10	0	0.95	3	1718.28
15	1	5	0	0.85	3	1866.681
16	2	8	5	0.95	3	1695.71
17	1	5	0	0.85	3	1886.878
18	2	7	0	0.95	3	1894.705
19	1	7	-5	0.95	3	1857.367
20	5	9	10	0.95	2	1374.379
21	2	20	0	0.95	3	1031.104
22	1	5	10	0.95	1	677.97
23	5	9	10	0.85	3	1284.808
24	1	15	0	0.95	3	917.844
25	1	5	10	0.85	3	1597.618
26	2	5	0	0.95	2	1721.221
27	10	7	0	0.85	3	1373.393
28	1	5	5	0.95	2	1025.677
29	5	6	5	0.85	3	1444.983
30	1	8	0	0.95	3	1750.748



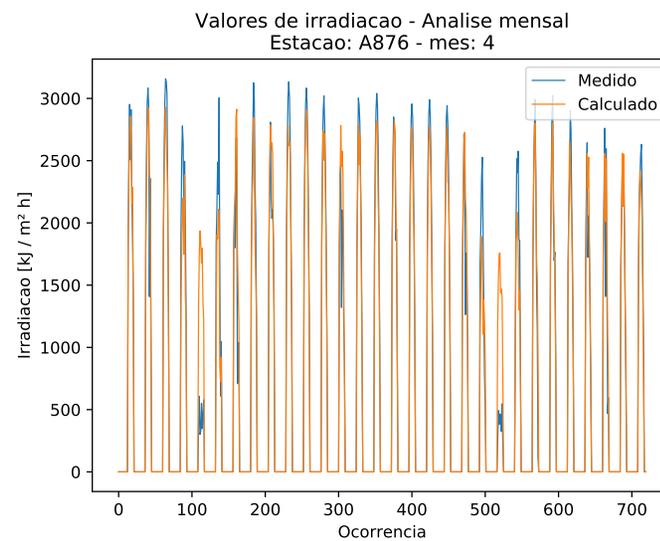
(a) Melhores ajustes diários.



(b) Melhores ajustes semanais.



(c) Melhores ajustes quinzenais.

