

Interpolação e Previsão de Precipitação por Redes Neurais Convolucionais para Grafos

Augusto Fonseca
augusto.fonseca@aluno.cefet-rj.br
CEFET/RJ

Ronaldo Goldschmidt
IME/RJ
ronaldo.rgold@ime.eb.br

Eduardo Ogasawara
CEFET/RJ
eogasawara@ieee.org

Mariza Ferro
IC/UFF
mariza@ic.uff.br

Fábio Porto
LNCC
fporto@lncc.br

Eduardo Bezerra
CEFET/RJ
ebezerra@cefet-rj.br

ABSTRACT

Statistical interpolation methods used to adapt data do not adequately capture the spatiotemporal dependencies of meteorological data. This work proposes the use of Graph Convolutional Neural Networks (GCNs) for precipitation interpolation and forecasting. The experiments utilized radar data and in-situ station data. Comparing GCN interpolation with the statistical Inverse Distance Weighting (IDW) method, preliminary results indicate that GCNs exhibit better accuracy in extreme precipitation events, also showing promise in events of lesser magnitude.

KEYWORDS

redes neurais, interpolação de dados, previsão de precipitação

1 INTRODUÇÃO

As condições atmosféricas têm implicações significativas em diversos campos como agricultura, transporte e segurança pública. O monitoramento e previsão dessas condições podem ajudar a mitigar e prevenir os impactos adversos de eventos climáticos severos, incluindo a perda de vidas humanas. Atualmente, os Modelos de Previsão Numérica do Tempo (NWP) são amplamente utilizados para estimar condições climáticas futuras, simulando a física da atmosfera com base em dados observados por instrumentos meteorológicos e técnicas matemáticas. No entanto, modelos NWP são computacionalmente intensivos. Por outro lado, modelos de Aprendizado de Máquina (AM) têm ganhado destaque na captura de padrões espaço-temporais e previsão de curto e longo prazos, com custos computacionais mais baixos e tempos de previsão menores. Por conta disso, diversos trabalhos recentes têm buscado empregar AM na geração de modelos de previsão do tempo [4, 8].

As Redes Neurais Convolucionais (CNN) são amplamente empregadas no treinamento de modelos de previsão do tempo [2, 10]. No entanto, sua arquitetura limita-se a operar sobre dados em grade, tais como os gerados por instrumentos meteorológicos como radar e satélite. De outro lado, dados de estações telemétricas (ET), *e.g. temperatura, umidade e velocidade do vento*, são significativamente valiosos no monitoramento e previsão do tempo. ETs são normalmente instaladas em pontos mais estratégicos em relação a cada área de interesse, resultando em uma malha de dados com

distribuição espacial irregular, o que dificulta o emprego desses dados em CNNs. Devido a sua importância, dados coletados por ETs são interpolados para uma matriz regular, adequando-os ao treinamento em uma CNN [5, 7]. Os processos de interpolação tradicionalmente empregados baseiam-se em métodos estatísticos (*e.g. distância inversa, kriging*), porém falham em capturar as dependências espaço-temporais inerentes aos dados meteorológicos.

Já as Redes Neurais Convolucionais para Grafos (GCN) foram desenvolvidas para viabilizar o processo de convolução das CNNs em estruturas irregulares de dados. Zhou et al. [11] empregaram dados de direção e velocidade do vento do CERA-SAT [3] juntamente com dados de ETs para treinar uma GCN para a previsão de concentração de poluente no ar. Os dados são modelados em um grafo dirigido onde um vértice representa uma ET e uma aresta representa a distância entre duas estações, distância essa calculada com base nas condições do vento. No entanto, as predições limitam-se aos pontos com ETs.

Lewenfus et al. [6] buscaram contornar tal limitação em um modelo de previsão treinado em GCN com dados de temperatura oriundos de 430 ETs dos Estados Unidos. A técnica consistiu em empregar processamento de sinais em grafos para definir uma função de interpolação ϕ . O modelo é então treinado com um subconjunto $S < N$ dentre N ETs. Os valores \hat{y}_S preditos pelo modelo são interpolados pela função ϕ para obter um vetor \hat{y} de tamanho $|N|$. Da mesma forma, os rótulos y_S de S também são interpolados pela função ϕ para um vetor y de tamanho $|N|$ para viabilizar o processamento da função de custo e a convergência do modelo.

