

1 2 9 0



UNIVERSIDADE D
COIMBRA

Álvaro Jorge Bento Almeida Santos

VALIDAÇÃO REGIONAL DE ESTIMATIVAS DE
PRECIPITAÇÃO OBTIDAS POR SATÉLITE
(IMERG) NA BACIA HIDROGRÁFICA DO RIO
MONDEGO

VOLUME I

Dissertação no âmbito do Mestrado em Geociências, orientada pelo Doutor Vasco Manuel Jorge Soares Mantas e pelo Professor Doutor Alcides José Sousa Castilho Pereira e apresentada ao Departamento de Ciências da Terra da Faculdade de Ciências e Tecnologias da Universidade de Coimbra.

Setembro de 2019



UNIVERSIDADE D
COIMBRA

Álvaro Jorge Bento Almeida Santos

VALIDAÇÃO REGIONAL DE ESTIMATIVAS DE
PRECIPITAÇÃO OBTIDAS POR SATÉLITE
(IMERG) NA BACIA HIDROGRÁFICA DO RIO
MONDEGO

Dissertação no âmbito do Mestrado em Geociências, orientada pelo Doutor Vasco Manuel Jorge Soares Mantas e pelo Professor Doutor Alcides José Sousa Castilho Pereira e apresentada ao Departamento de Ciências da Terra da Faculdade de Ciências e Tecnologias da Universidade de Coimbra.

Setembro de 2019

Agradecimentos

A construção desta dissertação foi um percurso de descoberta e crescimento pessoal e académico. Na etapa final deste percurso académico quero deixar o meu profundo agradecimento a todos os que de alguma forma contribuíram para o meu desenvolvimento e sucesso académico, quer Professores, quer colegas e amigos, quer à minha família. Em particular quero agradecer:

Ao Doutor Vasco Manuel Jorge Soares Mantas e ao Professor Doutor Alcides José Sousa Castilho Pereira, respetivamente Orientador e Coorientador desta dissertação, pela excelente orientação, pautada pela partilha de saber, rigor científico, estímulo e, sobretudo, pelas oportunidades de aprendizagem e desenvolvimento que me proporcionaram.

Aos meus colegas, Francisco Sousa, Filipe Quintas e Luís Carvalho, cuja amizade se criou através da convivência académica, pela entreatuda e companheirismo.

Ao Ricardo Guerra, ao Nelson Coito, ao João Cardoso e ao Flávio Pais, pelos anos de amizade, incentivo, otimismo e união e pelo apoio que sempre me transmitem.

A todo o Departamento de Ciências da Terra e a todos os seus professores com quem tive a oportunidade e gosto de aprender.

Por fim, à minha família, e em particular à minha mãe pelas oportunidades que sempre me deu e pelo carinho, amor e paciência com que sempre me tratou.

A todos, muito obrigada!

Resumo

A precipitação atmosférica é um componente essencial do ciclo hidrológico e energético global. Medir este fenómeno de maneira fiável e precisa é crucial para a gestão de recursos hídricos e para a monitorização de desastres naturais.

Medições de precipitação através de métodos convencionais são efetuadas com recurso a estações *in situ* e, quando disponíveis, radares meteorológicos. A distribuição destes sistemas raramente é adequada e a densidade das estações é altamente variável. Isto origina lacunas de dados significativas um pouco por todo o mundo, o que origina sérios problemas de representatividade.

Para solucionar estes problemas, várias agências espaciais criaram e lançaram missões de observação terrestre, para coletar informação meteorológica à escala quase global. Sendo a mais recente missão a Global Precipitation Measurement Mission. Para estes dados poderem ser usados para uma dada área geográfica, quer para o desenvolvimento de aplicações críticas, quer em estudos de carácter científico, é imperativo que sejam validados.

Neste estudo, dados gerados pelo GPM (IMERG) foram validados para a Bacia Hidrográfica do Rio Mondego. Esta é uma região com uma topografia complexa, que apresenta diversos obstáculos à obtenção de dados de precipitação via satélite. Comparou-se a *Late run* do IMERG com medições *in situ* disponibilizadas pela rede meteorológica do SNIRH.

Foram estudados quatro anos e meio de dados (Março/2014 até Dezembro/2018), a várias escalas temporais, com recurso a métodos estatísticos frequentemente utilizados neste tipo de estudos, analisando-se a distribuição espacial dos resultados.

Verificou-se que, de um modo geral, o produto IMERG é competente a quantificar a precipitação, no entanto os resultados não são homogéneos para a área em estudo. Existe uma sobrestimação da precipitação na zona costeira e uma subestimação na zona correspondente à encosta NO das Serras da Estrela e da Lousã.

Concluiu-se que a qualidade das estimativas do produto IMERG e a sua alta resolução espaciotemporal potenciam o uso dos dados gerados no desenvolvimento de aplicações operacionais e em estudos futuros de carácter hidrológico.

Palavras – chave: IMERG, deteção remota, estimativas de precipitação por satélite, bacia hidrográfica do Rio Mondego, hidrologia.

Abstract

Rainfall is an essential component of the energetic and hydrologic cycles. Gathering accurate rainfall measurements is a requirement for good water resource management and natural disaster monitoring.

Precipitation measurements through conventional methods employ the use of *in situ* stations and, when available, meteorological radars. The distribution of these systems is rarely adequate and the gauge density is highly variable, this can cause serious problems due to the data being non representative.

To find a solution to these issues, several space agencies designed and launched earth observation missions, with the aim to collect meteorological data at a near-global scale. The Global Precipitation Measurement Mission is the most recent of its kind.

However for this data to be used, for either the development of critical applications or hydrological studies, it needs to have been previously validated.

In this study, data generated by GPM (IMERG) was validated for the hydrographic basin of the Mondego River. This region is affected by complex topography which poses significant challenges to the gathering of rainfall data via satellite retrieval methods. The Late run of the IMERG product was compared with *in situ* measurements, made available via SNIRH's meteorological network.

Four years and a half of data were studied, from March 2014 to December 2018. Different observation lengths were studied and the data's spatial distribution was analyzed.

Overall the results show that the IMERG product is competent at estimating the amount of rainfall, however the results vary across the study area, with the coastal areas showing an overestimation of the rainfall amounts, and the southwest facing slopes of Serra da Estrela and Lousã, the two main topographic features present in the area showing an underestimation of the rainfall events.

Lastly it was deemed that the quality and high spatiotemporal resolution of the IMERG estimates, enable its data to be used in the development of operational applications and in future hydrological studies.

Keywords: IMERG, remote sensing, satellite rainfall estimates, Mondego River basin, hydrology

Índice

1. Introdução.....	1
2. Princípios e enquadramento das estimativas de precipitação por satélite.....	3
2.2. Métodos de micro-ondas passivas.....	4
2.3. Técnicas de micro-ondas ativo.....	6
2.4. Técnicas multi sensor.....	6
2.5. GPM.....	7
3. Enquadramento.....	9
3.1. Caracterização da bacia hidrográfica do Mondego.....	9
3.2. Hidrologia da bacia hidrográfica do Mondego.....	11
4. Metodologia.....	15
4.1. Seleção da versão do IMERG a utilizar.....	16
4.2. Dados <i>in situ</i>	17
4.3. Obtenção dos dados do SNIRH.....	17
4.4. Obtenção dos dados de satélite.....	19
4.5. Preparação dos Dados para análise.....	21
4.6. Métodos de validação.....	23
5. Resultados.....	28
5.1. Estatística <i>Standard</i>	31
5.2. Índice de Moran I.....	35
5.3. Análise da dependência espacial.....	35
6. Discussão.....	39
7. Conclusões e Recomendações.....	49
8. Referências Bibliográficas.....	51

ÍNDICE DE FIGURAS

Figura 1 - Mapa Hipsométrico da bacia hidrográfica do Rio Mondego com a rede hidrográfica representada.....	11
Figura 2 - Mapa da classificação Köppen-Geiger para Portugal continental, com destaque para a Bacia Hidrográfica do Mondego delineada a vermelho (adaptado de Kottek et al., 2006).....	12
Figura 3 - Mapa Hipsométrico da bacia hidrográfica do Rio Mondego lado a lado com o mapa da precipitação média anual para efeitos comparativos (metadados: SNIAmb, 2019).....	14
Figura 4 - Metodologia utilizada.....	15
Figura 5 - Processo de seleção das bacias pretendidas – Imagem retirada de https://snirh.apambiente.pt	17
Figura 6- Processo de descarregamento dos dados do SNIRH relativos a precipitação diária - Imagem retirada de https://snirh.apambiente.pt	18
Figura 7 - Estações sem dados a vermelho - Imagem retirada de https://snirh.apambiente.pt	19
Figura 8 - Processo de obtenção de dados de satélite - Imagem retirada de https://giovanni.gsfc.nasa.gov/giovanni/	20
Figura 9 - Processo descrito anteriormente de criação das boxes a partir das coordenadas de cada estação.....	20
Figura 10 - Exemplo de uma estação - à esquerda dados tal como descarregados do <i>site</i> do SNIRH e à direita dados após serem submetidos ao script.....	22
Figura 11 - Seleção manual da janela de análise para o fator de correlação de Pearson (agregação de dados a 30 dias).....	26
Figura 12 - Exemplo de um dos macros utilizados para ordenar valores.....	26
Figura 13- Figura ilustrativa do funcionamento do Índice de Moran I. Figura adaptada de (ESRI, 2019).....	27
Figura 14 - Comparação dos valores de precipitação diários in situ com os valores também diários estimados por satélite para a estação de Freixianda.....	33
Figura 15 - Comparação dos valores de precipitação agregados a 30 dias in situ com os valores também agregados estimados por satélite para a estação de Freixianda..	33
Figura 16 - Projeção da massa de dados global à escala diária (a linha representa uma relação 1:1).....	34
Figura 17 – Projeção da massa de dados global à escala mensal (a linha representa uma relação 1:1).....	34
Figura 18 - Dependência espacial dos valores de Bias diários	36
Figura 19 - Dependência espacial dos valores de Bias mensais	36
Figura 20 - Dependência espacial dos valores do POD.....	37
Figura 21 – Valores de Bias diários representados sobre a carta hipsométrica	38
Figura 22 - Valores de Bias mensais representados sobre a carta hipsométrica	38
Figura 23 - Figura ilustrativa do problema encontrado durante a preparação dos dados e da solução implementada.....	41
Figura 24 - A vermelho está representada a linha que une uma quantidade significativa de estações que apresentam baixos valores de POD e que coincide com o limite NO das Serras da Lousã e da Estrela	45
Figura 25 - A vermelho estão assinalada uma concentração dos valores de Bias mais elevados, coincidentes com cotas menos elevadas e a branco valores de Bias menores coincidentes com cotas mais elevadas	46

ÍNDICE DE TABELAS

Tabela 1 - Os parâmetros a, b, c e d representam o número total de pares que verificam a condição respectiva.	24
Tabela 2 - Tabela sumário da estatística individual realizada	29
Tabela 3 - Tabela sumário da estatística individual realizada (Continuação)	30
Tabela 4 - Valores médios do fator de correlação de Pearson para valores de precipitação diários e agregados a 8, 16 e 30 dias.	34
Tabela 5 - Resultados dos diversos parâmetros estatísticos à escala global	35
Tabela 6 - Resultados do índice de Moran I.....	35
Tabela 7 - Resultados da correlação do Bias com a elevação.....	37

ÍNDICE DE EQUAÇÕES

Equação 1 - RMSE	23
Equação 2 - Bias	23
Equação 3 - Coeficiente de correlação de Pearson	24
Equação 4 - FBI.....	24
Equação 5 - FAR	24
Equação 6 - POD.....	25

ABREVIATURAS, SIGLAS E ACRÓNIMOS

AIRS – Atmospheric Infrared Sounder

AMSR-E - Advanced Microwave Scanning Radiometer - Earth Observing System

AMSU - Advanced Microwave Sounding Unit

CMAP - Climate Prediction Center Merged Analysis of Precipitation

CMORPH – Climate Prediction Center Morphing Technique

Csa – Warm temperate summer dry hot summer

Csb – Warm temperate summer dry warm summer

ESRI - Environmental Systems Research Institute

FAR – False Alarm Ratio

FBI – Frequency Bias Index

GOES - *Geostationary Operational Environmental Satellite* system

GPCC - *Global Precipitation Climatology Centre*

GPM - Global Precipitation Measurement mission

GSMaP - Global Satellite Mapping of Precipitation

HSB - Humidity Sounder for Brazil

IMERG - Integrated Multi-satellitE Retrievals for GPM

IPMA – Instituto Portugues do Mar e da Atmosfera

JAXA - Japan Aerospace Exploration Agency

LEO – Low Earth Orbit

LIS - Lightning Imaging Sensor

LMODEL - Lagrangian Model

MDT – Modelo Digital de Terreno

mm - milímetros

MOP – Micro-ondas passivo

MSG - Meteosat Second Generation

NaN - not a number

N/D - No Data

NASA - National Aeronautics and Space Administration

NCAR - National Center for Atmospheric Research

NCEP - National Center for Environmental Prediction

NO - Noroeste

NRL - Naval Research Laboratory (NRL) technique

PERSIANN - Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks

POD – Probability of Detection

PP - algoritmo de propriedades de precipitação

REFAME - *Rain* Estimation using Forward-Adjusted advection of Microwave Estimates

RMSE – Root Mean Square Error

SE - Sudeste

SNIRH – Sistema Nacional de Informação de Recursos Hídricos

TMI - Tropical Rainfall Measuring Mission Microwave Imager

TMPA – TRMM Multisatellite Precipitation Analysis

TRMM - Tropical Rainfall Measuring Mission

TRMM PR - Tropical Rainfall Measuring Mission Precipitation Radar

VIS/IV – Visível / Infra Vermelho

1. INTRODUÇÃO

A precipitação é um componente essencial do ciclo hidrológico e energético global. Medir este fenómeno de maneira fiável e precisa é crucial para a gestão de recursos hídricos e para a monitorização de desastres naturais (Hou et al., 2014).

Medições de precipitação através de métodos convencionais são efetuadas com recurso a estações *in situ* e, quando disponíveis, radares meteorológicos. No entanto a distribuição destes sistemas raramente é adequada e a densidade das estações é altamente variável, com algumas áreas a apresentarem uma distribuição aceitável e outras, poucas ou nenhuma estações (Kidd & Levizzani, 2011). Isto faz com que existam lacunas de dados significativas, um pouco por todo o mundo, o que origina sérios problemas de representatividade (Liu et al., 2014).

Estas estações são também suscetíveis a eventos meteorológicos extremos que podem ser a causa de danos, impossibilitar a comunicação de dados ou mesmo da paragem completa de funcionamento das estações. Nesta eventualidade é imperativo que outras fontes de dados validadas estejam disponíveis (Chen et al., 2013). Como tal a procura de sistemas que meçam os dados de maneira contínua, precisa e regular tem vindo a aumentar (Fotopoulos et al., 2010; Meng et al., 2014; Huffman et al., 2010). Para corrigir estes problemas, várias agências internacionais criaram e lançaram missões de observação terrestre, com o intuito de colher informação meteorológica à escala quase global recorrendo a sensores de micro ondas passivas e sensores óticos de infravermelhos (Meng et al., 2014, Hou et al., 2014, Kidd and Levizzani, 2011). Entre estas missões destacam-se a Tropical Rainfall Measuring Mission (TRMM) e a Global Precipitation Measurement Mission (GPM) que resultaram de uma colaboração entre a National Aeronautics and Space Administration (NASA) e a Japan Aerospace Exploration Agency (JAXA) tendo sido ambas criadas para melhorar o conhecimento da distribuição e variabilidade dos fenómenos de precipitação no panorama climático atual (Liu et al., 2012). No entanto, os dados gerados por missões deste tipo precisam de ser submetidos a processos de validação rigorosos, para ser possível utiliza-los com alguma confiança em situações operacionais (Dinku et al., 2007).

O estudo que se segue pretende precisamente validar o produto IMERG, produzido pela mais recente missão deste tipo (GPM), na bacia hidrográfica do Rio Mondego. Uma vez que ainda há muito a fazer no que toca à validação de dados de precipitação obtidos via satélite em Portugal, a escolha da área a estudar não foi condicionada, qualquer bacia era uma opção possível, e foi então tomada a decisão dada a familiaridade com esta bacia. Uma vez que o estudo foi realizado na

Universidade de Coimbra é com naturalidade que a escolha tenha sido a bacia em que Coimbra se encontra, a Bacia do Rio Mondego.

Este estudo pretende contribuir para um melhor conhecimento da *performance* deste produto e abrir portas para o desenvolvimento de estudos hidrológicos e aplicações operacionais para a área em estudo. Para tal foram comparados os dados de 65 estações *in situ*, com as estimativas produzidas pelo algoritmo ao longo de um período de quatro anos e meio, com recurso a métodos de análise estatística recorrentemente utilizados no desenvolvimento deste tipo de trabalhos.

Para alcançar este objetivo global, que é a validação, foram definidas um conjunto de etapas, sub-objectivos se assim lhes quisermos chamar, e que se encontram a seguir listados:

- 1- Obter dados do SNIRH e do IMERG e efetuar um controlo de qualidade preliminar dos mesmos;
- 2- Efetuar a análise estatística dos dados quer diários, quer agregados temporalmente,
- 3- Analisar a correlação espacial e a autocorrelação dos dados;
- 4- Interpretar os resultados obtidos;
- 5- Apresentar conclusões possíveis com base na análise comparativa de resultados.

Para atingir estes objetivos, estruturou-se o trabalho da seguinte forma: O capítulo introdutório “**Princípios e enquadramento das estimativas de precipitação por satélite**” pretende apresentar uma visão global dos diversos métodos e sensores utilizados para a aquisição de dados usados em estimativas de satélite. O capítulo que se lhe segue “**Enquadramento**” tem como objetivo descrever a área de estudo sobre a qual o trabalho será desenvolvido, quer do ponto de vista geográfico, quer topográfico, quer hidrológico. Seguidamente, no capítulo “**Metodologias**” procurou-se descrever todos os processos e métodos utilizados para a realização do trabalho. Por fim apresentam-se os capítulos “**Resultados**”, “**Discussão**” e “**Conclusões**”.

2. PRINCÍPIOS E ENQUADRAMENTO DAS ESTIMATIVAS DE PRECIPITAÇÃO POR SATÉLITE

As estimativas de precipitação por satélite podem ser calculadas a partir de medições efetuadas por diversos tipos de sensores. As metodologias de captação de dados dividem-se em três categorias principais baseadas no tipo de observação, técnicas Visível/Infravermelho (VIS/IV), técnicas de micro-ondas passivo (MOP) e multi-sensor (Kidd & Levizzani, 2011).

2.1. Métodos VIS/IV

Na zona visível (VIS) do espectro as nuvens têm aparência relativamente clara em contraste com a superfície da terra devido ao seu elevado albedo. A precipitação pode ser inferida a partir de imagens VIS uma vez que as nuvens claras tendem a ser espessas, e nuvens espessas são normalmente associadas a precipitação. Contudo, a relação entre claridade e precipitação é ténue e conseqüentemente as imagens VIS são, de um modo geral, apenas usadas em conjunção com outras observações. A textura do topo das nuvens observada em imagens VIS pode fornecer informação útil uma vez que as nuvens do tipo stratus tendem a apresentar uma textura lisa por sua vez as nuvens convectivas tendem a apresentar uma textura mais granulosa. As propriedades das partículas de topo de nuvem, (tamanho e fase) podem ser obtidas a partir de dados multicanal de infravermelho próximo. As medições de radiância refletida/emitada com valores próximos de 1.6, 2.1 e 3.9 μm têm sido muito úteis no estudo das propriedades microfísicas das nuvens, no entanto têm algumas limitações, sendo por vezes limitadas a condições de luminosidade características do período diurno. A ferramenta de análise de medições de satélite relativas a nuvens, aerossóis e precipitação (Lenksy & Rosenfeld, 2008) classifica imagens com recurso a tabelas especificamente criadas para análise microfísica diurna e análise microfísica noturna o que permite uma delimitação de áreas de precipitação com base em microfísica de nuvens (Kidd & Levizzani, 2011).

Imagens de IV que medem as emissões térmicas de objetos são potencialmente mais úteis e podem ser obtidas quer durante a noite quer durante o dia. Precipitação mais severa tende a estar associada a nuvens maiores e mais altas com topos de nuvem mais frios. Através da observação das temperaturas de topo de nuvem uma estimativa simples de precipitação pode ser obtida. Contudo, a relação entre estas temperaturas e precipitação é indireta, com variações significativas no decurso do evento de

precipitação, entre sistemas de precipitação e entre regimes climatológicos. Não obstante, as técnicas com base no infra vermelho beneficiam da sua simplicidade bem como da sua disponibilidade no que diz respeito ao período em que obtenção de dados é possível, 24 horas Barrett e Martin (1981) apresentam uma visão alargada dos algoritmos e métodos iniciais. Um exemplo da utilização destas técnicas é o Índice Global de Precipitação (Arkin & Meisner, 1987).

As técnicas multicanal usam uma combinação de dados VIS/IV, um exemplo destas é o algoritmo de precipitação multi espectral (Ba & Gruber, 2001) que utiliza 5 canais do satélite GOES para retirar informação relativa às nuvens e potencial precipitação e utiliza essa informação para estimar a quantidade de precipitação e aplica correções dependendo do tipo de nuvens e de precipitação. Roebeling e Holleman (2009) por sua vez desenvolveram o algoritmo de propriedades de precipitação (PP) que utiliza propriedades físicas das nuvens obtidas pelo MSG.

Redes neuronais artificiais também foram utilizadas por Hung et al. (2009) para desenvolver um método que melhorasse a precisão da determinação de eventos de precipitação *versus* ausência dos mesmos (rain/ no rain). Os resultados demonstraram que, para o período diurno, grandes melhorias podem ser feitas (Kidd & Levizzani, 2011).

