

## Aplicação de técnicas de redes neuronais para previsão de chuvas torrenciais combinando dados de vapor de água GNSS e medições meteorológicas

Pedro BENEVIDES<sup>1\*</sup>, João CATALÃO<sup>1</sup>, Giovanni NICO<sup>2</sup> e Pedro M.A. MIRANDA<sup>1</sup>

<sup>1</sup>IDL, Universidade de Lisboa, Faculdade de Ciências

<sup>2</sup> Consiglio Nazionale delle Ricerche (CNR), Istituto per le Applicazioni del Calcolo, (Itália)

(pjbenevides@fc.ul.pt; jcfernandes@fc.ul.pt; g.nico@ba.iac.cnr.it; pmmiranda@fc.ul.pt)

**Palavras-chave:** Sistema de navegação por satélite (GNSS), Vapor de água precipitável (PWV), Precipitação, SEVIRI, Rede neuronal, Previsão de tempo

**Resumo:** Neste estudo é realizada a integração de medições GNSS juntamente com dados meteorológicos, num sistema de deteção de chuva baseado em inteligência artificial. O foco deste trabalho é melhorar a previsão a curto prazo de chuvas intensas. Em estudos anteriores foi observado que existe uma forte correlação entre a variação do sinal GNSS com a chuva intensa, mas com uma elevada taxa de falsos positivos (resposta do sinal GNSS sem chuva). Pretendemos melhorar esta previsão, identificando os eventos de chuva torrencial e diminuindo a taxa de falsos positivos através da aplicação dos dados GNSS nas redes neuronais combinada com informação meteorológica. Foi construída uma série de observações horárias contínuas do PWV, durante 3 anos, utilizando uma estação GNSS em Lisboa, dados de pressão à superfície, humidade relativa e temperatura do ar obtidos de uma estação meteorológica e também dados de deteção remota do topo das nuvens obtidos do sensor SEVIRI. São também recolhidos 3 anos de precipitação horária acumulada medidos na estação meteorológica. Um conjunto total de 18 variáveis (7 primárias e 11 derivadas) é aplicado a um algoritmo de segmentação de dados pelas características do sinal GNSS, resultando numa redução espacial dos dados em 2870 tendências. É ainda realizada uma classificação das estimativas de precipitação da rede neuronal em 3 classes distintas com a finalidade de avaliar a capacidade do método detetar chuva intensa. É utilizado um sistema de redes neuronais de aproximação (*fitting*) para processar o conjunto de variáveis de entrada e estimar a variável de saída, que neste caso é a precipitação horária. Uma série de testes realizados sobre as condições iniciais da rede neuronal mostram resultados promissores para a deteção de eventos de chuvas torrenciais sendo observada uma redução no número de falsos de positivos comparativamente a estudos anteriores.

## 1. Introdução

As variações espaço-temporais do vapor de água na baixa troposfera continuam a afetar a previsão precisa dos modelos numéricos de previsão (MNP). Os fenómenos de precipitação intensa estão geralmente associados a processos de convecção atmosférica com elevada variabilidade de vapor de água. Presentemente as técnicas de medição atmosférica ainda são insuficientes para observar as variações do vapor de água em todas as escalas espaciais que são necessárias para dar informação de qualidade aos MNP. A incerteza destes modelos no que diz respeito à distribuição do vapor de água limita a sua capacidade de identificar situações de instabilidade meteorológica que podem levar a fenómenos de convecção, que por sua vez podem desencadear tempestades. Esta particularidade é ainda mais importante para a previsão em tempo real (*nowcast*), uma vez que os mecanismos de prevenção e alarme são fundamentais para permitir antecipar fenómenos com grande potencial de causar danos antropogénicos, como frequentemente se verifica em episódios de tempestade. Desta forma é desejável um melhor conhecimento do estado do vapor de água na atmosfera, não só para a comunidade meteorológica, mas também para outras instituições públicas ou privadas em geral. A técnica de observação meteorológica por sistemas de navegação por satélite (GNSS) já está consagrada como um método fiável para avaliar continuamente o conteúdo de vapor de água atmosférico. As medições obtidas por uma estação GNSS são comparáveis em termos de precisão com os métodos diretos de medição meteorológica (Mateus *et al.*, 2015). Algumas experiências baseadas na técnica da meteorologia GNSS já provaram a sua utilidade para estudar eventos de precipitação intensa (Seco *et al.*, 2012; Benevides *et al.*, 2013). Além disso, o processamento meteorológico de rede densa de estações GNSS aplicando técnicas de tomografia permitem estimar mapas tridimensionais do vapor de água numa área de algumas dezenas de quilómetros (Benevides *et al.*, 2017). A utilização de mapas de alta resolução espacial obtida da técnica de interferometria radar (InSAR) com a tomografia GNSS, já provou ser benéfica para a melhoria da precisão dos mapas de vapor de água, quando comparados com os mesmos mapas obtidos de MNP (Benevides *et al.*, 2016). A assimilação de dados de vapor de água originários da meteorologia GNSS nos modelos MNP tem potencial para melhorar a precisão de previsão de tempestades, como foi recentemente verificado com a assimilação de dados meteorológicos InSAR (Mateus *et al.*, 2018), com a vantagem de o GNSS oferecer continuidade temporal não estando dependente das passagens de satélite.