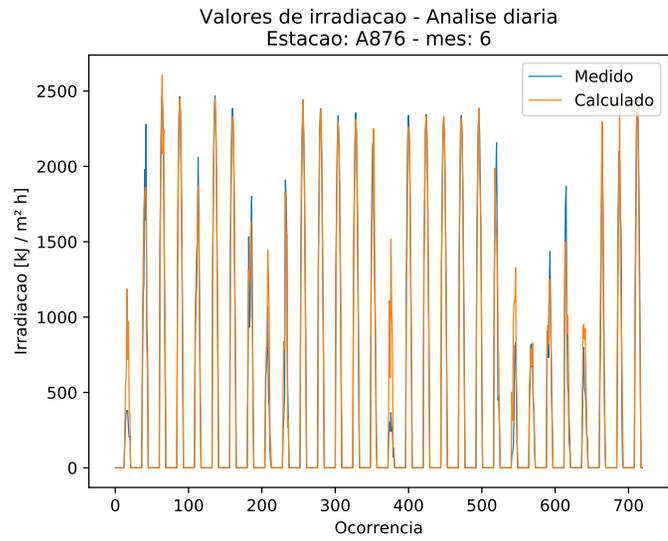


(d) Melhor ajuste mensal

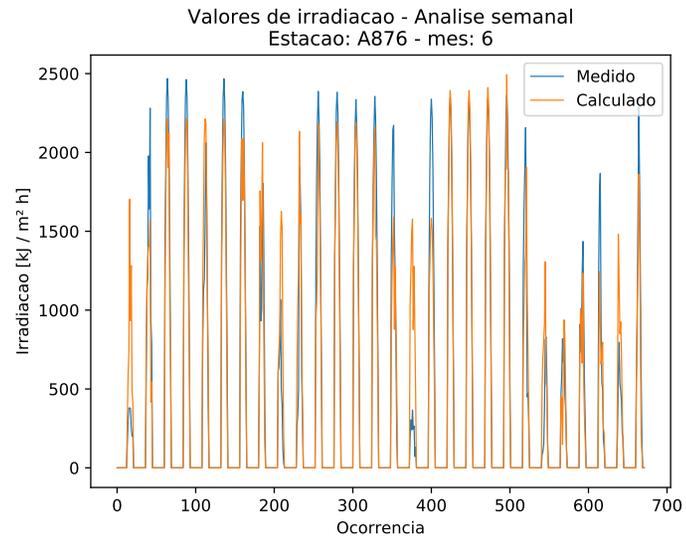
**Figura G.2:** Análises para a estação A876 para o mês de abril de 2009.

**Tabela G.3:** Parâmetros de melhor ajuste por período para o mês de junho de 2009 na estação A876.

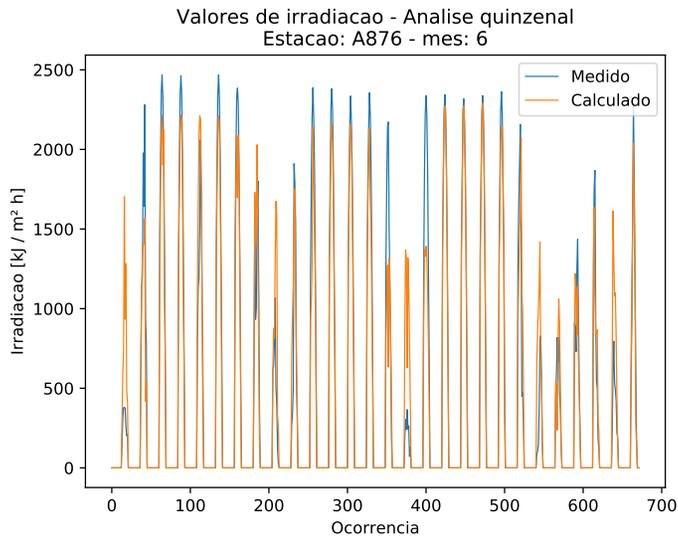
Período	Dias	Classes	Tolerância nos limites [%]	Coef. $p$ PageRank	Nível	GPI ( $\times 10^{-4}$ )
Mensal						
0	1	5	10	0.95	2	791.791
Quinzenal						
1	1	5	10	0.95	2	1002.215
2	1	5	-5	0.95	2	776.187
Semanal						
1	1	5	10	0.95	2	952.476
2	1	5	-10	0.95	2	1000.543
3	1	6	10	0.95	3	817.359
4	1	5	0	0.95	1	449.063
Diário						
1	1	5	5	0.85	1	607.476
2	2	8	0	0.75	3	961.922
3	1	5	0	0.95	3	1632.213
4	1	7	10	0.95	3	1861.854
5	2	6	5	0.95	1	921.839
6	1	8	0	0.95	3	1915.272
7	1	6	0	0.85	3	1697.728
8	5	10	0	0.85	1	568.848
9	2	5	5	0.95	1	772.69
10	2	6	10	0.95	1	773.784
11	1	6	-5	0.95	3	1723.612
12	1	5	5	0.95	3	1962.723
13	1	10	0	0.95	3	1858.641
14	1	5	0	0.85	3	1835.078
15	10	5	-5	0.95	3	1049.059
16	10	6	10	0.95	1	775.736
17	1	9	0	0.95	3	1535.437
18	1	5	5	0.95	3	1977.24
19	1	5	5	0.95	3	1957.472
20	1	5	0	0.85	3	1955.113
21	1	5	0	0.85	3	1742.928
22	10	5	-5	0.95	3	1030.099
23	2	6	-10	0.95	1	936.718
24	2	5	10	0.85	1	1112.659
25	10	9	0	0.75	1	1112.752
26	1	7	0	0.85	3	839.287
27	1	5	-10	0.65	1	725.774
28	1	5	5	0.95	3	1204.698
29	5	8	10	0.95	3	848.758
30	2	7	0	0.95	3	1494.58