2.2. Métodos de micro-ondas passivas

A Terra emite naturalmente níveis baixos de radiação micro-ondas que pode ser medida de forma passiva por radiómetros. O principal fator que interfere com este tipo de radiação é a presença de partículas do tamanho de gotas de água. Existem dois fatores que tornam possível a identificação do tipo de precipitação uma vez que a emissão de gotículas de chuva leva a um aumento da radiação micro-ondas e as partículas geladas levam a uma dispersão da radiação micro-ondas que faz diminuir os níveis medidos desta radiação. O sinal radiométrico de *background* sobre a água é baixo e constante, o que faz com que as emissões causadas pela precipitação possam ser usadas para identificar e quantificar eventos de precipitação utilizando canais de baixa frequência (< 20 GHz). Por sua vez, o valor de background sobre terra é muito mais elevado e conseqüentemente as emissões geradas pelas gotículas de chuva não podem ser medidas com precisão. Neste caso a dispersão causada por partículas geladas que eliminam frequências mais elevadas (> 35 GHz) tem que ser utilizada. Sobre terra é preciso ter cuidado redobrado para assegurar que os valores de background não contaminem as medições de precipitação, Ferraro et al. (1998) apresentam uma

discussão de métodos para a interpretação de diferentes assinaturas de sinal, com vista possibilitar a distinção entre eventos de precipitação e superfícies que apresentam uma assinatura semelhante (Kidd & Levizzani, 2011).

Os algoritmos para precipitação estimada por sensores de micro ondas passivas podem ser classificados em três categorias: algoritmos do tipo “emissão” (Wilheit et al., 1991); do tipo “dispersão” (Spencer et al., 1989); e “inversão multicanal” (Bauer, 2001). Estes, podem por sua vez ser divididos em técnicas empíricas, que são calibradas utilizando dados de superfície e técnicas físicas que minimizam a diferença entre a radiação estimada e observada. As técnicas físicas que apresentam um nível de sucesso mais elevado utilizam bases de dados que comparam as observações de satélite com os perfis atmosféricos, criados utilizando modelos generativos. A principal vantagem das técnicas físicas é que estas produzem mais informação sobre o sistema de precipitação do que apenas a precipitação.

Têm sido desenvolvidas outras técnicas com recurso a redes neuronais que procuram relacionar as observações de micro-ondas passivas, obtidas por satélite, com a precipitação. Em 2009 Capacci e Porcu utilizaram uma rede neuronal treinada para classificar a precipitação em 5 classes para melhorar a deteção de precipitação pelo AMSR-E da NASA.

Observações de alta frequência de sensores de micro-ondas passivas feitas pelo AMSU-B tornaram possível obter dados relativos a precipitação sobre zonas com backgrounds de superfície problemáticos, como é o exemplo da orla costeira e da cobertura de neve/gelo. Uma das primeiras técnicas à escala global para explorar estas observações e obter valores de precipitação, com resolução de 15 a 50 km efetuado através do AIRS, AMSU e do HSB, com recurso a uma rede neuronal e desenvolvida por Chen e Staelin, em 2003.

A principal limitação das técnicas que têm por base micro ondas passivas é que as observações só são possíveis a partir de satélites LEO, que fazem 2 observações por dia, por satélite. Para além disso a resolução espacial dos canais de baixa frequência que são usados sobre o oceano é de cerca de 50 x 50 km. Por sua vez, para as frequências mais altas, que são utilizadas sobre terra, as resoluções não tendem a ser melhores que 10 x 10 km.

2.3. Técnicas de micro-ondas ativo

As técnicas de micro-ondas são o método mais direto de estimativa da precipitação, contudo o uso de satélites que utilizam este método para medições de precipitação é muito limitado, sendo o TRMM PR o primeiro especificamente criado para obter dados relativos às características de precipitação. Mais recentemente, com o final da missão TRMM e início da nova, missão GPM, passaram a ser utilizados os dados obtidos pelo radar instalado nesta última que é um sistema de radar de dupla frequência desenvolvido especificamente para medições de precipitação. Tal como todos os sistemas de radar estes utilizam a interpretação da retrodifusão da radiação pela precipitação, que é diretamente proporcional à quantidade de partículas do tamanho de gotículas e por sua vez à intensidade. Contudo a relação ente intensidade e retrodifusão não é constante. Mesmo assim o PR foi usado extensivamente como a principal fonte de estimativas de precipitação de alta qualidade e para avaliar diferenças ente regimes de precipitação sobre a terra e sobre o oceano. Exemplos disto são os trabalhos de Ikai e Nakamura (2003) e Furuzawa e Nakamura em (2005). O novo radar de dupla frequência da missão GPM tem uma maior sensibilidade, o que lhe permite detetar precipitação mais fraca quer na forma de chuva ou neve, até valores da ordem dos 0.3 mm h^{-1} (Kidd & Levizzani, 2011).

2.4. Técnicas multi sensor

O número de técnicas com vista a explorar a sinergia entre as captações de dados de micro-ondas passivas por satélites de órbita polar, que são obtidos com menos frequência e de maneira mais direta, e com as observações geostacionárias, mais frequentes e menos diretas, tem vindo a aumentar. Têm sido desenvolvidas técnicas para ajuste de infra vermelhos, ou para gerar curvas de calibração para mapear a radiação infravermelha utilizando outros métodos de obtenção de dados como o radar, as estações *in situ* ou outros dados de satélite. A TRMM (TMPA; Huffman et al., 2007) utilizou dados de micro-ondas passivas, e de dados de IV de satélites geostacionários com ajustes feitos para cada um dos satélites, combinando-os posteriormente num único produto de precipitação. A CMAP, (Xie e Arkin, 1998) incorpora dados IV de satélite conjuntamente com valores de estações *in situ* e dados já analisados pelo NCEP e NCAR. Existem também outras técnicas, como por exemplo a técnica de micro-ondas passivas mais infravermelho (Kidd et al., 2003), a técnica NRL (Turk et al., 2000), e a GSMaP (Kubota et al., 2007). Outras técnicas têm usado redes neuronais para estimar

a precipitação através da combinação de informação obtida a partir de observações multi-canal e multi-sensor como é o caso da PERSIANN (Hsu et al., 1997).

Estas técnicas estão em última análise limitadas pela falta de capacidade dos métodos IV de medirem a precipitação em si propriamente, sendo um método bastante indireto. Contudo os métodos IV podem providenciar uma medida razoável de movimento das nuvens que pode ser depois usada para potenciar o uso dos métodos de micro-ondas passivas, mais diretos. Um exemplo do uso desta técnica é a CMORPH (Joyce et al., 2004). Técnicas mais complexas usam uma combinação de observações de satélite e modelação para produzir estimativas de precipitação. O modelo Lagrangian (LMODEL) proposto por Bellerby et al. (2009) é baseado num modelo conceptual de desenvolvimento de nuvens com recurso a imagens de satélite e a medições de precipitação por micro-ondas a partir de satélites LEO. Em 2010, Behrangi et al. desenvolveu a técnica REFAME que combina advecção e desenvolvimento de nuvens numa só técnica.

Dados de relâmpagos obtidos por redes de deteção terrestres ou por sensores espaciais têm-se provado úteis na melhoria de estimativas de precipitação. Em 2000, Grecu et al. desenvolveram uma técnica combinando dados de relâmpagos e dados de IV para estimação de chuva convectiva. Por sua vez dados do TRMM PR, TMI e LIS foram combinados na zona dos trópicos e sub-trópicos para examinar as características da precipitação (Kidd & Levizzani, 2011).

2.5. GPM

Uma vez que foi com recurso aos dados obtidos pela missão GPM que o trabalho foi realizado é necessário dedicar à mesma um subcapítulo próprio.

O Global Precipitation Measurement (Program) (GPM) é uma rede internacional de satélites de última geração que captam dados relativos à precipitação e à neve à escala global e que tem como objetivo melhorar o conhecimento no que diz respeito ao ciclo da água e ciclo energético da Terra, a melhoria da capacidade de previsão de eventos extremos e disponibilizar informação precisa e em tempo útil (NASA, GPM – Global Precipitation Measurement, 2018).

Tal como no passado, no que diz respeito a estimativas de precipitação por satélite, os sensores de micro-ondas passivas continuam, e continuarão no futuro próximo, a ser os principais responsáveis pela obtenção da grande maioria dos dados de qualidade superior no que diz respeito a este tipo de estimativas e, como já foi mencionado anteriormente, estes só estão disponíveis em satélites LEO. O IMERG está desenhado para compensar a falta de cobertura que os satélites LEO têm a carácter individual, utilizando não um mas sim tantos satélites quanto possível e preenchendo os dados com estimativas de infravermelho obtidas por satélites geoestacionários. Finalmente os dados de precipitação de estações locais, obtidos mensalmente, são utilizados para corrigir os dados regionalmente e para corrigir o bias das estimativas de satélite. Nenhum dos satélites utilizados, à exceção do satélite principal da GPM, é controlado pela GPM, como tal o IMERG usa tantos satélites de oportunidade quantos possível de maneira muito flexível (Huffman et al., 2018).

3. ENQUADRAMENTO

3.1. Caracterização da bacia hidrográfica do Mondego

O Rio Mondego nasce na Serra da Estrela, mais especificamente no Corgo das Mós (onde nasce o Mondeguinho), a 1547 metros de altitude e desagua na Figueira da Foz, no Oceano Atlântico. Tem uma extensão de 227 km, e uma bacia hidrográfica com uma área aproximada de 6670 km² (Lourenço, 1986), é a segunda maior bacia situada exclusivamente em território nacional (Ribeiro & Gamito, 2012).

Os principais tributários do Mondego são os rios Dão e Foja e a ribeira Ançã na margem direita e os Rios Alva, Arunca, Ceira, Ega, Pranto e a Ribeira de Cernache na margem esquerda (Lourenço 1986). O Rio Pranto converge com o Mondego já em zona de estuário. O vale, a montante de Coimbra, é bastante profundo, no entanto após a passagem por Coimbra o rio espalha-se formando uma vasta planície aluvial que constitui 15000 hectares de terra com alto potencial agrícola (Graça, Pardal, & Marques, 2016).

No que diz respeito à Geologia, uma parte importante da Bacia do Mondego, a leste da zona de cisalhamento Porto-Tomar, é predominantemente ocupada por rochas metassedimentares e eruptivas pertencentes ao Maciço Hespérico, essencialmente granitoides, xistos, grauvaques e alguns quartzitos. Devido à presença do rio Mondego e dos seus afluentes é possível também observar depósitos de cobertura, arcósicos e aluviões. A oeste do alinhamento Porto-Tomar as formações geológicas são de carácter distinto, tipicamente sedimentar, constituem a Orla Meso-Cenozóica Ocidental. É um domínio que apresenta grande espessura de sedimentos, com colinas calcárias e vales pouco profundos com aluvionamento significativo. Verifica-se grande variabilidade litológica, textural e estrutural. Os carbonatos, arenitos e argilitos abundam e é possível também observar locais que apresentam cobertura quaternária/ plio-quaternária composta por material arenoso desagregado (Almeida; Mendonça; Silva; Serra, 2018).

A bacia do Mondego do ponto de vista morfológico, é enquadrada pela Cordilheira Central no planalto da Beira Alta. Esta cordilheira separa a bacia do Mondego da Bacia do Tejo, sendo limitada a Noroeste pelas serras do Caramulo (1071 metros de altitude) e do Buçaco (altitude 568 metros). Estas serras separam a Bacia do Mondego da Bacia do Rio Vouga. O último acidente orográfico que encaixa o Rio Mondego antes de este entrar na zona de planície é a Serra do Lorvão com cerca de 500 metros de altitude. Importa ainda referir que a Serra da Boa Viagem, junto à foz do

Mondego, na zona de Buarcos, que constitui o Cabo Mondego é o único acidente orográfico em toda a costa de Espinho a Peniche (Ribeiro & Gamito, 2012).

Os distintos tipos de vales em que corre o Rio Mondego, ao longo do seu percurso, permitem-nos identificar/ delimitar diferentes zonas, particularmente três: Alto Mondego (que corresponde à parte do rio que corre ao longo de vales glaciares no maciço da Serra da Estrela); Médio Mondego (que corresponde à parte do rio que corre em vales encaixados entre a Serra da Estrela e Coimbra, neste ramo do rio afluem os rios Dão, Alva e Ceira) e Baixo Mondego (que corresponde à parte do rio que corre em vales abertos, em zona de planícies, a jusante de Coimbra até à Figueira da Foz. Neste ramo do rio afluem os rios Arunca e Pranto) (Ribeiro & Gamito, 2012).

A geomorfologia da região em que se insere a Bacia do rio Mondego, em particular a presença da cordilheira central a SE da bacia, tem especial importância no que diz respeito à precipitação, quer em termos de intensidade quer em termos de distribuição espacial, uma vez que a translação das massas de ar de NO para SE ao colidirem com esta barreira natural potenciam fenómenos de precipitação, por estímulo orográfico, com valores que podem chegar ser superiores ao triplo dos valores medidos nos vales (Rodrigues, Brandão & Costa, 2001).

A bacia do Rio Mondego (Figura 1) impacta de forma significativa a vida quotidiana de mais de meio milhão de pessoas (Graça et al., 2016).

Como já foi mencionado anteriormente a bacia do Mondego é a segunda maior bacia situada exclusivamente em território nacional (sendo a maior a bacia do Sado) e como tal, é evidente a importância estratégica destes rios e das suas bacias, quer para a região centro, quer a nível nacional.

Desde que há memória as cheias têm sido um problema constante desde a zona de Coimbra até à planície aluvial. Para tentar controlar este problema foi efetuada uma regularização das margens do rio e foram contruídas diversas barragens: Aguieira, Raiva e o Açude de Coimbra no Rio Mondego e a barragem de Fronhas no Rio Alva (Dias & Rebelo, 1984).

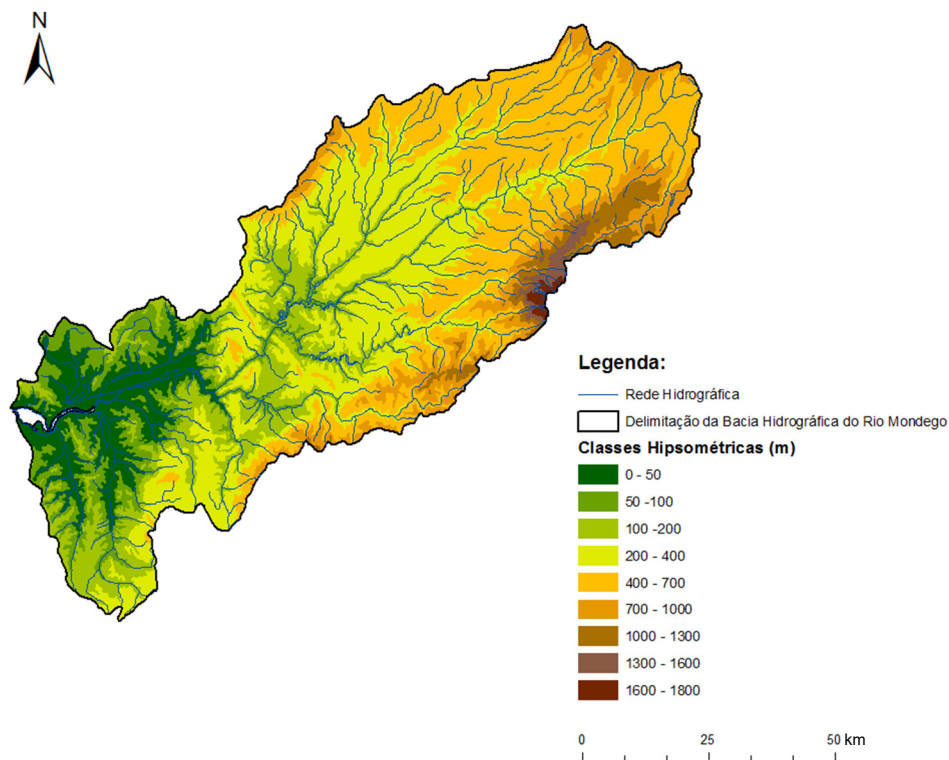


FIGURA 1 - MAPA HIPSOMÉTRICO DA BACIA HIDROGRÁFICA DO RIO MONDEGO COM A REDE HIDROGRÁFICA REPRESENTADA

A zona do Baixo Mondego consiste essencialmente em terreno de uso agrícola em que a maioria das plantações são de arroz (60% da área do Baixo Mondego). Existe também cultivo de Milho e Feijão (18%). As áreas em que não existe cultivo, como é o caso das zonas de pântano, situam-se de um modo geral na orla da planície e exibem uma fauna e flora exuberante (Anastácio et al., 1995).

3.2. Hidrologia da bacia hidrográfica do Mondego

O clima da região em que se insere a bacia hidrográfica do Mondego é do tipo Mediterrânico e é fortemente influenciado pela proximidade ao Oceano Atlântico. A proximidade ao Atlântico causa o aumento da humidade presente no ar que por sua vez afeta a temperatura e a precipitação (Graça et al., 2016).

Segundo a Classificação Köppen-Geiger, o clima de Portugal encontra-se dividido entre 2 classificações Csb (warm temperate, summer dry, warm summer) e Csa (warm temperate, summer dry, hot summer), estando a zona norte do país inserida

maioritariamente na denominação Csb e a zona sul na denominação Csa. A área de estudo encontra-se na zona de transição entre as duas classificações (Figura 2).

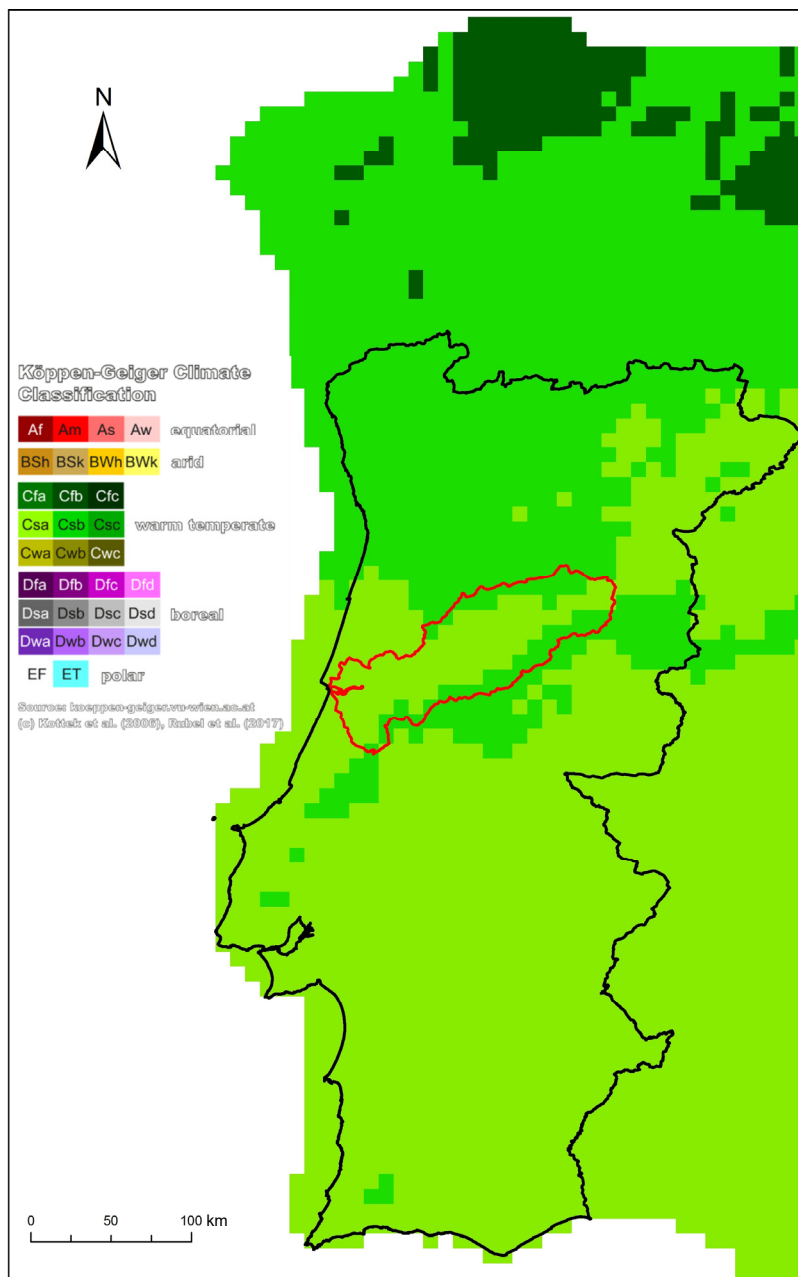


FIGURA 2 - MAPA DA CLASSIFICAÇÃO KÖPPEN-GEIGER PARA PORTUGAL CONTINENTAL, COM DESTAQUE PARA A BACIA HIDROGRÁFICA DO MONDEGO DELINEADA A VERMELHO (ADAPTADO DE KOTTEK ET AL., 2006)

A temperatura anual média da bacia do Mondego é aproximadamente 13°C, sendo a zona com temperatura média mais alta (16°C) a região do Baixo-Mondego e os locais com as temperaturas mais frias as Serras da Estrela e do Caramulo, em que a temperatura média é de apenas 10°C. Na orla costeira as flutuações de temperatura são reduzidas devido à influência do Oceano Atlântico. À medida que a distância à costa

umenta essas flutuações aumentam também. Nos meses mais frios do ano, Dezembro e Janeiro, a temperatura média da bacia é de cerca de 6°C, por sua vez, nos meses mais quentes do ano, em Julho e Agosto, a temperatura média ronda os 19°C (Graça et al., 2016).

A precipitação média anual na área da bacia é de aproximadamente 1130 mm. O período mais húmido estende-se de Outubro a Março, período em que é registada a maioria da precipitação. O mês mais húmido é Dezembro com registos de precipitação da ordem dos 160 mm. Os meses mais quentes do ano são também os mais secos, com Julho e Agosto a registarem valores mensais de precipitação perto dos 15 mm. É comum, durante a época seca, a existência de períodos mensais em que a precipitação registada é nula (Graça et al., 2016).

