

## MANUAL PARA TRATAMENTO DE DADOS SOLARIMÉTRICOS (PARTE II)

CRIAÇÃO DE UM ANO  
METEOROLÓGICO TÍPICO  
(TMY) USANDO DADOS  
MEDIDOS NO SOLO E  
DADOS DERIVADO DE  
SATÉLITES





## PROJETO Energia Heliotérmica

Este estudo foi elaborado pelo Projeto Energia Heliotérmica que atua no âmbito da Iniciativa Alemã de Tecnologias Limpas em Energia Solar Heliotérmica (DKTICSP: Deutsche Klima- und Technologieinitiative – Concentrating Solar Power). O projeto é gerido através do Ministério da Ciência, Tecnologia, Inovações e Comunicações (MCTIC) e da Gesellschaft für Internationale Zusammenarbeit (GIZ) GmbH e tem o objetivo de estabelecer os pré-requisitos para a aplicação e disseminação da Geração Heliotérmica no Brasil.

### **Coordenação:**

Eduardo Soriano Lousada, Ministério da Ciência, Tecnologia, Inovações e Comunicações (MCTIC)  
Torsten Rainer Schwab, Deutsche Gesellschaft für Internationale Zusammenarbeit (GIZ) GmbH

### **Autores:**

Nicolaj Röttinger, Schollenhaldenstr. 10, 74080 Heilbronn,  
n.roettinger@googlemail.com

### **Colaboradores da equipe CHESF:**

Pedro Bezerra de Carvalho Neto  
Alcides Codeceira Neto  
José Bione de Melo Filho  
Francisco José Maciel de Lyra  
Eduardo de Aguiar Sodré

### **Editores:**

Florian Remann e Marcos Oliveira Costa

**Informações Legais:** 1. Todas as indicações, dados e resultados deste estudo foram compilados e cuidadosamente revisados pelo(s) autor(es). No entanto, erros com relação ao conteúdo não podem ser evitados. Consequentemente, nem a GIZ, nem o MCTIC ou o(s) autor(es) podem ser responsabilizados por qualquer reivindicação, perda ou prejuízo direto ou indireto resultante do uso ou confiança depositada sobre as informações contidas neste estudo, ou direta ou indiretamente resultante dos erros, imprecisões ou omissões de informações neste estudo. 2. A duplicação ou reprodução de todo ou partes do estudo (incluindo a transferência de dados para sistemas de armazenamento de mídia) e distribuição para fins não comerciais é permitida, desde que a GIZ e/ou MCTIC seja citada como fonte da informação. Para outros usos comerciais, incluindo duplicação, reprodução ou distribuição de todo ou partes deste estudo, é necessário o consentimento escrito da GIZ e/ou MCTIC.

# MANUAL PARA TRATAMENTO DE DADOS SOLARIMÉTRICOS (PARTE II)

## CRIAÇÃO DE UM ANO METEOROLÓGICO TÍPICO (TMY) USANDO DADOS MEDIDOS NO SOLO E DADOS DERIVADO DE SATÉLITES

# ÍNDICE

<b>1. INTRODUÇÃO</b>	<b>8</b>
<b>2. DERIVAR RADIAÇÃO DE MODELOS SATÉLITES</b>	<b>10</b>
2.1 MODELOS EMPÍRICOS	11
2.2 MODELOS FÍSICOS	12
2.3 MODELOS SEMI-EMPÍRICOS	14
<b>3. CONVERTER PARA DADOS HORÁRIOS</b>	<b>16</b>
3.1 COLOCAR VALORES DE RADIAÇÃO <0 PARA 0	16
3.2 APLICAR BIAS ERROS DO GAP-FILLING AOS DADOS	16
3.3 CONVERTER DADOS (MIN -> H)	17
3.4 GRAVAR DADOS EM FORMATO TMY3	18
<b>4. CORRELAÇÃO DE DADOS MEDIDOS COM DADOS SATÉLITES</b>	<b>23</b>
4.1 O MÉTODO DE RELAÇÃO (RATIO METHOD / LINEAR CORRECTION)	26
4.2 COMBINAR VÁRIOS CONJUNTOS DE DADOS COM PONDERAÇÃO	27
4.3 ADAPTAR A DISTRIBUIÇÃO DE FREQUÊNCIA	29
4.4 POLINÔMIO DE 3º GRÃO	30
4.5 MÉTODO DESENVOLVIDO	31
4.5.1 ESCOLHER O CONJUNTO DE DADOS SATÉLITES (DADOS-SAT)	31
4.5.2 ESCOLHER O CONJUNTO DE DADOS DE MEDIÇÃO NO SOLO (DADOS-MED)	32
4.5.3 VERIFICAR DADOS EM COMUM E COLOCAR EM ORDEM	32
4.5.4 CALCULAR GRANDEZAS ESTATÍSTICAS (ANTES DA CORRELAÇÃO)	32
4.5.5 CORRELAÇÃO DOS DADOS	33
4.5.6 CALCULAR GRANDEZAS ESTATÍSTICAS (DEPOIS DA CORRELAÇÃO)	34
4.5.7 APLICAR BIAS AVALIADO AOS DADOS DE LONGO PRAZO	34
<b>5. CRIAÇÃO DE UM ANO METEOROLÓGICO TÍPICO (TMY) E UM MY90</b>	<b>35</b>
5.1 TYPICAL METEOROLOGICAL YEARS (TMYS)	36
5.1.1 ESCOLHER OS PESOS PARA OS PARÂMETROS	37
5.1.2 ESCOLHER OS ARQUIVOS DOS ANOS METEOROLÓGICOS	38
5.1.3 CONVERTER DADOS HORÁRIOS PARA DADOS DIÁRIOS	38
5.1.4 DIVIDIR ANO EM MÊS	38
5.1.5 AGLOMERAR DADOS DE LONGO PRAZO PARA CADA MÊS	38
5.1.6 COMPARAR MESES COM O MÊS MÉDIO	38
5.1.7 APLICAR OS PESOS PARA OBTER O WS PARA CADA MÊS	39
5.1.8 ESCOLHER O MÊS COM O MAIOR VALOR WS	39
5.1.9 CONCATENAR MESES PARA UM ANO	39
5.2 OBTER UM PERCENTILES DE EXCEDENCIA DE RADIAÇÃO	39
5.2.1 ASSUMIR UMA DISTRIBUIÇÃO NORMAL DE VARIABILIDADE ANUAL E INCERTEZA DO CONJUNTO	39

# ÍNDICE

5.2.2 CRIAÇÃO DE ANOS METEOROLÓGICOS REPRESENTATIVOS (RMY) QUE REPRESENTAM O PERCENTIL DE EXCEDENCIA	41
5.2.3 ABORDAGENS PROBABILÍSTICAS	41
<b>6. RESUMO</b>	<b>43</b>
FIGURAS	44
TABELAS	46
ABREVIACÕES	47
REFERÊNCIAS	49

# 1. INTRODUÇÃO

Por encomenda do Ministério Federal da Cooperação Econômica e Desenvolvimento da Alemanha (*Bundesministeriums für wirtschaftliche Zusammenarbeit und Entwicklung* - BMZ) e em parceria com o Ministério da Ciência Tecnologia, Inovações e Comunicação - MCTIC, o projeto DKTI-CSP tem o objetivo de estabelecer condições para o desenvolvimento e a difusão de energia heliotérmica no Brasil.

Para todas tecnologias de geração de energia solar, a radiação solar é o “combustível” e assim, como para outros tipos de combustíveis, o conhecimento da qualidade e da confiabilidade no futuro é crucial para analisar a performance do sistema e a viabilidade financeira do projeto.

Nesse contexto, a variabilidade do recurso solar é uma grande incerteza no processo de prever a produção de energia de uma planta heliotérmica. O conhecimento do recurso solar influencia três etapas de um projeto solar: a determinação da melhor localização, a previsão de energia produzida anual e a estratégia de operação). Na primeira parte do Manual (Tratamento de dados solarimétricos Parte I – Controle de dados e preenchimento de lacunas) foi descrito uma metodologia para controlar a qualidade de dados medidos e preencher lacunas com o objetivo de obter um conjunto de dados medidos contínuo e de alta precisão. Baseando-se nesse procedimento anterior, no Manual II é descrito a correlação desses dados medidos com dados satélites de longo prazo para incluir a variabilidade interanual do recurso solar. O conjunto de dados obtido, que pode ser considerado um conjunto de dados satélites corrigido, contém as características das duas fontes (medido no solo → alta precisão, dados satélites → longo prazo) e pode ser usado para criar um ano típico meteorológico (TMY – *Typical Meteorological Year*) que representa a média de longo prazo (P50) e um MY90, que representa o percentual P90.

Uma visão geral do caminho completo dos dados meteorológicos (do *datalogger* / banco de

dados até o TMY / MY90) é mostrada na Figura 1-2. O processamento de dados é dividido em 6 algoritmos:

- A. Checagem por lacunas / linhas múltiplas
- B. Testes de qualidade, marcação com bandeiras
- C. Preenchimento de lacunas de dados errados/ ausentes (*Gap-filling*)
- D. Converter para dados horários
- E. Correlação de dados medidos com dados satélites
- F. Criação de um ano meteorológico típico (TMY) e um MY90

Depois de ser extraído do *datalogger* ou do banco de dados, eles são chamados dados brutos, sem alguma alteração ou marcação de bandeira. Os dados brutos de nível 0 ainda podem possuir lacunas temporais ou linhas múltiplas. Nos dados brutos do nível 1 esses erros foram corrigidos. Depois dos testes de qualidade os dados são marcados através de bandeiras como dados “bons” ou “ruins” e são chamados “dados com bandeiras” ou de nível 2. O algoritmo do *gap-filling* tenta preencher esses dados “ruins” com valores mais realísticos ou “melhores”. Depois os dados chegam ao nível de “dados com lacunas preenchidas (nível 3). Esse nível é dividido em nível 3a que representa um conjunto de dados de resolução temporal de 1min e nível 3b que representa os mesmos dados convertidos para uma resolução horária e no formato de “TMY3”. Os dados do nível 3b podem ser usados para correlação com dados satélites. É recomendado de usar no mínimo um ano de dados medidos e dez anos de dados satélites para esse procedimento (veja [Suri/Cebauer 2011], [Meyer et al. 2009], [Vignola et al. 2012]). Com a correlação, os dados de satélite que representam um período de tempo maior, enquanto possuindo uma incerteza bem maior, são melhorados / corrigidos com os dados medidos nas estações solarimétricas (ESOL). É obtido um conjunto de dados de longo prazo com uma menor incerteza que representa o nível 4 no método. Dos dados desse nível um TMY ou um MY90 pode ser calculado no formato “TMY3”



que pode ser usado em aplicativos para simular a geração de energia como SAM ou Thermoflow.

Nesse Manual será explicado brevemente no capítulo 2 como dados meteorológicos são derivados de modelos satélites para um melhor entendimento das características desses dados. Depois, os algoritmos desenvolvidos serão explicados, começando com a conversão dos dados medidos de resolução de 1min para dados

horários (algoritmo D) no capítulo 3. O capítulo 4 contém uma visão geral de métodos para correlação de dados medidos e dados derivado de imagens satélites. Será explicado com mais detalhe as diferenças entre esses tipos de dados e também o método usado no algoritmo E. No capítulo 5 os termos TMY/MY90 serão explicados e o algoritmo F para construir esses produtos em resolução horária será apresentada. Para detalhes sobre os algoritmos A-C veja o Manual I.

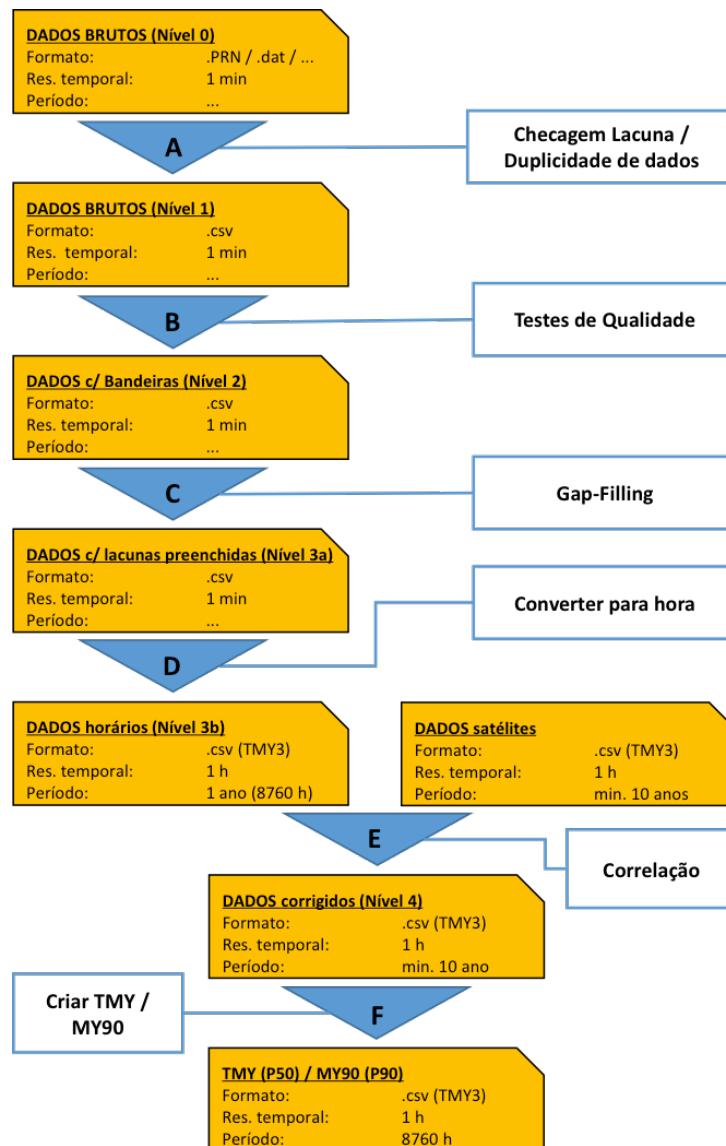


Figura 1-1: Processamento de dados do Datalogger/banco de dados até o TMY/MY90

## 2. DERIVAR RADIAÇÃO DE MODELOS SATÉLITES

O objetivo de modelos de imagens satélites é observar informações sobre radiação no topo da atmosfera (TOA – *top of atmosphere*) e albedos para calcular GHI e DNI para derivar radiação no solo. As imagens satélites são obtidas com satélites geoestacionários ou satélites em órbita polar. Satélites geoestacionários acompanham a rotação da terra, permanecendo na mesma posição. Assim, eles podem continuamente fornecer informações sobre certa parte da terra. Essa parte é dividida em células ou *pixels* de 1-10 km<sup>2</sup> que são escaneadas linha por linha em um intervalo fixo (0.5-3 horas) no espectro visível e infravermelho (veja Figura 2-1). Comparando scans visíveis e infravermelhos, por exemplo, índices de nuvens podem ser formados. Satélites em órbita polar passam sobre ambos os polos do planeta e podem ser usados para obter propriedades de nuvens e calcular radiação solar no solo também. Porém, a resolução temporal é limitada desde eles passam por o mesmo local somente uma vez por dia.




Figura 2-1: Escaneamento do satélite geoestacionário METEOSAT, Fonte: Suntrace

Para o Brasil, os seguintes conjuntos de dados de satélites são disponíveis (Tabela 2-1):

Tabela 2-1: Dados provenientes de satélites para o Brasil					
Fornecedor	Res. Esp. (km)	Res. Temp. (h)	Cobertura	Período	Gratuito/Pago
3Tier	3	1	Mundo	1999-2010	P
Brasil SR (INPE)	10(1)	Mensal(1)	Brasil	1995-2005(2012)	G
DLR-ISIS	280	3	Mundo	1983-2004	G
DLR-Solemi	1	1	Brasil+outros	1994-presente	P
GeoModel	≥0.25	0,5 / 1	Brasil+outros	1994-presente	P
IrSOLaV	3	1	Brasil+outros	1994-presente	P
Meteonorm	-	1	Mundo		P
NASA-SSE	100	Mensal	Mundo		G
NREL-2009	40	720	Mundo		G

Os modelos para derivar dados de radiação solar com satélites podem ser classificados em métodos empíricos, métodos físicos e métodos semi-empíricos. Os métodos empíricos são baseados no desenvolvimento de relações estatísticas entre observações dos satélites e observações feitas no solo. Eles são mais fáceis para implementar, porém específicas para um local. Os métodos físicos estimam a radiação no solo só com as informações dos satélites, usando modelos para determinar as propriedades da atmosfera responsáveis pela absorção e dispersão. Os modelos físicos não precisam uma adaptação num local específico da mesma extensão que os modelos empíricos e, se todos os parâmetros de entrada estiverem disponíveis, haverá o potencial de produzir resultados melhores. [Pinker/Laszlo 1992] Cada categoria de modelos será apresentada em breve junto com um modelo de exemplo.

