

MÉDIA OU MEDIANA: QUAL ESTIMADOR DESEMPENHA MELHOR NA TRANSFORMAÇÃO DE COORDENADAS POR REDES NEURAIS ARTIFICIAIS?

LUIZ FELIPE RODRIGUES DE ALMEIDA¹, MARCELO TOMIO MATSUOKA², VINICIUS FRANCISCO ROFATTO³



¹ Universidade Federal de Uberlândia – luiz.almeida1@ufu.br

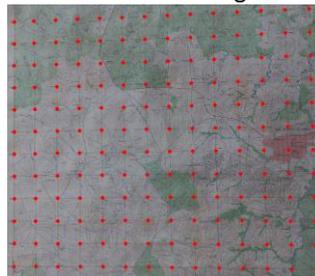
² Universidade Federal de Uberlândia – tomiomatsuoka@gmail.com

³ Universidade Federal de Uberlândia – vfrofatto@gmail.com



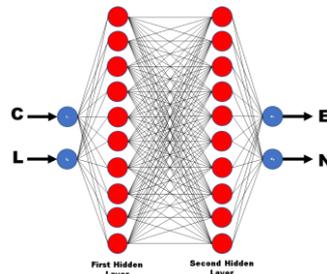
As transformações entre sistemas de coordenadas é uma atividade que ocorre com frequência em diversas engenharias e ramos da ciência moderna. Transformação isogonal, afim, projetiva são as mais comuns. Recentemente, redes neurais artificiais (RNA) vêm sendo estudadas e aplicadas em problemas envolvendo transformação de coordenadas, por exemplo no georreferenciamento de imagens, transformação entre referenciais geodésicos, transformação de nuvem de pontos 3D a partir de diferentes ocupações por scanner terrestres, para projetar e otimizar redes geodésicas, entre outros conforme, predito por Ziggah, Y [1]. Mais recentemente, Rofatto et al. 2022 [2] apresentaram algumas alternativas de como avaliar as estimativas de pontos transformados por RNA. Eles utilizaram alguns métodos de reamostragem com repetição. Como resultado, uma grande quantidade de estimativas diferentes para cada ponto transformado fica disponível. Logo, recaímos na questão clássica da teoria de estimação: obter solução única que minimiza os erros. Um estimador que cumpre esse papel é a média, que no caso é um estimador que minimiza a soma do quadrado dos erros. Entretanto, a média é afetada por outliers, o que faz com que este estimador não seja robusto. Uma outra alternativa, é utilizar a mediana, o que nos leva à uma questão: qual desses estimadores desempenha melhor na obtenção de uma solução única para cada ponto transformado por uma dada RNA? Para responder essa pergunta, utilizamos uma fotografia capturada de uma carta topográfica (Figura 1). O objetivo foi transformar as coordenadas dos pontos de intersecção entre as linhas horizontais e verticais coletadas no sistema da imagem [coluna, Linha] (C, L), para o sistema de coordenadas da projeção da carta – sistema de projeção UTM (E, N). Após algumas tentativas, a arquitetura da rede neural ficou definida como segue: 2 camadas ocultas, com 10 neurônios cada; função de normalização: Com o objetivo de se usar essa função a fim de colocar tudo em unidades com relação ao desvio padrão; função de ativação: tangente hiperbólica usada inicialmente com finalidade de manter os dados com variação entre -1 e 1 e a sigmoide como forma de modelar o comportamento com variações entre 0 e 1. Aqui, empregou-se o método intitulado como Jackknife para realizar o processo de validação e reamostragem, que consiste em remover uma observação dos conjuntos de dados disponíveis (n) para teste do modelo e usar as (n-1) amostras restantes no processo de treinamento da RNA, conforme apresentado por Rodrigues [3] e Rofatto et al. (2022) [2]. O processo termina quando todos os pontos passam pela amostra de teste. Repete-se, então, esse procedimento um certo número de vezes, de modo que cada ponto transformado tenha mais de uma solução advinda de mecanismos diferentes de treinamento da RNA. Ao final, temos a disposição mais de um modelo de RNA. Em geral, os resultados mostram que o RMSE (Raiz do Erro Médio Quadrático) foi menor para mediana do que para a média. Considerando, a escala zero do mapa a partir da acuidade visual de 0,2 mm (5 m na escala do mapa), observamos que 86% dos pontos apresentaram RMSE que ficaram acima desta tolerância de 5 m quando aplicado a média, enquanto para mediana apenas 29% ficaram acima desta tolerância. Para uma acuidade maior (0,5 mm; 12,5m na escala do mapa), a mediana foi ainda melhor, com 96% dos pontos dentro da tolerância. Na figura 4, podemos ver como se comporta a tendência do erro (exagerado 30x) pela mediana e o RMSE. Nota-se que o comportamento da tendência é aleatório, e não apresenta um comportamento sistemático. Outros problemas serão investigados: investigar a integração de métodos clássicos de transformação com RNAs; investigar dentro do contexto de transformação entre referenciais geodésicos; testar em problemas não-lineares mais complexos (por exemplo, uma foto capturada com camera orientada em diferentes ângulos, e em diferentes escalas.