A topografia tem, no caso da Bacia do Mondego, uma influência clara tanto na temperatura como na precipitação. Existe um claro aumento da precipitação (Figura 3) e clara diminuição da temperatura à medida que os valores de cota aumentam (Graça et al., 2016). Uma vez que é clara esta relação podemos então utilizar a classificação anterior atribuída à geomorfologia e transportá-la para a hidrologia considerando-a então como uma classificação hidro-morfológica e utilizando a mesma nomenclatura: Alto, Médio e Baixo Mondego.

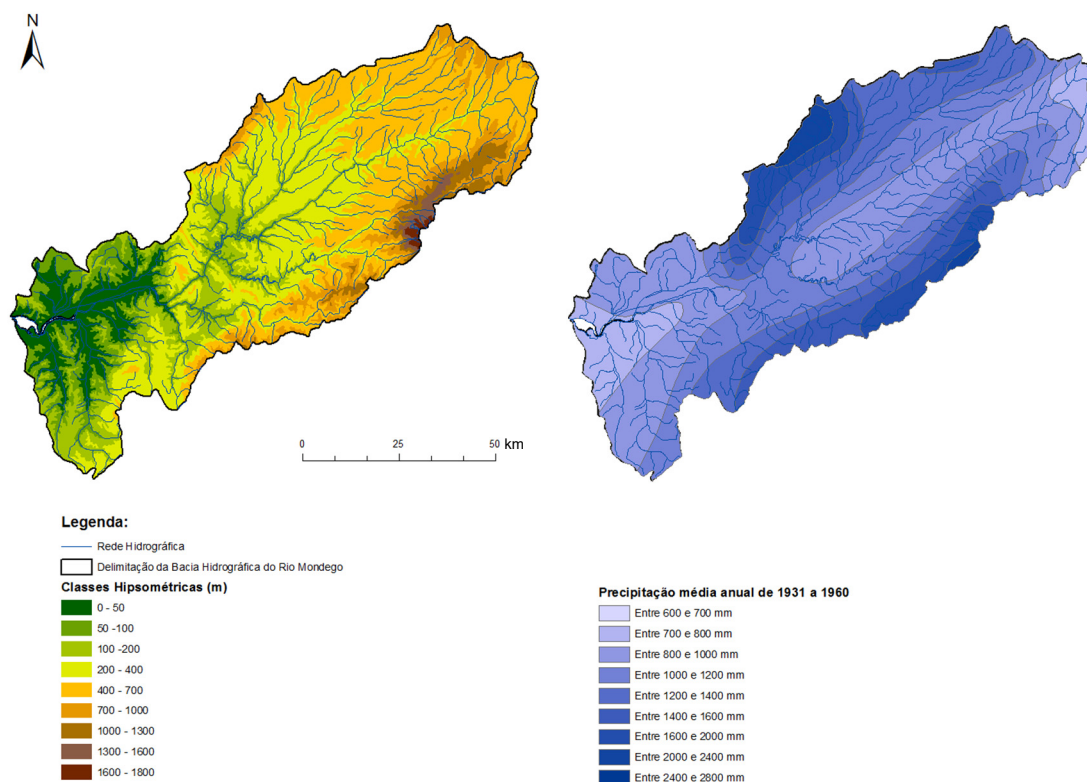


FIGURA 3 - MAPA HIPSOMÉTRICO DA BACIA HIDROGRÁFICA DO RIO MONDEGO LADO A LADO COM O MAPA DA PRECIPITAÇÃO MÉDIA ANUAL PARA EFEITOS COMPARATIVOS (METADADOS: SNIAMB, 2019)

O escoamento superficial anual médio do Rio Mondego é aproximadamente 86 m³/s (403 mm ou 2,7x10⁹ m³) ano, no entanto os valores diários e sazonais são extremamente variáveis, quer no Rio Mondego em si, quer para os seus tributários de primeira ordem. Na zona de Coimbra chegaram a ser registados valores da ordem dos 3000 m³/s que contrastam com valores da ordem de 1 m³/s registados em diversos outros dias do ano. Esta característica da bacia deu origem a frequentes cheias e problemas no que diz respeito ao acesso à água, em especial para uso agrícola. Após a construção das diversas barragens, já mencionadas anteriormente, Aguieira, Raiva e o Açude de Coimbra no Rio Mondego e a barragem de Fronhas no Rio Alva, as cheias continuam a ser um problema na bacia, embora de carácter muito menos frequente (Graça et al., 2016).

4. METODOLOGIA

Neste capítulo procurou-se descrever todos os processos e métodos utilizados no decorrer da realização da dissertação. A realização do trabalho teve por base a utilização de métodos estatísticos com vista à validação dos dados de precipitação gerados pelo GPM_3IMERGDF_v05 para a Bacia Hidrográfica do Rio Mondego.

Genericamente as tarefas executadas incluem uma análise geoespacial e estatística. Para esse efeito recorreu-se ao *software* ArcGis.

Segue-se um fluxograma (Figura 4) que pretende descrever de forma sucinta a metodologia utilizada.

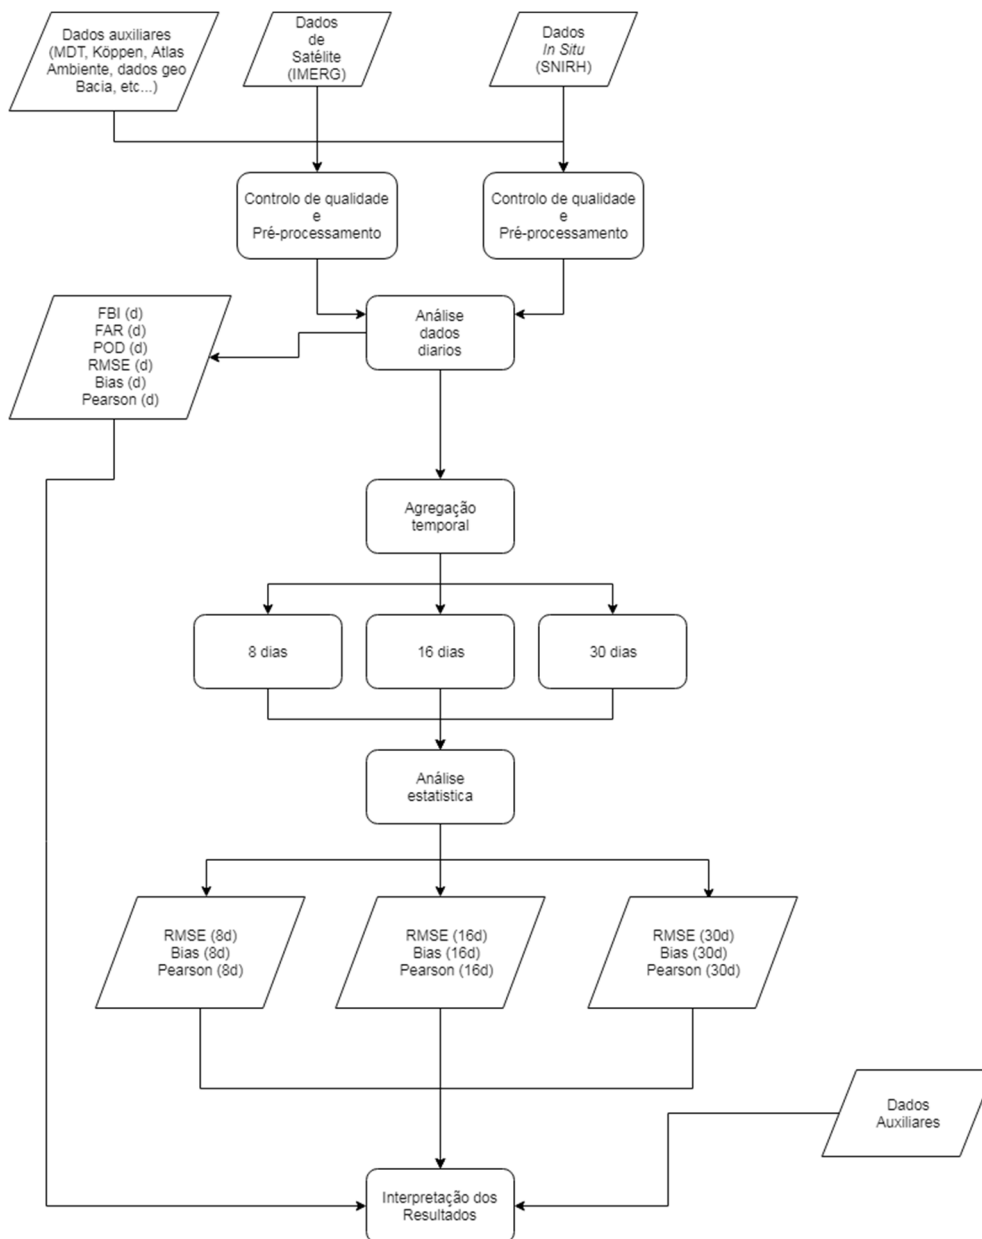


FIGURA 4 - METODOLOGIA UTILIZADA

4.1. Seleção da versão do IMERG a utilizar

O passo seguinte foi a decisão de que versão do IMERG deveria utilizar, *Early*, *Late* ou *Final* e o período de tempo a analisar. O segundo ponto foi uma decisão fácil e acabou por decidir também que versão deveria utilizar.

Os dados IMERG são disponibilizados nos formatos *Early*, *Late*, ou *Final*, sendo as versões *Early* e *Late* disponibilizadas no próprio dia, sendo a diferença essencial entre as duas que no caso da versão *Early* apenas é usada extrapolação, enquanto na *Late* é usada extrapolação e interpolação no tratamento dos dados. Para além disso as 10 horas de latência desde a disponibilização da versão *Early* até ser disponibilizada a versão *Late* permitem que dados que ainda não foram transmitidos aquando da disponibilização da versão *Early* sejam incluídos na versão *Late* tornando-a mais robusta. A versão *Final* para além dos dados de satélite usa também dados mensais de precipitação de estações *in situ* que fazem parte da rede do GPCC.

A definição da versão adequada relaciona-se com a seleção do intervalo temporal a considerar. Os dados IMERG (GPM_3IMERGDF_v05) são disponibilizados a partir de Março de 2014, considerando-se a data inicial da validação 14 de Março de 2014. Considerando a disponibilização com um pequeno intervalo temporal das versões *Early* e *Late*, optou-se pela escolha da segunda versão, mais robusta, de acordo com a descrição do algoritmo (Giovanni, 2019). Já a versão *Final*, é disponibilizada com uma latência que atinge praticamente 4 meses. Embora adequada a utilizações de carácter científico, não é indicada para usos operacionais, tendo, por essa razão, sido desconsiderada do presente estudo. Mesmo ciente deste problema, na altura da decisão foi feita uma breve análise comparativa entre as duas versões e alguns dados de estações *in situ* e o que foi observado é que a melhoria de performance do *Late* para o *Final* era, para a zona em estudo, de um modo geral muito pouco significativa e não justificava, face à latência previamente referida, a sua utilização para a realização do trabalho em detrimento da versão *Late*.

4.2. Dados *in situ*

Quanto aos dados de precipitação necessários para a realização do trabalho a decisão era entre os dados do SNIRH, que estão disponíveis ao público de forma gratuita, e que são obtidos através de uma vasta rede de estações udoográficas e climatológicas e os dados do IPMA, que não estão disponíveis ao público e que têm que ser comprados. No caso do meu trabalho em particular, que incluiu dados de 71 estações, registados ao longo de um período superior a 3 anos e meio ou seja mais de 100.000 dados diários de precipitação, o preço seria proibitivo, e uma vez que os dados do SNIRH têm vindo a ser utilizados em investigação e são dados com qualidade, a decisão foi então utilizar os dados desta fonte.

4.3. Obtenção dos dados do SNIRH

A obtenção dos dados do SNIRH foi bastante simples, e para o fazer bastou apenas aceder ao *síte* do SNIRH, e seleccionar as bacias pretendidas (Figura 5), neste caso o que se fez foi seleccionar todas as estações contidas na Bacia do Mondego e para além destas todas as estações que se encontravam perto do limite desta bacia mas que pertenciam já às bacias dos rios Vouga, Douro, Tejo e Lis.



FIGURA 5 - PROCESSO DE SELEÇÃO DAS BACIAS PRETENDIDAS – IMAGEM RETIRADA DE [HTTPS://SNIRH.APAMBIENTE.PT](https://snirh.apambiente.pt)

Para o descarregamento dos dados foram selecionadas as estações pretendidas para análise (Figura 6), o parâmetro sobre o qual pretendemos obter dados, neste caso precipitação diária e o período em análise, de 14-03-2014 até ao final de 2018 obtendo assim um ficheiro no formato CSV.

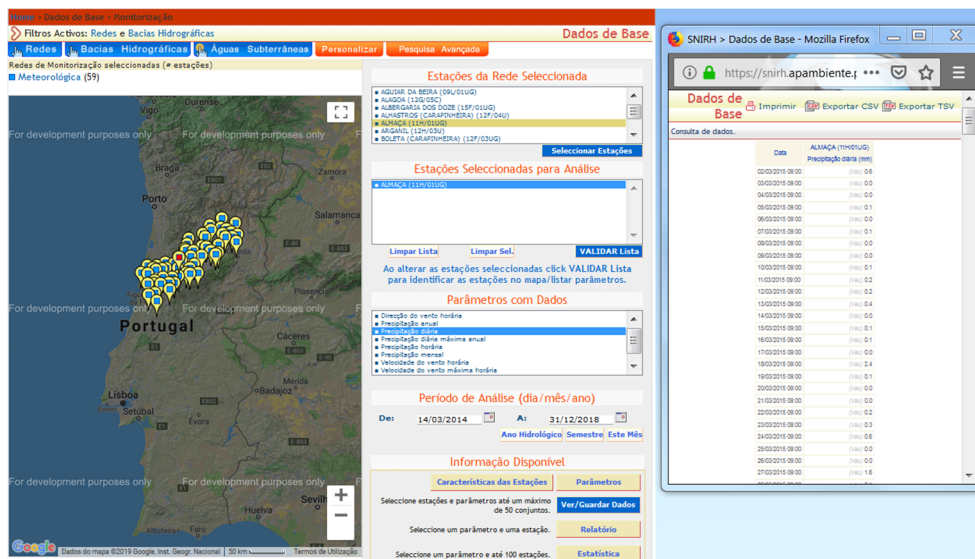


FIGURA 6- PROCESSO DE DESCARREGAMENTO DOS DADOS DO SNIRH RELATIVOS A PRECIPITAÇÃO DIÁRIA - IMAGEM RETIRADA DE [HTTPS://SNIRH.APAMBIENTE.PT](https://snirh.apambiente.pt)

Devido a lacunas no registo de precipitação diária para o período em estudo, das 59 estações incluídas na Bacia do Mondego 18 não tinham qualquer registo de dados (Figura 7) para o período em estudo, em especial na zona NO da bacia. Foi feito um consequente alargamento da área de estudo e novo descarregamento de dados de modo a complementar as lacunas encontradas. Foram então adicionadas mais 30 estações já com a perspectiva de que pudesse haver um número significativo de estações que, mesmo que tivessem registo de dados para o período em estudo, esse registo não fosse suficiente para executar a análise estatística pretendida.

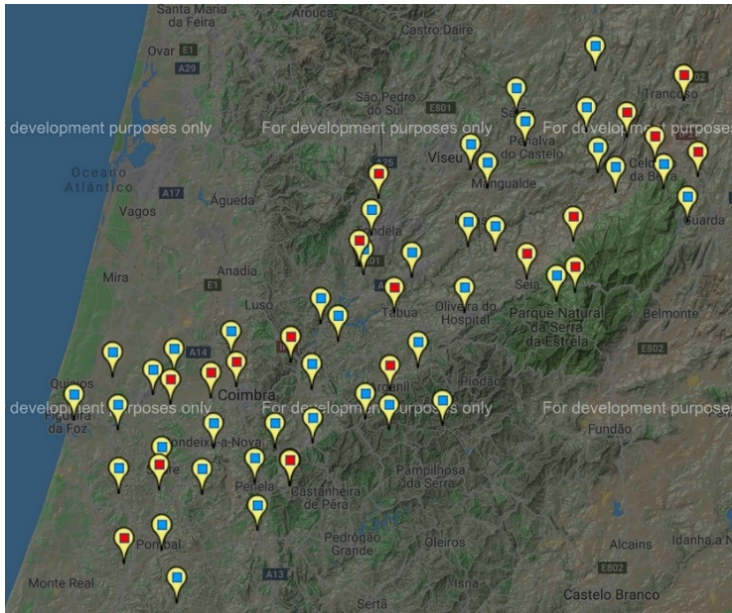


FIGURA 7 - ESTAÇÕES SEM DADOS A VERMELHO - IMAGEM RETIRADA DE [HTTPS://SNIRH.APAMBIENTE.PT](https://snirh.apambiente.pt)

4.4. Obtenção dos dados de satélite

Para a obtenção dos dados de satélite foi, após o descarregamento, verificação e posterior alargamento e novo descarregamento dos dados do SNIRH. Foi criada uma folha de excel em que constam todas as coordenadas de cada estação do SNIRH e que faz corresponder a cada estação a *box* a definir no *site* da NASA (Giovanni), para o descarregamento dos dados de satélite. Mais uma vez, é importante referir que estes dados são gratuitos e que estão disponíveis para *download* uma vez criada uma conta gratuita no *site* mencionado. O *site* funciona de maneira semelhante ao do SNIRH, no entanto, todos os parâmetros são seleccionados de uma só vez (Figura 8). Foi seleccionado o período em estudo, a variável pretendida, neste caso precipitação diária segundo o produto GPM_3IMERGDL v05 e por fim definiu-se a tal *box* (Figura 9), mencionada anteriormente, que consiste em quatro coordenadas na ordem Oeste, Sul, Este e Norte e que definem uma área, que no caso deste trabalho tinha como centro cada estação do SNIRH utilizada e cada coordenada divergia 0,15 % deste ponto central, o que corresponde a uma janela 3x3 píxeis com centro na estação *in situ* correspondente. Optou-se pela utilização de uma janela em deferimento de um ponto

de forma a minimizar os efeitos decorrentes da heterogeneidade espacial e temporal da precipitação.

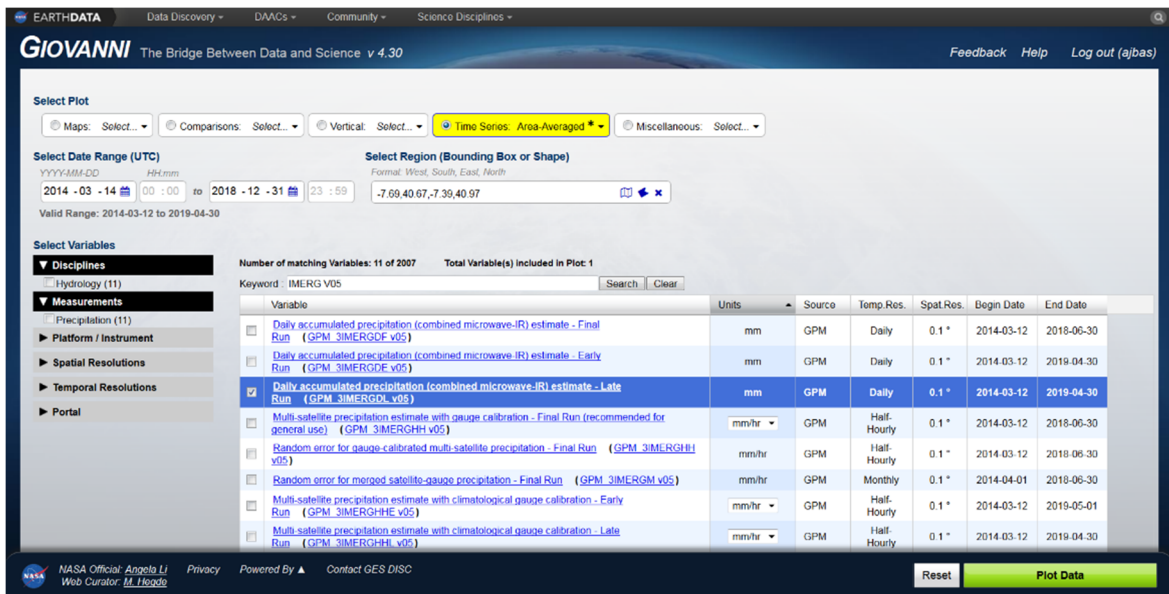


FIGURA 8 - PROCESSO DE OBTENÇÃO DE DADOS DE SATÉLITE - IMAGEM RETIRADA DE [HTTPS://GIOVANNI.GSFC.NASA.GOV/GIOVANNI/](https://giovanni.gsfc.nasa.gov/giovanni/)

Estação	Latitude	Longitude	W	S	E	N
AGUIAR DA BEIRA	40.820	-7.540	-7.690	40.670	-7.390	40.970
ALAGOA	40.305	-8.183	-8.333	40.155	-8.033	40.455
ALBERGARIA DOS DOZE	39.802	-8.586	-8.736	39.652	-8.436	39.952
ALMAÇA	40.338	-8.225	-8.375	40.188	-8.075	40.488
BOLETA	40.203	-8.646	-8.796	40.053	-8.496	40.353
CADAFAZ	40.134	-8.054	-8.204	39.984	-7.904	40.284
CALDAS DE FELGUEIRAS	40.484	-7.858	-8.008	40.334	-7.708	40.634
CARAPINHAL	40.099	-8.340	-8.490	39.949	-8.190	40.249
CARREGAL DO SAL	40.425	-7.998	-8.148	40.275	-7.848	40.575
CASAL DO RATO	40.153	-8.843	-8.993	40.003	-8.693	40.303
CÔJA	40.254	-7.982	-8.132	40.104	-7.832	40.404
CONDEIXA	40.098	-8.496	-8.646	39.948	-8.346	40.248
CUMIEIRA	39.942	-8.385	-8.535	39.792	-8.235	40.092
DEGRACIAS	40.010	-8.522	-8.672	39.860	-8.372	40.160

FIGURA 9 - PROCESSO DESCRITO ANTERIORMENTE DE CRIAÇÃO DAS BOXES A PARTIR DAS COORDENADAS DE CADA ESTAÇÃO

4.5. Preparação dos Dados para análise

Quanto aos dados de satélite não foi necessária grande preparação, uma vez que são dados contínuos sem qualquer lacuna. A cada dia, dos 1755, corresponde um valor de precipitação. A única operação necessária foi uma simples separação por vírgulas no Excel uma vez que os dados e a data correspondente se encontravam na mesma coluna e não duas colunas como era pretendido. Por sua vez os dados do SNIRH apresentavam um problema muito mais complexo derivado da falta de continuidade dos dados. No caso dos dados do SNIRH havia certos dias, meses ou até mesmo anos sem qualquer dado correspondente e para os dias sem dados não havia qualquer representação de data ou designação de dados em falta, simplesmente os dias sem dados estavam omissos do ficheiro descarregado. Podíamos ter por exemplo 22/11/2015 09:00,2.3 (formato dos dados do SNIRH - Data, Precipitação diária (mm)...) e logo de seguida 16/06/2016 09:00,11.6, tais lacunas eram aleatórias em todos os aspetos e variavam de estação para estação, era imperativo ultrapassar este problema e colocar os dados de satélite e *in situ* no mesmo formato e propriamente indexados e espaçados de acordo com as datas a que correspondiam, e para as datas sem dados fazer corresponder uma designação #N/D ou NaN, que significaria ausência de dados.