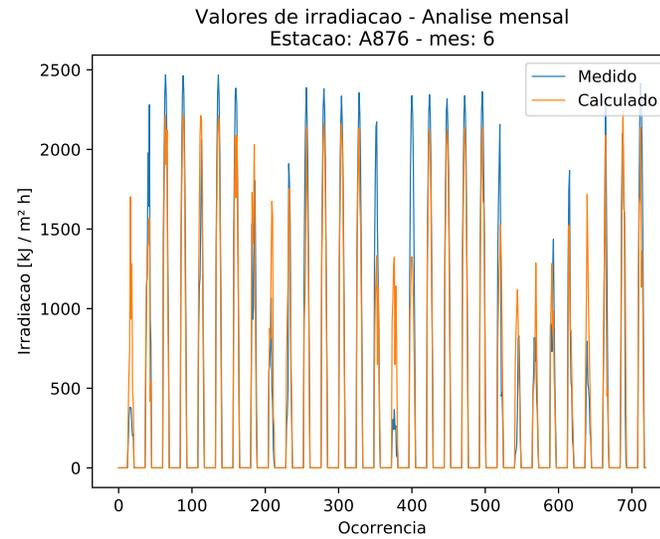
(a) Melhores ajustes diários.



(b) Melhores ajustes semanais.



(c) Melhores ajustes quinzenais.

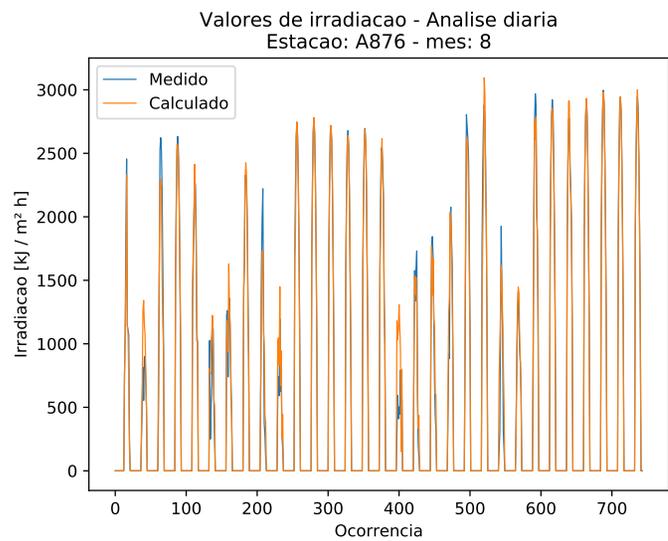


(d) Melhor ajuste mensal

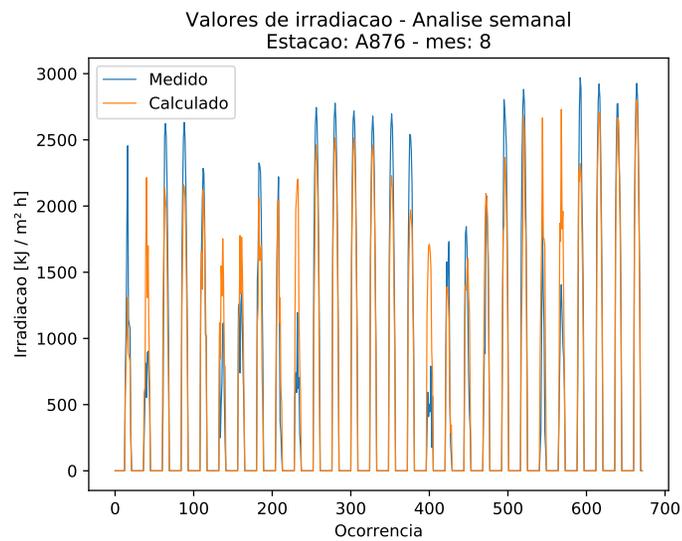
**Figura G.3:** Análises para a estação A876 para o mês de junho de 2009.