## 2.1 MODELOS EMPÍRICOS

Modelos empíricos criam equações de regressão na base de relações entre albedo do solo, transmitância

atmosférica e medições no solo. O Albedo é um coeficiente sem dimensão que representa entre a relação da radiação refletida e a radiação chegando no solo (0-100% de reflexao). Esse coeficiente é diferente para cada superfície (veja Figura 2 2). Assim o albedo é por exemplo 0.08-0.18 para florestas, 0.05-0.08 para agua, 0.25 para grama, 0.15 para solo descoberto, 0.04-0.12 para estadas asfaltadas ou ~0.55 para concreto. Um sensor no satélite mede a radiação refletida da terra e da atmosfera e assim o albedo pode ser calculado. Dependendo do método, os coeficientes do modelo de regressão mudam significativamente com o local e precisam ser calibrados com dados de medição no solo. Alguns métodos (por exemplo [Tarpley 1979]) também providenciam equações de regressão diferentes, classificados na base das condições do céu (claro / parcialmente nublado / nublado). Geralmente, modelos empíricos só estimam GHI e precisam de modelos adicionais para calcular DNI. Como um exemplo para um modelo empírico será apresentado o método de [Cano et al. 1986].




Figura 2-2: Medição da reflexão de radiação solar com satélites

A ideia básica do modelo é que a cobertura de nuvens em cima de uma área determina estatisticamente o GHI nessa área. Assim, o procedimento é o seguinte:

1. Estimar albedo de referência (sem cobertura de nuvens)
2. Comparar imagens de satélites com albedo de referência para derivar um índice de cobertura de nuvens
3. Regressão estatística entre fatores de transmissão atmosférica (derivado de medições) e o índice de cobertura de nuvens
4. Interpolação para obter GHI para locais entre estações de medição

Normalmente (exceções: cobertura de neve e alguns solos do deserto), o albedo de uma nuvem é maior do que o albedo do solo. Esse fato é usado para construir um mapa de albedo de referência em pixels de 5x5 km, assumindo que em uma série de tempo de imagens satélites, o local das nuvens não está estacionário e assim o valor mínimo de albedo observado em um pixel de satélite é o albedo do solo. O mapa é atualizado cada dia.

O índice de cobertura de nuvens é calculado por uma função do albedo de referência, o albedo medido pelo satélite e o albedo média dos topos das nuvens. A gama do índice é de 0 até 1 e pode ser interpretado como a porcentagem de cobertura de nuvens no pixel. Também ele providencia um indicador da transmissão atmosférica. Para cada ESOL no solo, coeficientes que definam uma regressão linear entre o índice de cobertura de nuvens e a transmissão na atmosfera derivado de medições no solo é calculado. Com esses coeficientes GHI pode ser obtido. Para locais entre ESOLs, um método de interpolação é aplicado para adaptar os coeficientes.

## 2.2 MODELOS FÍSICOS

Os modelos físicos geralmente usam métodos de transferência de radiação para estimar a radiação no solo direto de princípios primeiros. A transmissão pela atmosfera é calculada de conjuntos de dados globais incluindo os seguintes inputs (veja também Figura 2-3):

- Elevação
- Níveis de ozônio
- Índice de vapor
- Aerossóis
- Índice de cobertura de nuvens

Com esses parâmetros a radiação que chega no solo pode ser calculada. Modelos diferentes também podem ser usados para cada um calcular uma parte específica do método total [Kambeizidis 2012]. Se medições no solo estão disponíveis, os dados podem ser usados para avaliar a precisão do modelo (veja por exemplo [Ineichen 2006], [Ineichen 2011], [Porfirio/Ceballos 2013], [Suri/Cebauer 2011]). Um exemplo de dados de entrada para calcular a radiação no solo com um céu claro, sem cobertura de nuvens é apresentado em Figura 2.3.

Para melhor entendimento será explicado em breve o modelo de [Pinker/Laszlo 1992] como um exemplo de uma abordagem física:

A ideia básica é de estabelecer uma relação entre a transmissividade  $T$  (relação entre radiação no solo e no topo da atmosfera, TOA) e a refletividade  $R$  (relação entre a radiação em TOA e a radiação refletida para TOA):

$$T=f(R) \quad (2-1)$$

Assim que essa relação é conhecida,  $T$  e assim também a radiação no solo pode ser calculada.

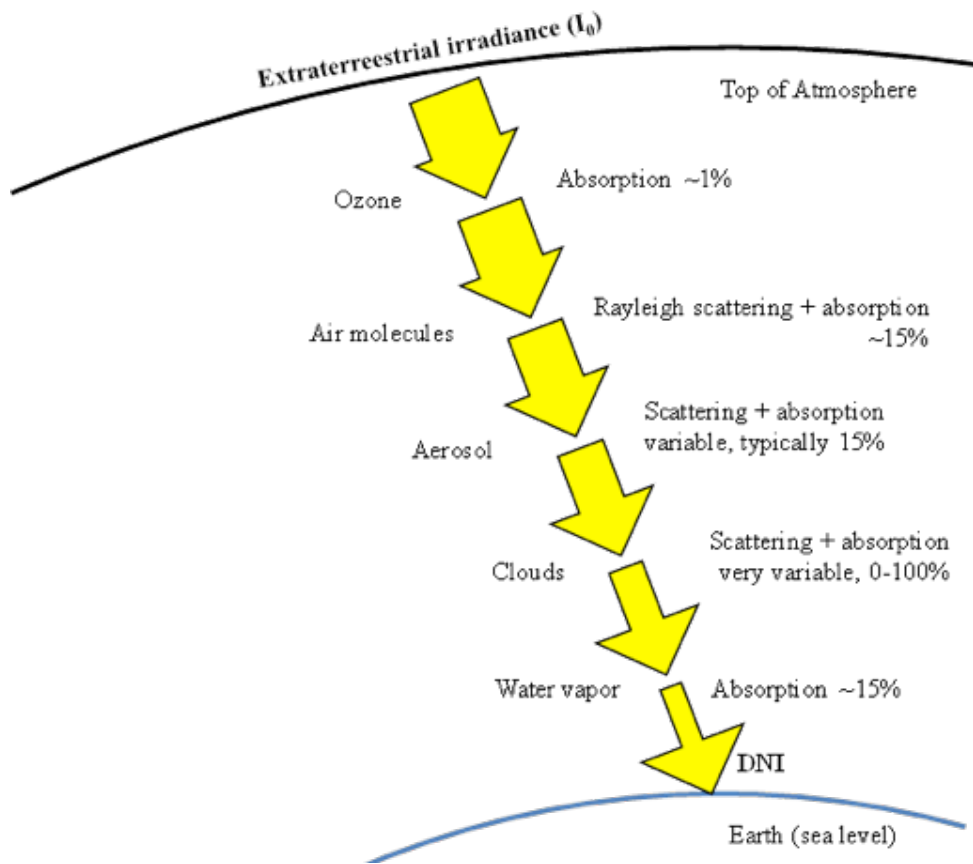


Figura 2-3: Absorção e dispersão de radiação na atmosfera, Fonte: Autor

Nesse contexto, três passos principais foram estabelecidos:

0. Estabelecer relações  $T=f_i(R)$ ,  $i=1,\dots,N$  com  $N$  condições de atmosfera-solo realísticas através de cálculos de transferência de radiação transmitida e refletida. Cada condição diferente é caracterizada com os seguintes parâmetros específicos:

- Albedo de superfície
- Quantidade de gases absorventes (ozônio, vapor)
- Quantidade de gases dispersantes (moléculas, aerossóis, gotículas de nuvens)

1. Determinar um albedo  $R_{sat}$  das imagens satélites em TOA

2. Escolher  $T=f_s(R)$  da biblioteca para a condição atmosfera-solo que existia quando a medição no satélite foi feita. Estimar  $T$  comparando o albedo  $R_{sat}$  e o albedos calculados  $R_m$ .

$T=f_s(R_{sat})$  é obtido com uma interpolação linear das transmissividades da biblioteca  $T=f_s(R_m)$  e  $T=f_s(R_{m+1})$  com  $R_m \leq R_{sat} < R_{m+1}$  ( $m=1,\dots,N_r$ ,  $N_r$  = quantidade de profundidades óticas diferentes)

O primeiro passo (0) precisa ser executado só uma vez para obter a biblioteca de condições atmosfera-solo. Os passos 1 e 2 precisam ser executados para cada observação do satélite. Com a transmissividade do  $R_{sat}$  calculado no passo 2, a radiação global total, direta e difusa pode ser calculada. Figura 2-4 mostra o fluxograma do modelo para obter a radiação no solo.

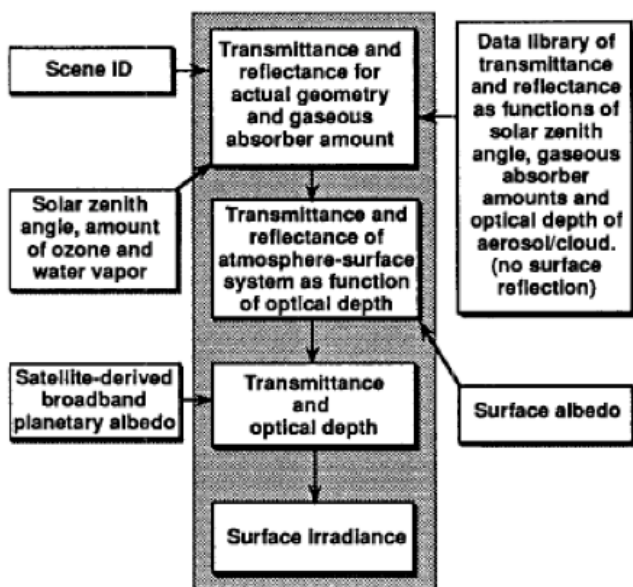


Figura 2-4: Fluxograma do método de [Pinker/Laszlo 1992] para derivar radiação solar combinando albedo planetário e uma biblioteca de dados com transmissão e reflexão na atmosfera

## 2.3 MODELOS SEMI-EMPÍRICOS

Modelos semi-empíricos têm uma abordagem híbrida para obter radiação no solo, relacionando reflexão normalizada observada por satélites com a GHI no solo. Primeiro, índices de cobertura de nuvens são criados usando imagens de satélites do espectro visível e equações de balanço entre TOA e solo. Esses índices são usados depois para modificar o GHI de céu claro para obter um GHI conforme a condição de nuvens. Com o GHI e o DNI de céu claro o DNI pode ser derivado.

Um modelo semi-empírico é por exemplo de [Perez et al. 2002]. O princípio do modelo é que transmissividade na atmosfera tem uma relação linear com o albedo planetário (chamado no modelo também de radiação da terra) que é observado pelo satélite. Essa relação linear é descrita por [Schmetz 1989] com:

$$\tau_{\text{atm}}(n) = \tau_{\text{atm}}(0)(1-n) \quad (2-2)$$

$\tau_{\text{atm}}(n=1)$  é a transmissividade atmosférica para céu nublado e  $\tau_{\text{atm}}(n=0)$  a transmissividade atmosférica para céu claro. A cobertura de nuvens  $n$  é expressado por [Perez et al. 2002] com o índice de nuvens (*CI – cloud index*). O modelo pode ser dividido em duas partes:

1. Conversão pixel para CI
2. Conversão CI para GHI

O satélite recebe a imagem em pixels “brutos” que são proporcionais a “radiação da terra” detectada pelo satélite. Esse pixel é normalizado ao ângulo solar de zênite (*solar zenith angle - SZA*) e depois avaliado com uma gama dinâmica (*dynamic range*) desse local. A gama dinâmica representa a faixa de valores que um pixel normalizado pode adquirir entre o valor mínimo (pixel mais escuro (solo) → condições claras) até o valor máximo (pixel mais claro (nuvens) → condições nubladas). Uma gama dinâmica é mostrada em Figura 2-5. O limite máximo geralmente fica constante (exceto a modulação temporal devido ao desvio de calibração do satélite), enquanto o limite mínimo muda e é adaptado a mudanças no solo (neve, umidade, efeitos de vegetação). O modelo de [Perez et al. 2002] por exemplo usa o período dos 60 dias anterior para obter o limite mínimo da gama dinâmica de um dia. Com o pixel normalizado (*norpix*), e o limite máximo (*up*) e o limite mínimo (*low\**), o CI é calculado da seguinte forma:

$$CI = \frac{\text{norpix} - \text{low}^*}{\text{up} - \text{low}^*} \quad (2-3)$$

Para o limite mínimo (*low*) uma segunda normalização é aplicada para responder por um efeito de massa de ar atmosférica e o efeito “hot spot” [Zelenka et al. 1999]. Isso conduz um valor normalizado *low\**. Com o CI, GHI pode ser calculada da GHI de céu claro (*Ghc*) (veja [Perez et al. 2002]):

$$GHI = (0.02 + 0.98(1 - CI)) \cdot Ghc \quad (2-4)$$

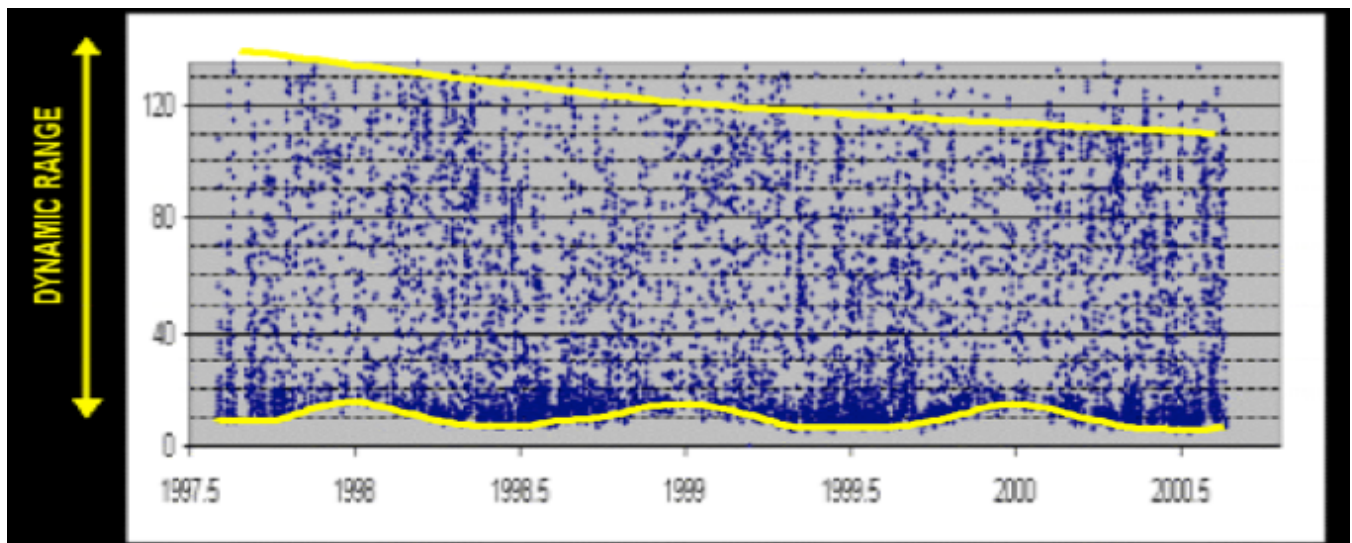


Figura 2-5: Gama dinâmica (dynamic range) de um pixel de satélite [Perez et al. 2002].

### 3. CONVERTER PARA DADOS HORÁRIOS

Como os dados do nível 3a (veja Figura 1 2) ainda são de uma resolução temporal de 1 minuto, eles têm que ser integrado para 1h para obter a mesma resolução dos dados satélites. Aliás, o formato já é alterado para o formato TMY3 (veja [Wilcox&Marion 2008]) desde esse é um dos formatos que pode ser lido de software de simulação de produção de energia.

Os passos do algoritmo D (D\_Converter\_Hora) são os seguintes e serão explicados com mais detalhe nesse capítulo:

1. Colocar valores de radiação <0 para 0
2. Aplicar bias erros do gap-filling aos dados
3. Converter dados (min → h)
4. Gravar dados em formato TMY3

#### 3.1 COLOCAR VALORES DE RADIAÇÃO <0 PARA 0

Na medição de dados de radiação, os instrumentos podem transmitir um sinal negativo. Como explicado

no Manual I, isso é causado por emissão de radiação infravermelho dos sensores durante a noite (“dark-offset”, principalmente dos piranômetros). Esses valores podem ser usados para adaptar a calibração dos instrumentos, mas iam atrapalhar a integração dos dados de radiação. Por isso, nesse passo todos os valores de radiação abaixo de zero são colocados para zero.

#### 3.2 APLICAR BIAS ERROS DO GAP-FILLING AOS DADOS

Antes de integrar os dados para 1 hora, os erros de bias do gap-filling são corrigidos. Cada procedimento de gap-filling vem com um erro que é expresso com um bias media. Esse bias media tem que ser avaliada, se for possível para cada estação, no estabelecimento do gap-filling. Como bias default foi usado para o algoritmo os bias avaliados em [Schwandt et al. 2013] (veja Tabela 3 1). Só os bias dos dados de radiação são corrigidas.

**Tabela 3-1: Bias default para a correção dos dados preenchidos**

Bandeira	GHI	DNI	DHI
A	-/+ 0%	-/+ 0	-/+ 0%
B	+0.3%	-0.8%	-0.7%
C	-	+19.0%	-9.0%
D	-2.0%	-2.0%	-1.0%
E	+4.0%		-0.5%
F	-	-	-

Para cada bandeira que é diferente de ‘A’, a correção de bias é aplicada no valor correspondente do mesmo tempo. Se por exemplo um valor de GHI de  $500 \text{ W/m}^2$  foi preenchido com o *gap-filling* para 3 componentes ausentes (lacuna  $\leq 1\text{h}$ ), a bandeira desse valor é “D”. O valor vai ser corrigido para  $0.998 \cdot 500 \text{ W/m}^2 = 499 \text{ W/m}^2$ .