Fazer esta tarefa manualmente era praticamente impossível uma vez que estamos a falar de mais de 100.000 dias de dados e como tal para ultrapassar este problema foi utilizado um script da autoria do Doutor Vasco Mantas escrito em Python que executava a seguinte tarefa: identificava todas as datas em falta no ficheiro Excel proveniente do SNIRH e introduzia-as, depois verificava se a cada data correspondia um valor e se sim esse valor mantinha-se e, se essa data não tivesse um correspondente valor de precipitação o script fazia-a corresponder às letras "NaN". Foi aplicado esse script a cada uma das estações do SNIRH e foram obtidos então 71 novos ficheiros prontos a

ser utilizados em conjunção com os respetivos ficheiros de satélite na análise de dados (Figura 10).

	A	B	C	D	E	F	G		A	B
1	SNIRH - SISTEMA NACIONAL DE INFORMAÇÃO DE RECURSOS HÍDRICOS							1	14/03/2014	NaN
2								2	15/03/2014	NaN
3	DATA,TENTÚGAL (12F/01UG),,							3	16/03/2014	NaN
4	,Precipitação diária (mm),FLAG,							4	17/03/2014	NaN
5	18/03/2014 09:00,0,(vau),							5	18/03/2014	0
6	19/03/2014 09:00,0,(vau),							6	19/03/2014	0
7	20/03/2014 09:00,0,(vau),							7	20/03/2014	0
8	21/03/2014 09:00,0,(vau),							8	21/03/2014	0
9	22/03/2014 09:00,0,(vau),							9	22/03/2014	0
10	23/03/2014 09:00,0,(vau),							10	23/03/2014	0
11	24/03/2014 09:00,0,(vau),							11	24/03/2014	0
12	25/03/2014 09:00,0,(vau),							12	25/03/2014	0
13	26/03/2014 09:00,0,(vau),							13	26/03/2014	0
14	27/03/2014 09:00,0,(vau),							14	27/03/2014	0
15	28/03/2014 09:00,0,(vau),							15	28/03/2014	0
16	29/03/2014 09:00,0,(vau),							16	29/03/2014	0
17	30/03/2014 09:00,0,(vau),							17	30/03/2014	0
18	31/03/2014 09:00,0,(vau),							18	31/03/2014	0
19	01/04/2014 09:00,0,(vau),							19	01/04/2014	0
20	02/04/2014 09:00,0,(vau),							20	02/04/2014	0
21	05/04/2014 09:00,0,(vau),							21	03/04/2014	NaN
22	12/04/2014 09:00,0,(vau),							22	04/04/2014	NaN
23	15/04/2014 09:00,0,(vau),							23	05/04/2014	0
24	16/04/2014 09:00,0,(vau),							24	06/04/2014	NaN
25	17/04/2014 09:00,0,(vau),							25	07/04/2014	NaN
26	18/04/2014 09:00,0,(vau),							26	08/04/2014	NaN
27	19/04/2014 09:00,0,(vau),							27	09/04/2014	NaN
28	20/04/2014 09:00,0,(vau),							28	10/04/2014	NaN
29	21/04/2014 09:00,0,(vau),							29	11/04/2014	NaN
								30	12/04/2014	0
								31	13/04/2014	NaN
								32	14/04/2014	NaN

FIGURA 10 - EXEMPLO DE UMA ESTAÇÃO - À ESQUERDA DADOS TAL COMO DESCARREGADOS DO SITE DO SNIRH E À DIREITA DADOS APÓS SEREM SUBMETIDOS AO SCRIPT

4.6. Métodos de validação

A comparação entre as estações e as estimativas de satélite foi realizada com recurso a métodos de análise estatística *standard*. Estas métricas têm vindo a ser empregues por autores distintos na realização de trabalhos nesta área. A utilização de métricas semelhantes na realização de trabalhos do mesmo âmbito, por autores variados, permite a comparação dos resultados obtidos.

Os parâmetros estatísticos avaliados foram o RMSE (Root Mean Square Error):

EQUAÇÃO 1 - RMSE

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n \left(R^{IMERG}(xi) - R^{estação}(xi) \right)^2} \quad (1)$$

em que R^{IMERG} é a estimativa de precipitação de satélite e $R^{estação}$ é o valor diário medido pela respetiva estação do SNIRH.

O Bias foi calculado usando a seguinte formula:

EQUAÇÃO 2 - BIAS

$$Bias = \sum IMERG / \sum estação \quad (2)$$

O coeficiente de correlação de Pearson foi usado para determinar a linearidade entre os pares de dados Satélite – Estação. Alguns estudos mencionam problemas potenciais do uso deste coeficiente em análise de dados de precipitação, considerando que nem sempre existe uma distribuição normal. No entanto vários trabalhos demonstram claras vantagens na utilização desta métrica (WANG & WOLFF, 2009) e a vasta quantidade de trabalhos de validação de produtos de precipitação que têm vindo a ser desenvolvidos a fazer uso desta medida (Gadelha et al., 2018; Mantas et al., 2015; Ochoa et al., 2014) reforça a decisão tomada de adotar também esta medida.

EQUAÇÃO 3 - COEFICIENTE DE CORRELAÇÃO DE PEARSON

$$r_{xy} = \frac{Cov(R^{IMERG}, R^{estação})}{\sqrt{Var(R^{IMERG})}\sqrt{Var(R^{estação})}} \quad (3)$$

Em conjunção com os métodos estatísticos já mencionados, foram também calculados parâmetros estatísticos adicionais a partir de tabelas de contingência (Tabela 1) para avaliar as estimativas para valores diários do IMERG *Late*. Estas medidas avaliam a capacidade do IMERG *Late* para identificar eventos de precipitação (precipitação ≥ 1 mm/dia).

TABELA 1 - OS PARÂMETROS A, B, C E D REPRESENTAM O NÚMERO TOTAL DE PARES QUE VERIFICAM A CONDIÇÃO

	Estação chove	Estação não chove
Satélite chove	a	b
Satélite não chove	c	d

Estes parâmetros incluem o FBI (Frequency Bias Index), que mede o rácio de eventos de precipitação medidos pelo IMERG versus o número de deteções pela estação do SNIRH e que é calculado da seguinte forma:

EQUAÇÃO 4 - FBI

$$FBI = (a + b)/(a + c) \quad (4)$$

em que a, b, c e d representam o número total de pares de dados (satélite – estação) que verificam as condições estipuladas na tabela de contingência (Tabela 1).

O FAR (False Alarm Ratio), que avalia o número de falsos positivos dados pelas estimativas de satélite e que é calculado da seguinte forma:

EQUAÇÃO 5 - FAR

$$FAR = b/(a + b) \quad (5)$$

O POD (Probability of Detection), que é calculado para determinar o número de corretos positivos das detecções de precipitação e que se calcula pela fórmula a seguir apresentada:

EQUAÇÃO 6 - POD

$$POD = a/(a + c) \quad (6)$$

foi também calculado o coeficiente de correlação de Pearson para os dados diários.

Quer para os dados individuais de cada estação quer para os dados acumulados de todas as estações, foram efetuadas agregações temporais de dados (os valores de precipitação foram somados) para períodos de 8, 16 e 30 dias e foram aplicados os métodos estatísticos acima mencionados.

Com vista à aplicação dos métodos estatísticos acima mencionados, foi criado um *template* em Microsoft Excel que pudesse ser utilizado para todas as 71 estações a analisar.

Foi feito um primeiro ensaio manual utilizando o *template* criado e foi a partir desse ensaio que o *template* foi ajustado e que foram mapeadas todas as ações necessárias desde a colagem inicial dos dados de satélite e *in situ* até à obtenção de resultados. A partir desse mapeamento foram então criados 7 macros que executavam ações desde copiar os valores de uma coluna para outra, ordenar valores (Figura 12) e substituições de caracteres. Estes macros permitiram tanto aumentar drasticamente a velocidade do trabalho estatístico, bem como diminuir significativamente a probabilidade de introdução de erros não sistemáticos. É importante referir que apenas as tarefas que em nada variavam de estação para estação puderam ser executadas via macro. Uma vez que a quantidade de dados das estações *in situ* varia de estação para estação, para parâmetros como o fator de correlação de Pearson, que não aceita lacunas, foi para cada estação necessário ordenar os valores de forma crescente via macro e depois manualmente selecionar a janela para análise (Figura 11).

	AG	AH	AI	AJ	AK	AL	AM	AN	AO	AP	AQ	AR	AS	AT
1	Person	D	SO	NO	30	COPIAR VALORES	Color Sal FINAL (Coluna T)	Color Extração (Coluna U)	Color Sal FINAL (Coluna V)	Color Extração (Coluna Z)	Color Sal FINAL (Coluna AD)	Color Extração (Coluna AE)		
2	[Não incluir NA]	0.391873	0.875058	0.891936	=PEAFSC		0.00	0.10	0.22780326	7.5	8.44595452	12.8		
3	Bias	0.957502	0.550402	0.578459	0.538372		0.02	0.10	0.702765219	9.5	14.3104659	19.9		
4							0.23	0.20	1.866872082	12.2	17.16327838	32.6		
5							0.02	0.20	19.26223754	15.1	5.869327627	37		
6							0.23	0.30	1.297339597	19.4	7.864636398	75.1		
7							9.51	0.70	7.844703279	32.4	41.95575368	86.2		
8							0.08	1.10	5.869327627	33.8	22.38785812	105.3		
9							0.00	2.20	1.650260107	35.4	15.43374295	111		
10							0.18	3.50	21.23979473	37.6	132.7849252	113.2		
11							6.57	3.70	0.065373653	38.9	136.8813861	147.8		
12							3.51	4.20	9.812530678	39.5	79.58235447	155.8		
13							0.03	5.70	30.66518456	40.4	88.54712261	176		
14							12.98	6.20	31.7334244	41.6	145.4358581	208		
15							4.52	7.30	40.36019377	45.1	101.2801717	209.8		
16							0.00	7.40	11.32671977	45.9	117.6439552	236.6		
17							0.70	7.40	22.18720904	50.9	286.1765855	331.9		
18							0.31	8.30	2.747235061	51.4	72.36788971	#N/D		
19							0.50	8.70	44.27631871	63.1	13.75418734	#N/D		
20							0.00	10.80	21.09623436	66	29.40689395	#N/D		
21							154	11.90	74.4634042	73.9	29.50576502	#N/D		
22							0.62	12.70	108.2083882	74.6	15.09107488	#N/D		

FIGURA 11 - SELEÇÃO MANUAL DA JANELA DE ANÁLISE PARA O FATOR DE CORRELAÇÃO DE PEARSON (AGREGAÇÃO DE DADOS A 30 DIAS)

```

Sub M5_Ordenar_colunas_AM_AN_AP_AQ()
'
' M5_Ordenar_colunas_AM_AN_AP_AQ Macro
' Atalho por teclado: Ctrl+t
'
Columns("AM:AN").Select
ActiveWorkbook.Worksheets("Estatistica Individual").Sort.SortFields.Clear
ActiveWorkbook.Worksheets("Estatistica Individual").Sort.SortFields.Add Key:= _
    Range("AN2:AN1755"), SortOn:=xlSortOnValues, Order:=xlAscending, _
    DataOption:=xlSortNormal
With ActiveWorkbook.Worksheets("Estatistica Individual").Sort
    .SetRange Range("AM1:AN1755")
    .Header = xlYes
    .MatchCase = False
    .Orientation = xlTopToBottom
    .SortMethod = xlPinYin
    .Apply
End With
Columns("AP:AQ").Select
ActiveWorkbook.Worksheets("Estatistica Individual").Sort.SortFields.Clear
ActiveWorkbook.Worksheets("Estatistica Individual").Sort.SortFields.Add Key:= _
    Range("AQ2:AQ1755"), SortOn:=xlSortOnValues, Order:=xlAscending, _
    DataOption:=xlSortNormal
With ActiveWorkbook.Worksheets("Estatistica Individual").Sort
    .SetRange Range("AP1:AQ1755")
    .Header = xlYes
    .MatchCase = False
    .Orientation = xlTopToBottom
    .SortMethod = xlPinYin
    .Apply
End With
Columns("AS:AT").Select
ActiveWorkbook.Worksheets("Estatistica Individual").Sort.SortFields.Clear
ActiveWorkbook.Worksheets("Estatistica Individual").Sort.SortFields.Add Key:= _
    Range("AT2:AT1755"), SortOn:=xlSortOnValues, Order:=xlAscending, _
    DataOption:=xlSortNormal
With ActiveWorkbook.Worksheets("Estatistica Individual").Sort
    .SetRange Range("AS1:AT1755")
    .Header = xlYes
    .MatchCase = False
    .Orientation = xlTopToBottom
    .SortMethod = xlPinYin
    .Apply
End With
Columns("AV:AW").Select
ActiveWorkbook.Worksheets("Estatistica Individual").Sort.SortFields.Clear
ActiveWorkbook.Worksheets("Estatistica Individual").Sort.SortFields.Add Key:= _
    Range("AW2:AW1755"), SortOn:=xlSortOnValues, Order:=xlAscending, _
    DataOption:=xlSortNormal
With ActiveWorkbook.Worksheets("Estatistica Individual").Sort
    .SetRange Range("AV1:AW1755")
    .Header = xlYes
    .MatchCase = False
    .Orientation = xlTopToBottom
    .SortMethod = xlPinYin
    .Apply
End With
End Sub

```

FIGURA 12 - EXEMPLO DE UM DOS MACROS UTILIZADOS PARA ORDENAR VALORES

Para além dos métodos anteriormente descritos foi também usado o índice de Moran I (Getis & Ord, 1992) através do *software* ArcGIS, para avaliar a auto correlação espacial dos parâmetros estatísticos anteriormente mencionados e o *software* Graphpad para avaliar a correlação desses mesmos parâmetros com o declive e com a elevação.

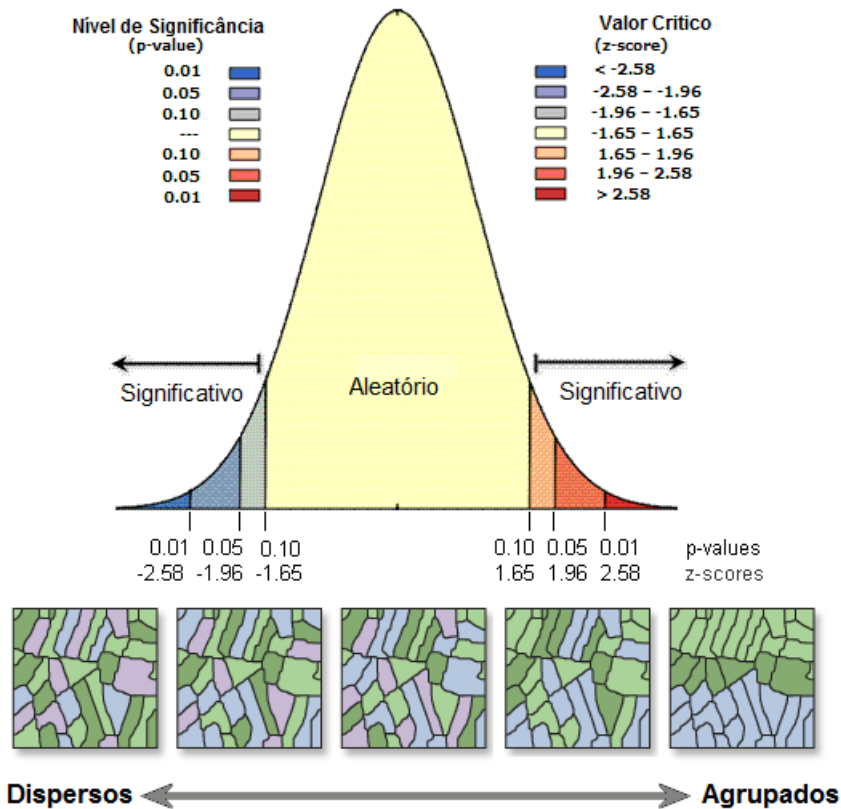


FIGURA 13- FIGURA ILUSTRATIVA DO FUNCIONAMENTO DO ÍNDICE DE MORAN I. FIGURA ADAPTADA DE (ESRI, 2019)

Como é possível observar na figura acima (Figura 13) valores de p inferiores a 0.1 indicam que a correlação é significativa e valores de z-score indicam de que maneira é que a correlação é significativa. Valores inferiores a -1.65 de z-score indicam uma dispersão espacial de dados não aleatória e valores de z-score superiores a 1.65 indicam um agrupamento dos dados.

5. RESULTADOS

De um modo geral verificou-se haver uma massa de dados suficientes robusta por parte do SNIRH para a realização do estudo. Das 71 estações que passaram à fase de análise estatística 65 tinham quantidade e qualidade suficiente para serem utilizadas e apenas 6 tiveram que ser eliminadas. No entanto, é importante referir que para o período analisado de 14 de Março de 2014 até final de 2018 existia um número considerável de lacunas por parte das estações do SNIRH, os dados de satélite não apresentam qualquer falta de informação. É importante mencionar também que as estações, embora não se apresentem com uma distribuição espacial perfeita, têm de um modo geral uma boa distribuição.

Dessas 71 estações submetidas à análise estatística anteriormente descrita, 3 não apresentavam uma massa de dados *in situ* suficientemente grande para a realização da análise na sua totalidade, essas estações foram Pega, Sátão e Trouxemil. No caso da primeira estação foi possível realizar a agregação temporal apenas até aos 8 dias, o mesmo se verificou para a estação de Sátão; a estação de Trouxemil por sua vez foi um caso particular que pelos métodos de controlo de qualidade iniciais não foi filtrada e denominada “estação sem dados” uma vez que a estação tecnicamente tinha um número significativo de células com dados, no entanto todas essas células apresentavam o valor de 0.0 mm. Estas estações foram então eliminadas e não serão apresentadas nos resultados.

Para além destas 3 estações que foram eliminadas por falta de dados, foram também excluídas outras 3 estações, Caldas de Felgueiras, Mourilhe e Penalva do Castelo por serem consideradas *outliers*. Os valores de precipitação registados *in situ* destas estações foram visualmente comparados com valores de estações adjacentes e esse foi o fator determinante desta conclusão para as estações de Mourilhe e Penalva do Castelo, num procedimento comum para controlo de qualidade.

No caso da estação de Caldas de Felgueiras, segundo os dados provenientes do SNIRH, foi registado um valor de precipitação de 0 mm desde dia 21 de Setembro de 2014 até dia 18 de Junho de 2015 o que equivale a um período de 270 dias sem precipitação e o mesmo se repete desde dia 11 de Setembro de 2015 até dia 25 de Fevereiro de 2016, mais 167 dias seguidos sem precipitação. Estes dados são certamente errados uma vez que esta estação se localiza perto da Serra da Estrela numa das zonas do país que regista maior quantidade de precipitação anualmente, para além disso fica a cerca de 14 km de Oliveira do Hospital que é uma das estações

analisadas e que ao contrário de Caldas de Felgueiras apresenta resultados dentro do esperado.

O número final de estações que constam dos resultados são então 65 e um sumário dos resultados é apresentado na tabela seguinte (Tabela 2).