**Tabela G.4:** Parâmetros de melhor ajuste por período para o mês de agosto de 2009 na estação A876.

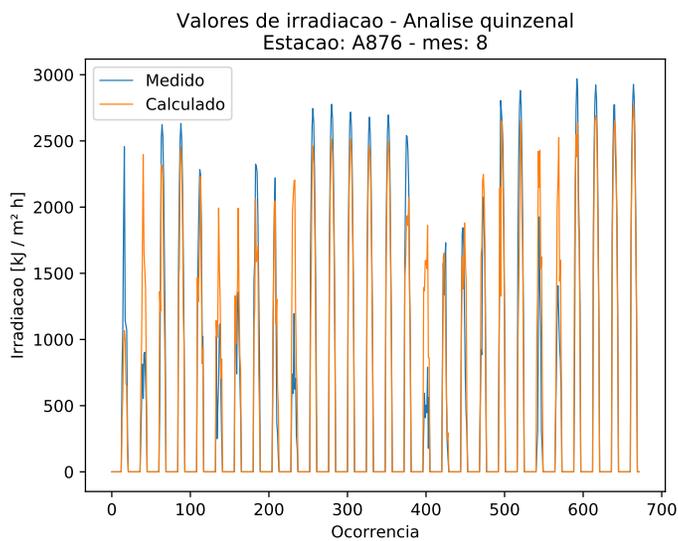
Período	Dias	Classes	Tolerância nos limites [%]	Coef. $p$ PageRank	Nível	GPI ( $\times 10^{-4}$ )
Mensal						
0	1	5	-10	0.95	2	789.141
Quinzenal						
1	1	5	10	0.95	2	728.062
2	1	8	0	0.95	2	753.759
Semanal						
1	1	10	-10	0.95	2	579.544
2	1	5	10	0.95	2	856.561
3	1	8	0	0.75	3	759.146
4	1	7	0	0.95	2	862.453
Diário						
1	1	6	-5	0.95	3	756.012
2	1	20	-10	0.65	1	830.506
3	2	10	-5	0.95	3	886.909
4	1	5	-10	0.95	3	1826.421
5	2	5	-5	0.85	3	1562.02
6	1	7	-10	0.65	1	882.22
7	2	10	5	0.85	1	908.305
8	5	20	0	0.95	3	1683.406
9	1	6	5	0.95	1	627.559
10	5	5	5	0.95	1	949.604
11	1	8	0	0.95	3	1643.589
12	1	7	10	0.95	3	1772.222
13	1	9	0	0.95	3	1956.565
14	1	5	10	0.85	3	1856.285
15	1	8	0	0.95	3	1841.025
16	2	7	10	0.95	3	1650.709
17	2	5	10	0.95	1	822.376
18	1	5	5	0.75	3	880.798
19	10	6	-10	0.85	1	852.104
20	1	8	-10	0.95	1	974.556
21	1	7	10	0.95	2	1349.496
22	1	5	0	0.95	3	1231.315
23	1	5	-10	0.65	1	662.988
24	1	20	-10	0.65	1	1228.346
25	5	8	0	0.95	3	1302.084
26	1	9	0	0.95	3	1839.576
27	2	6	-10	0.95	3	1799.341
28	1	9	0	0.95	3	1988.476
29	1	5	5	0.95	3	1963.655
30	1	8	10	0.95	3	1953.172
31	2	5	0	0.85	3	1884.166