Um ponto em comum nos trabalhos encontrados na literatura reside no processo de interpolação ser uma etapa de pré-processamento dos dados. Dado esse contexto, este trabalho tem por objetivo empregar GCNs e CNNs na tarefa de interpolação e previsão de precipitação. A questão de pesquisa consiste em avaliar a acurácia de modelos de previsão do tempo que incorporam o aprendizado do processo de interpolação à arquitetura de AM.

A área de estudo deste trabalho é a cidade do Rio de Janeiro. Os experimentos envolveram o uso de dados do radar meteorológico do Instituto Estadual do Ambiente (INEA) e de ETs do Instituto Nacional de Meteorologia (INMET) e do Alerta Rio. Na avaliação, comparamos as acurácias obtidas com a interpolação estimada por GCN e com método estatístico de interpolação por Inverso da Distância Ponderada (IDW) [9]. Nossos resultados preliminares mostram que as GCNs obtêm melhor acurácia em eventos mais extremos de precipitação e alcançam resultados promissores em eventos de menor magnitude.

Além desta introdução, a Seção 2 aborda a metodologia utilizada neste trabalho e detalhada as fontes dos dados meteorológicos utilizados e os procedimentos de pré-processamento aplicados. A Seção 3 detalha a configuração do experimento e apresenta os resultados obtidos. Finalmente, a Seção 4 destaca as principais conclusões e apresenta as direções de trabalhos futuros.

2 METODOLOGIA

Na Figura 1 é apresentada uma visão geral da técnica de interpolação proposta neste trabalho. Os dados coletados pelos instrumentos meteorológicos são introduzidos na rede na forma de séries temporais de grafos. As camadas da GCN têm a tarefa de aprender a interpolar os dados. Os dados interpolados são então passados como entrada para uma CNN que aprende os padrões espaciais e temporais processando a tarefa de regressão. Como saída, a rede gera as previsões da variável meteorológica de interesse para passos de tempo futuros.




Figura 1: Visão geral da arquitetura. As séries temporais de grafos são passadas como entrada para a GCN que interpola os dados. Os dados interpolados são passados para a CNN que aprende os padrões espaciais e temporais dos dados e gera as previsões.

O problema aqui abordado consiste em uma tarefa de aprendizado semi-supervisionado, uma vez que não conhecemos o valor de precipitação para toda a área de interesse. Cada instrumento meteorológico coleta diferentes subconjuntos de variáveis. Além disso, decisões estratégicas ou falhas nos equipamentos podem interromper o monitoramento por horas, ou até mesmo dias. Dado esse cenário, poderíamos modelar o problema para aprendizado sobre grafos heterogêneos e dinâmicos, *i.e.*, grafos em que os vértices possuem diferentes atributos e que variam sua topologia ao longo do tempo. No entanto, para fins de simplificação, modelamos o problema como aprendizado sobre grafos homogêneos e estáticos. Para viabilizar tal modelagem, aplicamos técnicas sobre o processamento dos dados abordadas na Seção 2.2.

Formalmente, o problema é definido como segue. Considere que $\mathcal{G}^{(t)} = (\mathcal{V}, \mathcal{E}, \mathcal{X}^{(t)})$ represente um grafo homogêneo no passo de tempo $t \in \{1, 2, \dots, T\}$. \mathcal{V} representa as coordenadas (latitude, longitude) que é definido pela união de coordenadas de uma grade regular de aproximadamente 3 km de resolução e as coordenadas associadas às ETs. \mathcal{E} é definido por um limiar de distância entre as coordenadas empregando a distância *Haversine*. $\mathcal{X} \in \mathbb{R}^{|\mathcal{V}| \times d}$ representa a matriz de características (variáveis meteorológicas) associadas aos vértices. O modelo de interpolação é treinado para aproximar uma função $f(\cdot)$ que mapeia uma sequência de variáveis meteorológicas observadas para uma grade regular de valores

de precipitação: $\mathcal{Z}^{(t)} = f(\mathcal{G}^{(t)}, \mathcal{G}^{(t-1)}, \dots, \mathcal{G}^{(t-T-1)})$, em que T representa o tamanho da série temporal de entrada e \mathcal{Z} representa a matriz de valores de precipitação interpolados.