O preenchimento de lacunas descrito no Manual I foi programado para preencher todo tipo de lacuna, por isso a bandeira “F” não existe. Para a possibilidade de usar essa bandeira numa futura outra versão do algoritmo, ela foi mantida na programação. Para o método de *gap-filling* da bandeira “E” para DNI, [Schwandt et al. 2013] não disponibiliza um bias



media e testes do método para uma estação no Brasil também mostraram resultados dispersos. Até a programação de um método de *gap-filling* mais preciso ou uma avaliação profunda dos efeitos desse método no Brasil, os dados de DNI com bandeira "E" não são corrigidos e são gravados com uma alta incerteza (99%). No posterior algoritmo F da correlação com dados derivados de satélites, o algoritmo vai dar preferência aos dados satélites neste caso.

### 3.3 CONVERTER DADOS (MIN → H)

Depois da correção dos bias para dados preenchidos, os parâmetros são integrados conforme Tabela 3-2

de um 1 min para 1 hora. No algoritmo o intervalo da hora anterior é integrado (por exemplo os valores de 00:01 h até 01:00 h são integrados para obter o valor da hora 01:00. Além disso, a temperatura húmida (*dew point temperature* - DPT) é calculada da temperatura ambiental (*air temperature*, ATC) e da humidade relativa (*relative humidity* - RHU) através da aproximação de Magnus:

$$H = \frac{\ln(RHU) - 2}{0.4343} + \frac{17.62 \cdot ATC}{243.12} \quad (3-1)$$

$$DPT = \frac{243.12 \cdot H}{17.62 - H} \quad (3-2)$$

**Tabela 3-2: Integração dos dados de resolução de 1min para dados horários**

Parâmetro	Conversão	Unidade <sub>min</sub>	Unidade <sub>h</sub>
<b>ETR normal</b>	$ETRn_h = \sum_{i=1}^{60} ETRn_{min,i} \cdot \frac{1}{60}$	W / m <sup>2</sup> / min	Wh / m <sup>2</sup>
<b>ETR horizontal</b>	$ETRh_h = \sum_{i=1}^{60} ETRh_{min,i} \cdot \frac{1}{60}$	W / m <sup>2</sup> / min	Wh / m <sup>2</sup>
<b>GHI</b>	$GHI_h = \sum_{i=1}^{60} GHI_{min,i} \cdot \frac{1}{60}$	W / m <sup>2</sup> / min	Wh / m <sup>2</sup>
<b>DNI</b>	$DNI_h = \sum_{i=1}^{60} DNI_{min,i} \cdot \frac{1}{60}$	W / m <sup>2</sup> / min	Wh / m <sup>2</sup>
<b>DHI</b>	$DHI_h = \sum_{i=1}^{60} DHI_{min,i} \cdot \frac{1}{60}$	W / m <sup>2</sup> / min	Wh / m <sup>2</sup>

**Tabela 3-2: Integração dos dados de resolução de 1min para dados horários (continuado)**

Parâmetro	Conversão	Unidade <sub>min</sub>	Unidade <sub>h</sub>
ATC	$ATC_h = \sum_{i=1}^{60} ATC_{min,i} \cdot \frac{1}{60}$	°C	°C
RHU	$RHU_h = \sum_{i=1}^{60} RHU_{min,i} \cdot \frac{1}{60}$	%	%
WSP	$WSP_h = \sum_{i=1}^{60} WSP_{min,i} \cdot \frac{1}{60}$	m / s	m / s
WDI	$WDI_h = \sum_{i=1}^{60} WDI_{min,i} \cdot \frac{1}{60}$	10°	10°
PRC	$PRC_h = \sum_{i=1}^{60} PRC_{min,i} \cdot \frac{1}{100}$	mm/min	cm/h
BPR	$BPR_h = \sum_{i=1}^{60} BPR_{min,i} \cdot \frac{1}{60}$	hPa	mbar

### 3.4 GRAVAR DADOS EM FORMATO TMY3

Diferente aos antigos formatos TMY e TMY2 da NREL, o TMY3 usa o formato CSV (*comma separated value* – valores de dados são separados por vírgulas), que é mais fácil a ler para muitos programas e aplicações como também o SAM ou o Thermoflux. Por isso o algoritmo apresentado tem o objetivo de providenciar os produtos finais no formato TMY3. Para mais informações sobre o formato TMY3 ou as diferenças para os TMY e TMY2 veja por exemplo [Wilcox&Marion 2008].

Um arquivo TMY3 começa com duas linhas de cabeçalho (*header*) que são apresentados em Tabela 3-3 e Tabela 3-4. O código de identificação no 1º header é um número da USAF (*United States Air Force* – Força aérea dos Estados Unidos) que é usado pelos ESOLs nos EUA. Para arquivos de locais fora dos EUA esse número pode ser trocado, por exemplo, com '999999'. A segunda linha do cabeçalho contém 68 campos que incluem informações sobre os campos de dados como o nome e a unidade. Em acordo, depois do cabeçalho, seguem os dados do ano meteorológico em 8,760 linhas e 68 campos de dados (veja Tabela 3-5). No

processamento apresentado é recomendado de processar os dados em conjunto de no máximo um mês, e assim, o número de linhas é menor do que 8,760 e o arquivo gravado ainda não pode ser

lido como TMY por um programa de simulação. Só depois do próximo passo, a correlação com dados satélites, que os dados vão ser juntados para um TMY no algoritmo F.

**Tabela 3-3: TMY3 formato do 1º header (cabeçalho linha 1)**

Campo	Elemento	Unidade / Descrição
1	Código de identificação	Número de seis dígitos da USAF, colocado para 99999 para locais fora dos EUA
2	Nome da ESOL	-
3	Estado da ESOL	Duas letras
4	Fuso horário da ESOL	Horas de Greenwich, negativo oeste
5	Latitude da ESOL	Em graus decimais
6	Longitude da ESOL	Em graus decimais
7	Elevação da ESOL	Em metros

**Tabela 3-4: TMY3 formato do 2º header (cabeçalho linha 2)**

Campo	Elemento
1-68	Nome do campo e unidade (por exemplo campo 1: 'Date (MM/DD/YYYY)')

Tabela 3 5 mostra todos os elementos gravados em arquivo TMY3. Só alguns desses (os mais importantes para a simulação de uma planta heliotermica) foram medidos na ESOL. O resto de parâmetros é preenchido com -9900 (sem valores de dados) ou 99 (bandeiras). As bandeiras de fonte são todos preenchidos com 99. No banco de dados TMY3, essa bandeira sinaliza para dados de radiação se eles foram derivados pelo modelo satélite METSTAT ou SUNY.

No algoritmo C, dados ausentes foram preenchidos com o *gap-filling* e depois no algoritmo D corrigidos com uma adaptação dos bias. Para as bandeiras de incerteza de radiação é assumido que a incerteza de todos os dados é a incerteza do instrumento (exceto DNI com bandeira 'E'). A visão geral de incerteza de medição solarimétrica em [Sengupta et al. 2015] dá como valor para pireliômetros em campo  $\pm 2.5\%$  (DNI) de incerteza padrão e  $\pm 3.0\%$  ( $30^\circ < \text{SZA} < 60^\circ$ ) respectivamente  $\pm 7.0\text{-}10.0\%$  ( $\text{SZA} > 60^\circ$ ) para pirano-

metros (DHI e GHI). [Sengupta et al. 2015] usa o dobro da incerteza ideal de medição com 6% para GHI e DHI e 5% para DNI. Para um futuro trabalho seria interessante executar uma avaliação profunda dos efeitos de diferentes métodos de *gap-filling* para a incerteza dos dados. Isso podia ser feito, por exemplo, com um grande número de ESOLs e dados e uma abordagem de simulação Monte Carlo, criando lacunas artificiais em conjuntos de boa qualidade (veja Endorse 3.2).

Para o algoritmo usado as seguintes incertezas absolutas foram colocadas como incertezas padrões:

GHI & DHI ( $\text{SZA} < 60^\circ$ )  $\rightarrow 4\%$

GHI & DHI ( $\text{SZA} > 60^\circ$ )  $\rightarrow 7\%$

DNI (bandeira F  $\leq 15\%$ )  $\rightarrow 3\%$

DNI (bandeira F  $> 15\%$ )  $\rightarrow 99$

Esses valores dependem da estimativa do usuário da qualidade da medição das ESOLs e podem ser modificados. Porém, o mínimo de incerteza para uma medição em campo não devia ser ultrapassado. Para DNI foi instalado um limite aceitável de bandeira 'F' no intervalo de uma hora. Se mais do que 15% (10min) de uma hora são marcados como 'F', a incerteza desses dados é colocada para 99 e ele será desconsiderado na correlação com dados satélites.

Para mais informações sobre a incerteza de medições com pireliômetros e piranômetros veja

[Meyer et al. 2008], [Sengupta et al. 2015], [Vignola et al. 2012] e [WMO 2010]

As incertezas dos outros dados meteorológicos são colocadas para o número 7 ou 8, conforme o padrão dos TMY3 [Wilcox&Marion 2008]. 7 significa que a incerteza é consistente com as práticas da NWS (National Weather Service – *servicio nacional do tempo* dos EUA) e o instrumento para obter o dado. 8 significa que a incerteza é um pouco maior, devido à interpolação ou estimativa do dado.

**Tabela 3-5: TMY3 Data formato**

<b>Campo</b>	<b>Elemento</b>	<b>Unidade / Resolução</b>	<b>Input</b>
1	Data	MM/DD/YYYY	Ano, mês, dia
2	Horário	HH:MM	Hora, minuto
3	ETR horizontal	1 Wh/m <sup>2</sup>	ETR <sub>h</sub>
4	ETR normal	1 Wh/m <sup>2</sup>	ETR <sub>n</sub>
5	GHI	1 Wh/m <sup>2</sup>	GHI <sub>h</sub>
6	GHI bandeira fonte	1-2	99
7	GHI bandeira incerteza	1 %	4% / 7%
8	DNI	1 Wh/m <sup>2</sup>	DNI <sub>h</sub>
9	DNI bandeira fonte	1-2	99
10	DNI bandeira incerteza	1 %	3% / 99%
11	DHI	1 Wh/m <sup>2</sup>	DHI <sub>h</sub>
12	DHI bandeira fonte	1-2	99
13	DHI bandeira incerteza	1 %	4% / 7%
14	Iluminação global horizontal	100 lx	-9900
15	Ilumin. global horizontal bandeira fonte	1-2	99
16	Ilumin. global horizontal bandeira incerteza	1 %	99
17	Iluminação direta normal	100 lx	-9900
18	Ilumin. direta normal bandeira fonte	1-2	99

**Tabela 3-5: TMY3 Data formato (continuado)**

<b>Campo</b>	<b>Elemento</b>	<b>Unidade / Resolução</b>	<b>Input</b>
19	Ilumin. direta normal bandeira incerteza	1 %	99
20	Iluminação difusa horizontal	100 lx	-9900
21	Ilumin. difusa horizontal bandeira fonte	1-2	99
22	Ilumin. difusa horizontal bandeira incerteza	1 %	99
23	Luminância zênite	10 cd/m <sup>2</sup>	-9900
24	Luminância zênite bandeira fonte	1-2	99
25	Luminância zênite bandeira incerteza	1 %	99
26	Cobertura total do céu	Décimos cobertos	-9900
27	Cobertura total do céu bandeira fonte	A-F, ?	99
28	Cobertura total do céu bandeira incerteza	0-9	99
29	Cobertura opaca do céu	Décimos cobertos	-9900
30	Cobertura opaca do céu bandeira fonte	A-F, ?	99
31	Cobertura opaca do céu bandeira incerteza	0-9	99
32	Temperatura seca	°C	ATC <sub>h</sub>
33	Temperatura seca	A-F, ?	99
34	Temperatura seca	0-9	7/8
35	Temperatura do ponto de orvalho	°C	DPT <sub>h</sub>
36	Temp. do ponto de orvalho bandeira fonte	A-F, ?	99
37	Temp. do ponto de orvalho bandeira incerteza	0-9	7/8
38	Humidade relativa	1 %	RHU <sub>h</sub>
39	Humidade relativa bandeira fonte	A-F, ?	99
40	Humidade relativa bandeira incerteza	0-9	7/8
41	Pressão	mbar	BPR <sub>h</sub>
42	Pressão bandeira fonte	A-F, ?	99
43	Pressão bandeira incerteza	0-9	7/8
44	Direção do vento	10° de norte	WDI <sub>h</sub>

**Tabela 3-5: TMY3 Data formato (continuado)**

<b>Campo</b>	<b>Elemento</b>	<b>Unidade / Resolução</b>	<b>Input</b>
<b>45</b>	Direção do vento bandeira fonte	A-F, ?	99
<b>46</b>	Direção do vento bandeira incerteza	0-9	7/8
<b>47</b>	Velocidade do vento	0.1 m/s	WSP <sub>h</sub>
<b>48</b>	Velocidade do vento bandeira fonte	A-F, ?	99
<b>49</b>	Velocidade do vento bandeira incerteza	0-9	7/8
<b>50</b>	Visibilidade horizontal	1 m (7777=sem limite)	-9900
<b>51</b>	Visibilidade horizontal bandeira fonte	A-F, ?	99
<b>52</b>	Visibilidade horizontal bandeira incerteza	0-9	99
<b>53</b>	Altura do teto (das nuvens)	1 m (7777=sem limite)	-9900
<b>54</b>	Altura do teto bandeira fonte	A-F, ?	99
<b>55</b>	Altura do teto bandeira incerteza	0-9	99
<b>56</b>	Água precipitável	0.1 cm	-9900
<b>57</b>	Água precipitável bandeira fonte	A-F, ?	99
<b>58</b>	Água precipitável	0-9	99
<b>59</b>	Profundidade ótica de aerossol, banda larga	0.001 (sem unidade)	-9900
<b>60</b>	Prof. ótica de aerossol bandeira fonte	A-F, ?	99
<b>61</b>	Prof. ótica de aerossol bandeira incerteza	0-9	99
<b>62</b>	Albedo	0.01 (sem unidade)	-9900
<b>63</b>	Albedo bandeira fonte	A-F, ?	99
<b>64</b>	Albedo bandeira incerteza	0-9	99
<b>65</b>	Profundidade de precipitação líquida	1 mm	-9900
<b>66</b>	Quantidade de precipitação líquida	1 hr (período do campo 65)	-9900
<b>67</b>	Prof. de prec. líquida bandeira fonte	A-F, ?	99
<b>68</b>	Prof. de prec. líquida bandeira incerteza	0-9	99

## 4. CORRELAÇÃO DE DADOS MEDIDOS COM DADOS SATÉLITES

[Gueymard&Wilcox 2009] mostraram que a média anual de longo prazo de GHI pode ser estimada com uma incerteza de  $\pm 5\%$  com só um ou dois anos de medição no local (veja Figura 4-1). Pelo contrário, uma aproximação similar para a média anual de longo prazo de DNI pode necessitar entre 10 e 15 anos. Além disso, se um ano só de medição de DNI for efetuado no 'melhor' período meteorológico, o DNI anual pode ser estimado otimista demais com 8-15%. No mesmo tempo, se for efetuado no 'pior' período, ele pode ser pessimista demais com 13-23% (Variância em cobertura de nuvens afeita anos 'bons' e 'ruins' mais ou menos na mesma gravidade, no entanto, efeitos de atividade vulcânica podem influenciar aerossóis e assim a quantidade de DNI, por isso o maior efeito de variabilidade durante anos 'ruins').

Consequentemente, o conjunto ideal de dados meteorológicos para calcular um valor de energia produzida confiável seria de dados medidos no local por um longo prazo de 20 até 30 anos (*long-term*). Infelizmente, em geral, não existe uma ESOL no local do projeto por todo esse tempo. O normal seria uma medição no próprio local ou perto da futura estação por um ou dois anos (*short-term*). No mesmo tempo dados calculado por modelos usando imagens de satélites geralmente são disponíveis para um longo prazo de 10+ anos. A pratica recomendada para os estudos de pre-viabilidade e passos de *due-diligence* de um projeto é melhorar os dados de satélites long-term com os anos medidos *short-term*. Os diferentes características dos dois conjuntos de dados são apresentados em Tabela 4-1.

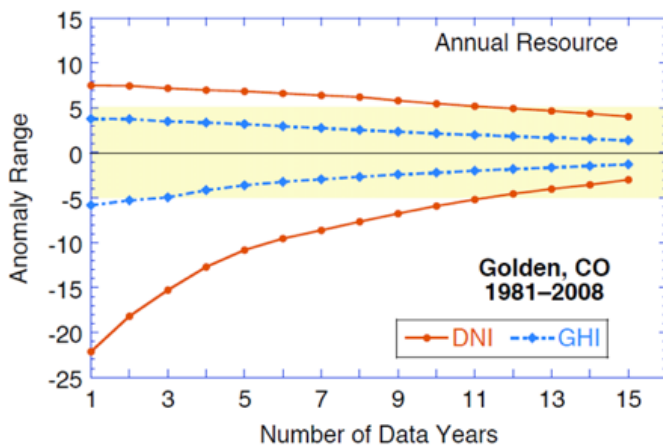


Figura 4-1: Número de anos para estabilizar DNI e GHI no pior dos cenários em Golden, EUA [Gueymard&Wilcox 2009]

**Tabela 4-1: Dados terrestres vs. Dados derivados de imagens satélites.**

	Dados medidos na terra	Dados através de imagens satélites
<b>Incerteza</b>	2-3 %	7+ %
<b>Resolução espacial</b>	Tamanho do sensor 2x2cm <sup>2</sup>	Pixel de satélite ~3x3 km <sup>2</sup>
<b>Resolução temporal</b>	1s integrado para 1 min	15min -3h
<b>Período de dados disponíveis</b>	1-2 anos	10+ anos

Como dados satélites são derivados de modelos que calculam a radiação que chega no solo através de informações sobre a atmosfera, eles geralmente têm uma maior incerteza do que dados que são medidos com um instrumento de alta precisão. Por exemplo, é difícil de saber a espessura de nuvens para calcular a difusão/absorção de radiação. Figura 4-2 mostra um exemplo de cinco dias com dados medidos e dados satélites de DNI em paralelo. O

dia cinco parece ser um dia nublado com pouca radiação direta e grandes variações. A diferença entre os dados *ground* e dados *satellite* é alta. O primeiro dia parece ser um dia de céu claro que tem uma boa conformidade dos dois conjuntos de dados. O objetivo da correlação entre os conjuntos de dados então, é de adaptar os dados satélites usando dados medidos, e assim diminuir a grande incerteza dos dados satélites.