O percurso do sinal eletromagnético GNSS pela troposfera é afetado por um atraso que é induzido pelas propriedades físicas do vapor de água. Estas características permitem a quantificação da variabilidade do vapor de água quando as estações terrestres GNSS têm coordenadas conhecidas e estão instaladas em locais estáveis. Este atraso pode ser convertido numa medição de vapor de água integrado, definida como vapor de água precipitável (PWV). Em estudos anteriores foi verificado que a variação temporal do PWV está correlacionada com a precipitação através de um aumento brusco da sua intensidade antes da ocorrência de chuva e posterior decréscimo acentuado. Contudo foi verificado que muitos destes picos de sinal são falsos positivos, o que significa que a evolução do PWV não contém informação suficiente por si só para antecipar a chuva (Benevides *et al.*, 2015). Neste trabalho é analisada a integração de medições meteorológicas com o PWV obtido do GNSS num sistema de redes neuronais para previsão de chuva intensa a curto prazo. Para tal, é processada em Lisboa uma série contínua de 3 anos de dados GNSS, de onde são extraídas medições horárias do PWV. São também obtidas de uma estação meteorológica próxima medições horárias de pressão atmosférica, temperatura à superfície e humidade relativa, durante o período do 3 anos. Dados de deteção remota obtidos do sensor SEVIRI são também recolhidos, o que permite obter continuamente outro tipo de informação sobre a troposfera, nomeadamente dados sobre o topo das nuvens. A precipitação horária acumulada medida na estação meteorológica durante o período de 3 anos é utilizada para avaliar a metodologia proposta. O incremento absoluto e a sua taxa de variação ao longo do tempo são variáveis derivadas das introduzidas anteriormente e serão integradas nos dados de entrada para a rede neuronal. Estas variáveis deverão ajudar a identificar padrões de comportamento durante longos períodos sem chuva, diferenciando-os do comportamento do sinal na presença de instabilidade atmosférica. A média mensal do PWV também é introduzida nas redes neuronais de forma a avaliar os padrões sazonais do comportamento do sinal, com expectável melhoria da previsibilidade de chuva. A previsão correta de chuva intensa é uma condição particularmente relevante para antecipar potenciais danos causados por este tipo de fenómeno e uma ferramenta válida para melhorar os mecanismos de previsão já implementados.

## 2. Métodos e descrição dos dados

### 2.1 Redes neuronais

As técnicas de redes neuronais são usualmente aplicadas a um vasto e diverso leque de domínios tais como medicina, economia, finanças, engenharia industrial e ciências naturais. O foco da sua aplicação são os problemas não lineares, incluindo os fenómenos meteorológicos como a precipitação. As redes neuronais são ferramentas de *machine learning* que permitem determinar uma relação generalizada entre dados sem um conhecimento da sua interdependência física e matemática. A sua arquitetura é composta por uma ou mais multicamadas (*multilayers*), onde um ou mais neurónios estão ligados e operam em paralelo. Cada neurónio é pesado e treinado por uma função que avalia as relações não lineares entre os dados de entrada/saída (Ramirez *et al.*, 2005). Neste trabalho são usadas redes neuronais de aproximação (*function fitting*) para estimar a grandeza de precipitação horária acumulada. O processo divide-se em 3 fases distintas com amostragem independente. A fase de treino avalia a relação entre os dados de entrada e a sua compatibilidade com os dados de saída, permitindo descobrir relações não linear entre si. A fase de validação supervisiona a performance do treino enquanto não for encontrado um conjunto de parâmetros generalizados. A fase de teste é utilizada para avaliar a qualidade desta generalização. Uma amostragem significativa de dados na fase de treino é recomendada para o modelo alcançar resultados viáveis (Ramirez *et al.*, 2005).