2.1 Dados Meteorológicos

O experimento empregou duas fontes de dados. A primeira é relativa ao radar meteorológico do INEA instalado na coordenada (lat: -22.99325, lon: -43.58794). A segunda corresponde a ETs do INMET e do Sistema Alerta Rio. A Figura 2 apresenta a localização dos instrumentos. O radar do INEA é do tipo *banda S, dupla polarização*, em operação desde 2015 e fornece, dentre outras variáveis, dados de refletividade¹ na atmosfera com resolução espacial de 500 metros. A cada 5 min o radar escaneia a atmosfera em 360° de azimute, em sete níveis de altitude, em um raio de abrangência de 250 km. Dentre as 33 ETs do Alerta Rio, dois são estações meteorológicas completas, cinco são estações meteorológicas parciais, *i.e.*, não observam todas as variáveis meteorológicas e 26 são pluviômetros, com resolução temporal de 15 minutos. As variáveis meteorológicas observadas são *pressão atmosférica (mB)*, *temperatura (°C)*, *ponto de orvalho (°C)*, *umidade relativa do ar (%)*, *direção do vento (°gr)*, *velocidade do vento (m/s)* e *precipitação (mm)*. As quatro estações do INMET são meteorológicas completas, com resolução temporal de uma hora. Usamos as seguintes categorias de precipitação definidas pela equipe do sistema Alerta Rio, conforme a quantidade de precipitação observada em mm/h, a seguir: *i) fraca*: [0, 5); *ii) moderada*: [5, 25); *iii) forte*: [25, 50) e; *iv) extrema*: [50, inf).

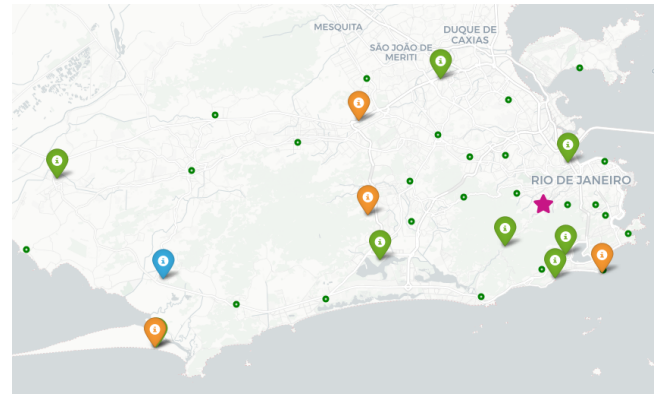


Figura 2: Localização dos instrumentos de observação. Pontos em verde representam os pluviômetros do Alerta Rio. Os ícones de informação nas cores verde, laranja e azul representam, respectivamente, as estações meteorológicas do Alerta Rio, as estações meteorológicas do INMET e o radar meteorológico do INEA. O ícone de estrela representa a estação *tijuca_muda*.

2.2 Pré-processamento dos Dados

Dados de precipitação têm por característica serem significativamente desbalanceados, *i.e.*, muitos dias sem chuva. Além disso, o

¹A refletividade é uma das variáveis registradas a partir do eco gerado pelas ondas eletromagnéticas irradiadas pelo radar. Essa variável detecta a presença de hidrometeoros na atmosfera, tais como água, gelo e neve.

volume de dados gerados pelo radar do INEA é de cerca de 1,3 GB por dia. Por conta disso, foram selecionados somente os dias em que ocorreu chuva acumulada em uma hora acima de 25 milímetros. Para cada dia selecionado, o dia anterior também foi incluído, totalizando 224 datas entre 2016 e 2023. Os dados de radar foram agregados espacialmente para cada vértice em \mathcal{G} com base nas observações em um raio de 1,5 km a partir do vértice, em resolução temporal horária, limitado às observações até 2 km de altitude devido ao efeito conhecido como *cone do silêncio*². No processo de agregação foram geradas as *features média, mínimo, máximo, 1º quartil, mediana e 3º quartil* em relação à refletividade observada dentro do raio.