Figura 4-2: Dados medidos (ground) e dados derivados de imagens satélites (satellite) de DNI [Pitz-Paal et al. 2007]

Antes da correlação dos dados, é importante entender todas as diferenças entre dados medidos na terra e dados derivados de satélites e assim também as limitações do procedimento. Além dos problemas de caracterizar nuvens pelos modelos satélites, [Espinhar et al. 2011] identificaram as seguintes limitações na comparação de dados medidos no solo e dados derivados de satélites:

A primeira limitação é a qualidade dos dados medidos no solo. Todos dados medidos devem passar por um processamento de controle de qualidade para garantir dados de referência de boa qualidade.

Um outro problema amplamente encontrado é ligado ao sistema de tempo. O tempo de aquisição pode ser em tempo universal, tempo solar médio, tempo solar verdadeiro ou tempo local. Em seguida, esse tempo pode ser convertido em um outro sistema de tempo na gravação no banco de dados. Os passos da reamostragem temporal em muitos casos não

são especificados e não podem ser compreendidos depois. Além disso, o padrão de definir dados horários nem sempre é aplicado corretamente. O WMO (World Meteorological Organization – Organização mundial de Meteorologia) [WMO 1981] define que o tempo assinado a um dado corresponde ao final do período de medição. Por exemplo, se a radiação solar foi medida entre 10:00 e 11:00, o dado horário é assinado a 11:00. Em alguns casos, o tempo associado a uma medição representa o início, a metade ou um outro ponto do período. A comparação de dois conjuntos com padrão diferente exige uma reamostragem que vai junto com uma perda de qualidade.

Uma limitação severa é devido a grandes diferenças entre os métodos de obter os dados medidos no solo e derivar eles de imagens satélites. Medições ‘ponto-único’ e dados temporalmente integrados (medição no solo) são comparados com dados espacialmente integrados e instantâneos (veja



Tabela 4-1, e). Os dados satélites representam valores medias sobre um pixel de satélite de geralmente vários quilômetros quadrados enquanto a ESOL

mede a radiação que cai em uma área incremental (veja Figura 4-4).


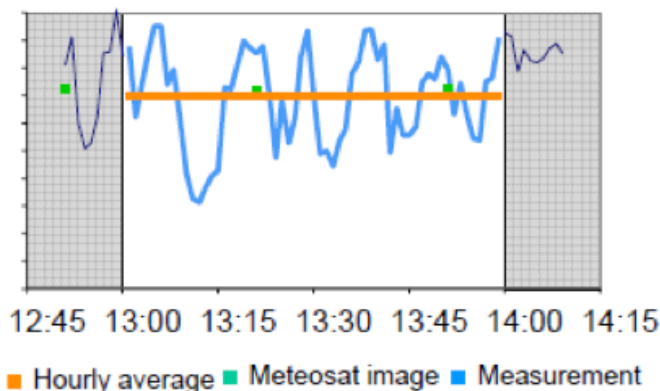


Figura 4-3: Medição terrestre com alta precisão (ponto-único) vs. Pixel (integrado espacialmente) de dados satélites [Pitz-Paal et al. 2007]

A mediação de radiação no solo é instantânea e geralmente integrada para valores de 1 min. O mínimo de resolução para dados satélites é 15 min, mas é normalmente mais alto, dependendo dos dados disponíveis para o local (veja Figura 4-3).

Geralmente uma equivalência entre as medias temporais e espaciais (ergodicidade) é assumido. Esse pressuposto é só correto se o campo é espacialmente homogêneo por uma área bem maior do que um pixel. Isso geralmente é errado se existe uma característica fisiografia significativa na área. Também, outros efeitos locais como reflexões nas encostas entorno ou as sombras de nuvens podem dificultar a comparação.

[Perez et al. 1997] e [Zelenka et al. 1999] analisaram a variabilidade local de GHI usando medições de ESOLs bem calibrados e perto de um ao outro. Foi mostrado que a própria variabilidade é muito variável de uma região por outro e que esse fato não pode ser ignorado. Expressado pela relação entre a variância relativa e o valor médio pela área, eles acharam uma variabilidade de radiação horária de 17 % para uma área com um raio de 10 km. Isso significa que em uma área de 10 x10 km<sup>2</sup>, radiação medida por sensores similares e intercalibrados, mostra o mesmo valor médio, mas difere de hora-por-hora com uma variância relativa de 17%. Portanto, observando uma diferença hora-por-hora de 17 % entre um piranometro localizado dentro de um pixel (veja Figura 4 3) não significa que a estimativa derivada das imagens satélites foi de baixa qualidade. A variabilidade aumenta com a área de surface. Para um raio de 30 km<sup>2</sup> por exemplo chega a 25 %. Com uma aumenta da integração temporal, a variabilidade diminui. Por exemplo ela chega a 10 % para valores diários e um raio de 10 km.



[Zelenka et al. 1999] também analisou a precisão verdadeira de estimativas de radiação no solo com resolução horaria através de imagens satélites. Eles

Figura 4-4: Integração temporal de dados medidos no solo vs. imagens instantâneas de satélites [Pitz-Paal et al. 2007]

manifestaram que para um desvio relativo de 23% (RMSE) entre dados do solo e de imagens satélites, só a metade desse desvio é devido ao método de estimação. A diferença também vem do:

- Erro do instrumento (piranometro 3-5 %)
- Erro devido à variabilidade espacial de radiação solar no pixel (5-8 %)
- Erro devido ao pressuposto de ergodicidade (3-5 %)

Uma outra limitação pode ser causada por diferenças de elevação entre o pixel da imagem satélite e o ESOL (veja Figura 4-5). Se o tamanho do pixel for muito grande e dependendo da topografia do local, as mudanças de elevação podem ser descritas com baixa precisão. Isso pode efetuar por exemplo os dados de temperatura do ar, mas também a radiação que pode diferir de 1% na média mensal para uma diferença de elevação de 300 m [Abdel Wahab et al. 2009].



Figura 4-5: Exemplo de uma diferença de elevação de dois pontos em um pixel de satélite [Espinar et al. 2011]

Apesar dessas limitações e dificuldades na adaptação de dados satélites às medições no solo, o procedimento é necessário para obter um conjunto de dados de longo prazo e alta precisão. Existem

dados satélites cobrando um período de dez anos e mais para quase todas regiões da terra. Eles incluem a variabilidade interanual, que é crucial para a avaliação do recurso solar em um local. [Sengupta et al. 2015] faz uma distinção entre quatro metodologias para combinar dados *short-term* e *long-term* que serão apresentados nesse capítulo:

1. O método de relação / correção linear (ratio method) [Gueymard&Wilcox 2009]
2. Combinar vários conjuntos de dados com ponderação [Meyer et al. 2008]
3. Adaptar a distribuição de frequência [Schumann et al. 2011]
4. Polinômio de 3º grau [Mieslinger et al. 2014]

Existem também outros métodos na literatura ([Bender et al. 2011], [Cebauer&Suri 2010], [Gueymard et al. 2012], [Harmsen et al. 2014], [Thuman et al. 2012]) que são geralmente usados de fornecedores de dados comerciais. Atualmente não existe um estudo que compara a performance desses métodos, desde os detalhes deles normalmente não são publicados. Finalmente, também foi apresentado um método de interpolação para realizar correções de dados *long-term* na escala regional invés de um local específico de [Ruiz-Arias et al. 2015].

#### 4.1 O MÉTODO DE RELAÇÃO (RATIO METHOD / LINEAR CORRECTION)

O método basicamente calcula a relação entre os conjuntos simultâneos durante um período de cálculo da média (por exemplo uma hora, um dia ou um mês). Depois, essas relações são aplicadas ao conjunto de dados *long-term* para melhorar a estimativa do longo prazo para esse local.

Esse método consegue muito bem remover os bias entre os conjuntos *short-term* e *long-term* no período de aplicação, no entanto, esses bias podem variar de ano por ano ou de estação por estação do ano.

- Em um cenário ideal, a variabilidade do bias de ano por ano é baixa como em El Paso na Figura 4.6. Nesse caso, um fator de correção simples baseado no método de relação pode ser aplicado. Esse caso é mais provável em áreas com muito sol.
- Em locais que tem uma variabilidade aleatória de mês por mês alta como em McAllen na Figura 4.6 uma correção precisa do bias para um conjunto de longo prazo vai ter uma alta incerteza.

- Em um terceiro cenário existem fortes características sazonais no local (veja Bondville e Eugene na Figura 4-7. Nesse caso, pode ser necessário de colher mais dados de medição no solo para confirmar ou definir essas características. Ao final isso também ia levar a uma aplicação de um fator de correção simples como no primeiro cenário.

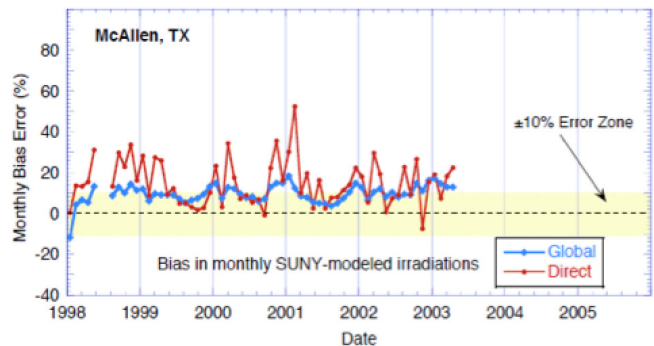
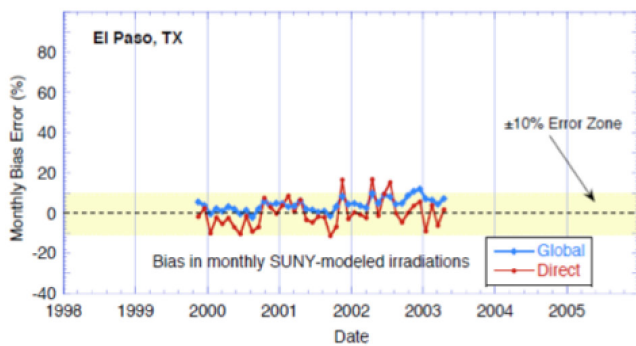


Figura 4-6: Bias mensal de dados satélites com referência a dados medidos para El Paso, EUA (esquerda), Mc Allen, EUA (direita) [Gueymard&Wilcox 2009]

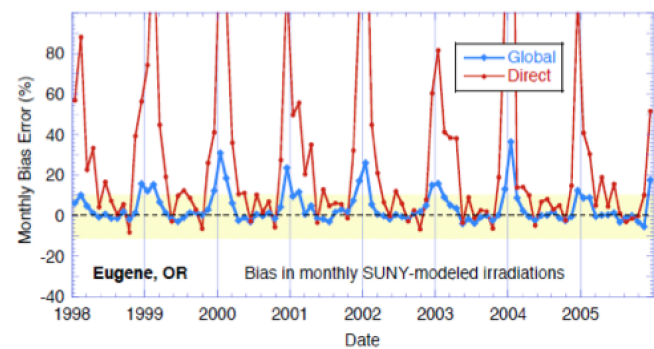
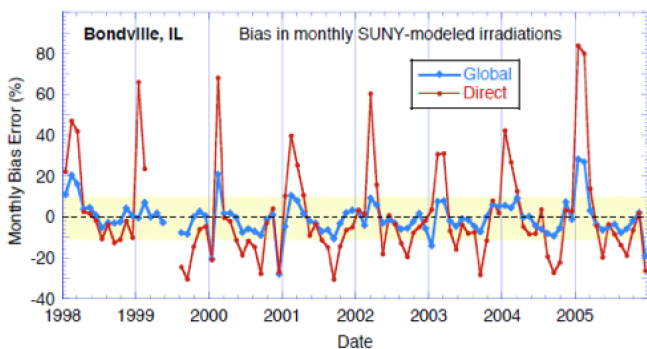


Figura 4-7: Bias mensal de dados satélites com referência a dados medidos para Bondville, EUA (esquerda) e Eugene, EUA (direita) [Gueymard&Wilcox 2009]

## 4.2 COMBINAR VÁRIOS CONJUNTOS DE DADOS COM PONDERAÇÃO

O segundo método é a combinação de diferentes conjuntos de dados com uma ponderação. [Meyer et al. 2008] sugeriu nesse contexto uma ponderação com o inverso da 1-sigma incerteza de cada

conjunto de dados  $j$  (veja equação (4.1)). Assim, a melhor estimativa de radiação é calculada em um período simultâneo que inclui dados medidos no solo ou derivados de satélites

$$I = \frac{1}{\sum \sigma_j^{-1}} \cdot \sum_{j=1}^n \sigma_j^{-1} \cdot I_j \quad (4-1)$$

com:  $\sigma_j$  = Incerteza (1-sigma) do conjunto j  
 $l_j$  = media temporal de radiação do conjunto durante o período definido

Figura 4-8 mostra os resultados de uma aplicação desse método. No período que existem conjuntos de dados simultâneos, a melhor estimação é calculada através de dois conjuntos de dados medidos e dois conjuntos de dados derivados de imagens satélites. Assumindo que os desvios do valor verdadeiro seguem uma distribuição normal e são estatisticamente independentes, a lei de propagação de erros de Gauss pode ser aplicado para calcular a combinação das incertezas dos diferentes conjuntos.

Figura 4-9 apresenta curvas que mostram que o segundo conjunto de dados não necessariamente

precisa ser da mesma qualidade do conjunto de base para obter um conjunto combinado de melhor qualidade. Por exemplo a combinação de um conjunto de dados de uma incerteza de 6% com um segundo conjunto de dados de 5% conduz um conjunto com uma incerteza de cerca 4%.

[Meyer et al. 2008] também mostrou que, com o uso de mais do que dois conjuntos de dados independentes, a qualidade do conjunto combinado pode ser aumentada mais ainda. Portanto, o uso de conjuntos de dados com uma incerteza maior do que 10 %, ele não recomenda. Para aplicar esse método é importante verificar se os conjuntos de dados usados realmente são independentes e também que não existem correlações entre eles.