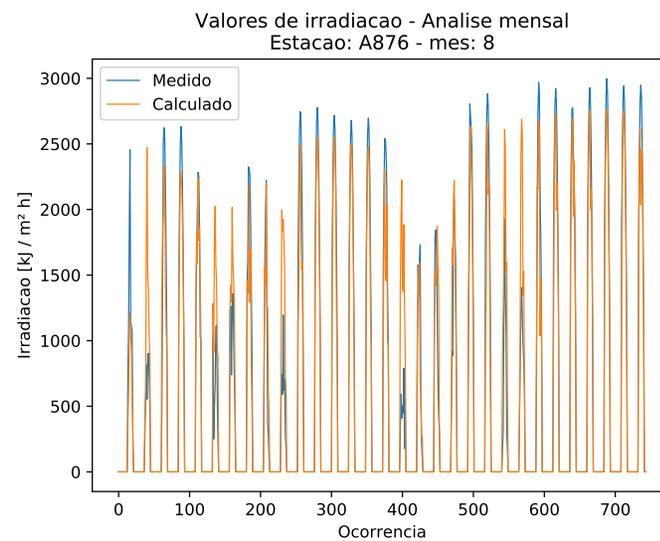
(a) Melhores ajustes diários.



(b) Melhores ajustes semanais.



(c) Melhores ajustes quinzenais.

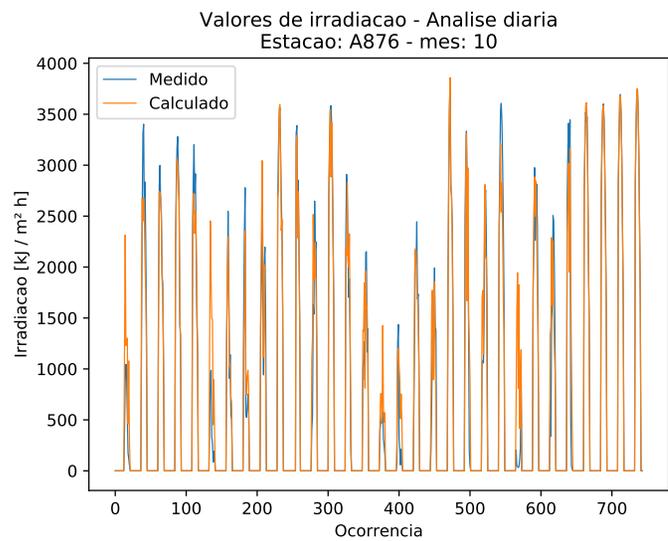


(d) Melhor ajuste mensal

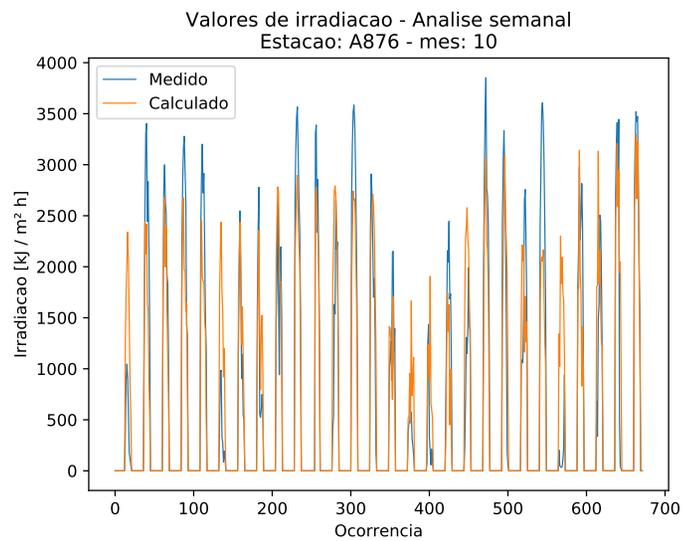
**Figura G.4:** Análises para a estação A876 para o mês de agosto de 2009.