Os dados das estações do Alerta Rio e INMET passaram por um processo de curadoria em que foram tratadas as seguintes questões:

- i) duplicatas temporais, *i.e.*, dois ou mais registros para a mesma tupla (coordenada, horário) com valores distintos observados;
- ii) período de operação da estação e quantidade de registros esperada por intervalo de tempo;
- iii) dados faltantes;
- iv) dados espúrios, *i.e.*, valores fora do intervalo esperado para a variável e ;
- v) outras questões de qualidade encontradas durante a análise.

Os dados foram filtrados conforme as datas disponíveis para os dados de radar. Um ponto a ser ressaltado são os falsos nulos para a variável *direção do vento*, quando uma estação meteorológica registra velocidade 0.0 para a variável *velocidade do vento*. No processo de imputação, os falsos nulos receberam valor arbitrário 0.0. As variáveis associadas à direção e velocidade do vento foram transformadas para componentes cíclicas³. A data/hora também foi empregada como *feature* pelo método de transformação usando o seno e cosseno⁴. Os dados anteriores a 01/fev/22 foram selecionados para compor o conjunto de treino e igual ou superior como conjunto de teste. Os parâmetros de normalização e imputação foram ajustados somente sobre o conjunto de treino para evitar *vazamento de dados*. Foram empregados, respectivamente, a função *Min-max* e o algoritmo *k-NN Imputer* disponíveis na biblioteca *scikit-learn*⁵.

Os dados de radar e de ETs foram integrados por junção *outer join*. Variáveis não observadas em uma determinada coordenada receberam valor 0.0. Para distinguir os valores 0.0 verdadeiros, foi adicionada uma variável binária marcadora de preenchimento para cada variável meteorológica. Por fim, os dados foram processados em séries temporais de grafos, em que os vértices representam as coordenadas e as arestas uma relação entre coordenadas definida por um limiar de distância de 3,4 km. Cuidados especiais foram tomados para evitar gerar séries temporais não contíguas, uma vez que não tínhamos a série histórica completa. Ao final foram gerados 3.644 exemplos de treino (78%) e 1.012 exemplos de teste (22%).

3 EXPERIMENTOS E RESULTADOS

Nesta seção, descrevemos os experimentos realizados. Na Seção 3.1 descrevemos aspectos de configuração, e na Seção 3.2 apresentamos os resultados, junto com uma análise sobre os mesmos.

²Cone do silêncio. Uma porção da área acima e em torno do radar não é observada. O tamanho da porção varia conforme o ângulo de elevação do radar.

³<https://bit.ly/metpy-wind-vector-components>

⁴<https://bit.ly/kaggle-encoding-cyclical-features>

⁵<https://scikit-learn.org/stable/index.html>

3.1 Configuração do Experimento

Neste primeiro experimento buscamos investigar duas questões: *i)* o impacto sobre a acurácia quando empregada a *feature refletividade e*; *ii)* a influência dos dados de estações vizinhas em uma determinada coordenada de interesse. Para tal, escolhemos a estação *tijuca_muda* como estação de interesse (EI) por apresentar a maior quantidade de exemplos em duas das quatro categorias de precipitação, sendo elas *moderada* e *forte*. Em seguida foram identificadas as 11 estações vizinhas (EV) mais próximas da EI (Apêndice A). A análise gradativa consistiu em processar 11 conjuntos distintos de *datasets* (conjuntos de treino e teste), conforme detalhado na Seção 2.2. Em cada conjunto, identificados e ordenados como $\{v_1, v_2, \dots, v_{11}\}$, um novo vizinho é adicionado ao *dataset*, do mais próximo para o mais distante, cumulativamente aos já adicionados no conjunto anterior, de forma que o conjunto v_1 possui apenas uma EV e o conjunto v_{11} possui as 11 EVs. Importante ressaltar que os dados da EI não são empregados em nenhuma fase do pré-processamento, treinamento e inferência, simulando portanto uma coordenada sem informação à qual desejamos inferir por interpolação.