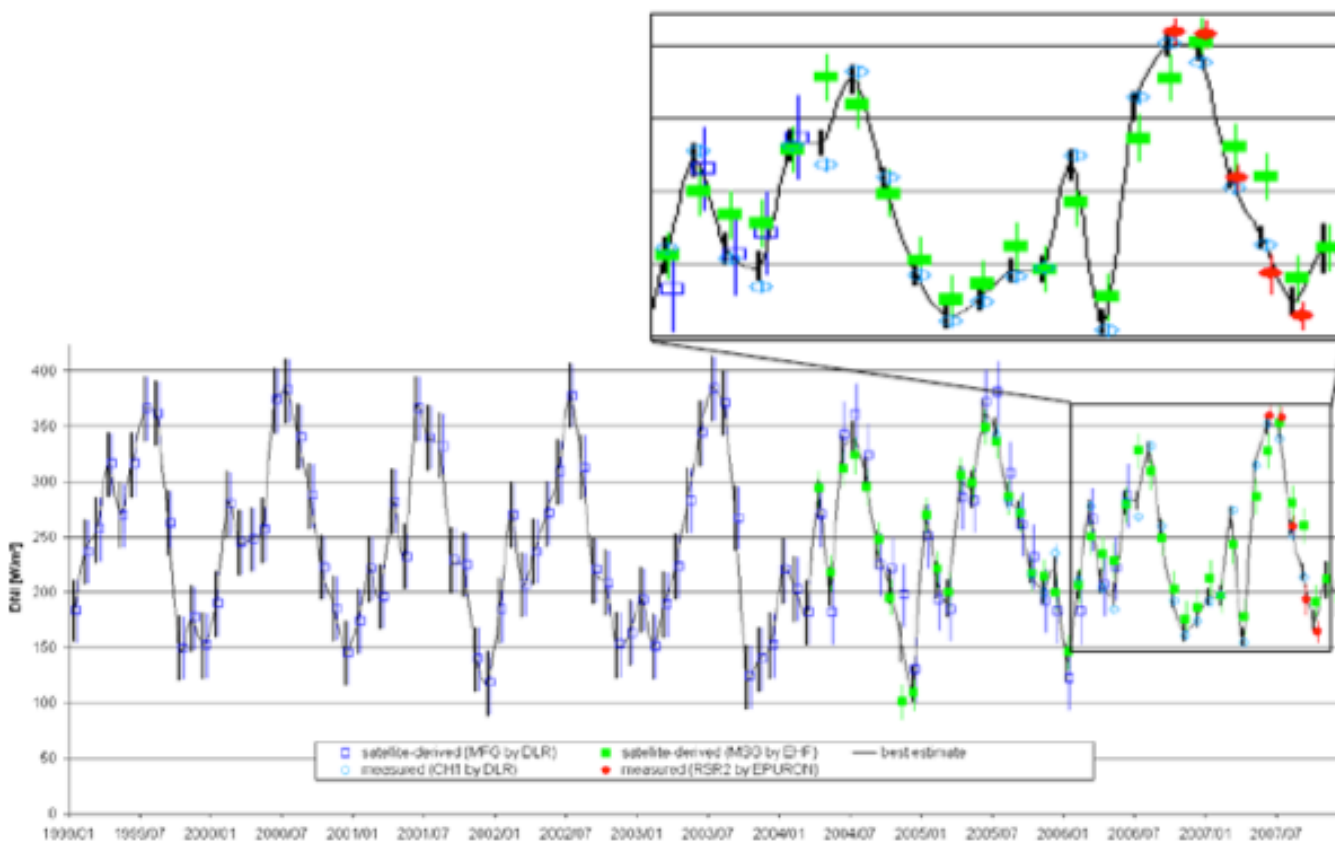


Figura 4-8: Serie de tempo mensal para vários conjuntos de dados correlacionados [Meyer et al. 2008]




Figura 4-9: Incerteza resultando se combinar um conjunto de dados com 2%, 4%, 6%, ou 8% de incerteza total com um conjunto de dado adicional de diferentes qualidades [Meyer et al. 2008]

### 4.3 ADAPTAR A DISTRIBUIÇÃO DE FREQUÊNCIA

Uma outra abordagem para reduzir a incerteza de dados satélites de longo prazo usando dados medidos *short-term* com alta precisão foi desenvolvido por [Schumann et al. 2011]. Nesse método, a distribuição da frequência dos dados medidos no solo é usada para melhorar o conjunto *long-term*. O método deles resultou em erros de bias reduzidos e integrais de Kolmogorov-Smirnov (KSI) melhoradas, sobretudo para dados de DNI (veja mais sobre KSI em seção 4.5). O método até mostrou resultado bons se apenas três meses de dados medidos no solo foram disponíveis para correlação. Em particular, o método de [Schumann et al. 2011] mostra que apenas um ano completo de dados *ground* é suficiente para obter melhorias significantes dos conjuntos satélites de DNI. Para GHI o método mostrou resultados menos bem. O método é baseado em estudos prévios de [Carrow 2008] e [Beyer et al. 2010] que usaram também a

distribuição de frequência invés de uma técnica simples de relação para melhorar o conjunto satélite. Isso considera o fato que a distribuição de frequência de DNI tem uma grande influencia na produção de energia de estacoes CSP, igual a distribuição de frequência da velocidade do vento tem uma alta influência na produção de energia em plantas eólicas. Figura 4 10 mostra o método de “treinar” os dados satélites usando períodos de tempo sobrepostos de dados medidos no solo. A diferença nos CDFs dos dados de treino é aplicada aos dados de satélite de teste, produzindo um conjunto de dados corrigidos (2ª imagem de cima). As duas imagens em baixo mostram como os CDFs dos dados satélites são adaptados para uma nova distribuição de frequência baseada nos fatores de correção declaradas com os dados de solo. Apesar das melhorias oferecidas pelo método de [Schumann et al. 2011], permanecem bias significantes no DNI como demonstrado de [Killius&Schroedter-Homscheidt 2012].

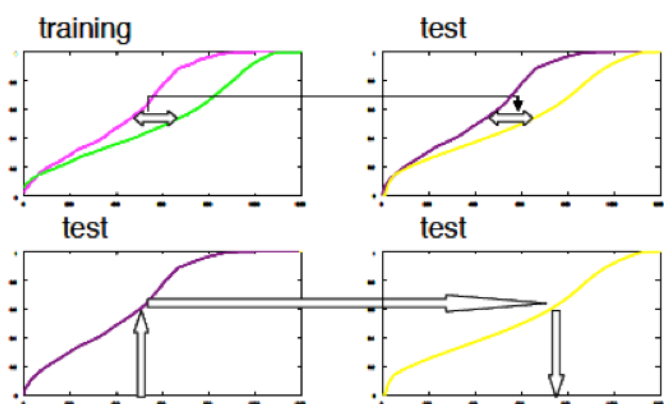


Figura 4-10: Método de [Schumann et al. 2011]

1ª imagem de cima: CDF de tempo de treinamento dos conjuntos sobrepostos de dados ground e dados satélites

2ª imagem de cima: CDF do conjunto de dados satélites no período de teste

1ª imagem de abaixo: Mapeamento de valores de radiação de satélite original ao CDF original (seta e fundo da 2ª imagem abaixo). O CDF original primeiro é mapeado para produzir um CDF corrigido e depois o CDF corrigido é ajustado aos valores dos dados satélites. Magenta: dados satélites do conjunto de treinamento; roxo: dados de satélite do conjunto de teste; amarelo: dados satélites corrigidos.

#### 4.4 POLINÔMIO DE 3º GRÃO

Um método para reduzir os erros de bias para quase zero e especialmente minimizar os bias das radiações mais altas que são usadas para o dimensionamento da planta foi apresentado de [Mieslinger et al. 2014]. Ao contrário dos métodos apresentados acima nesse capítulo, o método não considera apenas os erros sistemáticos, mas também erros aleatórios que aparecem na comparação de dados medidos no solo e dados satélites. Erros aleatórios podem ser causados pela dificuldade de determinar a espessura vertical de nuvens em imagens satélites ou por

erros 'parallax'. Um erro 'parallax' é chamado uma mudança de valores horários geralmente causado por nuvens. Ele acontece quando nuvens observadas pelo satélite não combinam com o local atual.

O princípio de adaptação do método é a aplicação de uma relação polinomial de terceira ordem ao invés de um modelo de regressão simples, para ter em conta tanto os erros sistemáticos quanto os erros aleatórios. Para incluir os erros sistemáticos, a base do método é um modelo de regressão que recebe condições adicionais. Se baseado no fato que intensidades baixas de radiação muitas vezes são superestimadas e intensidades altas de radiação muitas vezes são subestimadas e vice-versa, [Mieslinger et al. 2014] acharam mais razoável de usar um polinômio de 3º grau ao invés de uma função de regressão linear simples:

$$y(x) = p_1 x^3 + p_2 x^2 + p_3 x + p_4 \quad (4-2)$$

O vetor  $p(p_1, p_2, p_3, p_4)$  modifica os dados satélites para combinar melhor com os dados medidos no solo (veja Figura 4-11). Desde valores de radiação a noite são zero e não existem valores negativos de radiação  $p_4$  deve ser zero. Uma outra condição é que o conjunto adaptado deve ter um bias na faixa de pelo menos da média da incerteza de medições no solo. Do ponto de vista estatístico as medições no solo são consideradas verdadeiras então a seguinte equação pode ser aplicada:

$$\overline{y(x)} - \overline{y_{grad}(x)} = 0 \quad (4-3)$$

Consequentemente os níveis de liberdade são diminuídos para dois, desde  $p_4=0$  e  $p_1$  pode ser descrito como função de  $p_2$  e  $p_3$ . A função de custo  $J$  é

$$J(p_2, p_3) = \frac{1}{2N} \sum_{i=1}^N (y - y_{grad})^2 \quad (4-4)$$

Minimizando  $J$  com respeito a  $p_2$  e  $p_3$  resulta em um algoritmo de adaptação sem bias onde a diferença

de valores de input em quadrado causa grandes desvios, então sendo corrigido mais intenso do que menores. A adaptação com esse algoritmo já mostra um bias e KSI melhorada. No entanto, para ponderar mais os valores altos de radiação, uma ponderação simples e linear é aplicada (veja equação (4-5)). A ponderação é incluída na derivada da função de custo. Para a maioria dos locais na terra o máximo de medição no solo em resolução horaria não excede  $1,100 \text{ W/m}^2$ .

$$w(x) = \frac{x}{\max(x)} \quad (4-5)$$

O Método de [Mieslinger et al. 2014] mostra melhorias significativas nas diferenças entre os dados medidos e modelados com altos valores de irradiância. Usando o critério de que um conjunto de dados adaptado devia demonstrar um bias media relativa comparável a medições no solo de alta qualidade (+2%), o método conseguiu até exceder esse limite. Além disso foi demonstrado que forçando o bias para zero reduz consideravelmente o KSI dos valores derivados de satélites. No entanto, para validar este método ainda são necessários teste adicionais em diferentes zonas climáticas e topográficas

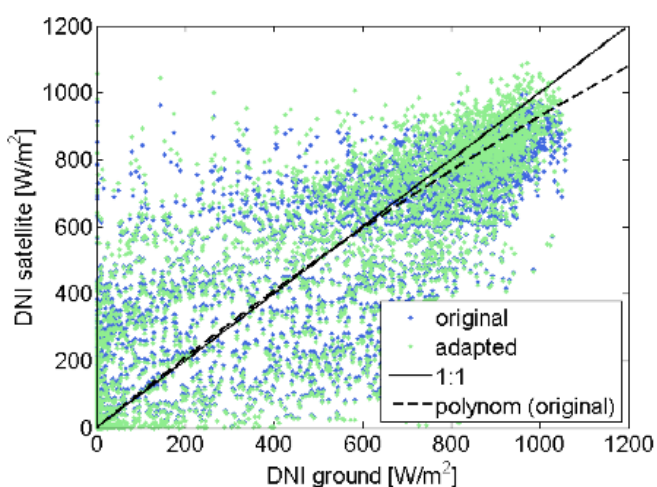


Figura 4-11: Gráfico de dispersão de dados medidos no solo e dados de satélites originais e adaptados; A linha tracejada mostra o polinômio aplicado aos dados satélites.

## 4.5 MÉTODO DESENVOLVIDO

Para escolher o método para a programação do algoritmo E\_Correlação foi experimentado com alguns métodos de correlação, tais como, Linear, Polinômio de 3º grau e até uma abordagem de Redes Neurais Artificiais, tendo encontrado melhores resultados para a correlação linear. O método de correlação linear usado é baseado em [Hidalgo&Mau 2012] e para achar a constante mais adequada da correlação linear é usada uma função custo igual no artigo de [Mieslinger et al. 2014] O algoritmo tem os seguintes passos para a correlação que serão apresentados com mais detalhe nessa seção:

1. Escolher o conjunto de dados satélites (DADOS-SAT)
2. Escolher o conjunto de dados de medição no solo (DADOS-MED)
3. Verificar dados em comum e colocar em ordem
4. Calcular grandezas estatísticas (antes da correlação)
5. Correlação dos dados
6. Calcular grandezas estatísticas (depois da correlação)
7. Aplicar bias avaliado aos dados de longo prazo

### 4.5.1 ESCOLHER O CONJUNTO DE DADOS SATÉLITES (DADOS-SAT)

Nesse passo os dados satélites que são simultâneos com os dados de medição do solo devem ser escolhidos. Se esse período é espalhado por dois ou mais arquivos, eles podem ser escolhidos, desde o algoritmo vai achar o período simultâneo automaticamente. Só não devia ser escolhido um período de dados com lacunas (por exemplo Janeiro 2013 até Novembro 2013 e Janeiro 2014 até Junho 2014).

#### 4.5.2 ESCOLHER O CONJUNTO DE DADOS DE MEDIÇÃO NO SOLO (DADOS-MED)

Nesse passo os dados de medição no solo devem ser escolhidos. Eles geralmente são gravados em arquivos que incluem dados de um mês. Se um período de dados satélites maior é escolhido do que disponível o algoritmo corta automaticamente esses meses adicionais.

#### 4.5.3 VERIFICAR DADOS EM COMUM E COLOCAR EM ORDEM

Nesse passo o algoritmo classifica os dois conjuntos de dados em ordem crescente e corta períodos de dados que não são simultâneos.

#### 4.5.4 CALCULAR GRANDEZAS ESTATÍSTICAS (ANTES DA CORRELAÇÃO)

Esse passo é importante para saber as diferenças entre os conjuntos de dados antes da correlação. As mesmas grandezas estatísticas serão calculadas de novo depois da adaptação dos dados satélites para avaliar o resultado da correlação. As grandezas estatísticas usadas são de [Espinhar et al. 2011] e calculadas com as seguintes equações:

**NDATA: Quantidade de dados**

$$NDATA = N_v \quad (4-6)$$

**MREF: media dos dados de referência (DADOS-MED)**

$$MREF = \frac{1}{N_v} \sum_{k \in K_v} r(k) \quad (4-7)$$

**MBE & MBEr: media do erro de bias & media do erro de bias relativo**

$$MBE = \frac{1}{N_v} \sum_{k \in K_v} (m(k) - r(k)) \quad (4-8)$$

$$MBEr = \frac{MBE}{MREF} \quad (4-9)$$

**STDE & STDEr: desvio-padrão do erro & desvio-padrão do erro relativo**

$$STDE = \sqrt{\frac{1}{N_v} \sum_{k \in K_v} ((m(k) - r(k)) - MBE)^2} \quad (4-10)$$

$$STDEr = \frac{STDE}{MREF} \quad (4-11)$$

**RMSE & RMSEr: erro médio quadrático e erro médio quadrático relativo**

$$RMSE = \sqrt{\frac{1}{N_v} \sum_{k \in K_v} (m(k) - r(k))^2} = \sqrt{MBE^2 + STDE^2} \quad (4-12)$$

$$RMSEr = \frac{RMSE}{MREF} \quad (4-13)$$

**MAE & MAEr: media do erro absoluto e media do erro absoluto relativo**

$$MAE = \frac{1}{N_v} \sum_{k \in K_v} |m(k) - r(k)| \quad (4-14)$$

$$MAEr = \frac{MAE}{MREF} \quad (4-15)$$

**CC: coeficiente de correlação**

$$CC = \frac{1}{\sqrt{\sigma_m \sigma_r}} \sum_{k \in K_v} (m(k) - \bar{m})(r(k) - \bar{r}) \quad (4-16)$$

Com:

$$\bar{m} = \frac{1}{N_v} \sum_{k \in K_v} m(k) \quad \sigma_m = \sqrt{\frac{1}{N_v} \sum_{k \in K_v} (m(k) - \bar{m})^2}$$

$$\bar{r} = \frac{1}{N_v} \sum_{k \in K_v} r(k) \quad \sigma_r = \sqrt{\frac{1}{N_v} \sum_{k \in K_v} (r(k) - \bar{r})^2}$$



**KSI: integral do teste Kolmogorov-Smirnov [Espinar et al. 2009]**

O KSI é um valor para quantificar a diferença entre dois CDFs. Para o CDF<sub>m</sub> e o CDF<sub>r</sub> dos conjuntos de dados m e r,

$$\begin{aligned} CDF_m(p) &= \frac{\#\{k \in K_v / m(k) \leq s_{m,r}(p)\}}{N_v} \\ CDF_r(p) &= \frac{\#\{k \in K_v / r(k) \leq s_{m,r}(p)\}}{N_v} \end{aligned} \quad (4-17)$$

Com #A sendo o cardeal do conjunto A.

X seja um vetor linear de M bins{x(m)} entre x<sub>min</sub>=s<sub>m,r</sub>(1) e x<sub>max</sub>=s<sub>m,r</sub>(P) com:

$$x(m) = x_{min} + (m-1)dm \quad (4-18)$$

Com

$$dm = \frac{x_{max} - x_{min}}{M}$$

[Espinar et al. 2009] colocou o número de bins para 100.

A diferença D(m) entre os dois CDFs para o intervalo [x(m),x(m+1)] é definido com:

$$D(m) = \max \left\{ \frac{|CDF_m(p) - CDF_r(p)|}{s_{m,r} \in [x(m), x(m+1)]} \right\} \quad (4-19)$$

O KSI, ao final, é expressado em % e é definido com:

$$KSI = \frac{dm}{a_{critical}} \sum_{m=1}^M D_m \quad (4-20)$$

Com o coeficiente a<sub>critical</sub> que é definido para N<sub>v</sub>>35 com:

$$a_{critical} = \frac{1.63}{\sqrt{N_v}} (x_{max} - x_{min}) \quad (4-21)$$

Se o KSI é menor do que 100%, a hipótese que os dois conjuntos de dados têm o mesmo CDF não pode ser rejeitada com um level de 99% de confiança. O quanto menor o KSI, quanto mais similar o CDF. Acima de 100%, a chance de ter dois CDF diferentes aumenta com o KSI.

#### 4.5.5 CORRELAÇÃO DOS DADOS

Esse é o passo principal do algoritmo, que foi dividido nos seguintes passos:

1. Primeiro todos valores de radiação (nos DADOS-MED e nos DADOS-SAT) que são menos ou igual a 100 W/m<sup>2</sup> são desconsiderados, como sugerido de [Hidalgo&Mau 2012].