Figura 1 – Coordenadas do referencial da imagem implementadas após coleta



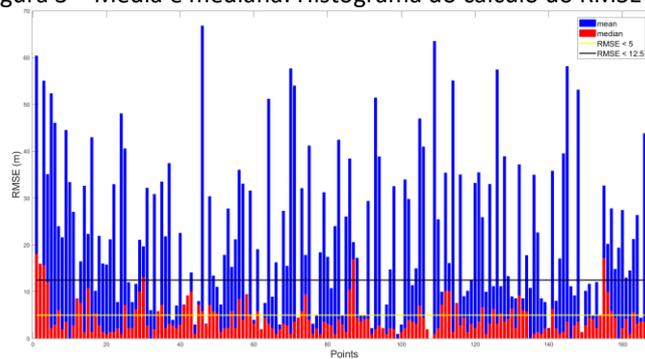
Fonte: O autor.

Figura 2 – Arquitetura Rede Neural Artificial com dados de entrada e saída



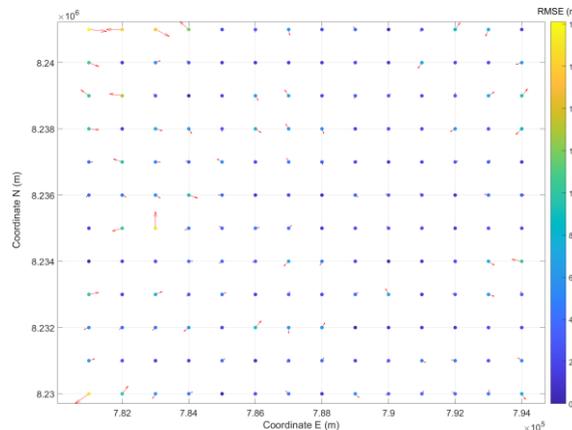
Fonte: O autor.

Figura 3 – Média e mediana: Histograma do cálculo do RMSE (m)



Fonte: O autor.

Figura 4 – Comportamento da tendência do erro pela mediana



Fonte: O autor.

Palavras-chaves: Redes Neurais; Coordenadas; Referencial; Treinamento; Média; Mediana.

Referências

[1] ZIGGAH, Y. Y., YOUJIAN, H., TIERRA, A. R., AND LAARI, P. B.. Coordinate transformation between global and local datums based on artificial neural network with k-fold cross-validation: A case study, ghana. Earth Sciences Research Journal, v. 3, n. 1, p. 67–77, 2019.

[2] ROFATTO, V. F. et al. An artificial neural network-based critical values for multiple hypothesis testing: data-snooping case. Survey Review, p. 1–16, 8 set. 2021.

[3] Bruno Póvoa Rodrigues, Vinicius Francisco Rofatto, Marcelo Tomio Matsuoka & Talita Teles Assunção (2022) Resampling in neural networks with application to spatial analysis, Geo-spatial Information Science,25:3, 413-424, DOI: [10.1080/10095020.2022.2040923](https://doi.org/10.1080/10095020.2022.2040923)