A GCN empregada para treinar o modelo foi a desenvolvida por Bai et al. [1] e se encontra implementada no *framework PyTorch Geometric Temporal*⁶. Comparando a arquitetura implementada no *framework* com a apresentada no artigo, identificamos um provável erro de implementação nas camadas que operam a convolução temporal. De fato, a nossa versão corrigida obteve melhores resultados nos testes preliminares. A GCN foi definida com uma camada de convolução espaço-temporal conforme Bai et al. [1] e duas camadas *fully connected* para operar, respectivamente, as *embeddings* e a correlação entre os vértices. Como função de custo foi empregada a *Mean Squared Error*. A taxa de aprendizado foi configurada para 1×10^{-3} e a rede foi treinada com *batches* de tamanho 32. Foram treinados dois modelos para cada *dataset*: o modelo *gcn_r* treinado com todas as *features* e o modelo *gcn* em que a *feature refletividade* é removida.

3.2 Resultados e Análise

A Tabela 1 apresenta valores de RMSE por modelo e categoria para cada *dataset*. Para eventos de precipitação *forte* e *extrema*, os modelos *gcn* e *gcn_r* apresentam melhores resultados em todos os *datasets*, com erros significativamente menores em diversos casos, chegando a um erro aproximadamente 82% menor para chuva *extrema* no conjunto v_6 em relação ao IDW. Outros destaques ocorrem na categoria *extrema* para os conjuntos v_5 e v_{10} e na categoria *forte* para os conjuntos v_3 e v_4 que apresentam erros relativos entre 40% e 50% abaixo do método IDW. Na categoria *moderada* o método IDW obtém melhores resultados em todas os conjuntos, exceto o conjunto v_1 e na categoria *fraca* ocorrem seis resultados a favor do IDW contra cinco das GCN. Apesar disso, a diferença de erro entre os métodos nas categorias *fraca* e *moderada* é relativamente pequena em quase todos os *datasets*.

Quanto ao emprego da *feature refletividade*, a Tabela 1 apresenta que o modelo treinado com a inclusão dessa *feature* retorna oito melhores resultados para a categoria *forte* e seis para a categoria *extrema*. A maioria dos resultados em todas as categorias apresentam resultados próximos quando comparados os modelos *gcn* e

⁶<https://pytorch-geometric-temporal.readthedocs.io/en/latest/index.html>

Tabela 1: Resultados da análise gradativa para a estação tijuca_muda (RMSE).

Categoria	Modelo	v_1	v_2	v_3	v_4	v_5	v_6	v_7	v_8	v_9	v_{10}	v_{11}
fraca	gcn	0.773	1.053	0.688	0.655	0.666	0.615	0.538	0.568	0.641	0.677	0.610
	gcn_r	0.807	0.930	0.778	0.684	0.644	0.675	0.570	0.623	0.649	0.651	0.630
	idw	0.799	0.544	0.521	0.522	0.614	0.608	0.621	0.599	0.626	0.663	0.658
moderada	gcn	4.839	5.512	4.521	4.688	3.807	3.834	3.720	3.941	3.930	4.771	3.733
	gcn_r	4.890	5.681	4.593	4.285	3.875	3.881	4.065	3.836	4.133	4.059	3.887
	idw	4.989	3.296	3.164	3.061	2.975	3.077	3.169	3.115	3.109	3.144	3.150
forte	gcn	9.843	6.078	6.285	6.862	9.639	10.450	9.756	11.997	11.599	8.304	12.903
	gcn_r	9.417	6.606	5.663	6.947	7.196	9.426	8.976	10.617	9.908	11.624	11.134
	idw	11.307	10.598	11.385	12.006	11.732	10.351	10.725	11.274	11.533	11.748	12.154
extrema	gcn	18.941	17.570	11.752	13.891	11.255	3.692	11.345	18.451	15.373	5.334	14.368
	gcn_r	18.341	25.899	12.979	15.192	6.657	2.624	13.661	14.528	9.837	10.586	12.701
	idw	18.400	18.241	16.403	17.477	16.069	14.881	15.166	17.400	18.250	19.052	18.293

gcn_r. No entanto, algumas exceções chamam a atenção. Por exemplo, na categoria *extrema* os resultados para os *datasets* v_2 e v_{10} apresentam erro significativamente maior para o modelo treinado com *refletividade*. Por outro lado, para os *datasets* v_5 e v_9 ocorre o inverso, em que o modelo treinado com *refletividade* apresenta erro significativamente menor.