**Tabela G.5:** Parâmetros de melhor ajuste por período para o mês de outubro de 2009 na estação A876.

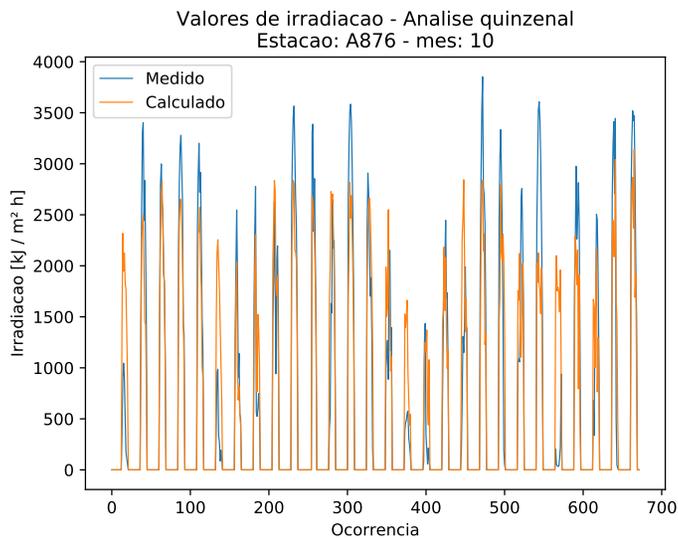
Período	Dias	Classes	Tolerância nos limites [%]	Coef. $p$ PageRank	Nível	GPI ( $\times 10^{-4}$ )
Mensal						
0	1	5	10	0.95	2	590.669
Quinzenal						
1	1	5	0	0.75	2	641.533
2	2	15	5	0.95	1	403.695
Semanal						
1	2	15	10	0.95	1	533.482
2	1	9	10	0.75	3	653.514
3	1	8	10	0.95	1	496.48
4	2	9	0	0.95	2	488.135
Diário						
1	2	5	10	0.95	1	568.219
2	2	5	0	0.65	3	1037.422
3	2	5	10	0.75	3	1504.47
4	1	5	0	0.95	2	1688.906
5	10	5	0	0.65	3	1380.672
6	2	8	-5	0.95	1	668.558
7	2	7	-5	0.85	1	1036
8	1	5	-10	0.95	1	907.746
9	2	5	5	0.95	2	715.142
10	1	7	0	0.95	3	1761.238
11	1	8	5	0.95	3	1760.088
12	1	5	5	0.95	1	1042.359
13	1	7	0	0.95	3	1612.764
14	2	10	5	0.95	2	1109.398
15	5	15	5	0.95	1	1235.861
16	1	5	5	0.95	1	864.787
17	1	6	5	0.95	1	874.199
18	2	5	0	0.65	2	915.162
19	10	15	-10	0.95	1	1134.886
20	1	7	0	0.95	3	1553.125
21	10	8	-10	0.95	3	654.605
22	1	5	-5	0.95	1	1349.174
23	10	5	0	0.75	3	1077.328
24	5	5	10	0.95	1	642.062
25	10	6	10	0.65	3	1265.855
26	5	7	10	0.75	1	717.279
27	1	6	5	0.95	2	933.355
28	2	8	0	0.95	3	1821.846
29	1	5	10	0.85	3	1910.122
30	1	8	10	0.95	3	1931.123
31	1	7	10	0.95	3	1714.743



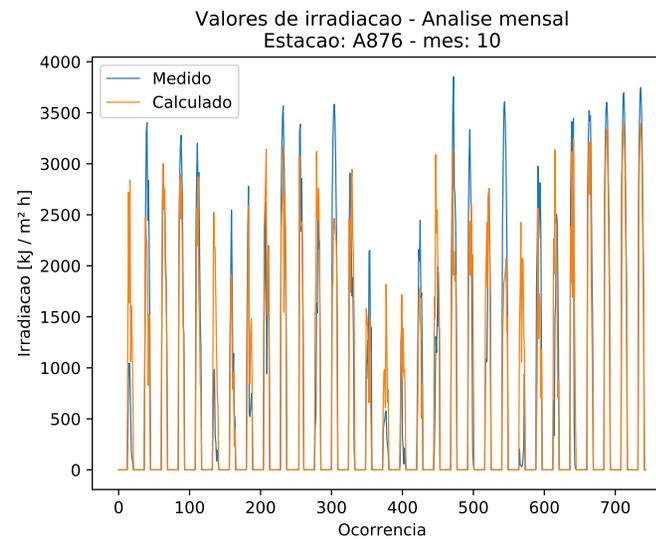
(a) Melhores ajustes diários.