2. Uma função de custo bruta é calculada através da seguinte equação:

$$J = \frac{1}{2N} \sum_{i=1}^N (DADOS_{MED_i} - DADOS_{SAT_i})^2 \quad (4-22)$$

3. A melhor constante p<sub>1</sub> para a adaptação linear dos DADOS-SAT (veja equação (4 23)) é procurado, usando a função de custo (veja equação (4 24)). O p<sub>1</sub> que resulta no mínimo da função de custo é escolhido.

$$DADOS_{SAT_{adaptados}} = p_1 \cdot DADOS_{SAT} \quad (4-23)$$

$$J = \frac{1}{2N} \sum_{i=1}^N (DADOS_{MED_i} - DADOS_{SAT_{adaptados}_i})^2 \quad (4-24)$$

O resultado da correlação linear dos dados horários de DNI é mostrado em Figura 4-12. No eixo x estão os dados medidos e no eixo y os dados de satélite. Os dados em vermelho são os dados satélites originais de DNI e os dados em amarelo os dados satélites adaptados. A função linear que relaciona os dados medidos com os dados de satélite é apresentada em azul.




Figura 4-12: Correlação linear dos dados

#### 4.5.6 CALCULAR GRANDEZAS ESTATÍSTICAS (DEPOIS DA CORRELAÇÃO)

Veja seção 4.5.4.

#### 4.5.7 APLICAR BIAS AVALIADO AOS DADOS DE LONGO PRAZO

Depois de obter um bom resultado na correlação dos conjuntos com o período simultâneo de um ano, os outros anos de dados satélites são adaptados conforme o bias encontrada.

Figura 4-13 mostra as distribuições de probabilidade para três series temporais de um ano de valores DNI: os valores médios na ESOL, os valores derivados de imagens satélites e os valões satélites corrigidos.

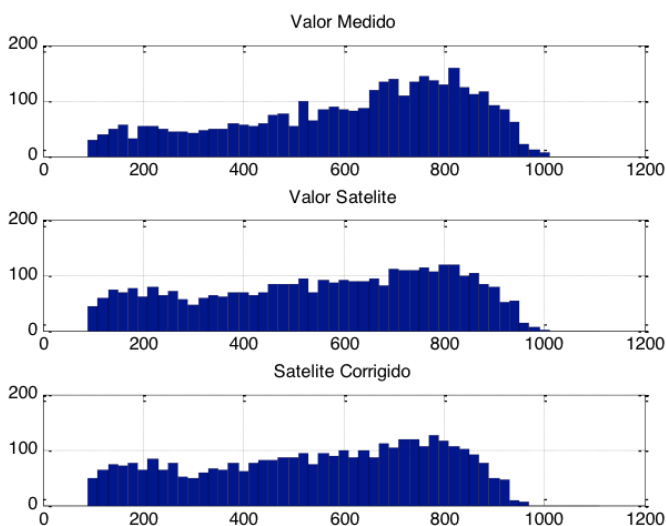


Figura 4-13: Distribuição de probabilidades dos valores correlacionados

## 5. CRIAÇÃO DE UM ANO METEOROLÓGICO TÍPICO (TMY) E UM MY90

Hoje em dia, a prática mais usada para prever a produção de energia de plantas heliotérmicas é a simulação de performance da média anual de longo prazo usando um conjunto de dados meteorológicos típico para o local, um ano meteorológico típico, ou TMY (*Typical Meteorological Year*). Ele representa a média de longo prazo ou a probabilidade de 50% de excedência (P50) de DNI para o local do projeto. Para uma avaliação de risco mais conservadora, é

comum de também calcular a probabilidade de 90% de excedência (P90), estimando a incerteza do DNI de longo prazo que depende da incerteza do conjunto de dados e da variabilidade anual (veja Figura 5 1). A incerteza do conjunto de dados consiste da incerteza no processo de medição dos dados e da incerteza do método para adaptação dos dados derivados de satélites a dados medidos no solo.

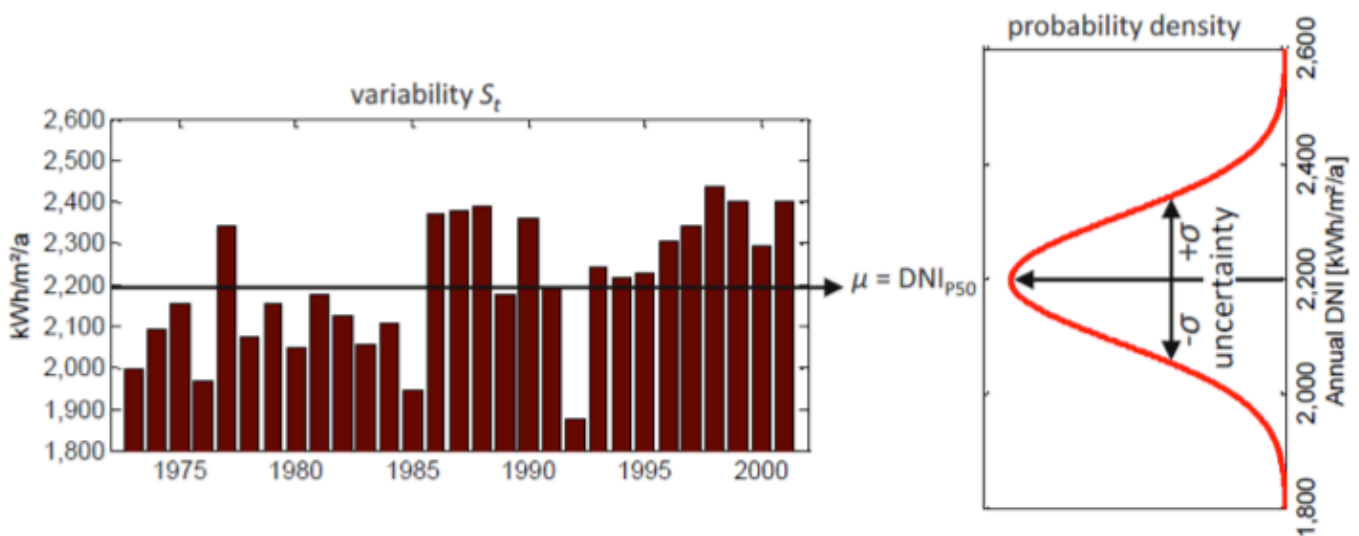


Figura 5-1: Variabilidade anual e incerteza do conjunto de dados DNI [Röttinger et al. 2015]

O algoritmo F (veja Figura 1-2) para criar o TMY segue principalmente o artigo de [Wilcox&Marion 2008] que será apresentado na primeira parte desse capítulo. O alvo é criar um ano com valores horários de radiação solar e outros parâmetros meteorológicos através de um conjunto de dados com vários anos meteorológicos. O TMY deve representar um ano que caracteriza as condições meteorológicas em um local específico para um período de tempo mais prolongado. Um bom TMY deve ficar muito perto dos valores médios e assim representar o valor P50.

Para obter um P90 de radiação / geração de energia existem três métodos:

1. Assumir uma distribuição normal para a incerteza dos dados e uma relação direta de

- 1:1 de DNI para produção de energia. O P90 de radiação e da produção de energia é calculado com a incerteza e a radiação anual do TMY respectivamente a produção de energia anual simulada com o TMY. Esse é o método mais simples. Porém, ele inclui o ponto fraco que a relação da incerteza de DNI e da produção de energia em geral não é linear.

2. Outro método é criar um ano meteorológico que representa o P90 (MY90), com o método parecido com a criação de um TMY. Só que os meses não são típicos para a média de longo prazo, mas para a probabilidade de excedência de 90%. O MY90 depois é usado para simulação de um valor P90 de produção anual de energia. Esse método costuma a produzir P90 mais realísticos do que o primeiro.

3. O terceiro método usa uma abordagem probabilística com a criação de múltiplos anos meteorológicos de amostra, conforme a incerteza e a variabilidade interanual do conjunto de dados. Desse jeito a incerteza dos dados e a variabilidade interanual são incluídas na simulação de um valor P90 de produção anual de energia de uma maneira mais realística do que nos primeiros dois métodos.

O algoritmo F usa o segundo método para criar um MY90 além do TMY. Porém os outros dois métodos para obter um valor P90 de produção anual de energia serão também apresentados em breve na segunda parte do capítulo.

### 5.1 TYPICAL METEOROLOGICAL YEARS (TMYs)

Os primeiros TMYs foram criados dos Sandia Natial Laboratorios nos Estados Unidos em 1978 (veja Hall). O método para derivar esses TMYs, chamado

o “Sandia method” foi usado depois da NREL para criar as bases de dados TMY2 e TMY3 que são baseados em períodos de tempo diferentes e usam uma ponderação modificada. As diferenças na ponderação serão discutidas em baixo na explicação do método. Nesse relatório todos os anos meteorológicos típicos serão chamados de TMY desde isso é o termo mais usado. Os termos TMY2 e TMY3 são mais usados ou para a base de dados da NREL para locais nos Estados Unidos ou para desvrevir a formatação dos arquivos. Os arquivos TMY criados pelo algoritmo F serão no formato de TMY3, desde ele é mais aplicável para a posterior simulação.

O método Sandia é uma abordagem empírica que seleciona meses individuais de anos diferentes para construir um ano representando a média de longo prazo. Figura 5-2 mostra uma visão geral do método da criação de um TMY. Para cada mês, o mês com o CDF que é mais parecido com CDF da média de longo prazo é escolhido.

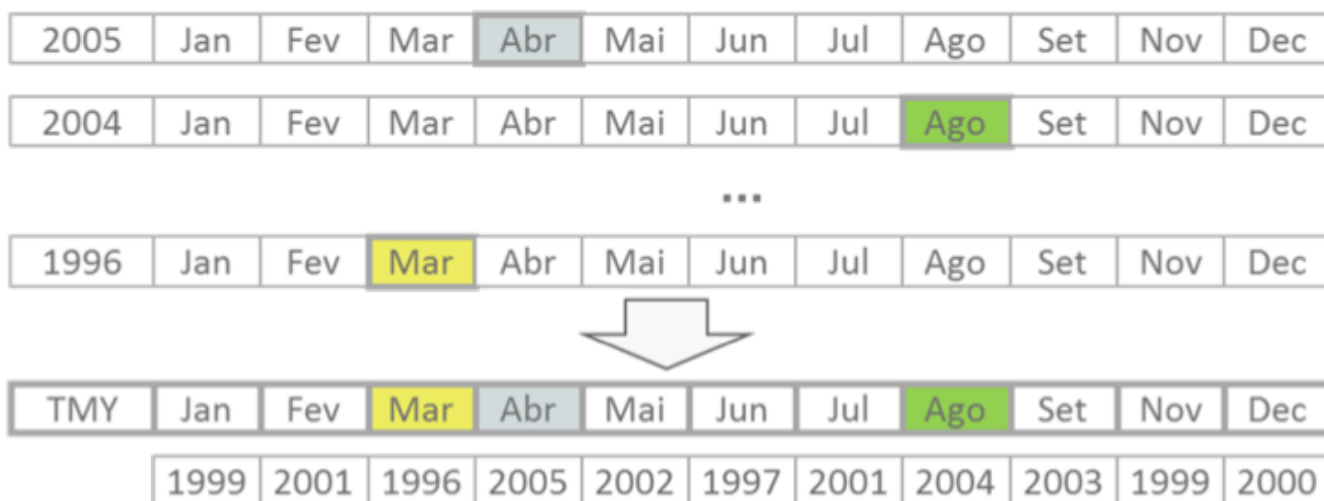


Figura 5-2: Criação de um TMY

Se por exemplo 30 anos de dados são disponíveis, os 30 Janeiros são examinados e o Janeiro considerado o mais típico é selecionado para ser incluído no TMY. Os outros 11 meses são tratados do mesmo jeito e os 12 meses escolhidos são concatenados para completar um ano. Figura 5 3 mostra os CDF de longo prazo, o CDF do mês do ano menos parecido, o CDF

do mês do ano mais parecido e o CDF do mês do ano escolhido de GHI. Nem sempre o CDF mais parecido para um parâmetro é escolhido, desde vários parâmetros com diferente ponderação podem ser considerados. Entretanto, o CDF escolhido deve ser parecido ao CDF de longo prazo igual em Figura 5-3.

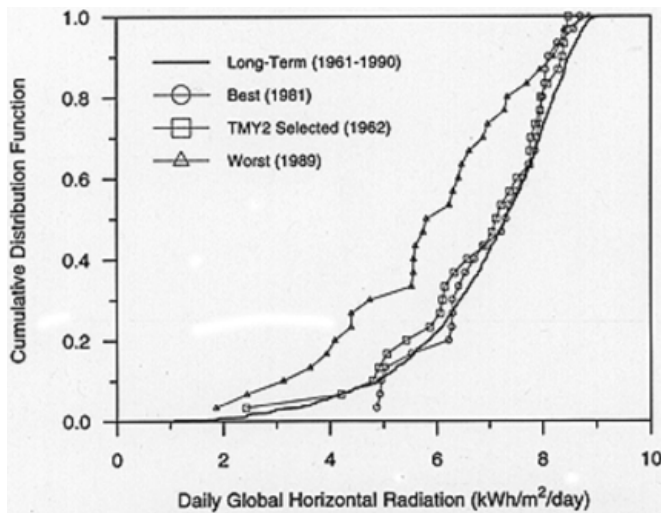


Figura 5-3: Escolher o CDF mais parecido com o CDF da media de longo prazo [Wilcox&Marion 2008]

Para mais informações sobre o método veja: [Hall et al. 1978], [Wilcox&Marion 2008] and [Marion/Urban 1995].

Para a programação o método foi classificado nos seguintes passos:

1. Escolher os pesos para os parâmetros
2. Escolher os arquivos dos anos meteorológicos
3. Converter dados horários para dados diários
4. Dividir anos em meses

5. Calcular média de todos os dias de um mês
6. Comparar meses com o mês médio (usando estatística Finkelstein-Schafer)
7. Aplicar os pesos aos parâmetros para obter valores WS (*weighting sum*)
8. Escolher o mês com o maior valor WS
9. Concatenar meses para um ano

Em seguinte, esses passos serão brevemente explicados.

### 5.1.1 ESCOLHER OS PESOS PARA OS PARÂMETROS

Tabela 5 1 mostra diferentes tipos de ponderação para criar um TMY. O método da Sandia e da NREL considera o máximo, o mínimo e a média de temperatura seca e húmida e o máximo e a média de velocidade do vento. No método Sandia, GHI tem um grande peso enquanto DNI não é considerado. O NREL já distribui mais os pesos e inclui também DNI. Na avaliação do recurso solar do Upington Solar Park na Africa do Sul, o Geomodel Solar deu uma grande emphasis nos componentes de radiação solar com o objetivo de criar um típico ano solar. No algoritmo F a ponderação predefinida é o da NREL e pode ser modificado conforme as preferencias do usuário.

Tabela 5-1: Ponderação de parâmetros para criação de um TMY (continuado)

Parâmetro	Método Sandia (TMY)	NREL (TMY2/TMY3)	GeomodelSolar – Upington Solar Park
Temperatura seca (max.)	1/24	1/20	-
Temperatura seca (min.)	1/24	1/20	-
Temperatura seca (media)	2/24	2/20	1/11
Temperatura húmida (max.)	1/24	1/20	-
Temperatura húmida (max.)	1/24	1/20	-

**Tabela 5-1: Ponderação de parâmetros para criação de um TMY (continuado)**

Parâmetro	Método Sandia (TMY)	NREL (TMY2/TMY3)	GeomodelSolar – Uppington Solar Park
Temperatura húmida (media)	2/24	2/20	-
Velocidade do vento (max.)	2/24	1/20	-
Velocidade do vento (media)	2/24	1/20	-
GHI	12/24	5/20	6/11
DNI	-	5/20	4/11

### 5.1.2 ESCOLHER OS ARQUIVOS DOS ANOS METEOROLÓGICOS

Nesse passo os anos disponíveis para criar o TMY tem que ser escolhidos. A recomendação é de usar pelo menos 10 anos de dados. Quanto maior a quantidade de anos disponíveis, quanto mais típico o ano produzido.

### 5.1.3 CONVERTER DADOS HORÁRIOS PARA DADOS DIÁRIOS

Nesse passo do algoritmo, os dados com resolução temporal de 1 hora são convertidos para dados diários. Isso significa que, dependendo do parâmetro, a soma / a media / o máximo ou o mínimo de 24h é calculado.

### 5.1.4 DIVIDIR ANO EM MÊS

Os dados que foram lidos na área de trabalho pelo algoritmo são conjuntos anuais e cada ano é dividido em 12 meses nesse passo.

### 5.1.5 AGLOMERAR DADOS DE LONGO PRAZO PARA CADA MÊS

Para cada mês e cada parâmetro, todos dados disponíveis são aglomerados para um conjunto que contem os dados de todos os anos para esse mês.

### 5.1.6 COMPARAR MESES COM O MÊS MÉDIO

Nesse passo para cada ano, cada mês e cada parâmetro um CDF é calculado, além de um CDF de longo prazo para cada mês e parâmetro. Seguindo [Finkelstein&Schafer 1971], se um numero n de observações de uma variável X é disponível e o conjunto foi classificado em ordenação crescente, o CDF desse variável pode ser calculado pela função  $S_n(X)$  que é definido da seguinte forma:

$$S_n(X) = \begin{cases} 0, & \text{se } X < X_1 \\ \frac{(k - 0.5)}{n}, & \text{se } X_k < X < X_{k+1} \\ 1, & \text{se } X > X_n \end{cases} \quad (5-1)$$

O valor FS, que expressa a diferença entre o CDF de longo prazo e o CDF de cada ano individual para esse mês é calculado pela seguinte formula:

$$FS = (1/n) \sum_{i=1}^n \delta_i \quad (5-2)$$

Com  $\delta_i$  sendo a diferença absoluta entre o CDF de longo prazo do mês e o CDF de um ano para o meso mês em  $X_i$  ( $i=1,2,\dots,n$ ), n sendo o numero de observações diários por mês (por exemplo 31 em Janeiro).