### 2.2 Enquadramento da experiência

A região de estudo escolhida foi a de Lisboa (Figura 1). Para este trabalho é reunido um conjunto de 3 anos (2011-2013) de registos horários de dados meteorológicos: pressão atmosférica, temperatura e humidade relativa medidos de uma estação meteorológica. É estimada uma série contínua de dados PWV a partir de uma estação GNSS da região. A estação meteorológica utilizada, Geofísico, é uma estação automática principal gerida pelo Instituto Dom Luiz (IDL). A estação GNSS utilizada é a IGP0 e é propriedade da Direção-Geral do Território (DGT). As estações estão apenas distanciadas por 1.25 km, estando a GNSS localizada a 125 m de altitude acima do nível do mar e a meteorológica a 77 m, representando um desnível vertical de menos de 50 m.

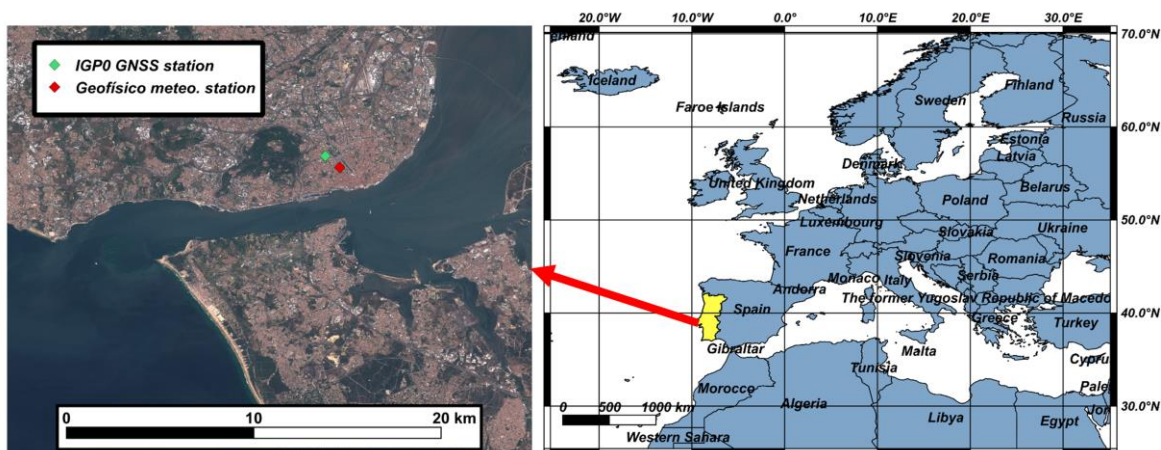
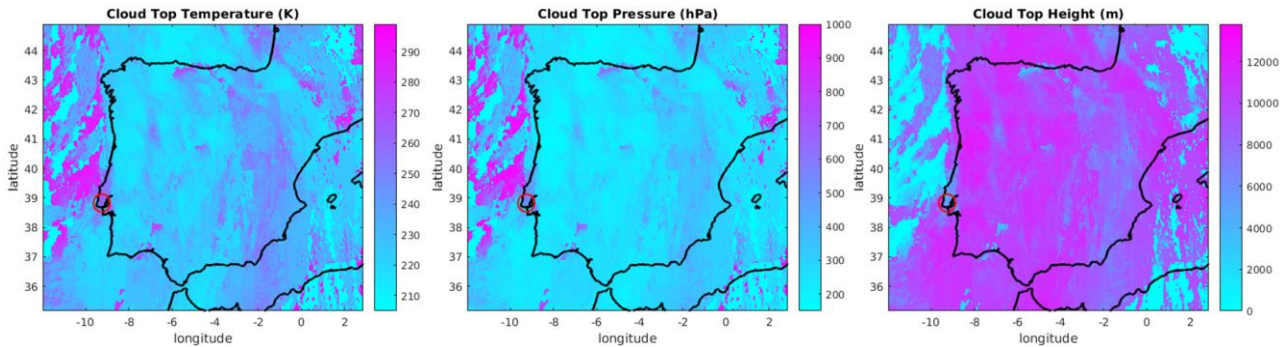