TABELA 2 - TABELA SUMÁRIO DA ESTATÍSTICA INDIVIDUAL REALIZADA

Nome	Pearson D	Pearson 30D	Bias D	Bias 30D	RMSE D	RMSE 30D	FBI	FAR	POD
AGUIAR DA BEIRA	0.39	0.88	0.56	0.59	5.38	34.59	0.42	0.32	0.29
ALAGOA	0.43	0.82	0.98	1.02	5.15	27.73	0.71	0.33	0.48
ALBERGARIA DOS DOZE	0.27	0.77	0.90	0.83	4.36	28.07	0.79	0.46	0.42
ALMAÇA	0.49	0.76	1.23	1.29	3.92	27.60	0.91	0.46	0.49
ALMEIDINHA	0.38	0.90	0.92	0.92	4.12	12.64	0.81	0.43	0.46
ALVAIÁZERE	0.26	0.76	1.13	1.01	5.48	27.25	0.90	0.48	0.47
BOLETA	0.46	0.85	1.16	1.18	4.50	25.36	0.77	0.31	0.53
CADAFAZ	0.36	0.90	0.73	0.70	4.34	26.28	0.78	0.49	0.40
CAMPIA	0.19	0.71	0.80	0.79	7.49	40.03	0.87	0.39	0.53
CARANGUEJEIRA	0.36	0.79	0.95	0.93	3.59	19.52	0.73	0.38	0.45
CARAPINHAL	0.35	0.56	1.38	1.41	4.86	43.68	0.97	0.56	0.43
CARREGAL DO SAL	0.73	0.99	1.17	1.42	1.85	6.42	0.81	0.51	0.40
CASAL DO RATO	0.42	0.93	1.49	1.30	3.08	11.58	0.93	0.46	0.50
CASTANHEIRA DE PÊRA	0.33	0.78	0.75	0.69	4.79	39.49	0.78	0.43	0.44
CHÃO DE COUCE	0.21	0.82	0.68	1.02	3.43	13.69	0.72	0.44	0.40
CODECEIRO	0.17	0.51	1.62	1.77	5.11	37.70	1.34	0.71	0.38
COENTRAL GRANDE	0.34	0.77	0.46	0.47	6.50	63.46	0.58	0.28	0.41
CÔJA	0.42	0.78	0.96	1.01	3.99	27.30	0.85	0.43	0.48
CONDEIXA	0.39	0.88	1.29	1.42	3.99	19.28	0.81	0.37	0.51
COVILHÃ	0.33	0.92	0.51	0.57	8.73	42.26	0.92	0.42	0.54
CUMIEIRA	0.30	0.73	0.90	1.00	3.86	27.47	0.78	0.43	0.44
DEGRACIAS	0.38	0.78	0.70	0.76	4.68	34.81	0.62	0.34	0.41
ERMIDA (TONDELA)	0.39	0.94	0.91	1.03	3.75	6.66	0.84	0.37	0.53
ESTRADA	0.28	0.69	0.59	1.17	10.09	26.69	0.78	0.33	0.52
FAJÃO	0.25	0.63	0.80	0.82	5.69	39.77	0.80	0.49	0.41
FERREIRA-A-NOVA	0.26	0.67	1.98	1.92	3.36	27.30	1.45	0.61	0.57
FIGUEIRÓ DOS VINHOS	0.27	0.82	0.68	0.66	4.68	31.67	0.70	0.28	0.50
FORNINHOS	0.55	0.95	0.86	0.86	4.12	15.34	0.77	0.46	0.42
FORNOS DE ALGODRES	0.24	0.45	1.50	1.64	3.80	32.89	0.96	0.60	0.39
FRAGOSELA DE BAIXO	0.14	0.56	1.15	1.18	2.47	12.95	0.53	0.32	0.36
FREIXIANDA	0.39	0.93	0.98	0.98	3.11	11.35	0.75	0.37	0.47
GÓIS	0.38	0.84	0.74	0.76	4.87	32.82	0.70	0.36	0.44
LAGOA COMPRIDA	0.41	0.88	0.52	0.56	5.34	38.29	0.61	0.29	0.43
LEOMIL	0.42	0.90	1.08	1.11	4.46	18.10	0.90	0.44	0.50
LOUÇAINHA (OUTEIRO)	0.40	0.87	0.77	0.87	4.28	21.77	0.65	0.39	0.40
LOURIÇAL	0.44	0.86	1.35	1.43	3.87	21.90	0.84	0.34	0.55

TABELA 3 - TABELA SUMÁRIO DA ESTATÍSTICA INDIVIDUAL REALIZADA (CONTINUAÇÃO)

Nome	Pearson D	Pearson 30D	Bias D	Bias 30D	RMSE D	RMSE 30D	FBI	FAR	POD
LOUSÃ	0.15	0.97	1.15	1.13	1.26	3.41	0.89	0.71	0.26
MAÇAINHAS	0.37	0.85	0.87	0.82	4.56	21.82	0.81	0.38	0.51
MANGUALDE	0.48	0.96	0.97	0.92	5.02	14.99	0.81	0.45	0.44
MATA DA BIDOEIRA	0.05	0.79	0.7	1.58	10.19	14.83	1.01	0.57	0.43
MESQUITELA	0.59	0.73	1.49	1.57	1.09	7.98	1.65	0.82	0.3
MONTE REAL	0.33	0.5	1.43	1.48	3.55	32.73	1	0.55	0.45
OLIVEIRA DO BAIRRO	0.41	0.91	1.15	1.12	5.82	18.87	0.84	0.33	0.57
OLIVEIRA DO HOSPITAL	0.47	0.95	1.2	1.18	2.41	4.7	0.95	0.59	0.39
PAMPILHOSA DA SERRA	0.37	0.92	0.72	0.77	3.7	19.23	0.65	0.29	0.46
PARADINHA	0.33	0.88	1.06	1.09	3.25	10.51	0.95	0.55	0.43
PARANHOS DA BEIRA	0.18	0.96	1.32	1.12	2.14	4.58	0.93	0.5	0.47
PEDROGÃO GRANDE	0.32	0.84	0.76	0.75	4.15	22.74	0.85	0.38	0.53
PENELA	0.43	0.79	0.48	0.52	3.03	26.54	0.54	0.38	0.34
PENHAS DOURADAS	0.33	0.83	0.51	0.6	7.59	28.41	0.66	0.35	0.43
PÍNZIO	0.34	0.9	1.17	1.17	3.37	13.82	0.86	0.5	0.43
POMBAL	0.22	0.75	1.44	1.64	7.45	35.56	1.14	0.57	0.49
RAMELA	0.41	0.86	0.81	0.79	3.76	20.17	0.78	0.39	0.48
REGO DA MURTA	0.27	0.91	0.92	0.99	6.67	14.98	0.81	0.39	0.5
REVELES (ABRUNHEIRA)	0.72	0.96	1.09	1.15	1.26	4.7	0.74	0.34	0.49
SANTA COMBA DÃO	0.32	0.65	1.2	1.31	8.22	45.51	1.11	0.56	0.48
SERNANCELHE	0.4	0.99	0.89	0.97	1.52	3.09	1.1	0.57	0.48
SILVARES	0.39	0.9	0.86	0.84	3.99	15.92	0.84	0.42	0.49
SOBRAL DE SÃO MIGUEL	0.38	0.85	0.66	0.65	4.96	34.73	0.7	0.29	0.5
SOURE	0.32	0.68	1.35	1.44	6.61	44.87	0.96	0.49	0.49
TENTÚGAL	0.3	0.62	1.3	1.47	7.68	49.13	0.96	0.48	0.5
TOURO	0.51	0.88	0.8	0.82	5.45	36.74	0.84	0.45	0.46
VALHELHAS	0.36	0.74	0.81	0.83	4.2	28.93	0.93	0.44	0.52
VARZIELAS	0.28	0.8	0.59	0.82	11.02	55.68	0.88	0.45	0.49
VILA NOVA DE POIARES	0.27	0.86	1.23	1.29	2.79	13.12	0.77	0.33	0.51
	Pearson D	Pearson 30D	Bias D	Bias 30D	RMSE D	RMSE 30D	FBI	FAR	POD
Médias	0.36	0.81	0.99	1.04	4.67	24.95	0.85	0.44	0.46

A tabela sumário (Tabela 2 - 3) apresenta os resultados obtidos para todos os métodos estatísticos determinados com recurso ao software Excel. Os parâmetros mais à direita FBI, FAR e POD foram calculados com base em tabelas de contingência individuais para cada estação e como tal apenas apresentam um valor relativo à totalidade de cada estação analisada. Por sua vez os parâmetros, Pearson, Bias e RMSE foram calculados quer para os dados diários quer para os dados após agregação temporal a 8, 16 e 30 dias. Na (Tabela 2) apenas estão apresentados os resultados para os extremos temporais, análise diária e agregação mensal.

5.1. Estatística Standard

No que diz respeito ao FBI este parâmetro mede o rácio de eventos de precipitação medidos pelo IMERG versus o número de deteções pela estação do SNIRH, um valor de FBI superior a 1 significa que existe uma sobrestimativa por parte do satélite dos eventos de precipitação e por sua vez um valor inferior a 1 indica uma subestimativa. Uma vez que o FBI médio é de 0.85 pode-se afirmar que de um modo geral se verifica uma subestimativa dos eventos de precipitação por parte do IMERG, no entanto é importante mencionar que este valor não se encontra muito distante de 1.

O FAR por sua vez é uma medida indicativa da ocorrência de falsos positivos por parte do satélite, ou seja da quantidade de vezes que a estimativa do satélite indica ocorrência de precipitação ($\text{valor} \geq 1\text{mm}$) e a medida *in situ* contraria esse resultado. O FAR varia entre 0 e 1, sendo 0 o valor perfeito indicativo de uma ausência de falsos positivos. O valor médio calculado para este parâmetro foi de 0.44, sendo o valor máximo 0.82 registado na estação de Mesquitela e o valor mínimo de 0.28 registado em Figueiró dos Vinhos.

O POD é utilizado para identificar a quantidade de corretos positivos. Varia em valor absoluto entre 0 e 1 e sendo o resultado perfeito 1. O valor médio registado para o POD foi de 0.46 sendo o valor máximo registado 0.57, registado em Oliveira do Bairro e o valor mínimo 0.28 obtido para a estação da Lousã.

Relativamente a estes dois últimos parâmetros, FAR e POD é importante mencionar que, devido à maneira como são calculados, estes valores são afetados pela sobre e sub estimação de precipitação. Sendo o POD beneficiado quando ocorre uma sobrestimação de precipitação e o FAR beneficiado quando existe uma subestimação de precipitação.

Quanto ao RMSE este parâmetro indica diferenças entre os valores estimados e os valores medidos, com a agregação temporal é de esperar que se verifique um

aumento do valor absoluto desta medida uma vez que a agregação temporal implica o somatório dos valores, quer estimados quer medidos. Valores inferiores de RMSE indicam, de um modo geral, uma melhor performance. O valor médio do RMSE para as análises diárias foi de 4.67 e o valor médio para a agregação mensal foi de 24.95.

O Bias pode variar entre 0 e + infinito, sendo que o valor ideal seria 1, indicativo de uma estimativa pelo IMERG de quantidade de precipitação igual ao valor medido *in situ*. Um Bias superior a 1 indica uma quantidade de precipitação estimada superior à real, ou seja uma sobrestimação da quantidade de precipitação. Um valor de Bias inferior a 1 indica uma subestimação. Quanto mais próximo de 1 se encontra o valor melhor. O Bias médio para valores diários foi 0.99 e o Bias médio mensal foi 1.04. Ambos excelentes resultados.

Quanto ao fator de correlação de Pearson o valor máximo registado para a análise diária foi de 0.73 que se verificou na estação de Carregal do Sal, por sua vez o valor mínimo foi 0.05 e foi registado na Mata da Bidoeira. O valor médio registado para a análise diária foi de apenas 0.36, indicativo de uma correlação fraca. Por sua vez após agregação temporal os resultados obtidos melhoram significativamente, o valor de Pearson máximo obtido foi de 0.99 e foi registado em Sernancelhe e o valor mínimo obtido foi de 0.45 para a estação de Fornos de Algodres. Como é possível observar o valor mínimo após agregação temporal para 30 dias, embora fraco, de 0.45 é superior ao valor médio calculado para os dados diários 0.36. Comparando ambos os valores médios obtidos quer para a análise diária quer para a análise mensal vemos que existe um incremento significativo do fator de correlação que cresce de 0.36 para 0.81 ou seja de uma correlação fraca para uma forte correlação.

Para melhor compreender os efeitos da agregação temporal seguem-se as figuras 14 e 15 que dizem respeito à análise dos dados de precipitação da estação de Freixianda e nas quais é possível observar uma clara melhoria no que diz respeito à qualidade das estimativas mensais versus valores diários. Consultando a Tabela 2 e os valores de Pearson para a estação de Freixianda é possível observar que com a agregação temporal passamos de 0.39 para 0.93 ou seja de uma correlação fraca para uma correlação muito forte.

IMERG vs SNIRH Dados Diários

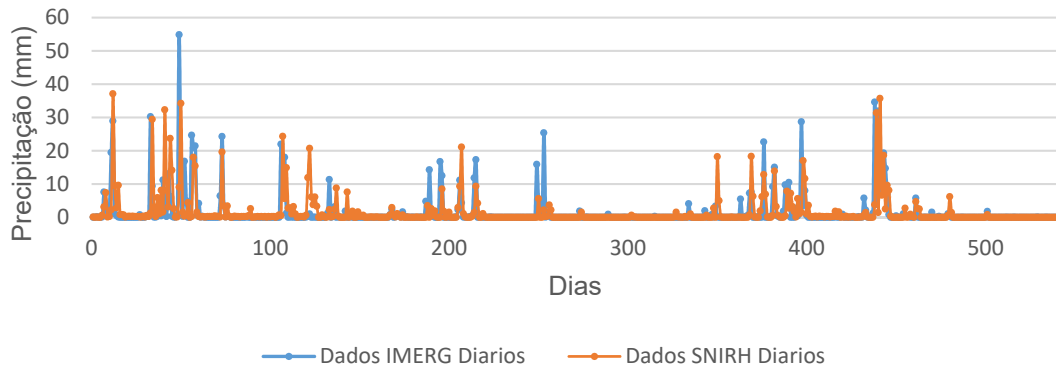


FIGURA 14 - COMPARAÇÃO DOS VALORES DE PRECIPITAÇÃO DIÁRIOS IN SITU COM OS VALORES TAMBÉM DIÁRIOS ESTIMADOS POR SATÉLITE PARA A ESTAÇÃO DE FREIXIANDA

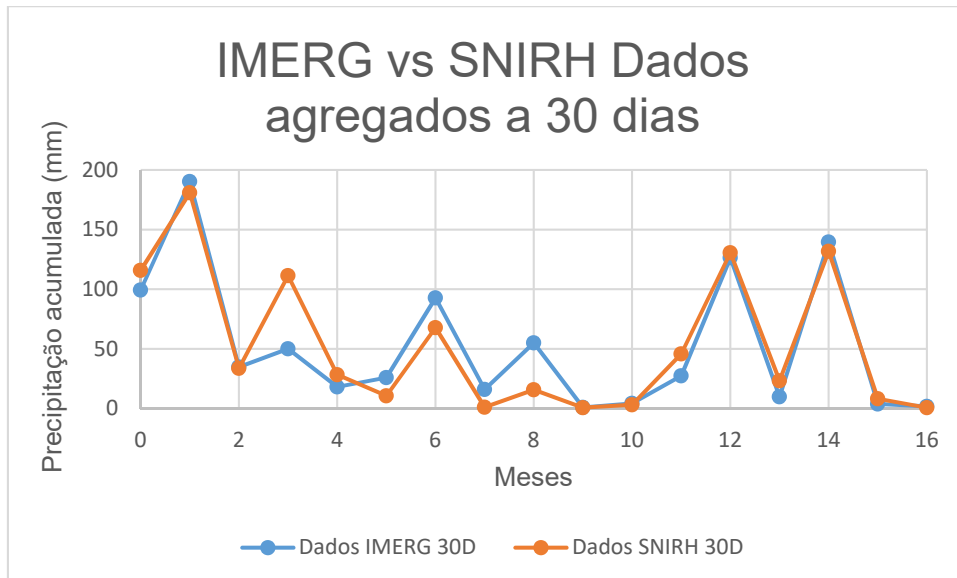


FIGURA 15 - COMPARAÇÃO DOS VALORES DE PRECIPITAÇÃO AGREGADOS A 30 DIAS IN SITU COM OS VALORES TAMBÉM AGREGADOS ESTIMADOS POR SATÉLITE PARA A ESTAÇÃO DE FREIXIANDA

É importante referir que embora de um modo geral as agregações temporais mensais apresentem os melhores resultados, as agregações temporais para 8 dias e 16 dias apresentam valores médios de correlação significativamente melhores que os valores diários 0.75 e 0.78 respetivamente (Tabela 4).

TABELA 4 - VALORES MÉDIOS DO FATOR DE CORRELAÇÃO DE PEARSON PARA VALORES DE PRECIPITAÇÃO DIÁRIOS E AGREGADOS A 8, 16 E 30 DIAS.

	Pearson D	8D	16D	30D
Médias	0.36	0.75	0.78	0.81

Para além da análise individual de cada estação foi também efetuada a agregação dos dados de todas as estações analisadas numa só folha de Excel, com o intuito de projetar os valores de precipitação na sua totalidade e perceber tendências globais. Os resultados encontram-se apresentados nas Figuras seguintes (Figura 16 e 17) e na tabela 5.

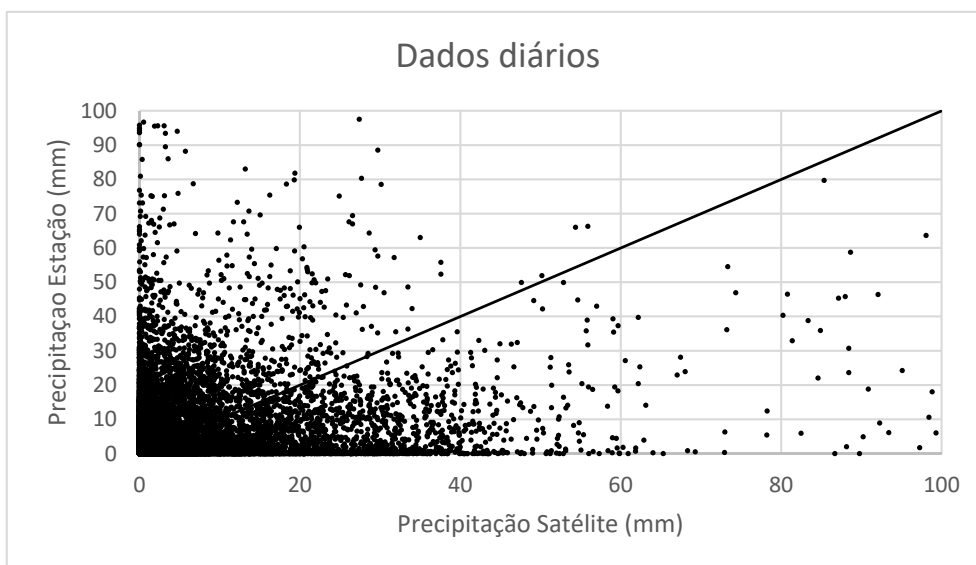


FIGURA 16 - PROJEÇÃO DA MASSA DE DADOS GLOBAL À ESCALA DIÁRIA (A LINHA REPRESENTA UMA RELAÇÃO 1:1)

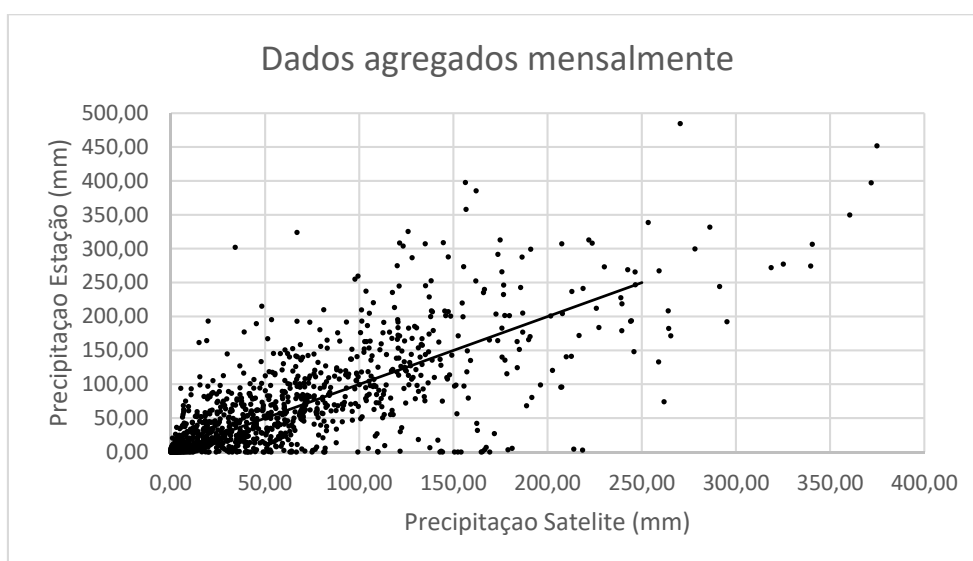


FIGURA 17 – PROJEÇÃO DA MASSA DE DADOS GLOBAL À ESCALA MENSAL (A LINHA REPRESENTA UMA RELAÇÃO 1:1)

TABELA 5 - RESULTADOS DOS DIVERSOS PARÂMETROS ESTATÍSTICOS À ESCALA GLOBAL

	D	8D	16D	30D		
Pearson	0.31	0.69	0.74	0.76	FBI	0.83
Bias	0.89	0.94	0.93	0.92	FAR	0.44
RMSE	5.09	14.20	19.65	27.95	POD	0.47

5.2. Índice de Moran I

O índice de Moran I foi utilizado para avaliar a auto correlação espacial dos parâmetros estatísticos. O objetivo foi perceber se existiam agregações de valores absolutos de resultados para zonas específicas da área em estudo. Os resultados obtidos encontram-se explícitos na tabela seguinte (Tabela 6).

TABELA 6 - RESULTADOS DO ÍNDICE DE MORAN I

	Pearson 30D	Pearson Diário	Bias 30D	Bias Diário	RMSE 30D	FBI	FAR	POD
Z-score	-0.51	0.308	3.74	3.299	0.106	1.07	0.26	3.045
p value	0.608	0.75	0.000184	0.00097	0.9156	0.9156	0.79	0.002

5.3. Análise da dependência espacial

Observando os valores obtidos de Z-score para os diferentes parâmetros estatísticos é possível concluir que quer para o fator de correlação de Pearson, quer para o RMSE, FBI e FAR não parece existir qualquer tipo de dependência espacial. Por sua vez quer para os valores diários (Figura 18) quer mensais (Figura 19) de Bias parece existir uma dependência espacial clara, Z-score > 3. Para o POD o mesmo se verifica, sendo o Z-score=3.045. Os valores de p-value indicam que existe uma probabilidade inferior a 1% deste padrão de aglutinação ser o resultado de pura chance quer para o Bias quer para o POD (Figura 20).