$\delta_i$  e  $F(X_i)$  são calculados pelas seguintes equações:

$$\delta_i = \max[|F(X_i) - (i-1)/n|, |F(X_i) - i/n|] \quad (5-3)$$

$$F(X_i) = 1 - \exp\left(-\frac{X_i}{\bar{X}}\right) \quad (5-4)$$

com  $X_i$  sendo um valor em um conjunto de  $n$  observações classificado em ordem crescente e  $\bar{X}$  sendo a média do conjunto. Conforme essas formulas, um mês com um valor FS baixo, é mais parecido com a média do que um mês com um valor FS alto.

### 5.1.7 APLICAR OS PESOS PARA OBTER O WS PARA CADA MÊS

Depois do calculo dos valores FS, os pesos são aplicados conforme a escolha no início. O FS de cada parâmetro é multiplicado com o peso desse parâmetro para obter um valor WS (*weighted sum*):

$$WS = \sum w_i \cdot FS_i \quad (5-5)$$

### 5.1.8 ESCOLHER O MÊS COM O MAIOR VALOR WS

Para cada mês, o mês do ano que tem a menor WS é escolhido para ser o TMY. O método descrito para obter as bases de dados da NREL sugere de escolher 5 anos de candidato para cada mês e uma aplicação de testes de persistência para escolher o mês do TMY desses 5 anos. No algoritmo apresentado esse passo de testes de persistência foi retirado, desde ele resultou na exclusão de todos 5 anos em alguns meses. Isso pode ser causada pela quantidade de anos disponíveis relativamente pequena que foi usada (14 anos e da NREL 30 anos). Também outros relatórios descrevendo a criação de um TMY através do método presente não consideraram os testes de persistência (veja [Mosalam&Tadrost 1993] [Zang et al. 2011]).

### 5.1.9 CONCATENAR MESES PARA UM ANO

No ultimo passo, os meses dos anos escolhidos são concatenados para formar um ano (veja Figura 5.2 em cima). O produto final, o TMY, providencia um ano de dados horários de radiação solar e outros parâmetros meteorológicos que podem ser usados em comparações de performance de tipos de sistemas e configurações. Um TMY não necessariamente é um bom indicador das condições do próximo ano no futuro ou até os próximos 5 anos. Ele representa condições que são considerados típicos para um longo prazo de tempo (15-30 anos). Assim também um TMY não considera condições extremas e eles não são adequados para desenhar um sistema e seus componentes para o pior cenário de condições de tempo que podiam acontecer em um local. Por isso serão explicados também outras abordagens em baixo desse capítulo para obter estimativas meteorológicos mais conservadores do que um TMY.

### 5.2 OBTER UM PERCENTILES DE EXCEDENCIA DE RADIAÇÃO

Se vários anos de dados estão disponíveis, uma avaliação de risco pode ser aplicada. Um valor amplamente usado nesse contexto é probabilidade de excedencia de 90%, P90. O P90 para DNI anual, por exemplo, indica que tem uma probabilidade de 90% que um ano terá um DNI anual maior do que esse valor. Esse valor então deve ser relativamente baixo, comparado com os outros DNI anuais.

#### 5.2.1 ASSUMIR UMA DISTRIBUIÇÃO NORMAL DE VARIABILIDADE ANUAL E INCERTEZA DO CONJUNTO

A abordagem mais simples de calcular um P90 para um conjunto de dados meteorológicos é de assumir uma distribuição normal de DNI. [Dobos et al. 2012] descrevem o cálculo de valores DNI com o CDF de uma distribuição normal da seguinte forma:

$$\Phi\left(\frac{x-\mu}{\sigma}\right) = \frac{1}{2} \left[ 1 + \operatorname{erf}\left(\frac{x-\mu}{\sigma \sqrt{2}}\right) \right] \quad (5-6)$$

com:  $\mu$  = Valor médio  
 $\sigma$  = Desvio-padrão  
 $\operatorname{erf}$  = função de erro

Para o lado esquerdo da equação (5-6) sendo 0.1 uma equação para obter o P90 pode ser derivada:

$$\Phi(\gamma) = 0.1 \rightarrow \gamma = -1.282 = \frac{x-\mu}{\sigma} \rightarrow x = \mu - 1.282\sigma \quad (5-7)$$

Para um entendimento melhor, esse cálculo será demonstrado em um pequeno exemplo:

Para uma localização de um projeto, a média de DNI de longo prazo representado pelo TMY será 2,000 kWh/m<sup>2</sup>/ano. A variabilidade anual para um único ano será  $\sigma_{\text{longterm},1} = 7\%$  e pode ser reduzida para  $\sigma_{\text{longterm},10} = 2.21\%$  para a média de dez anos consecutivos através de equação (5-8) (veja [Meyer et al. 2009], [GeoModel Solar 2011]).

$$\operatorname{var}_n = \frac{\sigma_{\text{annual}}}{\sqrt{n}} \quad (5-8)$$

com:  $\sigma_{\text{annual}}$  = desvio-padrão das somas de DNI anuais

$n$  = quantidade de anos no conjunto

Assumindo uma incerteza do conjunto de dados (por causa do erro da medição / erro do método de correlação, ...)  $\sigma_{\text{combined}} = 5\%$  a incerteza total de DNI pode ser calculada usando equação (5-9) de [Meyer et al. 2009].

$$\sigma_{\text{DNI}} = \sqrt{\sigma_{\text{longterm},1}^2 + \sigma_{\text{combined}}^2} \quad (5-9)$$

Para cada ano único isso resulta em  $\sigma_{\text{DNI},1} = 8.60\%$  e para um período de 10 anos em  $\sigma_{\text{DNI},10} = 5.47\%$ . Com essas incertezas e equação (5-6), dois valores P90 para o DNI anual podem ser calculados. Nota que equação (5-6) usa o desvio-padrão absoluto, por isso a média ainda tem que ser multiplicada com a parte de trás da equação:

$$P90_{\text{DNI},1} = 2,000 \text{ kWh/m}^2/\text{ano} - 1.282 * 0.086 * 2,000 \text{ kWh/m}^2/\text{ano} = 1,778.5 \text{ kWh/m}^2/\text{ano}$$

$$P90_{\text{DNI},10} = 2,000 \text{ kWh/m}^2/\text{ano} - 1.282 * 0.0547 * 2,000 \text{ kWh/m}^2/\text{ano} = 1,859.7 \text{ kWh/m}^2/\text{ano}$$

Isso significa que para cada ano único, tem uma probabilidade de 90% que o DNI anual será maior do que 1,778.5 kWh/m<sup>2</sup>/ano e para 10 anos consecutivos tem uma probabilidade de 90% que a média desse 10 anos será maior do que 1,859.7 kWh/m<sup>2</sup>/ano.

Esse método pode ser também expandido para a avaliação de produção de energia anual. Assumindo a distribuição normal das incertezas e uma relação 1:1 de incerteza de DNI para incerteza de produção de energia, a energia produzida é calculada com o TMY e depois os valores P90 de produção de energia são calculados iguais em cima. Assumindo uma produção de energia simulada com o TMY de 100 GWh<sub>e</sub>, o P90<sub>AEP,1</sub> é 88.97 GWh<sub>e</sub> e o P90<sub>AEP,10</sub> é 92.98 GWh<sub>e</sub> (AEP = Anual Energy Production – produção de energia anual).

Figura 5-4 mostra o CDF da distribuição normal de produção de energia do exemplo para um único ano e dez anos consecutivos. Para um exemplo desse método veja também [GeoModel Solar 2011].

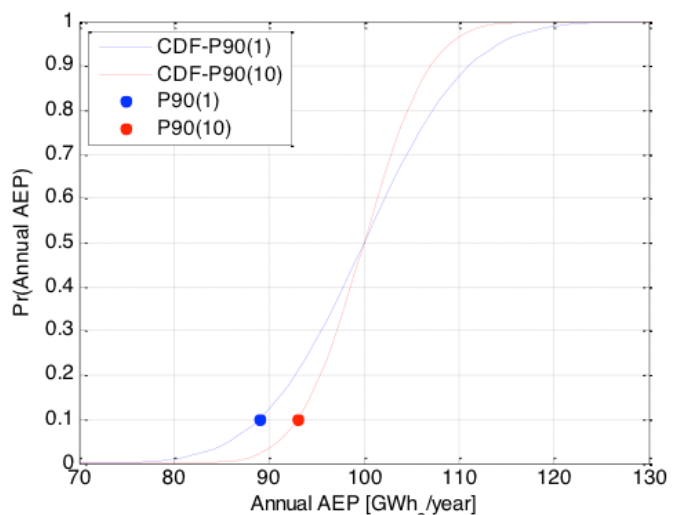


Figura 5-4: CDF de distribuição normal e valores P90 do exemplo



## 5.2.2 CRIAÇÃO DE ANOS METEOROLÓGICOS REPRESENTATIVOS (RMY) QUE REPRESENTAM O PERCENTIL DE EXCEDENCIA

Desde a correlação da incerteza de DNI para a incerteza da produção de energia pode ser maior ou menor do que 1:1 e na realidade geralmente é menor (veja equação (5-10) de [Meyer et al. 2009]), a abordagem de calcular P90 de produção de energia de um ano de dados meteorológicos (MY90) que representa as médias P90 de DNI promete resultados mais altos e realísticos.

$$\Delta E_{el} \propto 0.7 \cdot \Delta DNI \quad (5-10)$$

As médias P90 de DNI no conjunto têm uma distribuição de valores reais e são construídos similar de um TMY. Invés de calcular os CDFs de cada mês, só a diferença entre o valor P90 do mês e os meses reais é calculado. Nessas diferenças os pesos são aplicados para escolher depois o mês com o menor

valor WS. O resultado é um ano que não representa do melhor jeito a média de longo prazo, mais que inclui os meses que combinam do melhor jeito com o P90 de cada mês. Dependendo do produto desejado, MY90 para um único ano ou vários anos consecutivos podem ser calculados (veja seção em cima). Uma aplicação desse método pode ser vista em GeoModel Solar (2012).

## 5.2.3 ABORDAGENS PROBABILÍSTICAS

[Röttinger et al. 2015] tentou de chegar a valores P90 mais realísticas do que com os métodos apresentados em cima com uma abordagem probabilística. Ele desenvolveu um método para criar varias conjuntos de dados de amostragem que representam a incerteza estimada da DNI. A incerteza dos dados de DNI causada pelos instrumentos, pela medição e a adaptação dos dados satélites é colocada em cima de cada ano (incluindo a variabilidade interanual, veja Figura 5-1 e Figura 5-5). Assim o conjunto inteiro de amostragens inclui todas as fontes de incerteza.




Figura 5-5: Criação de amostragens que representam a incerteza do conjunto de dados [Röttinger et al. 2015]

Todas as amostragens depois são simuladas e as produções de energia são avaliadas estatisticamente. Do conjunto dos resultados de produção de energia, vários valores de excedencia podem ser calculados, como por exemplo um P50, P75, P90 ou P95.

Figura 5-6 mostra os resultados desse método comparado com os outros dois apresentados. O primeiro método que assume uma relação 1:1 pouco realística de incerteza de DNI a incerteza de AEP conduz um CDF muito largo e um P90 bem

conservador. O MY90, usando meses reais que representam a média P90 de cada mês, já conduz um resultado melhor. O método de [Röttinger et al. 2015] inclui todas as incertezas, faz um esforço

grande de simulação e assim consegue calcular um P90 que é provavelmente mais realístico e alto. No entanto, o esforço de computação pode ser uma desvantagem desse método.

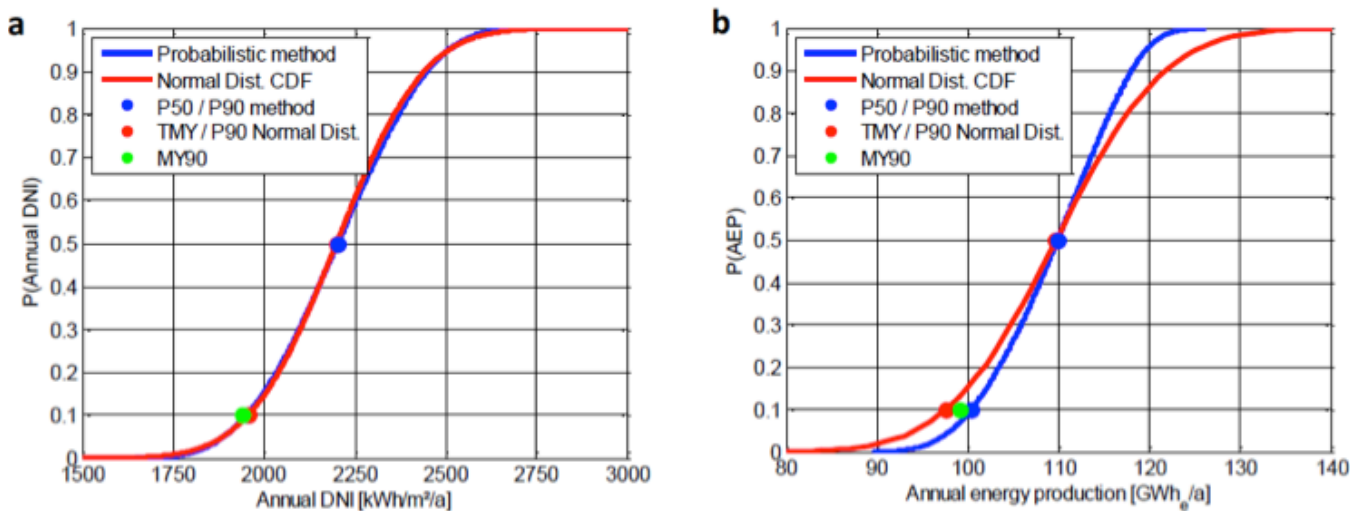


Figura 5-6: (a) CDF & P50/P90 de DNI anual para (b) CDF & P50/P90 de AEP

## 6. RESUMO

Os algoritmos apresentados continuam o procedimento começado no primeiro trabalho 'Manual para tratamento de dados solarimétricos (Parte 1) – Controle de qualidade e preenchimento de lacunas' e completam o caminho dos dados medidos em uma ESOL até obter um TMY(P50) e MY90(P90). Ter uma boa medição e um bom sistema de controle da qualidade dessas medições é indispensável para garantir o melhor P50/P90 da energia do projeto, seja fotovoltaico ou termossolar. Os valores P50 e P90 de probabilidade de geração são baseados em muitos anos de dados meteorológicos através de uma correlação de longo prazo. Dados de irradiação solar medidos em terra são utilizados no processo de correlação para melhorar o conjunto de dados de longo prazo, validando os dados por satélite. As estimativas estatísticas da quantidade de energia que uma usina vai gerar no futuro, são necessárias para determinar o risco financeiro de um projeto.

Os algoritmos representam ferramentas poderosas para obter conjuntos de dados em resolução temporal horária e no formato 'TMY3' que podem ser diretamente usadas em um programa de simulação de energia com SAM ou Thermoflow.

Mesmo mostrando boas resultados na correlação, vale lembrar que nem para todo local uma simples adaptação linear do bias é aplicável (veja variabilidade do bias em capítulo 4). Por isso a possibilidade da aplicação dessa correlação deve ser avaliada antes. Além disso, é uma boa oportunidade para futuros trabalhos de melhorar o algoritmo de adaptação com a implementação de por exemplo um polinômio de 3º grau como [Mieslinger et al. 2014] ou fortalecer os esforços para estabelecer um sistema de Redes Neurais Artificiais.

Outro potencial para aperfeiçoamento é o cálculo do valor P90. O método de construir um MY90 já dá um bom resultado como também foi mostrado de [Röttinger et al. 2015]. Todavia, no futuro seria interessante estabelecer um algoritmo probabilístico para melhorar a análise de risco, principalmente em conjunto com a simulação de energia. Isso pode ser baseado nos trabalhos de [Röttinger et al. 2015] e [Ho et al. 2011].