(b) Melhores ajustes semanais.



(c) Melhores ajustes quinzenais.

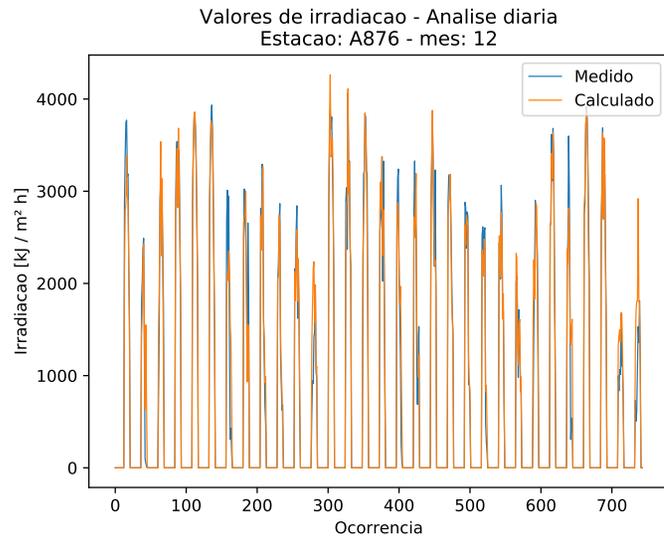


(d) Melhor ajuste mensal

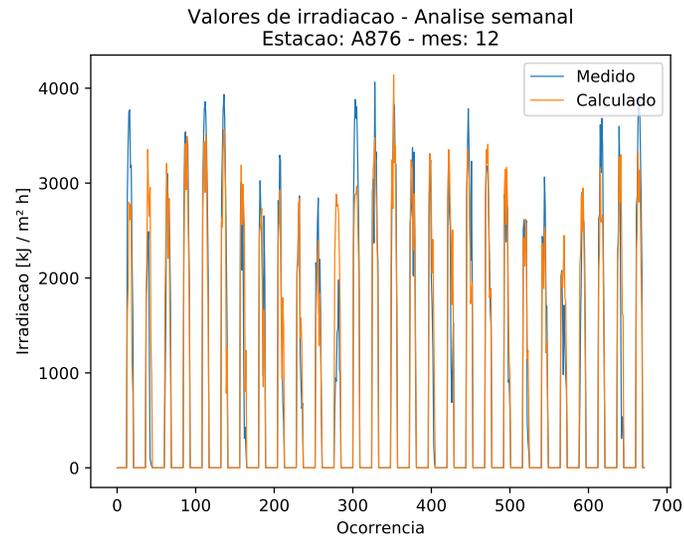
**Figura G.5:** Análises para a estação A876 para o mês de outubro de 2009.