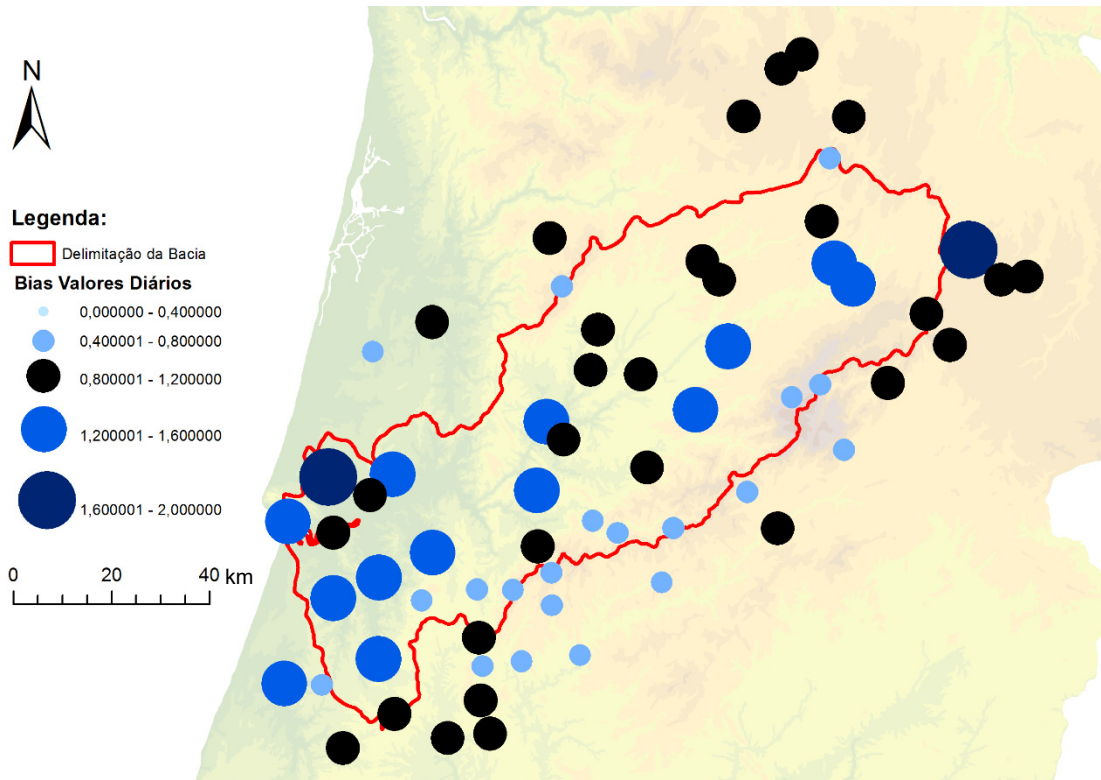


FIGURA 18 - DEPENDÊNCIA ESPACIAL DOS VALORES DE BIAS DIÁRIOS

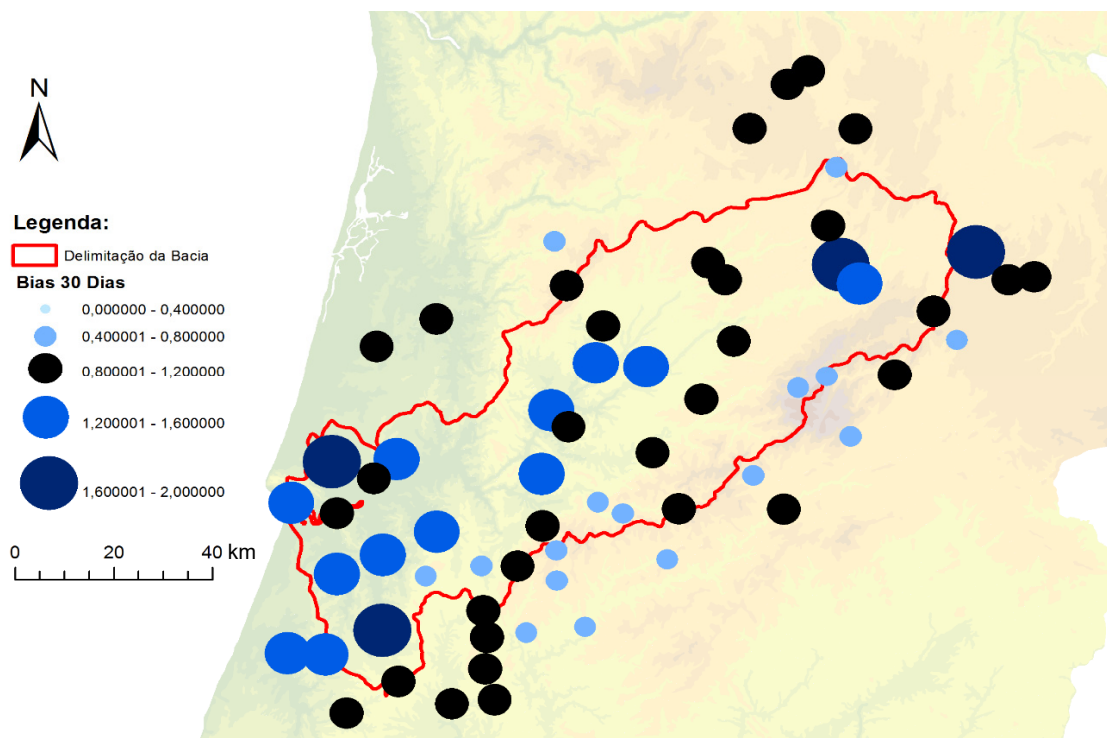


FIGURA 19 - DEPENDÊNCIA ESPACIAL DOS VALORES DE BIAS MENSAIS

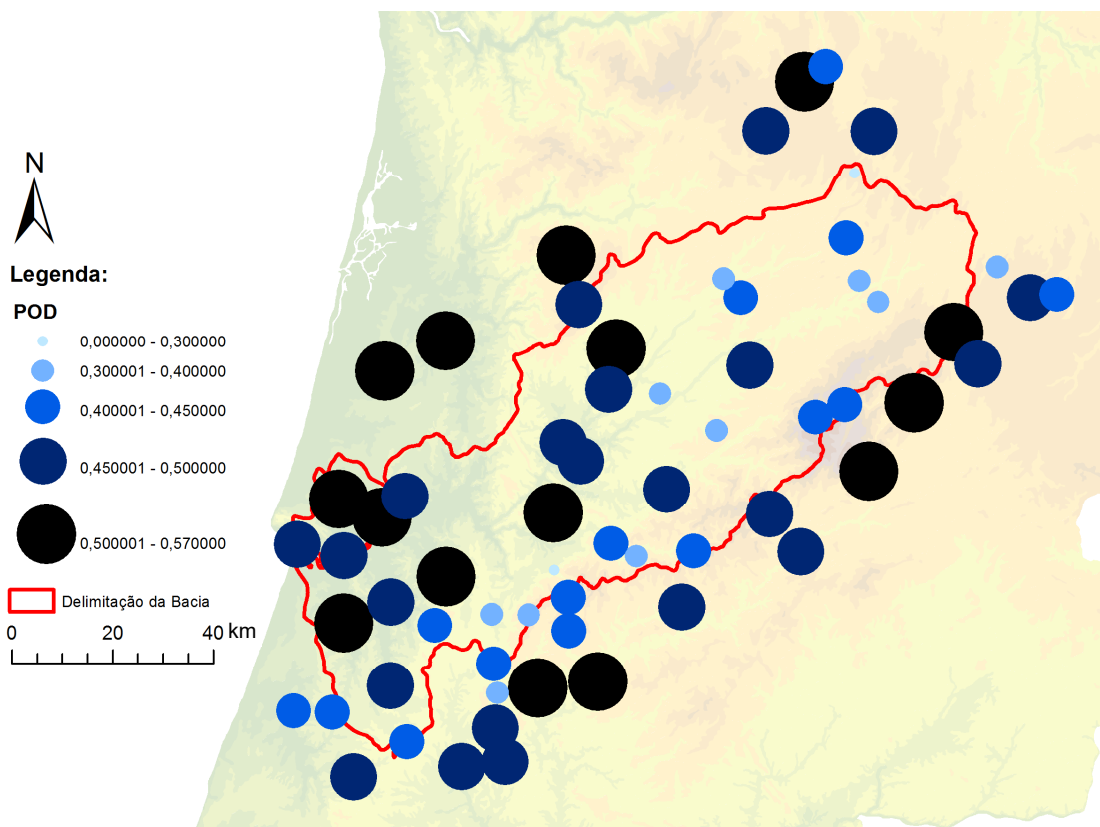


FIGURA 20 - DEPENDÊNCIA ESPACIAL DOS VALORES DO POD

5.4. Análise da correlação entre métricas de performance, elevação (MDT) e declive

Após a análise da dependência espacial dos resultados foi também avaliada a correlação entre as métricas de performance e o declive e entre as métricas de performance e a elevação com recurso ao *software* GraphPad. Para o declive não foram encontradas correlações significativas. Para a elevação foi encontrada uma correlação significativa quer para o Bias diário (Figura 21) quer para o Bias 30 dias (Figura 22). Como é possível ver na tabela seguinte (Tabela 7) os valores de (p) quer para o Bias dos dados diários quer mensais é inferior a 0.0001 o que indica uma clara correlação. Os valores de r^2 indicam que no caso dos valores diários a correlação não é tão forte como no caso dos valores mensais.

TABELA 7 - RESULTADOS DA CORRELAÇÃO DO BIAS COM A ELEVAÇÃO

	Bias D	Bias 30D
p	< 0.0001	< 0.0001
r^2	0.2185	0.2613

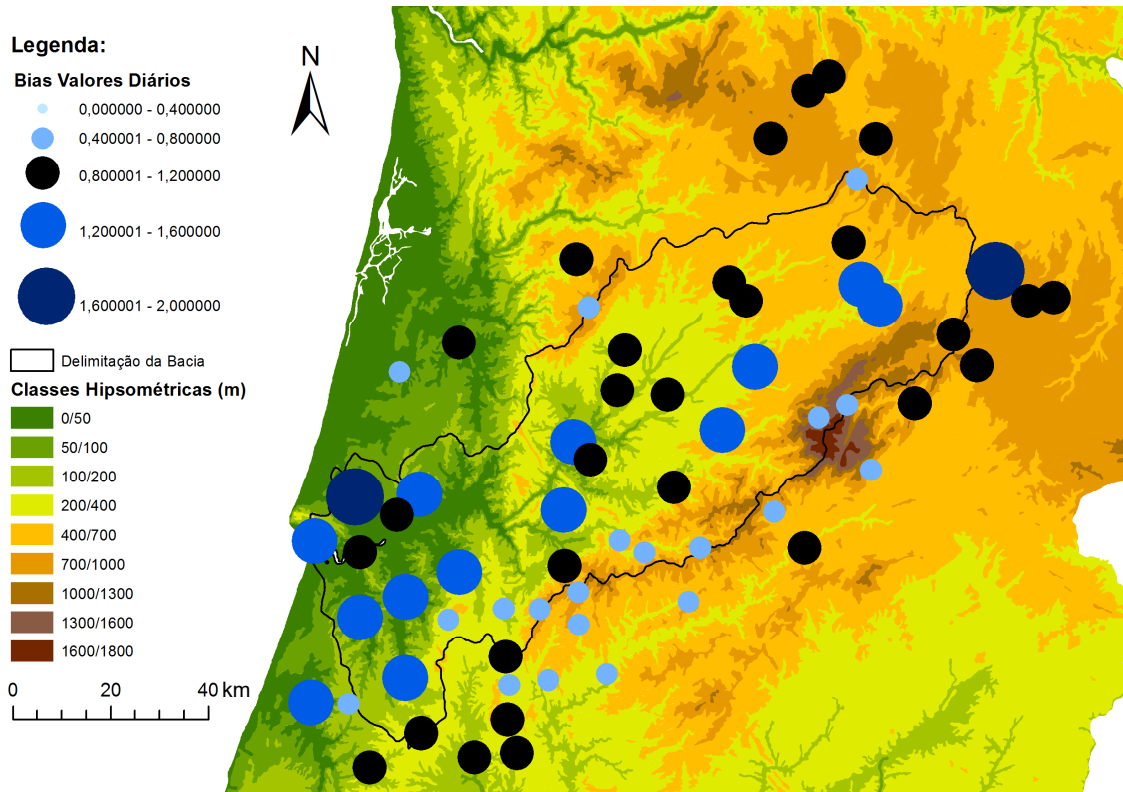


FIGURA 21 – VALORES DE BIAS DIÁRIOS REPRESENTADOS SOBRE A CARTA HIPSONÉTICA

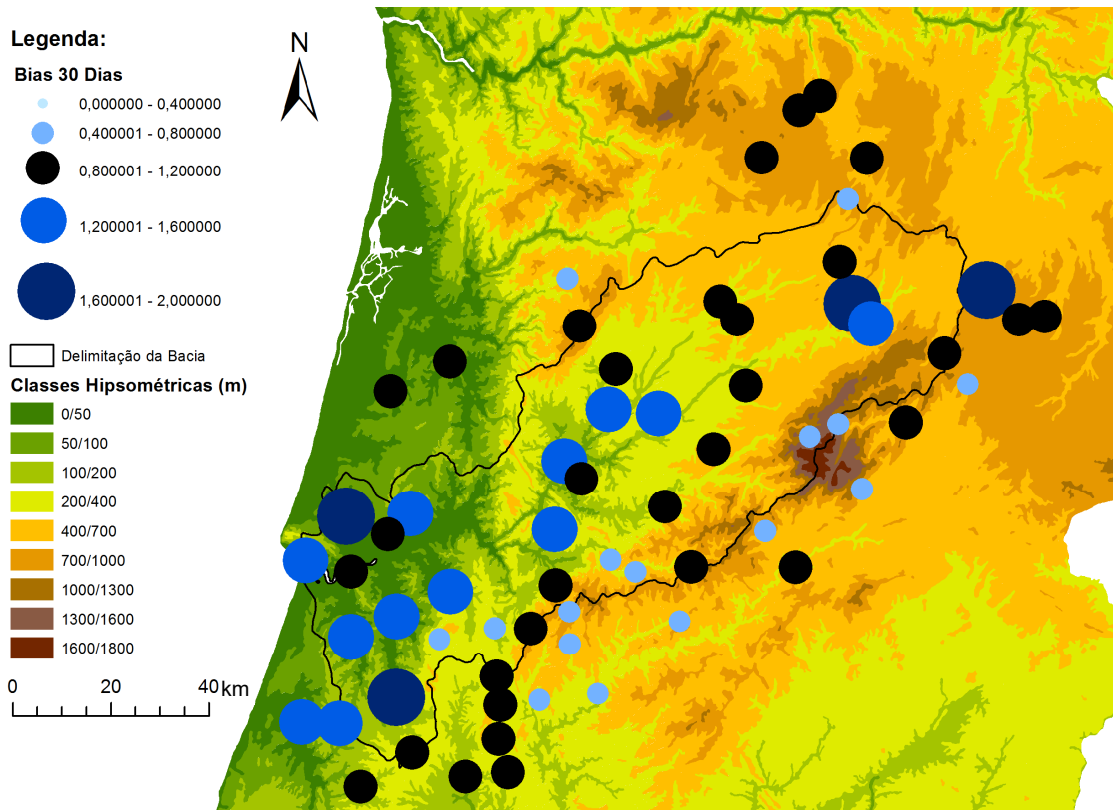


FIGURA 22 - VALORES DE BIAS MENSAIS REPRESENTADOS SOBRE A CARTA HIPSONÉTICA

6. DISCUSSÃO

De um modo geral, segundo a bibliografia consultada, os resultados estão em linha com o esperado.

No capítulo que se segue serão abordadas todas as questões pertinentes à discussão destes resultados. Serão também mencionadas as dificuldades encontradas ao longo da realização do trabalho e serão também apresentadas recomendações quer de carácter pontual quer de carácter mais generalista e discutidas possíveis utilizações dos dados quer no desenvolvimento de novos estudos de investigação bem como em aplicações de carácter prático.

Devido ao carácter do trabalho a vasta maioria das dificuldades encontradas estavam relacionadas com os dados em si.

É importante antes de mais mencionar que este trabalho não teria sido possível sem a disponibilização dos dados de estimativas de satélite por parte da NASA através da plataforma Giovanni e dos dados das estações disponibilizados pelo SNIRH na plataforma respetiva, ambos de forma gratuita, uma vez que é nesses dados que assenta toda a realização da dissertação.

O primeiro problema encontrado no decurso da realização do trabalho surgiu logo na fase de aquisição de dados. A ideia inicial, ainda na fase conceptual do trabalho, era incluir, na realização do mesmo, todas as estações contidas na bacia hidrográfica do Rio Mondego bem como todas as estações situadas na periferia imediata. Uma vez iniciado o processo de descarga de dados *in situ* ficou clara a existência de lacunas na rede do SNIRH para o período em análise. Como já foi referido anteriormente, das 59 estações da rede que estavam contidas na bacia, 18 não tinham qualquer dado. Após a análise da distribuição espacial das estações com dados, e identificada a zona com mais lacunas, setor NO, quando se passou para a descarga dos dados periféricos foi então prestada especial atenção a esse setor com o intuito de o reforçar e de tornar a distribuição espacial mais equilibrada.

Concluído então o descarregamento dos dados quer de satélite, quer das estações, seguiu-se então a próxima etapa, que consistiu na preparação dos dados para estes poderem ser submetidos à análise estatística utilizada. Esta etapa apresentou definitivamente os problemas mais complexos de ultrapassar para a realização do trabalho por diversas razões.

Em primeiro lugar devido à massa de dados analisada, uma vez que quanto maior esta é mais difícil é de identificar e corrigir qualquer tipo de problema encontrado, em especial se este for recorrente mas irregular, como é o caso das lacunas temporais no registo. Para a realização deste trabalho foram analisados dados de 71 estações e, para tal, uma vez que se trata de um trabalho essencialmente comparativo, foram preparados para análise 71 ficheiros com dados de precipitação do SNIRH cada um deveria ter 1754 dias de dados e o mesmo para os dados de satélite, o que constitui um total de 3508 dados diários de precipitação por estação. Uma vez que foram analisadas 71 estações foram então analisados 124534 pares de dados de precipitação diária IMERG/SNIRH ou seja 249098 valores de precipitação.

Em segundo lugar, e com certeza a maior dificuldade à execução desta etapa de preparação de dados, é a maneira como são disponibilizados os dados do SNIRH. Como já foi mencionado anteriormente os dados das estações do SNIRH, mesmo das estações que têm dados, não são perfeitos e apresentam lacunas, períodos temporais para os quais não existe registo de dados. Este problema é agravado pelo facto de não ser introduzido qual quer registo da lacuna no ficheiro que resulta do descarregamento dos dados, isto resulta provavelmente do facto de que, quer a origem quer as características das estações integradas nesta rede, serem diferentes entre elas. O que resulta num registo seguido de dados célula a célula, mas descontinuo do ponto de vista temporal (Figura 23).

	A	B	C	D	E	F	G		A	B
1	SNIRH - SISTEMA NACIONAL DE INFORMAÇÃO DE RECURSOS HÍDRICOS							1	14/03/2014	NaN
2								2	15/03/2014	NaN
3	DATA,TENTÚGAL (12F/01UG),,							3	16/03/2014	NaN
4	,Precipitação diária (mm),FLAG,							4	17/03/2014	NaN
5	18/03/2014 09:00,0,(vau),							5	18/03/2014	0
6	19/03/2014 09:00,0,(vau),							6	19/03/2014	0
7	20/03/2014 09:00,0,(vau),							7	20/03/2014	0
8	21/03/2014 09:00,0,(vau),							8	21/03/2014	0
9	22/03/2014 09:00,0,(vau),							9	22/03/2014	0
10	23/03/2014 09:00,0,(vau),							10	23/03/2014	0
11	24/03/2014 09:00,0,(vau),							11	24/03/2014	0
12	25/03/2014 09:00,0,(vau),							12	25/03/2014	0
13	26/03/2014 09:00,0,(vau),							13	26/03/2014	0
14	27/03/2014 09:00,0,(vau),							14	27/03/2014	0
15	28/03/2014 09:00,0,(vau),							15	28/03/2014	0
16	29/03/2014 09:00,0,(vau),							16	29/03/2014	0
17	30/03/2014 09:00,0,(vau),							17	30/03/2014	0
18	31/03/2014 09:00,0,(vau),							18	31/03/2014	0
19	01/04/2014 09:00,0,(vau),							19	01/04/2014	0
20	02/04/2014 09:00,0,(vau),							20	02/04/2014	0
21	05/04/2014 09:00,0,(vau),							21	03/04/2014	NaN
22	12/04/2014 09:00,0,(vau),							22	04/04/2014	NaN
23	15/04/2014 09:00,0,(vau),							23	05/04/2014	0
24	16/04/2014 09:00,0,(vau),							24	06/04/2014	NaN
25	17/04/2014 09:00,0,(vau),							25	07/04/2014	NaN
26	18/04/2014 09:00,0,(vau),							26	08/04/2014	NaN
27	19/04/2014 09:00,0,(vau),							27	09/04/2014	NaN
28	20/04/2014 09:00,0,(vau),							28	10/04/2014	NaN
29	21/04/2014 09:00,0,(vau),							29	11/04/2014	NaN
								30	12/04/2014	0
								31	13/04/2014	NaN
								32	14/04/2014	NaN

FIGURA 23 - FIGURA ILUSTRATIVA DO PROBLEMA ENCONTRADO DURANTE A PREPARAÇÃO DOS DADOS E DA SOLUÇÃO IMPLEMENTADA

Tal como foi mencionado anteriormente este problema é exacerbado pela quantidade de dados a preparar para análise. Realizar a preparação de um ficheiro que apresenta esta particularidade implicaria a verificação dos dados um a um e colmatação manual das lacunas uma a uma, o que seria um trabalho demorado e com alta propensão para a introdução de erros, mas factível. No entanto, realizar este processo para 71 estações implicaria a verificação de 124534 células, uma a uma, a colmatação das respetivas lacunas manualmente também. Para ultrapassar este problema foi então usado um script escrito em Python pelo Doutor Vasco Mantas e adaptado por mim para as necessidades específicas deste trabalho e que executa o processo anteriormente descrito de identificação e colmatação de lacunas automaticamente, introduzindo a denominação “NaN” quando para uma data em análise não existe um valor

correspondente sendo então produzido um ficheiro sem qualquer lacuna temporal e preparado então para ser analisado. A necessidade de execução deste processo complexo e demorado de tratamento de dados, apresenta um obstáculo significativo à sua utilização, e vai contra os princípios FAIR que defendem que os dados devem ser *Findable, Accessible, Interoperable, and Reusable*.