## FIGURAS

Figura 1-1:	Processamento de dados	9
Figura 2-1:	Escaneamento do satélite geoestacionário METEOSAT	10
Figura 2-2:	Medição da reflexão de radiação solar com satélites	11
Figura 2-3:	Absorção e dispersão de radiação na atmosfera	13
Figura 2-4:	Fluxograma do método de [Pinker/Laszlo 1992]	14
Figura 2-5:	Gama dinâmica (dynamic range) de um pixel de satélite	15
Figura 4-1:	Número de anos para estabilizar DNI e GHI no pior dos cenários	23
Figura 4-2:	Dados medidos (ground) e dados derivados de imagens satélites	24
Figura 4-3:	Medição terrestre com alta precisão (ponto-único) vs. Pixel	25
Figura 4-4:	Integração temporal de dados medidos no solo vs. imagens instantâneas	25
Figura 4-5:	Exemplo de uma diferença de elevação de dois pontos em um pixel	26
Figura 4-6:	Bias mensal de dados satélites com referência a dados medidos	27
Figura 4-7:	Bias mensal de dados satélites com referência a dados medidos	27
Figura 4-8:	Serie de tempo mensal para vários conjuntos de dados correlacionados	28
Figura 4-9:	Incerteza resultando se combinar um conjunto de dados	29
Figura 4-10:	Método de [Schumann et al. 2011]	30
Figura 4-11:	Gráfico de dispersão de dados medidos no solo e dados de satélites	31
Figura 4-12:	Correlação linear dos dados filtrados ( $DNI > 100 \text{ W/m}^2$ )	34
Figura 4-13:	Distribuição de probabilidades dos valores correlacionados	34
Figura 5-1:	Variabilidade annual e incerteza do conjunto de dados DNI	35
Figura 5-2:	Criação de um TMY	36

Figura 5-3:	Escolher o CDF mais parecido com o CDF da media de longo prazo	37
Figura 5-4:	CDF de distribuição normal e valores P90 do exemplo	40
Figura 5-5:	Criação de amostragens que representam a incerteza do conjunto	41
Figura 5-6:	(a) CDF & P50/P90 de DNI anual para (b) CDF & P50/P90 de AEP	42

## TABELAS

Tabela 2-1:	Dados provenientes de satélites para o Brasil	10
Tabela 3-1:	Bias default para a correção dos dados preenchidos	16
Tabela 3-2:	Integração dos dados de resolução de 1min para dados horários	17
Tabela 3-3:	TMY3 formato do 1º header (cabeçalho linha 1)	19
Tabela 3-4:	TMY3 formato do 2º header (cabeçalho linha 2)	19
Tabela 3-5:	TMY3 Data formato	20
Tabela 4-1:	Dados terrestres vs. Dados derivados de imagens satélites.	23
Tabela 5-1:	Ponderação de parâmetros para criação de um TMY	37

## ABREVIACOES

ATC	Temperatura do ar (air temperature)
BMZ	Ministrio Federal da Cooperao Econmica e Desenvolvimento da Alemanha (Bundesministeriums fr wirtschaftliche Zusammenarbeit und Entwicklung)
BPR	Presso atmosfrica (barometric pressure)
CDF	Funcao de distribuio cumulativa (Cumulative Distribution Function)
CI	ndice de cobertura de nuvens (cloud index)
CQ	Controle de qualidade
CSP	Energia heliotrmica (Concentrating Solar Power)
DHI	Radiao solar difusa horizontal (Diffuse Horizontal Irradiance)
DKTI	Iniciativa alem para tecnologias limpas (Deutsche Klima-Technologie Initiative)
DNI	Radiao solar direta normal (Direct Normal Irradiance)
DPT	Teperatura hmida (dew point temperature)
ESOL	Estao solarimtrica
ETR	Radiao extraterrestre (em TOA)
EUA	Estados Unidos da America
GHI	Radiao solar total horizontal (Global Horizontal Irradiance)
GIZ	Deutsche Gesellschaft fr Internationale Zusammenarbeit
KSI	Integral do teste Kolmogorov-Smirnov
NREL	Laboratrio nacional de energias renovveis das EUA (National Renewable Energy Laboratory)
NWS	Servicio nacional do tempo dos EUA (National Weather Service)
PRC	Precipitao
RHU	Humidade relativa (relative humidity)

RMSE Erro médio quadrático (Root Mean Square Error)

TOA Topo da atmosfera

USAF Força aérea dos EUA (United States Air Force)

WDI Direção do vento (Wind direction)

WMO Organização Mundial de Meteorologia (World Meteorological Organization)

WSP Velocidade do vento (Wind speed)



## REFERÊNCIAS

- [Abdel Wahab et al. 2009] Abdel Wahab, M., El Metwally, M., Hassan, R., Lefèvre, M., Oumbe, A., Wald, L. 2009. Assessing surface solar irradiance in Northern Africa desert climate and its long-term variations from Meteosat images. *International Journal of Remote Sensing*, 31(01), 261 – 280, doi: 10.1080/01431160902882645
- [Bender et al. 2011] Bender, G.; Davidson, F.; Eichelberger, F.; Gueymard, C.A. (2011). "The Road to Bankability: Improving Assessments for More Accurate Financial Planning." *Solar 2011 Conference Proceedings*; May 16–21, 2011, Raleigh, North Carolina.
- [Beyer et al. 2010] Beyer, H.G.; Martinez, J.P.; Suri, M.; Torres, J.L.; Lorenz, E.; Müller, S.C.; Hoyer-Klick, C.; Ineichen, P. (2009). Management and Exploitation of Solar Resource Knowledge: Ca-Contract No. 038665— D 1.1.3. Report on Benchmarking of Radiation Products. [http://www.mesor.org/docs/MESoR\\_Benchmarking\\_of\\_radiation\\_products.pdf](http://www.mesor.org/docs/MESoR_Benchmarking_of_radiation_products.pdf).
- [Cano et al. 1986] Cano, D.; Monget, J.M.; Albuisson, M.; Guillard, H.; Regas, N.; Wald, L. (1986). "A Method for the Determination of the Global Solar Radiation from Meteorological Satellite Data." *Solar Energy* (37:1); pp. 31–39.
- [Carow 2008] Carow, J.R. (2008). Anpassung langjähriger Satelliten-Strahlungszeitreihen an Bodenmesswerte eines Jahres. Diploma Thesis. Nordhausen, Germany: University of Applied Science.
- [Cebauer&Suri 2010] Cebecauer, T.; Suri, M. (2010). "Accuracy Improvements of Satellite-Derived Solar Resource Based on GEMS Re-Analysis Aerosols." *SolarPACES Conference Proceedings*; September 21–24, 2010, Perpignan, France.
- [Hidalgo&Mau 2012] Cesar Hidalgo and Stefan Mau, "Findings in the Correlation of Ground Measured Irradiance Data with Satellite Derived Data", *EQ International*, July/August 2012.
- [Endorse] endorse\_d3.5v1.1 - Methods for data fusion
- [Espinar et al. 2009] Espinar, B.; Ramírez, L.; Drews, A.; Beyer, H.G.; Zarzalejo, L.; Polo, J.; Martín, L.: Analysis of different comparison parameters applied to solar radiation data from satellite and German radiometric stations. In: *Solar Energy* 83 (2009): 118-125.
- [Espinar et al. 2011] Espinar, B.; Wald, L.; Blanc, P.; Hoyer-Klick, C.; Schroedter-Homscheidt, M.; Wanderer, T.: Report on the Harmonization and Qualification of Meteorological Data v1.0; Project Endorse D3.2, 2011.
- [Finkelstein&Schafer 1971] Finkelstein, J.; Schafer, R: Improved goodness-of-fit tests. In: *Biometrika* 59 (3), p.641-645 Oxford Journals, 1971.

- [Gueymard et al. 2012] Gueymard, C.A.; Gustafson, W.T.; Bender, G.; Etringer, A.; Storck, P. (2012). "Evaluation of Procedures to Improve Solar Resource Assessments: Optimum Use of Short-Term Data from a Local Weather Station to Correct Bias in Long-Term Satellite-Derived Solar Radiation Time Series. World Renewable Energy Forum Conference Proceedings; May 13–17, 2012. Denver, CO.
- [Gueymard&Wilcox 2009] Gueymard, C.A.; Wilcox, S.M. (2009). "Spatial and Temporal Variability in the Solar Resource: Assessing the Value of Short-Term Measurements at Potential Solar Power Plant Sites." Solar 2009 Conference Proceedings; May 11–16, 2009, Buffalo, New York.
- [Harmsen et al. 2014] Harmsen, E.W.; Tosado-Cruz, P.; Mecikalski, J.R. (2014). "Calibration of Selected Pyranometers and Satellite-Derived Solar Radiation in Puerto Rico." International Journal of Renewable Energy Technology (5); pp. 43–54.
- [Ineichen 2006] Ineichen P. (2006) Comparison of eight clear sky broadband models against 16 independent data banks, Solar Energy, vol. 80, no. 4, pp. 468–478, Apr. 2006.
- [Ineichen 2011] Ineichen, P.: Five satellite products deriving beam and global irradiance validation on data from 23 ground stations. International Energy Agency (IEA) / University of Geneva, 2011.
- [Kambezidis 2012] Kambezidis, H.: The Solar Resource. In: Comprehensive Renewable Energy, Volume 3. Amsterdam: Elsevier, 2012.
- [Killius & Schroedter-Homscheidt 2012] Killius, N.; Schroedter-Homscheidt, M. (2012). Data Fusion of Satellite and Ground Measurement Time Series. EU-Project Report ENDORSE D3.5—Part B, September 2012.
- [Kumar et al. 1997] Kumar, L.; Skidmore, A.; Knowles, E.:(1997): Modelling topographic variation in solar radiation in a GIS environment, Int. journal of geographical information science, 1997, vol. 11, no. 5, 475 – 497.
- [Maxwell 1998] Maxwell, EL: METSTAT – the solar radiation model used in the production of the National Solar Radiation Data Base (NSRDB). In: Solar Energy 62(4): pp 263-279, 1991.
- [Meyer et al. 2008] Meyer, R.; Torres Butron, J.; Marquardt, G; Schwandt, M.; Geuder, N.; Hoyer-Klick, C.; Lorenz, E.; Hammer, A.; Beyer, H.G. (2008). "Combining Solar Irradiance Measurements and Various Satellite- Derived Products to a Site-Specific Best Estimate." SolarPACES Conference Proceedings; March 4–7, 2008, Las Vegas, Nevada.

- [Meyer et al. 2009] R. Meyer, H.G. Beyer, J. Fanslau, N. Geuder, A. Hammer, T. Hirsch, C. Hoyer-Klick, N. Schmidt, M.Schwandt: Towards Standardization of CSP Yield Assessment, SolarPACES 2009, 15-18.9, Berlin.
- [Mieslinger et al. 2014] Mieslinger, T.; Ament, F.; Chhatbar, K.; Meyer, R. (2014). "A New Method for Fusion of Measured and Model-Derived Solar Radiation Time Series." International Conference on Solar Heating and Cooling for Buildings and Industry Proceedings; September 23-25, Freiburg, Germany; Energy Procedia (48); pp. 1,617–1,626.
- [Mosalam&Tadrost 1993] Mosalam Shaltout, M.; Tadrost, M.: Typical solar radiation year for Egypt. In: Renewable Energy Vol. 4, No. 4 pp.387-393. Elsevier Science, 1994.
- [Perez et al. 1997] Perez R., Seals R., Zelenka A., 1997. Comparing satellite remote sensing and ground network measurements for the production of site/time specific irradiance data. Solar Energy, 60, 89–96.
- [Perez et al. 2002] Perez, R.; Ineichen, P.; Moore, K.; Kmiecik, M.; Chain, C.; George, R.; Vignola, F. A New Operational Satellite-to-Irradiance Model. In: Solar Energy 73(5):307–317, 2002.
- [Pinker/Laszlo 1992] Pinker, R.T.; Laszlo, I. (1992). "Modeling of Surface Solar Irradiance for Satellite Applications on a Global Scale." Journal of Applied Meteorology and Climatology (31); pp. 194–211.
- [Pitz-Paal et al. 2007] Pitz-Paal, R.; Norbert, G; Carsten, H.-K.; Christoph, S.: How to get bankable meteo data? - DLR solar resource assessment, NREL 2007 parabolic trough technology work-shop, Golden, CO, March 8-9, 2007.
- [Porfirio/Ceballos 2013] Silva Porfirio, A. C.; Ceballos, J. C.: Um método de estimativa de irradiação solar direta normal a partir de imagens de satélite geoestacionário: resultados preliminares. Anais XVI Simpósio Brasileira de Sensoriamento Remoto, Foz do Iguaçu: INPE, 2013.
- [Reda&Andreas 2003] Reda, I., Andreas, A. (2003) Solar position algorithm for solar radiation application. National Renewable Energy Laboratory (NREL) Technical report NREL/TP-560-34302.
- [Remund&Page 2002] Remund, J., Page, J., 2002. Advanced parameters. Chain of algorithms. Part I: shortwave radiation. Report to the European Commission, SoDa project IST-1999-12245
- [Rigolier et al. 2000] Rigolier, C., Bauer, O., Wald, L.: On the clear sky model of the 4th European solar atlas with respect to Heliosat method. Solar Energy 68 (2000), p.33–48.

- [Ruiz-Arias et al. 2015] Ruiz-Arias, J.A.; Quesada-Ruiz, S.; Fernández, E.F.; Gueymard, C.A. (2015). "Optimal Combination of Gridded and Ground-Observed Solar Radiation Data for Regional Solar Resource Assessment." *Solar Energy* (112); pp. 411–424.
- [Röttinger et al. 2015] N. Röttinger, F. Remann, R. Meyer, T. Telsnig, Calculation of CSP Yields with Probabilistic Meteorological Data Sets: A Case Study in Brazil, *Energy Procedia*, Volume 69, May 2015, Pages 2009-2018, (<http://www.sciencedirect.com/science/article/pii/S1876610215005160>)
- [Ho et al. 2011] Ho C, Siri SS, Kolb GJ. Methods for probabilistic modeling of concentrating solar power plants, In: *Solar Energy* 85, 2011. p. 669-675
- [Schwandt et al. 2013] Schwandt, M.; Chhatbar, K.; Meyer, R.; Fross, K.; Mitra, I.; Vashistha, R.; Giridhar, G.; Gomathinayagam, S.; Kumar, A.: Development and test of gap filling procedures for solar radiation data of the Indian SRRRA measurement network; ISES World Congress, 2013.
- [Schmetz 1989] Schmetz, J., 1989: Towards a surface radiation climatology: Retrieval of downward irradiances from satellites. *Atmospheric Res.*, 23, 287-321.
- [Schumann et al. 2011] K. Schumann, H. G. Beyer, K. Chhatbar, R. Meyer, "Improving satellite-derived solar resource analysis with parallel ground-based measurements.," ISES Solar World Congress, Kassel, Germany, 2011.
- [Sengupta et al. 2015] Sengupta, M.; Habte, A.; Kurtz, S.; Dobos, A.; Wilbert, S.; Lorenz, E.; Stoffel, T.; Renné, D.; Gueymard, C.; Myers, D.; Wilcox, S.; Blanc, P. & Perez, R.: Best Practices Handbook for the Collection and Use of Solar Resource Data for Solar Energy Applications. Technical Report NREL/TP-5D00-63112, 2015.
- [Suri/Cebauer 2011] Suri, M.; Cebauer, T.: Requirements for bankable DNI data products in CSP products. In: *Proceedings of the SolarPACES Conference Granada, Spain, 20-23 September 2011.*
- [Suri/Cebauer 2011] Suri, M.; Cebauer, T.: Requirements for bankable DNI data products in CSP products. In: *Proceedings of the SolarPACES Conference Granada, Spain, 20-23 September 2011.*
- [Tarpley 1979] Tarpley, J.D.: Estimating Incident Solar Radiation at the Surface from Geostationary Satellite Data. *Journal of Applied Meteorology* (18); pp. 1,172–1,181, 1979.

[Thuman et al. 2012] Thuman, C.; Schnitzer, M.; Johnson, P. (2012). "Quantifying the Accuracy of the use of Measure-Correlate-Predict Methodology for Long-Term Solar Resource Estimates." Solar 2012 Conference Proceedings; May 13–17, 2012, Denver, Colorado.

[Hall et al. 1978] Hall, I; Prairie, R.; Anderson, H.; Boes, E.: Generation of Typical Meteorological Years for 26 SOLMET Stations. Sandia National Laboratories, 1978.

[Vignola et al. 2012] Vignola, F.; Grover, C.; Lemon, N.; McMahan, A.: Building a bankable solar radiation set. In: Solar Energy 86; Elsevier, 2012.

[Dobos et al. 2012] Dobos, A.; Kasberg, M.; Gilman, P.: P50/P90 analysis for solar energy systems using the system advisory model. Presented at the World Renewable Energy Forum, Denver, Colorado, May 13-17, 2012.

[Wilcox&Marion 2008] Wilcox, S.; Marion, W.: Users Manual for TMY3 Data Sets. Technical Report NREL/TP-581-43156, National Renewable Energy Laboratory.

[WMO 1981] WMO, 1981. Technical Note N° 172, WMO-No. 554, World Meteorological Organization, Geneva, Switzerland, pp. 121-123.

[Younkin&Long 2004] Younkin, K.; Long, C.N.: Improved Correction of IR Loss in Diffuse Shortwave Measurements: An ARM Value Added Product. Atmospheric Radiation Measurement Program Technical Report, ARM TR-009, 2004.

[WMO 2010] World Meteorological Organization (WMO): Guide to Meteorological Instruments and Methods of Observation. 2008 edition, updated in 2010. WMO-No. 8. Geneva, 2010.

[Vignola et al. 2012] Vignola, F.; Grover, C.; Lemon, N.; McMahan, A.: Building a bankable solar radiation set. In: Solar Energy 86; Elsevier, 2012.

[GeoModel Solar 2011] GeoModel Solar s.r.o: Site Assessment of Solar Resource – Upington Solar Park, Province Northern Cape, South Africa. June, 2011.

[Zang et al. 2011] Zang, H.; Xu, Q.; Du, P.; Ichiyanagi, K.: A Modified Method to Generate Typical Meteorological Years from the Long-Term Weather Database. In: International Journal of Photoenergy, Volume 2012, Article ID 538279. Hindawi Publishing Corporation, 2011.

[Zelenka et al. 1999] Zelenka, A., Perez, R., Seals, R., Renné, D., (1999). Effective accuracy of satellite-derived hourly irradiances. Theoretical and Applied Climatology, 62, pp 199-207.



Por meio da:



MINISTÉRIO DA  
CIÊNCIA, TECNOLOGIA,  
INOVAÇÕES E COMUNICAÇÕES