Figura 1 – Região de estudo utilizada neste trabalho (Lisboa, Portugal). Imagem de composição de cor verdadeira Sentinel-2 utilizada como fundo (esquerda)

### 2.3 Dados de satélite SEVIRI

Para este trabalho são também utilizados dados de deteção remota do topo das nuvens através do sensor SEVIRI (*Spinning Enhanced Visible and Infrared Image*). Este instrumento está instalado a bordo do satélite METEOSAT-9 (*Meteosat Second Generation*), que está geostacionário a uma altitude de 36000 km e é capaz de fornecer imagens em tempo quase real. O SEVIRI é composto por 12 canais que podem ser utilizados para diferentes aplicações como análise de ventos, monitorização do vapor de água e observação de nuvens. As variáveis escolhidas para este trabalho são a temperatura do topo das nuvens (CTT), pressão do topo das nuvens (CTP) e altitude do topo das nuvens (CTH). Estes dados são produzidos continuamente a uma frequência de 15 minutos com um pixel médio de 15 km de resolução espacial. A imagem original é composta por uma

grelha de 3636 x 3636 pixels, correspondente a uma resolução de  $0.05^\circ \times 0.05^\circ$  (latitude x longitude). Felizmente é possível selecionar uma região de interesse a partir desta imagem original o que diminui consideravelmente o volume de dados a descarregar. Os dados SEVIRI sobre a região de estudo podem ser observados na Figura 2. O passo final consiste na extração dos dados de topo de nuvem a partir do pixel que contém no seu interior a localização da estação GNSS.



**Figura 2** – Temperatura, pressão e altitude do topo das nuvens obtidos do SEVIRI na região de estudo. Os dados correspondem a um evento de precipitação torrencial que ocorreu a 2011/11/02, 11:00, registando 36.3 mm/h de precipitação em Lisboa

## 2.4 Processamento de dados GNSS

O processamento de dados GNSS foi realizado utilizando o *software* GAMIT/GLOBK que permite estimar com precisão as coordenadas e os parâmetros atmosféricos em cada estação (Herring *et al.*, 2010). A estação IGPO foi processada durante 3 anos em sessões diárias de diferenças duplas. O referencial ITRF08 (Altamimi *et al.*, 2011) é utilizado juntamente com um conjunto de cerca de 40 estações IGS (*International GNSS Service*) distribuídas globalmente, de forma a assegurar uma estimativa precisa das coordenadas e baixa correlação entre parâmetros atmosféricos. As órbitas precisas IGS são também utilizadas. O processamento dos dados é efetuado em dois passos distintos: o primeiro é focado na obtenção das coordenadas com precisão milimétrica, e o segundo fixa as coordenadas estimadas no primeiro passo e aplica uma série de parametrizações favoráveis ao aumento da precisão dos parâmetros atmosféricos (Benevides *et al.*, 2018). O *zenith wet delay* (ZWD) é o parâmetro que está relacionado com o vapor de água troposférico, e é estimado durante o processamento e para cada estação a cada 15 minutos. O ZWD é convertido no final do processamento GNSS para PWV através de uma relação empírica que é previamente calibrada para o clima da região de estudo (Mateus *et al.*, 2014).

## 2.5 Tratamento de dados e harmonização

Os dados provenientes das diferentes fontes recolhidas para este estudo (GNSS, meteorologia e SEVIRI) foram harmonizados para se obter um conjunto consistente de dados de entrada para a aplicação da rede neuronal. É aplicada uma média horária à frequência de dados GNSS de 15 minutos, para se ter dados comparáveis aos dados de precipitação, pressão, temperatura e humidade relativa obtidos a cada hora pela estação meteorológica. O mesmo procedimento é executado para os dados do topo das nuvens obtidos do SEVIRI, sendo realizada uma média em cada hora sobre as imagens obtidas a cada 15 minutos.