**Tabela G.6:** Parâmetros de melhor ajuste por período para o mês de dezembro de 2009 na estação A876.

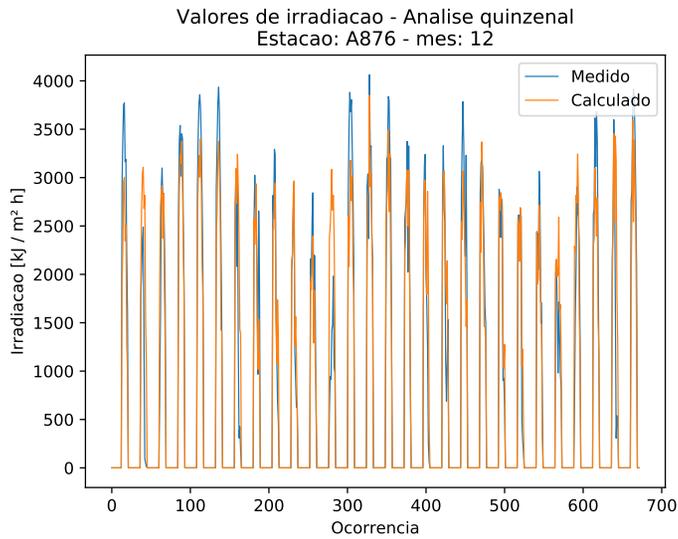
Período	Dias	Classes	Tolerância nos limites [%]	Coef. $p$ PageRank	Nível	GPI ( $\times 10^{-4}$ )
Mensal						
0	1	5	10	0.95	2	584.233
Quinzenal						
1	1	7	5	0.85	3	558.064
2	1	9	10	0.95	2	837.349
Semanal						
1	1	6	10	0.95	2	588.971
2	1	6	0	0.65	3	570.09
3	1	5	5	0.95	3	1024.483
4	1	6	-5	0.75	3	603.307
Diário						
1	5	5	10	0.65	3	1160.276
2	10	6	-5	0.95	1	572.555
3	10	8	0	0.95	3	920.275
4	1	9	5	0.95	3	1729.122
5	1	5	0	0.85	3	1986.694
6	1	5	0	0.85	3	1827.151
7	1	5	5	0.75	1	442.319
8	1	5	10	0.65	3	1126.928
9	2	7	5	0.95	3	1175.928
10	1	5	0	0.95	1	1058.414
11	2	5	-5	0.85	1	895.377
12	10	5	5	0.75	1	678.051
13	1	5	0	0.95	3	1688.613
14	1	7	5	0.95	3	1450.911
15	1	6	5	0.95	3	1389.362
16	2	6	-5	0.95	3	1303.659
17	1	5	5	0.95	2	781.376
18	2	5	-10	0.95	2	738.162
19	1	7	0	0.95	3	1468.979
20	5	6	0	0.85	3	1390.696
21	1	5	-10	0.95	2	1240.916
22	1	7	-5	0.95	1	928.676
23	2	8	-10	0.95	3	1297.881
24	10	7	5	0.95	1	1118.13
25	5	7	5	0.95	2	668.507
26	1	5	0	0.85	3	1621.707
27	10	5	10	0.95	2	649.686
28	1	5	0	0.85	3	1722.473
29	1	8	0	0.95	3	1613.036
30	1	6	-10	0.65	1	857.56
31	2	6	-5	0.95	1	936.851



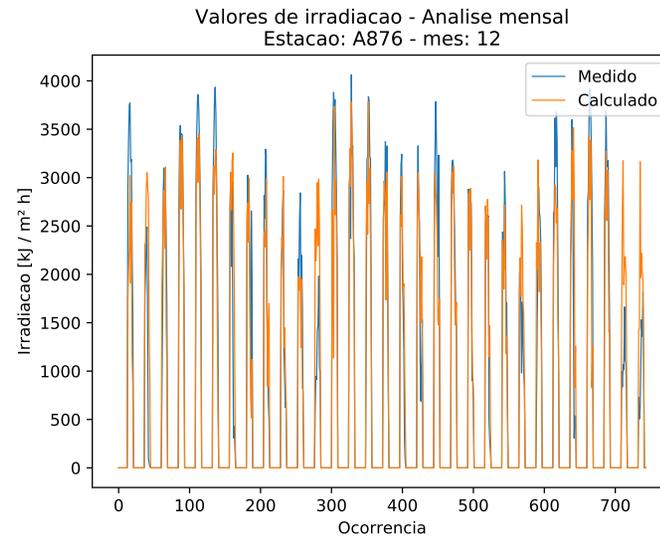
(a) Melhores ajustes diários.



(b) Melhores ajustes semanais.



(c) Melhores ajustes quinzenais.



(d) Melhor ajuste mensal

**Figura G.6:** Análises para a estação A876 para o mês de dezembro de 2009.