Em terceiro lugar surge então outro problema causado pela massa de dados a analisar. Uma vez que o objetivo era não só fazer uma validação dos dados da bacia, mas procurar analisar os resultados com um nível de detalhe elevado, não foram feitas agregações de estações por sectores, mas sim feita uma análise estatística individual para cada estação. Esta análise individual permitiu então a criação dos mapas de correlação apresentados anteriormente e uma avaliação muito pormenorizada da bacia mas obrigou também a uma análise estatística muito mais extensa. Para tornar possível esta avaliação estatística extensa foi então criado um conjunto de macros em VBA (Figura 12), a linguagem de programação utilizada pelo Excel, que permitiram agilizar este processo e torna-lo tanto mais rápido como menos propenso à introdução de erros.

Foram também encontradas outras dificuldades ao longo da realização do trabalho, quer devido a problemas de transposição de dados entre programas utilizados, bem como problemas de execução de análise estatística devido às lacunas já mencionadas, mas nenhuma dessas dificuldades obrigou à criação de ferramentas adicionais ou ao desenvolvimento de soluções da dimensão das mencionadas anteriormente e como tal não serão exploradas nesta secção.

Finalmente, sinto-me na obrigação de mencionar que embora os dados do SNIRH não sejam perfeitos, são a única alternativa viável à execução de um trabalho com uma massa de dados desta natureza. Utilizar dados do IPMA implicaria uma despesa avultada. O SNIRH é a única fonte de dados recentes de precipitação para o território nacional, que os disponibiliza de forma gratuita. É importante também referir que as lacunas mencionadas não foram apenas um problema para a realização do trabalho, mas que servem também para justificar a necessidade da realização deste tipo de validações para todo o território nacional, uma vez que os dados de satélite são gratuitos e não apresentam qualquer tipo de lacuna.

Os dados de satélite em contraste com os dados das estações apresentam uma série de vantagens. Os dados de satélite são disponibilizados gratuitamente para qualquer versão pretendida. São disponibilizados num registo contínuo, sem lacunas. Não tem restrições espaciais exceto para os polos, ao contrário do que se passa com as estações *in situ*, em que estamos sempre dependentes da sua distribuição espacial

que nunca é ideal. Os satélites continuam a registar eventos mesmo em situações de ocorrências meteorológicas extremas que muitas vezes causam o encerramento das estações ou mesmo danos que impossibilitam o registo. É possível obter dados horários de precipitação estimados por satélite também de forma gratuita. Efetuar medições e precipitação sobre o oceano continua a ser um problema impossível de ultrapassar com os métodos tradicionais, e que as estimativas de satélite podem ajudar a resolver. A disponibilização destes dados numa plataforma *online*, sem necessidade de requisição ou pagamento, possibilita a criação de aplicações automáticas para o terreno, como por exemplo um sistema de calibração de rega automática que faça uma agregação temporal a 8 dias, e que com base nesse valor ajuste o tempo de atividade dos aspersores.

De seguida procurar-se-á fazer uma análise crítica dos resultados, procurando justificar os valores obtidos e comparando-os do ponto de vista qualitativo com trabalhos de validação realizados por outros autores. Este capítulo procurará seguir uma ordem semelhante à do capítulo “Resultados”, começando com o parâmetro estatístico FBI e terminando com o coeficiente de correlação de Pearson, no entanto como muitos destes parâmetros não são independentes uns dos outros essa ordem será pontualmente desrespeitada. Será feita também uma discussão integrada dos resultados, incluindo o contexto da bacia em causa e serão também apresentadas algumas perspetivas globalizantes e de futuro.

Como já foi mencionado anteriormente o FBI mede o rácio de eventos de precipitação detetados pelo IMERG versus o número de medições pela estação do SNIRH, o FBI médio calculado foi 0.85 o que indica uma ligeira subestimativa por parte do IMERG da quantidade de eventos de precipitação. Este valor está relacionado com o POD, uma vez que este segundo parâmetro avalia a probabilidade de deteção de eventos de precipitação pelo IMERG. Visto que o valor médio de POD foi relativamente baixo, 0.46, é normal que haja uma subestimativa dos eventos registados.

O FAR mede a quantidade de vezes que o IMERG indica a existência de precipitação e por sua vez a estação *in situ* indica a ausência do mesmo fenómeno. O valor médio do FAR registado para a área em estudo foi 0.44. Este resultado demonstra uma melhor performance que a obtida por Mantas et al. (2015) para os Andes Peruanos utilizando o TRMM com um resultado médio de FAR de 0.48 para o produto 3B42V7 e de 0.51 para o produto 3B42RT. O valor obtido é também melhor do que o registado por Mayor et al. (2017) para o México, já para o produto IMERG que obteve valores médios entre os 0.6 e 0.8 no entanto é pior que o valor registado por Gadelha et al. (2018) que,

também utilizando os dados do IMERG, obteve valores de FAR inferiores a 0.22 para mais de 90% dos casos analisados.

O POD mede a quantidade de corretos positivos, o valor médio calculado foi de 0.46. Este valor é baixo quando comparado com valores registados por outros autores, Dinku et al. (2008, 2010), Mantas et al. (2015) e Dezfuli et al. (2017) que registam valores entre 0.6 e 0.7, no entanto é coincidente com valores registados por Mayor et al. (2017) que indica que grande parte dos valores se situam entre 0.4 e 0.6.

O POD é bastante afetado pela ocorrência de precipitação orogénica/convectiva uma vez que este tipo de precipitação, por ser um fenómeno localizado, dificulta a deteção dos eventos de precipitação que é precisamente o que o parâmetro mede. Este tipo de precipitação não só apresenta dificuldades às estimativas de satélite mas também às medições *in situ*, estas dificuldades de medição são aliás exacerbadas pela, por vezes, pobre distribuição das estações. A presença de precipitação sob a forma de neve também pode prejudicar a precisão das estimativas. Na área de estudo a influência da cordilheira central nos valores de POD é clara, sendo que os piores registos de POD formam uma linha aparente ao longo da encosta NO da Serra da Lousã e que se estende ao longo da Serra da Estrela (Figura 24). No futuro será possível contornar este problema utilizando constelações de satélites *low cost* do tipo *cube sat* para reforçar as medições nestas zonas problemáticas.

Foi denotado em diversos trabalhos (Caracciolo et al., 2018; Gadelha et al., 2018; Dinku et al., 2010) que a proximidade à costa, devido à dificuldade dos sensores de micro ondas passivas e de infra vermelhos de detetar os chamados *warm-rain processes* sobre terra, tem um impacto negativo na performance dos produtos de satélite e em particular quer nas métricas POD quer de Pearson e enquanto para a segunda é possível, embora a significância calculada seja baixa, ver uma tendência semelhante para o POD, isso não se verifica para a área em estudo. No entanto é importante denotar que os trabalhos anteriormente mencionados são a uma escala mais abrangente e menos pormenorizada, o trabalho de Dinku et al. (2010) faz uma avaliação de produtos de satélite sobre o território Colombiano na sua totalidade e, isto para dizer, que num trabalho que avaliasse a *performance* de toda a Península Ibérica não seria descabido que toda a área estudada aqui fosse considerada zona costeira. Seria aliás interessante realizar esse mesmo trabalho para tentar perceber se toda a zona costeira de Portugal apresenta valores de POD inferiores ao interior da Península Ibérica, concordante com o que seria de esperar uma vez que uma melhoria do POD foi

verificada com um afastamento da costa quer para o Brasil (Gadelha et al., 2018) quer para a Colômbia (Dinku et al., 2010).

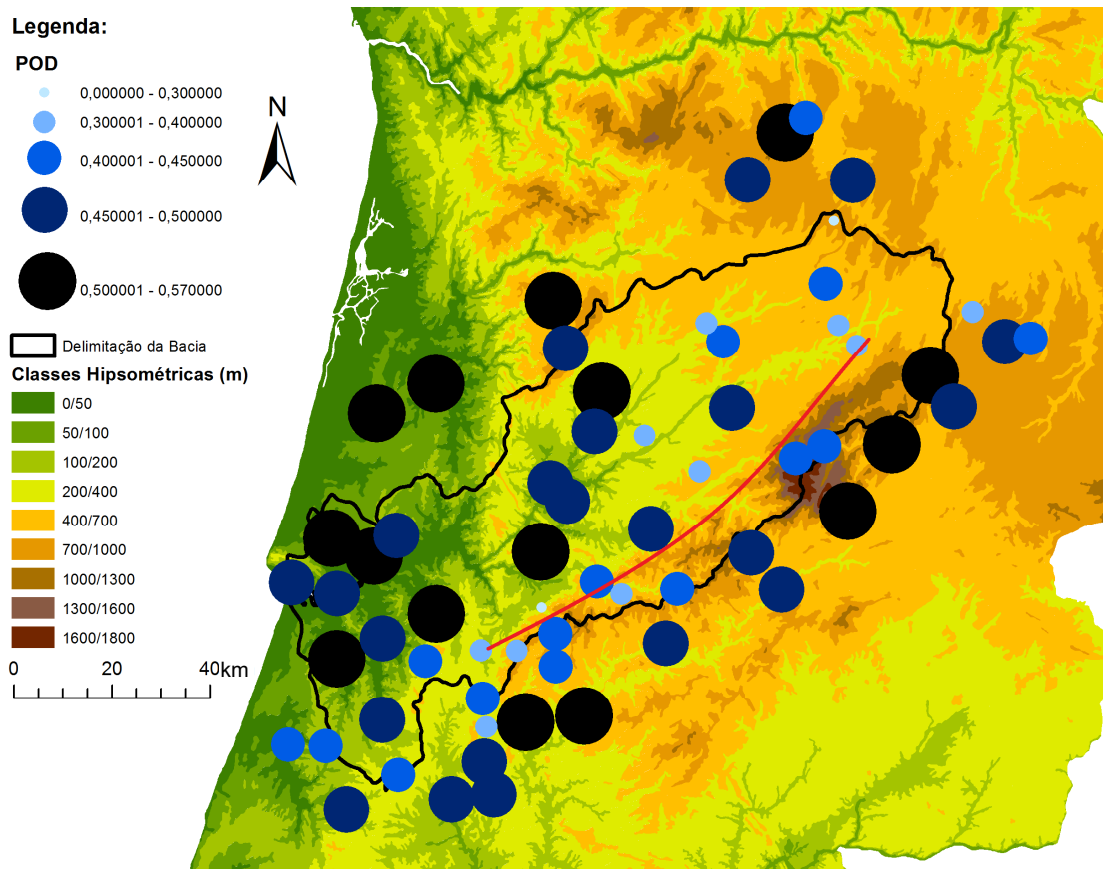


FIGURA 24 - A VERMELHO ESTÁ REPRESENTADA A LINHA QUE UNE UMA QUANTIDADE SIGNIFICATIVA DE ESTAÇÕES QUE APRESENTAM BAIXOS VALORES DE POD E QUE COINCIDE COM O LIMITE NO DAS SERRAS DA LOUSÃ E DA ESTRELA

Quanto ao RMSE o valor mensal calculado foi de 24.95 mm/mês, este resultado é melhor do que grande parte dos resultados obtidos por outros trabalhos. No Equador Ballari et al. (2016) reporta valores de 76.33 mm/mês para os Andes, de 68.27 para a Amazônia e 88.49 para a costa do Pacífico, para o Peru Mantas et al. (2015) obteve um RMSE de 49.17 mm/mês. Todos estes resultados são piores do que os obtidos para a área em estudo. É importante no entanto denotar que o clima na área em estudo é diferente das áreas acima mencionadas, mais estável, e segundo Mayor et al. (2017) o IMERG tem de um modo geral uma performance pior para a estação húmida do que para a estação seca, o trabalho mencionado foi realizado no México e apresenta uma precipitação média de 200 mm para a estação seca Nov-Abr e de 600 mm para a estação húmida. Em Portugal historicamente a precipitação é mais distribuída o que pode

beneficiar as estimativas uma vez que o RMSE é um parâmetro, que dada a sua natureza matemática, tende a piorar com o aumento do valor absoluto de precipitação. Isto é também observável nas agregações temporais, uma vez que o RMSE é o único parâmetro estatístico que consistentemente piora com a agregação temporal.

Quanto ao Bias, quer para a análise diária quer mensal, foi encontrada uma correlação para a elevação, em que é aparente que o Bias apresenta valores superiores para as zonas de cota mais baixa e valores inferiores para zonas de cota mais elevada.

Foi também encontrada uma correlação espacial, uma vez que a zona de mais baixa cota se localiza no setor oeste da área estudada (Figura 25).

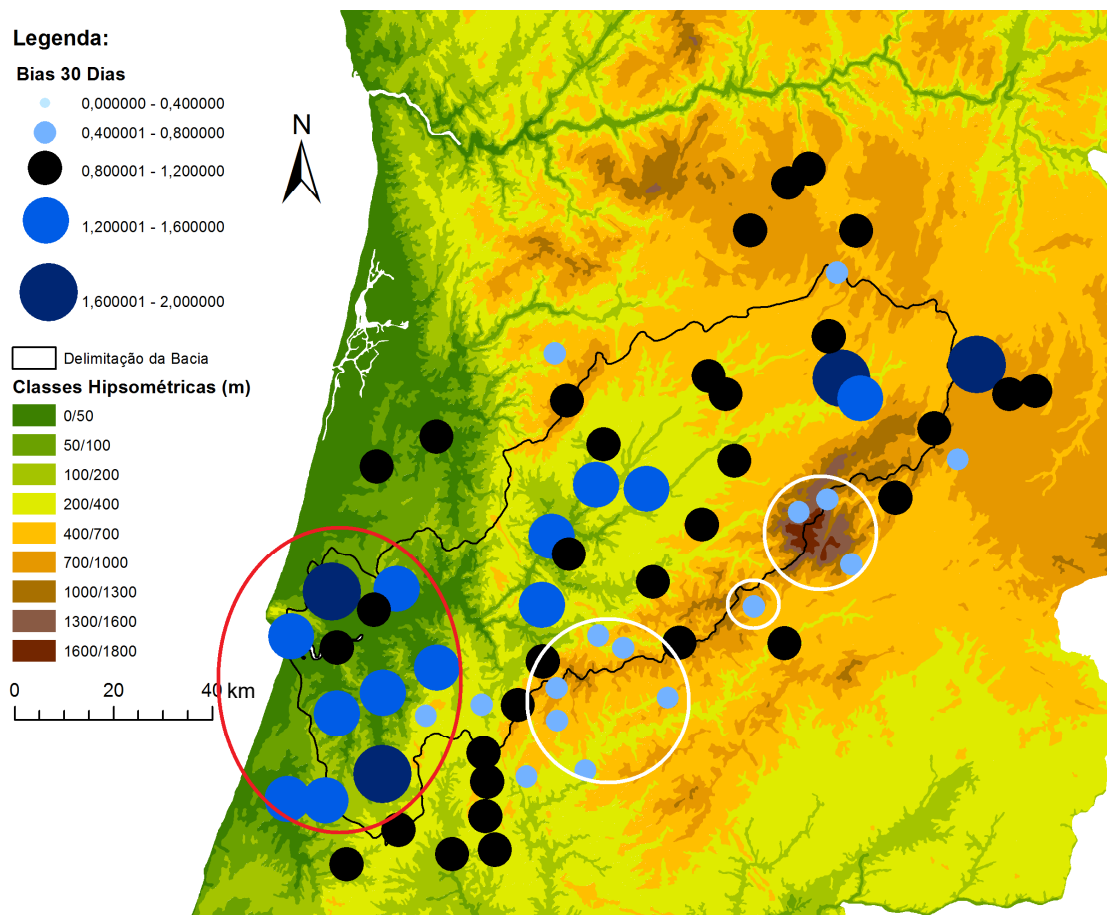


FIGURA 25 - A VERMELHO ESTÃO ASSINALADA UMA CONCENTRAÇÃO DOS VALORES DE BIAS MAIS ELEVADOS, COINCIDENTES COM COTAS MENOS ELEVADAS E A BRANCO VALORES DE BIAS MENORES COINCIDENTES COM COTAS MAIS ELEVADAS

Como já referido anteriormente o Bias ideal é 1 e o que corresponde a uma estimativa perfeita por parte do IMERG da quantidade de precipitação.

Face ao já mencionado anteriormente, relativamente ao POD, é normal que haja subestimativas, Bias <1, da quantidade de precipitação perto das Serras da Lousã e da Estrela uma vez que a probabilidade de deteção de eventos de precipitação (POD) é menor nessas zonas da área em estudo facto já explicado anteriormente. Tal como Dinku et al. (2010) que observou uma subestimação de precipitação na zona oeste da Colômbia e que atribuiu ao processo de *uplift* orográfico causado pela colisão do fluxo de ar proveniente da costa da Colômbia em direção aos Andes, pode ser estabelecida a mesma relação para a área em estudo entre os ventos dominantes provenientes de N e a cordilheira central.

Os valores médios de Bias obtidos para este trabalho foram excepcionais uma vez que o valor de Bias médio diário foi 0.99 e o valor de Bias mensal foi de 1.04 no entanto isto parece dever-se também em parte, ao facto das sobrestimativas compensarem as subestimativas, tal também foi observado por (Dinku et al., 2007) para o produto 3B42RT, e não ao facto de os valores absolutos serem perto de 1 para todas as estações, mesmo assim é possível identificar no mapa (Figura 23) um número significativo de estações que apresentam um valor de Bias perto do ideal (bolas pretas).

Quanto ao coeficiente de correlação de Pearson os valores obtidos foram também bastante bons, uma vez feita a agregação temporal dos dados. A correlação melhora progressivamente com a agregação temporal, uma vez que o problema da incapacidade de alinhamento perfeito dos dados diários (IMERG-SNIRH), do ponto de vista temporal é mitigado, facto também observado na vasta maioria dos trabalhos de validação desenvolvidos por outros autores quer para os produtos mais antigos pertencentes à TRMM (Mantas et al., 2015), quer para os produtos mais recentes obtidos pela GPM como é o caso do produto IMERG (Gadelha et al., 2018; Caracciolo et al., 2018). No caso da área de estudo analisada o maior salto em qualidade da estimativa dá-se com a primeira agregação temporal (D) para (8D) em que os valores médios passam de 0.36 para 0.75 isto deve-se em grande parte à falta de precisão no alinhamento temporal dos dados uma vez que ambos os dados são diários e não horários. Este problema é no entanto muito facilmente ultrapassado pela agregação temporal, uma vez que um desfasamento temporal de duas horas que tem um impacto potencialmente visível numa análise diária se torna progressivamente mais insignificante com a agregação temporal. Com a agregação de 8 dias para 16 dias os valores de correlação médios melhoram de 0.75 para 0.78 e com a agregação mensal atingem então o valor de 0.81 que indica uma forte correlação entre os valores estimados pelo IMERG e os valores medidos pelas estações do SNIRH, valor este que

indica uma grande competência do produto IMERG para estimar a precipitação na área estudada.

Em suma, os resultados obtidos para a área analisada foram bons, sendo a correlação mensal superior a 0.8. O fator dominante que afeta os resultados obtidos é a elevação. Sendo a ocorrência de fenômenos localizados de precipitação, devido à colisão dos ventos dominantes proveniente de N com a cordilheira central, a principal causa de perda de qualidade nas estimativas.

7. CONCLUSÕES E RECOMENDAÇÕES

Foi avaliada a performance do produto IMERG com recurso a dados de 65 estações *in situ*. A avaliação foi feita a diversas escalas temporais, diária, a 8 dias, a 16 dias e a 30 dias. A validação estatística foi efetuada, quer para a bacia no seu todo, quer para cada estação individualmente. Tal como em trabalhos anteriores, verificou-se uma melhoria de performance com a crescente agregação temporal. A performance do IMERG para a área em estudo foi semelhante à observada para outras regiões do globo. De um modo geral o IMERG é competente a quantificar eventos de precipitação no entanto os resultados não são homogéneos para a área de estudo. Existe uma sobrestimação da precipitação na zona costeira e uma subestimação na zona correspondente às encostas NO das Serras da Estrela e da Lousã. A subestimação parece estar associada a fenómenos de precipitação localizada e de curta duração, causados pela colisão dos ventos dominantes com os acidentes de relevo já mencionados. Uma diminuição da precisão das estimativas com a aproximação à costa tem vindo a ser documentada para o produto IMERG, no entanto seria imprudente estabelecer tal relação para a área em estudo dada a dimensão reduzida da área analisada. Um estudo a esta escala é sempre mais complexo uma vez que a variabilidade do território é analisada com maior detalhe. Esta análise tem as suas vantagens uma vez que para aplicações no terreno convém conhecer a performance do produto com o máximo nível de detalhe possível, no entanto não permite avaliar tendências à escala nacional ou continental. Para confirmar ou não esta tendência seria necessário alargar o estudo a Portugal continental na sua totalidade ou, idealmente a toda a Península Ibérica. Com base nas descobertas do estudo, conclui-se que o produto IMERG tem qualidade para complementar as medidas de precipitação *in-situ* para a bacia estudada. No entanto é preciso ter especial atenção e efetuar correções para as encostas NO da Cordilheira Central, uma vez que o satélite tende a subestimar a quantidade de precipitação que aí ocorre e para a zona costeira em que o satélite tende a sobrestimar os valores.

Face aos resultados obtidos é recomendado que para a utilização dos dados do IMERG no desenvolvimento de aplicações operacionais para a área estudada, seja pelo menos feita uma agregação temporal a 8 dias. É também recomendado que se tenha especial atenção às áreas problemáticas mencionadas, orla costeira, onde ficou demonstrado haver uma sobrestimação dos valores e na zona imediatamente a NO das Serras da Estrela e da Lousã para as quais foi verificada uma subestimação. Seria

benéfica a criação de um produto específico calibrado para a área em estudo que procura-se corrigir estas discrepâncias.

Num carácter mais generalista, seria também interessante o desenvolvimento de um produto específico do IMERG, a utilizar na orla costeira e outro a utilizar em zonas afetadas por precipitação convectiva, uma vez que foram já identificados problemas de carácter idêntico para as situações mencionadas em estudos conduzidos para diversas partes do globo.