Considerando o intervalo temporal de uma hora numa amostra de dados contínuos de 3 anos, são obtidos mais de 26000 registos para cada variável. Contudo, foi detetada anteriormente uma forte correlação entre as variações de PWV em intervalos curtos e a ocorrência de precipitação, indicando que a segmentação de dados pode ser benéfica para o estudo deste fenómeno meteorológico (Benevides *et al.*, 2015). Esta metodologia foi aplicada neste trabalho, onde é utilizado um algoritmo de aproximação linear à evolução temporal do sinal PWV utilizando as 6 horas anteriores, sendo este intervalo definido para cumprir os requisitos mínimos da previsão em *nowcasting*. Desta forma é obtida uma segmentação de dados em tendências onde também é possível derivar variáveis em função do tempo como por exemplo o incremento do PWV (dPWV) e a sua taxa de variação ou gradiente temporal (dPWV/dt). A aplicação do algoritmo ao período de estudo de 3 anos resulta num total de 2870 tendências. Os restantes dados meteorológicos são adaptados à referência temporal determinada pelo algoritmo anterior. No caso da precipitação é contabilizado o valor máximo de precipitação horária registado em cada tendência.

### 3. Resultados

#### 3.1 Configuração da rede neuronal

As variáveis utilizadas nesta experiência de redes neurais são descritas no Quadro 1. Neste trabalho é utilizada uma rede neuronal de aproximação composta por 1 camada *hidden layer* com 50 neurónios para os dados *input* e 1 camada para o *output*. A função de treino utilizada é o algoritmo de Levenberg-Marquardt, com uma divisão de dados de 57%, 10% e 33% para as fases de treino, validação e teste. A divisão dos dados é feita continuamente no tempo, assegurando uma cobertura de um ano para a validação da técnica (ano 2013). O peso atribuído para cada uma das variáveis de entrada (18 no total) e de saída (apenas 1) é definido aleatoriamente na função de treino. Foram realizadas várias experiências aplicando as redes neurais com diferentes condições iniciais. Para cada uma é realizado um conjunto de 100 corridas devido à aleatoriedade na atribuição dos pesos, o que afeta o resultado final, sendo considerado como resultado de referência o melhor resultado obtido em todas as corridas.


**Quadro 1** – Caracterização dos dados utilizados na experiência da rede neuronal

Variável	Fonte	Acrónimo	Unidades	Função
Precipitação horária	Primária meteorologia	Rain	mm/h	<i>Output</i>
Vapor de água precipitável	Primária GNSS	PWV	mm	<i>Input</i>
Pressão	Primária meteorologia	P	hPa	<i>Input</i>
Temperatura	Primária meteorologia	T	°C	<i>Input</i>
Humidade Relativa	Primária meteorologia	RH	%	<i>Input</i>
Varição PWV	Derivada GNSS	dPWV	mm	<i>Input</i>
Gradiente PWV	Derivada GNSS	dPWV/dt	mm/h	<i>Input</i>
Varição Pressão	Derivada meteorologia	dP	hPa	<i>Input</i>
Gradiente Pressão	Derivada meteorologia	dP/dt	hPa/h	<i>Input</i>
Varição Temperatura	Derivada meteorologia	dT	°C	<i>Input</i>
Gradiente Temperatura	Derivada meteorologia	dT/dt	°C/h	<i>Input</i>
Varição Humidade Relativa	Derivada meteorologia	dRH	%	<i>Input</i>
Gradiente Humidade Relativa	Derivada meteorologia	dRH/dt	%/h	<i>Input</i>
Temperatura Topo Nuvens	Primária satélite	CTT	K	<i>Input</i>
Pressão Topo Nuvens	Primária satélite	CTP	hPa	<i>Input</i>
Altitude Topo Nuvens	Primária satélite	CTH	m	<i>Input</i>
Média mensal PWV	Derivada GNSS	PWVm	mm	<i>Input</i>
Nº horas tendência	Derivada GNSS	h	h	<i>Input</i>
Chuva da tendência anterior	Derivada meteorologia	PrevRain	mm/h	<i>Input</i>