A Figura 3 apresenta a variação na acurácia dos modelos a medida que adicionamos informações de EVs. Nas categorias *fraca* e *moderada*, o erro tende a diminuir com a adição de EVs, estabelecendo a partir da 5ª EV adicionada. Na categoria *forte*, ocorre um efeito não esperado, em que a partir da 3ª EV o erro tende a crescer. Na categoria *extrema*, o erro diminui significativamente até a adição da 6ª EV, momento em que o erro começa a aumentar novamente. Já para o método IDW, o erro tende a permanecer constante conforme a adição de EVs mais distantes, o que é esperado dada a formulação matemática do próprio método, que pondera inversamente as informações de EVs mais distantes.

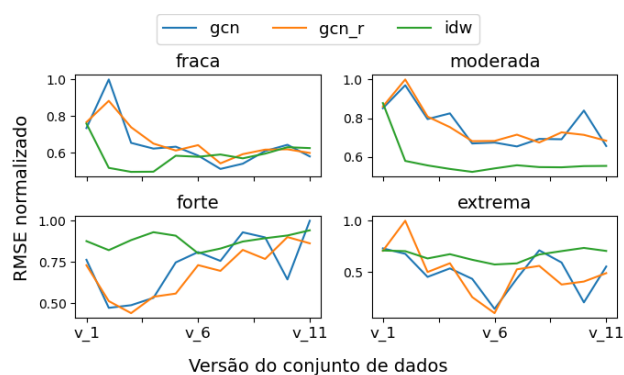


Figura 3: Impacto da acurácia para o ponto de interesse a medida que são adicionados dados de vizinhos mais distantes.

4 CONCLUSÃO

Neste trabalho, nosso objetivo foi empregar GCNs na tarefa de interpolação e previsão de precipitação. Para tal, treinamos GCNs

de forma semi-supervisionada empregando dados de radar meteorológico e ETs. Por ser um trabalho em progresso, inicialmente avaliamos a acurácia da interpolação estimada por uma GCN em comparação ao método estatístico IDW. Avaliamos os modelos com foco em duas questões: *i*) impacto sobre a acurácia quando empregados dados de radar e; *ii*) influência dos dados de estações vizinhas em uma determinada coordenada de interesse.

Foi observado que as GCNs obtêm melhor acurácia em eventos mais extremos de precipitação e alcançam resultados promissores em eventos de menor magnitude. Para eventos mais extremos, a GCN chega a alcançar resultados até 80% superiores em relação ao método IDW. Além disso, nos experimentos em que o método IDW obteve melhor resultado, a diferença para o resultado alcançado pela GCN foi relativamente pequena, mostrando o potencial da abordagem. O emprego dos dados de radar aumentou frequentemente a acurácia para eventos mais extremos. De forma geral, a adição de mais informações vizinhas à coordenada de interesse aumentou a acurácia da interpolação no caso das GCNs. Também observou-se que, aumentar em demasia a quantidade de vizinhos pode diminuir a acurácia. Conforme esperado, o método IDW tende a estabilizar conforme são adicionados vizinhos mais distantes.

Como trabalhos futuros, pretendemos entender o motivo da diminuição da acurácia das abordagens por GCN quando da adição de certas EVs. Para tal, faremos análises separadas para cada evento em que a GCN apresentou erro alto. Pretendemos também investigar o motivo para a inclusão de dados de radar diminuir significativamente a acurácia em casos específicos. Também realizaremos os mesmos experimentos com outras EI, explorando distribuições espaciais distintas de vizinhança. Além disso, avaliaremos o impacto com outras fontes de dados meteorológicos (e.g. satélite).

ACKNOWLEDGMENTS

Agradecemos à CAPES, ao CNPq, à Faperj (Proc. E-26/210.242/2024) e Instituto Serrapilheira (N Processo Serra – 2211-41897), pelo financiamento parcial desta pesquisa; ao LNCC e ao Instituto de IA, por ceder os recursos computacionais e apoio à missões de pesquisa; e ao COR, à GeoRio e ao INEA, pelo fornecimento dos dados usados nos experimentos.