Uma vez que o produto IMERG está constantemente a ser melhorado, e que são frequentemente lançadas novas versões é importante que atualizações das validações sejam também efetuadas com alguma regularidade.

É também recomendado que seja feita, por parte da APA, uma revisão séria a todas as estações que fazem parte da rede do SNIRH por forma a melhorar a rede existente. Assegurando em primeiro lugar que todas as estações ativas efetuam um registo contínuo e preciso dos dados e em segundo lugar incrementando a quantidade de estações ativas de maneira a ter, para todo o território nacional, uma distribuição que permita a obtenção de dados representativos, tornando-se assim uma instituição de referência a todos os níveis no que toca a dados pluviométricos em Portugal.

Importa ainda referir que o acesso aos dados do IPMA passar a ser gratuito seria uma mudança muito positiva que potenciará o desenvolvimento de trabalhos futuros nesta área.

No futuro, uma vez validados os dados seria interessante o desenvolvimento de aplicações no terreno, modelos de recarga aquífera, software de calibração de rega automática, etc., em que fossem utilizados em simultâneo dados *in situ* e estimativas de satélite para desenvolver os mesmos modelos e produtos, para que fosse possível fazer uma análise comparativa de *performance* de ambas as soluções. Uma colaboração com o IPMA que permitisse ter acesso a dados contínuos, e como tal estudar o efeito da sazonalidade na qualidade das estimativas, seria uma outra possibilidade. Outra colaboração interessante seria com os departamentos de engenharia eletrotécnica e de computadores e engenharia informática, de modo a realizar uma prova de conceito do sistema de calibração automática de irrigação já mencionado.

Validações deste tipo tem vindo a ser efetuadas um pouco por todo o mundo, no entanto, embora os resultados sejam de um modo geral bastante bons, falta ainda dar o próximo passo e explorar estes dados em aplicações operacionais, em particular no território nacional.

8. REFERÊNCIAS BIBLIOGRÁFICAS

- Almeida, C. A. C., & Cunha, L. (2008). *António Ferreira Soares e a Geomorfologia do Baixo Mondego*. (March 2008), 17–24.
- Almeida, C., Mendonça, J. J. L., Silva, M. A. M., & A., S. (1999). *Síntese da Hidrogeologia das Bacias do Mondego, Vouga e Lis*. (January).
- Alves, M. H., Rafael, M. T., Rodrigues, S., Bernardino, R., & Henriques, A. G. (2000). *Análise comparativa da qualidade ecológica das águas superficiais nacionais tendo como base os planos de bacia hidrográfica*. 1–14.
- Anastácio, P.M., Marques, J.C (1995). Population biology and production of the red swamp crayfish *Procambarus daooi* (Girard) in the lower Mondego River valley. Portugal. J. Crust. Biol. 15: 156- 168.
- Arkin, P. A., & Meisner, B. N. (1987). *The Relationship between fraction coverage of high cloud over the western hemisphere during 1982-84*.
- Ba, M. B., & Gruber, A. (2001). GOES Multispectral Rainfall Algorithm (GMSRA). *Journal of Applied Meteorology*, 40(8), 1500–1514. [https://doi.org/10.1175/1520-0450\(2001\)040<1500:GMRAG>2.0.CO;2](https://doi.org/10.1175/1520-0450(2001)040<1500:GMRAG>2.0.CO;2)
- Ballari, D., Castro, E., & Campozano, L. (2016). Validation of satellite precipitation (TRMM 3B43) in Ecuadorian coastal plains, Andean highlands and Amazonian rainforest. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 41(July), 305–311. <https://doi.org/10.5194/isprsarchives-XLI-B8-305-2016>
- Barrett, E. C., Martin, D. W. (1981). The use of satellite data in rainfall monitoring, Academic Press, London, p. 340.
- Bauer, P. (2001). Over-Ocean Rainfall Retrieval from Multisensor Data of the Tropical Rainfall Measuring Mission. Part I: Design and Evaluation of Inversion Databases. *Journal of Atmospheric and Oceanic Technology*, 18(8), 1315–1330. Retrieved from [http://dx.doi.org/10.1175/1520-0426\(2001\)018%3C1315:OORRFM%3E2.0.CO;2](http://dx.doi.org/10.1175/1520-0426(2001)018%3C1315:OORRFM%3E2.0.CO;2)
- Behrangi, A., Imam, B., Hsu, K., Sorooshian, S., Bellerby, T. J., & Huffman, G. J. (2010). REFAME: Rain estimation using forward-adjusted advection of microwave estimates. *Journal of Hydrometeorology*, 11(6), 1305–1321. <https://doi.org/10.1175/2010JHM1248.1>
- Bellerby, T., Hsu, K. L., & Sorooshian, S. (2009). LMODEL: A satellite precipitation methodology using cloud development modeling. Part I: Algorithm construction and calibration. *Journal of Hydrometeorology*, 10(5), 1081–1095. <https://doi.org/10.1175/2009JHM1091.1>
- Capacci, D., & Porcù, F. (2009). Evaluation of a satellite multispectral VIS-IR daytime statistical rain-rate classifier and comparison with passive microwave rainfall estimates. *Journal of Applied Meteorology and Climatology*, 48(2), 284–300. <https://doi.org/10.1175/2008JAMC1969.1>
- Caracciolo, D., Francipane, A., Viola, F., Valerio, L., & Deidda, R. (2018). Performances of GPM satellite precipitation over the two major Mediterranean islands Atmospheric Research Performances of GPM satellite precipitation over the two major Mediterranean islands. *Atmospheric Research*, 213(June), 309–322. <https://doi.org/10.1016/j.atmosres.2018.06.010>

- Chen, F. W., Member, S., & Staelin, D. H. (2003). *AIRS / AMSU / HSB Precipitation Estimates*. 41(2), 410–417.
- Chen, S., Hong, Y., Cao, Q., Kirstetter, P. E., Gourley, J. J., Qi, Y., ... Wang, J. (2013). Performance evaluation of radar and satellite rainfalls for Typhoon Morakot over Taiwan: Are remote-sensing products ready for gauge denial scenario of extreme events? *Journal of Hydrology*, 506, 4–13. <https://doi.org/10.1016/j.jhydrol.2012.12.026>
- Cunha, P. P. (1999). *Unidades litostratigráficas do Terciário na região de Miranda do Corvo-Viseu (Bacia do Mondego, Portugal)*.
- Cunha, P. P. (2002). *Vulnerabilidade e risco resultante da ocupação de uma planície aluvial - o exemplo das cheias*.
- Dezfuli, A., Ichoku, C., Huffman, G., Mohr, K., Selker, J., Giesen, N. van de, Annor, F. (2017). AMERICAN METEOROLOGICAL This is a preliminary PDF of the author-produced. *Journal of Hydrometeorology*. <https://doi.org/10.1175/JHM-D-17-0139.1>
- Dias, P., Rebelo, F. (1984). *Arte e Paisagem na Região de Turismo do Centro*. Coimbra RTC.
- Dinku, T., Ceccato, P., & Lemma, M. (2007). Validation of satellite rainfall products over East Africa ' s complex topography. *International Journal of Remote Sensing*, 28(7), 1503–1526. <https://doi.org/10.1080/01431160600954688>
- Dinku, T., Chidzambwa, S., Ceccato, P., & Connor, S. J. (2008). *Validation of high - resolution satellite rainfall products over complex terrain*. (November 2012), 37–41. <https://doi.org/10.1080/01431160701772526>
- Dinku, T., Ruiz, F., Connor, S. J., & Ceccato, P. (2010). Validation and Intercomparison of Satellite Rainfall Estimates over Colombia. *JOURNAL OF APPLIED METEOROLOGY AND CLIMATOLOGY*, 1004–1015. <https://doi.org/10.1175/2009JAMC2260.1>
- Duarte, A. A. L. S., & Pinho, J. L. S. (2000). *MODELAÇÃO DA HIDRODINÂMICA E DA DISPERSÃO LONGITUDINAL NO RIO MONDEGO*.
- Ferraro, R. R., Smith, E. A., Berg, W., & Huffman, G. J. (2002). A Screening Methodology for Passive Microwave Precipitation Retrieval Algorithms. *Journal of the Atmospheric Sciences*, 55(9), 1583–1600. [https://doi.org/10.1175/1520-0469\(1998\)055<1583:asmfpm>2.0.co;2](https://doi.org/10.1175/1520-0469(1998)055<1583:asmfpm>2.0.co;2)
- Fotopoulos, F., Makropoulos, C., & Mimikou, M. A. (2010). Flood forecasting in transboundary catchments using the Open Modeling Interface. *Environmental Modelling and Software*, 25(12), 1640–1649. <https://doi.org/10.1016/j.envsoft.2010.06.013>
- Furuzawa, F. A., & Nakamura, K. (2005). Differences of rainfall estimates over Land by Tropical Rainfall Measuring Mission (TRMM) precipitation radar (PR) and TRMM Microwave Imager (TMI) - Dependence on storm height. *Journal of Applied Meteorology*, 44(3), 367–382. <https://doi.org/10.1175/JAM-2200.1>
- Gadelha, A. N., Coelho, V. H. R., Xavier, A. C., Barbosa, L. R., Melo, D. C. D., Xuan, Y., ... Almeida, C. N. (2018). Grid box-level evaluation of IMERG over Brazil at various space and time scales. *Atmospheric Research*, #pagerange#. <https://doi.org/10.1016/j.atmosres.2018.12.001>
- Gebremichael, M., & Hossain, F. (2010). *Satellite Rainfall Application for Surface Hydrology*.
- Getis, A., & Ord, J. K. (1992). *The Analysis of Spatial Association*. 24(3).

Giovanni, <https://giovanni.gsfc.nasa.gov/giovanni/> acedido em Fevereiro de 2018

- Graça, M. A., Pardal, M. Â., & Marques, J. C. (2016). *Aquatic ecology of the Mondego River basin global importance of local experience* Autor (es): Publicado por : URL persistente : DOI : Accessed : URI : <http://hdl.handle.net/10316.2/2803> DOI : <http://dx.doi.org/10.14195/978-989-26-0336-0>.
- Greco, M., Anagnostou, E. N., & Adler, R. F. (2000). Assessment of the use of lightning information in satellite infrared rainfall estimation. *Journal of Hydrometeorology*, 1(3), 211–221. [https://doi.org/10.1175/1525-7541\(2000\)001<0211:AOTUOL>2.0.CO;2](https://doi.org/10.1175/1525-7541(2000)001<0211:AOTUOL>2.0.CO;2)
- Hou, A. Y., Kakar, R. K., Neeck, S., Azarbarzin, A. A., Kummerow, C. D., Kojima, M., ... Iguchi, T. (2014). The global precipitation measurement mission. *Bulletin of the American Meteorological Society*, 95(5), 701–722. <https://doi.org/10.1175/BAMS-D-13-00164.1>
- Hsu, K. L., Gao, X., Sorooshian, S., & Gupta, H. V. (1997). Precipitation estimation from remotely sensed information using artificial neural networks. *Journal of Applied Meteorology*, 36(9), 1176–1190. [https://doi.org/10.1175/1520-0450\(1997\)036<1176:PEFRSI>2.0.CO;2](https://doi.org/10.1175/1520-0450(1997)036<1176:PEFRSI>2.0.CO;2)
- Huffman, G. J., Bolvin, D. T., Braithwaite, D., Hsu, K., Joyce, R., Kidd, C., ... Xie, P. (2018). Algorithm Theoretical Basis Document (ATBD) Version 5.2 NASA - NASA Global Precipitation Measurement (GPM) Integrated Multi-satellitE Retrievals for GPM (IMERG) - Algorithm Theoretical Basis Document (ATBD) Version 5.2. *IMERG Algorithm Theoretical Basis Document (ATBD)*, IMERG Algo(February), 1–31. <https://doi.org/https://pmm.nasa.gov/resources/documents/gpm-integrated-multi-satellite-retrievals-gpm-imerg-algorithm-theoretical-basis>
- Hung, N. Q., Babel, M. S., Weesakul, S., & Tripathi, N. K. (2009). An artificial neural network model for rainfall forecasting in Bangkok, Thailand. *Hydrology and Earth System Sciences*, 13(8), 1413–1425. <https://doi.org/10.5194/hess-13-1413-2009>
- Ikai, J., & Nakamura, K. (2003). Comparison of rain rates over the ocean derived from TRMM Microwave Imager and precipitation radar. *Journal of Atmospheric and Oceanic Technology*, 20(12), 1709–1726. [https://doi.org/10.1175/1520-0426\(2003\)020<1709:CORROT>2.0.CO;2](https://doi.org/10.1175/1520-0426(2003)020<1709:CORROT>2.0.CO;2)
- Immerzeel, W. W., Rutten, M. M., & Droogers, P. (2009). Spatial downscaling of TRMM precipitation using vegetative response on the Iberian Peninsula. *Remote Sensing of Environment*, 113(2), 362–370. <https://doi.org/10.1016/j.rse.2008.10.004>
- Joyce, R. J., Janowiak, J. E., Arkin, P. A., & Xie, P. (2004). CMORPH: A method that produces global precipitation estimates from passive microwave and infrared data at high spatial and temporal resolution. *Journal of Hydrometeorology*, 5(3), 487–503. [https://doi.org/10.1175/1525-7541\(2004\)005<0487:CAMTPG>2.0.CO;2](https://doi.org/10.1175/1525-7541(2004)005<0487:CAMTPG>2.0.CO;2)
- Kidd, C., & Levizzani, V. (2011). Status of satellite precipitation retrievals. *Hydrology and Earth System Sciences*, 15(4), 1109–1116. <https://doi.org/10.5194/hess-15-1109-2011>
- Kidd, C., Kniveton, D. R., Todd, M. C., & Bellerby, T. J. (2003). Satellite rainfall estimation using combined passive microwave and infrared algorithms. *Journal of Hydrometeorology*, 4(6), 1088–1104. [https://doi.org/10.1175/1525-7541\(2003\)004<1088:SREUCP>2.0.CO;2](https://doi.org/10.1175/1525-7541(2003)004<1088:SREUCP>2.0.CO;2)
- Kottke, M., J. Grieser, C. Beck, B. Rudolf, and F. Rubel, 2006: World Map of the Köppen-Geiger climate classification updated. *Meteorol. Z.*, 15, 259-263. doi: 10.1127/0941-2948/2006/0130.

- Kubota, T., Hashizume, H., Shige, S., Okamoto, K., Aonashi, K., Takahashi, N., ... Kachi, M. (2006). Global precipitation map using satelliteborne microwave radiometers by the GSMaP project: Production and validation. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 45(7), 2584–2587. <https://doi.org/10.1109/IGARSS.2006.668>
- Lensky, I. M., & Rosenfeld, D. (2008). Atmospheric Chemistry and Physics Clouds-Aerosols-Precipitation Satellite Analysis Tool (CAPSAT). *Atmos. Chem. Phys*, 8(1998), 6739–6753. Retrieved from www.atmos-chem-phys.net/8/6739/2008/
- Levizzani, V., Bauer, P., & Turk, J. F. (2007). *Measuring Precipitation from Space*.
- Levizzani, V., Bauer, P., Buzzi, A., Davolio, S., Hinsman, D. E., Kidd, C., ... Vicente, G. A. (2001). Looking into the future of satellite rainfall estimations. *Proc. 2001 EUMETSAT Meteorological Satellite Data Users' Conf.*, (May 2014), 375–384. Retrieved from <http://www.isao.bo.cnr.it/~eurainsat/>.%0Ahttps://www.researchgate.net/profile/Vincenzo_Levizzani/publication/257105883_EURAINSAT_-_Looking_into_the_future_of_satellite_rainfall_estimations/links/004635245801ed911300000.pdf
- Liu, Z., Ostrenga, D., Teng, W., Kempler, S., & Milich, L. (2014). Developing GIOVANNI-based online prototypes to intercompare TRMM-related global gridded-precipitation products. *Computers and Geosciences*, 66(2014), 168–181. <https://doi.org/10.1016/j.cageo.2013.12.012>
- Lourenço, L. (1986). *Aproveitamento Hidráulico do Vale do Mondego in Atas IV colóquio ibérico de geografia. Coimbra, Portugal. 45-59.*
- Lourenço, L. (1986). *Estudo Hidrogeomorfológico in Cadernos de Geografia* (January 1986). 5, 43-123. doi.org/10.14195/0871-1623
- Mantas, V. M., Liu, Z., & Pereira, A. J. S. C. (2015). A web service and android application for the distribution of rainfall estimates and Earth observation data. *Computers and Geosciences*, 77, 66–76. <https://doi.org/10.1016/j.cageo.2015.01.011>
- Mantas, V. M., Liu, Z., Caro, C., & Pereira, A. J. S. C. (2015). Validation of TRMM multi-satellite precipitation analysis (TMPA) products in the Peruvian Andes. *Atmospheric Research*, 163, 132–145. <https://doi.org/10.1016/j.atmosres.2014.11.012>
- Mantas, V. M., Pereira, A. J. S. C., & Marques, J. C. (2019). *Partitioning the ocean using dense time series of Earth Observation data . Regions and natural boundaries in the Western Iberian Peninsula. 103(November 2018), 9–21.*
- Massari, C., Crow, W., & Brocca, L. (2017). An assessment of the performance of global rainfall estimates without ground-based observations. *Hydrology and Earth System Sciences*, 21(9), 4347–4361. <https://doi.org/10.5194/hess-21-4347-2017>
- Mayor, Y. G., Tereshchenko, I., Fonseca-hern, M., Pantoja, D. A., & Montes, J. M. (2017). *Evaluation of Error in IMERG Precipitation Estimates under Different Topographic Conditions and Temporal Scales over Mexico. 1–18.* <https://doi.org/10.3390/rs9050503>
- Meng, J., Li, L., Hao, Z., Wang, J., & Shao, Q. (2014). Suitability of TRMM satellite rainfall in driving a distributed hydrological model in the source region of Yellow River. *Journal of Hydrology*, 509(November 1997), 320–332. <https://doi.org/10.1016/j.jhydrol.2013.11.049>
- Norberto, P. dos S. (2012). A GESTÃO DAS BACIAS HIDROGRÁFICAS E A VALORIZAÇÃO TURÍSTICA DOS AMBIENTES FLUVIAIS: O RIO MONDEGO. *REVISTA GEONORTE*, 4(4), 210–219.

- Ochoa, A., Pineda, L., Crespo, P., & Willems, P. (2014). Evaluation of TRMM 3B42 precipitation estimates and WRF retrospective precipitation simulation over the Pacific-Andean region of Ecuador and Peru. *Hydrology and Earth System Sciences*, 18(8), 3179–3193. <https://doi.org/10.5194/hess-18-3179-2014>
- Ribeiro, L. T., & Gamito, T. M. (2012). *Plano de Gestão das Bacias Hidrográficas dos rios Vouga, Mondego e Lis Integrados na Região Hidrográfica 4*.
- Rodrigues, R., Brandão, C., & Costa, J. P. da. (2001). Hidrologia das cheias do Mondego de 26 e 27 de Janeiro de 2001. *Relatório Do INAG, 2001*.
- Roebeling, R. A., & Holleman, I. (2009). SEVIRI rainfall retrieval and validation using weather radar observations. *Journal of Geophysical Research Atmospheres*, 114(21), 1–13. <https://doi.org/10.1029/2009JD012102>
- Rocha, S. J., & Freitas, H. (1998). *O Rio Mondego: o ambiente fluvial e a sua ecologia. Congresso da Água, Lisboa, (1)*. https://www.researchgate.net/publication/242128948_O_RIO_MONDEGO_O_AMBIENTE_FLUVIAL_E_A_SUA_ECOLOGIA
- SNIRH, <https://snirh.apambiente.pt/> acedido em Fevereiro de 2018
- Spencer, R. W., Goodman, H. M., & Hood, R. E. (1989). Precipitation Retrieval over Land and Ocean with the SSM/I: Identification and Characteristics of the Scattering Signal. *Journal of Atmospheric and Oceanic Technology*, 6(2), 254–273. [https://doi.org/10.1175/1520-0426\(1989\)006<0254:PROLAO>2.0.CO;2](https://doi.org/10.1175/1520-0426(1989)006<0254:PROLAO>2.0.CO;2)
- Tapiador, F. J., Turk, F. J., Petersen, W., Hou, A. Y., García-Ortega, E., Machado, L. A. T., ... de Castro, M. (2011). Global precipitation measurement: Methods, datasets and applications. *Atmospheric Research*, 104–105, 70–97. <https://doi.org/10.1016/j.atmosres.2011.10.021>
- Turk, F. J., Rohaly, G. D., Hawkins, J., Smith, E. A., Marzano, F. S., Mugnai, A., & Levizzani, V. (1999). Meteorological applications of precipitation estimation from combined SSM/I, TRMM and infrared geostationary satellite data. *Microwave Radiometry and Remote Sensing of the Earth's Surface and Atmosphere*, (January), 353–363.
- Wang, J., & Wolff, D. B. (2009). Evaluation of TRMM Ground-Validation Radar-Rain Errors Using Rain Gauge Measurements. *JOURNAL OF APPLIED METEOROLOGY AND CLIMATOLOGY*, 49, 310–324. <https://doi.org/10.1175/2009JAMC2264.1>
- Wilheit, T. T., Chang, A. T. C., & Chiu, L. S. (1991). Retrieval of Monthly Rainfall Indices from Microwave Radiometric Measurements Using Probability Distribution Functions. *Journal of Atmospheric and Oceanic Technology*, Vol. 8, pp. 118–136. [https://doi.org/10.1175/1520-0426\(1991\)008<0118:romrif>2.0.co;2](https://doi.org/10.1175/1520-0426(1991)008<0118:romrif>2.0.co;2)
- Xie, P., & Arkin, P. A. (1998). Global monthly precipitation estimates from satellite-observed outgoing longwave radiation. *Journal of Climate*, 11(2), 137–164. [https://doi.org/10.1175/1520-0442\(1998\)011<0137:GMPEFS>2.0.CO;2](https://doi.org/10.1175/1520-0442(1998)011<0137:GMPEFS>2.0.CO;2)