Após se obter a estimativa de precipitação horária resultante do processamento da rede neuronal, é implementada uma classificação simples de valores precipitação. Desta forma são definidas 3 classes de chuva: classe para valores sem chuva, classe intermédia com valores de chuva entre 0.1 e 5.0 mm/h e uma classe correspondendo a valores maiores que 5 mm/h, caracterizando a chuva intensa. Esta classificação simples permite avaliar de forma mais clara a capacidade desta metodologia identificar corretamente episódios de chuva intensa. Contudo é importante ter em consideração que a classe de chuva intensa ocorre apenas em 2.5% da totalidade das tendências, o que tem características de acontecimento raro.

#### 3.2 Melhor caso com todas as variáveis de entrada

A primeira experiência consiste na utilização de todas as variáveis de *input* presentes no Quadro 1, escolhendo o melhor caso do conjunto de 100 corridas através da avaliação do melhor rácio da classificação de chuva intensa (classificação correta sobre falsos positivos).



**Figura 3** – Regressão linear do *output* de precipitação horária em mm/h obtido da rede neuronal com 18 variáveis de *input* (melhor resultado). Os dados estão divididos em total, treino, validação e teste, com o coeficiente de correlação R no topo de cada figura

Na Figura 3 é representada a correlação entre os dados medidos de referência (estação meteorológica) e os estimados da aplicação da rede neuronal (*output*). Observa-se uma correlação máxima para a fase de treino e mínima para fase da validação, enquanto que para os dados de teste a correlação é intermédia, com alguns *outliers* visíveis para os eventos de chuva mais intensos.

Na Figura 4 é apresentado o resultado da classificação de chuvas sobre a forma de matriz de confusão. Aqui é possível avaliar a precipitação classificada pela rede neuronal (linha) versus a precipitação medida na estação meteorológica (coluna), que neste caso é a verdade do terreno. O interior da matriz mostra a distribuição das tendências por cada classe com as corretamente classificadas localizadas na diagonal. A linha limite inferior representa a percentagem de classificação correta para os valores de *output* (percentagem verde) relativamente aos valores medidos, enquanto a coluna na extremidade direita identifica para a classificação dos *outputs* a percentagem de tendências bem classificadas (verde) e a percentagem de falsos positivos (vermelho). Analisando a classe de interesse, chuva intensa, é observado cerca de 70% de verdade de terreno (71% dados teste) mas com uma percentagem considerável de falsos positivos de 56% (62% dados teste).

		confusion matrix all dataset				confusion matrix test dataset			
		no rain	moderated	intense	all	no rain	moderated	intense	all
output classification	no rain	1085 37.8%	35 1.2%	1 0.0%	96.8% 3.2%	371 39.2%	15 1.6%	0 0.0%	96.1% 3.9%
	moderated	1331 46.4%	284 9.9%	21 0.7%	17.4% 82.6%	407 43.0%	101 10.7%	7 0.7%	19.6% 80.4%
	intense	16 0.6%	47 1.6%	50 1.7%	44.2% 55.8%	6 0.6%	22 2.3%	17 1.8%	37.8% 62.2%
	all	44.6% 55.4%	77.6% 22.4%	69.4% 30.6%	49.4% 50.6%	47.3% 52.7%	73.2% 26.8%	70.8% 29.2%	51.7% 48.3%
		ground truth				ground truth			

**Figura 4** – Matriz de confusão para a totalidade dos dados (esquerda) e dados teste (direita) para o melhor resultado com 18 variáveis, relacionando o *output* da rede neuronal com os valores medidos de precipitação (verdade do terreno)

### 3.3 Sensibilidade da rede neuronal a variáveis de entrada

Nesta seção são realizadas experiências na rede neuronal fazendo variar o número de variáveis de entrada. No quadro 2 é visível uma compilação dos resultados e das configurações das experiências efetuadas. Quando apenas são consideradas as variáveis primárias a percentagem de classificação correta de chuva intensa baixa para 54% com uma ligeira diminuição dos falsos positivos para 59%, quando comparado com o resultado da secção anterior. Na experiência seguinte, quando são

introduzidas as variáveis derivadas no tempo, os resultados de classificação não variam muito, mas é obtida uma melhoria significativa no coeficiente de correlação (0.52). Contudo é verificado que a maior percentagem de classificação correta é obtida quando são introduzidas mais variáveis, com um ligeiro aumento de cerca de 3% de falsos positivos. Os resultados indiciam que a introdução de mais variáveis de entrada na rede neuronal produz geralmente melhores resultados.