REFERÊNCIAS

- [1] Jiandong Bai, Jiawei Zhu, Yujiao Song, Ling Zhao, Zhixiang Hou, Ronghua Du, and Haifeng Li. 2021. A3T-GCN: Attention Temporal Graph Convolutional Network for Traffic Forecasting. *ISPRS International Journal of Geo-Information* 10, 7 (2021). <https://doi.org/10.3390/ijgi10070485>
- [2] Rafaela Castro, Yania M Souto, Eduardo Ogasawara, Fabio Porto, and Eduardo Bezerra. 2021. STconvS2S: Spatiotemporal convolutional sequence to sequence network for weather forecasting. *Neurocomputing* 426 (2021), 285–298.
- [3] ECMWF. 2024. *Coupled Earth-system reanalysis*. European Centre for Medium-Range Weather Forecasts. Retrieved June 22, 2024 from <https://www.ecmwf.int/en/research/climate-reanalysis/coupled-earth-system-reanalysis>
- [4] Porto et al. 2022. Machine Learning Approaches to Extreme Weather Events Forecast in Urban Areas: Challenges and Initial Results. *Supercomputing Frontiers and Innovations* 9 (2022), 49–73. <https://doi.org/10.14529/jsfi220104>
- [5] Chris Funk, Pete Peterson, Martin Landsfeld, Diego Pedreros, James Verdin, Shradhdhanand Shukla, Gregory Husak, James Rowland, Laura Harrison, Andrew Hoell, et al. 2015. The climate hazards infrared precipitation with stations—a new environmental record for monitoring extremes. *Scientific data* 2, 1 (2015), 1–21.
- [6] Gabriela Lewenfus, Wallace Alves Martins, Symeon Chatzinotas, and Björn Ottersten. 2020. Joint Forecasting and Interpolation of Graph Signals Using Deep Learning. *arXiv preprint arXiv:2006.01536* (2020).
- [7] Brant Liebmann and Dave Allured. 2005. Daily precipitation grids for South America. *Bulletin of the American Meteorological Society* 86, 11 (2005), 1567–1570.
- [8] Xiaoli Ren, Xiaoyong Li, Kaijun Ren, Junqiang Song, Zichen Xu, Kefeng Deng, and Xiang Wang. 2021. Deep Learning-Based Weather Prediction: A Survey. *Big Data Research* 54 (2021), 100178. <https://doi.org/10.1016/j.bdr.2020.100178>
- [9] Donald Shepard. 1968. A two-dimensional interpolation function for irregularly-spaced data. In *Proceedings of the 1968 23rd ACM National Conference (ACM '68)*. Association for Computing Machinery, New York, NY, USA, 517–524. <https://doi.org/10.1145/800186.810616>
- [10] Selim Furkan Tekin, Oguzhan Karaahmetoglu, Fatih Ilhan, Ismail Balaban, and Suleyman Serdar Kozat. 2021. Spatio-temporal Weather Forecasting and Attention Mechanism on Convolutional LSTMs. *arXiv preprint arXiv:2102.00696* (2021).
- [11] Hongye Zhou, Feng Zhang, Zhenhong Du, and Renyi Liu. 2021. Forecasting PM2.5 using hybrid graph convolution-based model considering dynamic wind-field

to offer the benefit of spatial interpretability. *Environmental Pollution* 273 (2021), 116473.

A ESTAÇÕES VIZINHAS

A Tabela 2 apresenta as informações das estações vizinhas empregadas no experimento, conforme detalhado na Seção 3.1. A informação *Distância (Km)* é em relação à estação *tijuca_muda*.

Tabela 2: Informações das estações vizinhas empregadas no experimento

Id	Tipo	Distância (km)	Latitude	Longitude
1	Pluviômetro	2.220095	-22.931940	-43.221670
2	Pluviômetro	2.739652	-22.922220	-43.267500
2	Meteorológica	4.587330	-22.896670	-43.221670
4	Pluviômetro	4.808559	-22.931670	-43.196390
5	Meteorológica	4.872877	-22.972780	-43.223890
6	Meteorológica	5.133136	-22.965830	-43.278330
7	Pluviômetro	5.782264	-22.940560	-43.187500
8	Pluviômetro	5.890067	-22.890560	-43.278060
9	Pluviômetro	5.901368	-22.985830	-43.245000
10	Meteorológica	6.723293	-22.992500	-43.233060
11	Pluviômetro	6.996295	-22.896060	-43.187860