**Quadro 2** – Caracterização das experiências com diferentes configurações dos dados *input* (melhor resultado, 100 corridas). A classificação correta e falsos positivos correspondem aos dados de teste e à classe de chuva intensa

Configuração	Variáveis	Classificação correta	Falsos positivos	Correlação
Dados primários GNSS, Meteo, Sat.	7	0.54	0.59	0.49
Dados primários c/ derivadas GNSS, Meteo, Sat.	15	0.54	0.59	0.52
Todas as variáveis (Quadro 1)	18	0.71	0.62	0.55

### 3.4 Sensibilidade da rede neuronal a divisão dos dados

A experiência realizada nesta seção consiste na avaliação da sensibilidade da rede neuronal fazendo variar os períodos de seleção da amostragem de dados. A configuração inicial do melhor caso com todas as variáveis de *input* é aqui considerada, associando à amostragem de dados de teste o período de estudo de cada ano ainda não testado; 2011 e 2012. Os restantes dados são distribuídos uniformemente pelas fases de treino e validação, mantendo as percentagens definidas inicialmente (57% treino, 10% validação, 33% teste).

**Quadro 3** – Caracterização das experiências com 18 variáveis de *input* (melhor resultado, 100 corridas) variando a distribuição dos dados de teste. A classificação correta e falsos positivos correspondem aos dados de teste e à classe de chuva intensa

Configuração	Chuvas intensas	Classificação correta	Falsos positivos	Correlação
Dados de teste 2011	32	0.31	0.17	0.53
Dados de teste 2012	14	0.64	0.68	0.51
Dados de teste 2013	24	0.71	0.62	0.55

No Quadro 3 é apresentado o resultado da classificação de chuvas intensas desta experiência, onde é de notar uma variação bastante considerável. Os dados de teste com o ano 2011 revelam uma percentagem de falsos positivos baixa (17%) mas apenas 31% de um total de 32 eventos de chuva intensa são classificados corretamente. Para o ano 2012, comparativamente a 2011, é registada uma maior percentagem de classificação (64%) mas com um crescimento elevado da taxa de falsos positivos (68%), que é ainda acentuado pelo facto de apenas serem observadas 14 chuvas intensas. Desta forma a experiência de redes neuronais com estes dados utilizando o ano de 2013 revela-se a melhor para classificar chuvas intensas mostrando percentagem de classificação correta, taxa de falsos positivos e coeficiente de correlação superiores.

## 3. Conclusões

Neste trabalho são utilizados 3 anos de dados contínuos com observações horárias, recorrendo a técnicas GNSS e observações meteorológicas, num sistema de redes neuronais com o objetivo de estimar a chuva intensa. Foram realizadas várias experiências fazendo variar as condições iniciais do sistema, com 100 corridas definidas para cada experiência e considerando como referência o melhor resultado no âmbito da classificação de chuva intensa. Foi verificado que o sistema deteta 71% chuvas intensas com 62% de taxa de falsos positivos quando são utilizadas as 18 variáveis de entrada. Os testes de sensibilidade da rede neuronal a variáveis de entrada mostram que a técnica tem uma performance mais sólida na caracterização de chuvas intensas quando são incluídas mais variáveis. Por outro lado, os testes de sensibilidade da rede neuronal a divisão dos dados, utilizando diferentes anos do período de estudo para a amostragem de dados de teste mostram resultados bastante distintos.

A inconsistência destes resultados enfatiza a complexidade dos fenómenos meteorológicos como a precipitação, como é também refletida na diferença do número de eventos de precipitação entre os 3 anos consecutivos. Outra condicionante importante pode estar relacionada com o facto de o número de dados disponível neste trabalho poder não ser suficiente para se ter uma distribuição apropriada em cada uma das fases de processamento da rede neuronal. Deste modo é desejável ter um maior conjunto de dados, para aumentar as amostragens das fases de treino e validação, com vista a se obter resultados mais consistentes na fase de testes e consequentemente uma caracterização melhorada dos fenómenos de precipitação intensa. É também de notar que o fenómeno de precipitação intensa tem características raras, o que dificulta ainda mais a sua previsão. A combinação de dados GNSS com dados meteorológicos auxiliares e a sua inclusão num sistema de redes neuronais apresenta resultados preliminares promissores, que necessitam de ser melhorados, por exemplo com a inclusão de mais dados e variáveis, de forma a permitir o seu uso como ferramenta auxiliar para a melhoria da previsão de chuvas intensas em *nowcasting*.

## Agradecimentos

Este trabalho foi financiado pela Fundação para a Ciência e Tecnologia (FCT), através do projeto do IDL UID/GEO/50019/2013.

## Referências Bibliográficas

- Altamimi, Z.; Collilieux, X.; Métivier, L. (2011). ITRF2008: an improved solution of the international terrestrial reference frame. *Journal of Geodesy*, 85(8), 457-473.
- Benevides, P.; Catalão, J.; Miranda, P.M.A.; Chinita, M.J. (2013). Analysis of the relation between GPS tropospheric delay and intense precipitation, *Proc. SPIE Remote Sensing*, 88900Y-88900Y.
- Benevides, P.; Catalao, J.; Miranda, P.M.A. (2015). On the inclusion of GPS precipitable water vapour in the nowcasting of rainfall", *Nat. Hazards Earth Syst. Sci. Discuss.* 3, 3861-3895.
- Benevides, P.; Nico, G.; Catalao, J.; Miranda, P.M.A. (2016). Bridging InSAR and GPS tomography data: a new differential geometrical constraint, *IEEE Transactions on Geoscience and Remote Sensing*, 54(2): 697-702.
- Benevides, P.; Nico, G.; Catalao, J.; Miranda, P.M.A. (2017). Analysis of Galileo and GPS Integration for GNSS Tomography, *IEEE Transactions on Geoscience and Remote Sensing*, 55(4): 1936-1943.
- Benevides, P.; Catalao, J.; Nico, G.; Miranda, P.M.A. (2018). 4D wet refractivity estimation in the atmosphere using GNSS tomography initialized by radiosonde and AIRS measurements: results from a 1-week intensive campaign, *GPS Solutions*, 22(4), 91.
- Herring, T.; King, R.W.; McClusky, S.C. (2010). *GAMIT Reference Manual – GPS Analysis at MIT – Release 10.4*, Dep. of Earth, Atm. and Planetary Sciences, MIT.
- Mateus, P.; Nico, G.; Catalão, J. (2014). Maps of PWV temporal changes by SAR interferometry: A study on the properties of atmosphere's temperature profiles, *IEEE Geoscience and Remote Sensing Letters*, 11(12), 2065-2069.
- Mateus, P.; Nico, G.; Catalao, J. (2015). Uncertainty Assessment of the Estimated Atmospheric Delay Obtained by a Numerical Weather Model (NMW), *IEEE Transactions on Geoscience and Remote Sensing*, 53(12), 6710-6717.
- Mateus, P.; Miranda, P.M.A.; Nico, G.; Catalão, J.; Pinto, P.; Tomé, R. (2018) Assimilating InSAR maps of water vapor to improve heavy rainfall forecasts: A case study with two successive storms", *Journal of Geophysical Research: Atmospheres*, 123(7), 3341-3355.
- Ramirez, M.C.V.; de Campos Velho, H.F.; Ferreira, N.J. (2005). Artificial neural network technique for rainfall forecasting applied to the Sao Paulo region, *Journal of hydrology*, 301(1-4), 146-162.
- Seco, A.; Ramírez, F.; Serna, E.; Prieto, E.; García, R.; Moreno, A.; Cantera, J.C.; Miqueleiz, L.; Priego, J.E. (2012). Rain pattern analysis and forecast model based on GPS estimated atmospheric water vapor content, *Atmospheric Environment*, 49, March 2012, Pages 85-93, ISSN 1352-2310.