

Predição de Perda de Percurso em Veículos Aéreos Não Tripulados Utilizando Rede Neural Artificial

Matheus H. A. Miranda, João P. S. H. Lima, Pedro H. da R. Cândido, Álvaro A. M. de Medeiros

Resumo—Este trabalho tem como objetivo propor uma arquitetura de rede neural artificial para estimar a perda de percurso baseada em medidas de potência realizadas com um veículo aéreo não tripulado. Para avaliação, a rede proposta é comparada ao modelo *log-distance* a fim de verificar qual obtém o melhor desempenho. Os resultados apontam a rede neural como o modelo que apresentou o menor erro quadrático médio.

Palavras-Chave—Perda de Percurso, Rede Neural, VANT.

Abstract—This work aims to propose a new model of artificial neural network in order to estimate the path loss based on power measurements conducted by an unmanned aerial vehicle. As an evaluation intent, the neural network is compared to the Log-distance model for verifying which model performs better. Results indicate the proposed neural network has a minor mean squared error.

Keywords—Path Loss, Neural Network, UAV.

I. INTRODUÇÃO

A aplicabilidade dos Veículos Aéreos Não Tripulados (VANTs) em uma grande variedade de problemas tem atraído a atenção de pesquisadores. Diversas aplicações civis e militares fazem uso de tecnologias VANT a fim de prover serviços variados, desde assistência em áreas remotas, monitoramento de grandes áreas e fronteiras, medidas de poluição e qualidade do ar, medidas para telecomunicações, entre outros [1] [2]. Nesse sentido, na área das comunicações móveis, a perda de percurso é uma característica importante para uma modelagem competente do canal. Existem diversos métodos tradicionais na literatura para tal objetivo [2] [3]. Ademais, há um esforço significativo para estimar tal comportamento utilizando-se estratégias conhecidas da inteligência artificial [4] [5] [6].

Sendo assim, esse trabalho tem como objetivo a elaboração de um método baseado em rede neural para estimar a perda de percurso a partir de medidas realizadas com um VANT. Além disso, é realizada a comparação entre tal proposta e um modelo tradicional a fim de verificar qual método se adapta melhor para a configuração abordada. A Seção II apresenta a coleta de dados e a arquitetura da rede neural artificial. Já a Seção III exhibe o desempenho de ambos os métodos. Finalmente, a Seção IV aponta o desfecho desse trabalho.

II. MODELO PROPOSTO

A. Medidas e tratamento dos dados

A aeronave utilizada para as medições foi a *AM 204* (cadastro na ANAC PR-112042018), Figura 1, da equipe

Matheus H. A. Miranda, João Paulo S. H. Lima, Pedro H. da R. Cândido, Álvaro A. M. de Medeiros são do Laboratório de Telecomunicações Aplicadas da Faculdade de Engenharia da Universidade Federal de Juiz de Fora. E-mails: {matheus.abreu,joao.lima,pedro.candido, alvaro}@engenharia.ufjf.br.

Microraptor de Aerodesign da Universidade Federal de Juiz de Fora. A coleta dos dados foi feita por meio de um sistema de telemetria operante na frequência de 433 MHz e processado por meio de uma controladora de voo modelo *Pixhawk* [7]. As medições foram feitas em localidade rural, a fim de reduzir a possibilidade de interferências, e possuíam um envelope de voo fechado, isto é, eram cercados por morros e árvores ao longo da sua trajetória.



Fig. 1. Aeronave AM204.

Para o processo de aprendizagem da rede neural, foram utilizados dois dados coletados durante o voo: as coordenadas da posição do avião e RSSI (*Received Signal Strength Indicator*) referente à potência recebida pela controladora a partir do sinal emitido pelo VANT. A relação entre a potência recebida em dBm pela controladora P_r e o RSSI medido é dada por [8]

$$P_r = \frac{RSSI}{1,9} - 129. \quad (1)$$

B. Arquitetura da rede neural e treinamento

As redes neurais artificiais são modelos computacionais que se espelham na forma com a qual o cérebro realiza um trabalho. Dentre suas aplicações, uma delas é a estimação de saídas adequadas para entradas não conhecidas anteriormente. No entanto, para isso é necessário que a rede passe por um processo de aprendizagem [9].

Neste trabalho é proposto o modelo de rede neural *feedforward* de multicamadas, contendo uma entrada, uma camada oculta com n neurônios e uma camada de saída. A única entrada da rede é a distância entre o receptor e o avião. A única saída da rede é valor de potência recebida. A quantidade de neurônios para a camada oculta foi escolhida por meio de testes com as amostras coletadas. Para esse estudo, foi obtido melhor desempenho com 3 neurônios na camada oculta. Dessa forma, a rede proposta tem a estrutura 1 – 3 – 1.

Considerando essa estrutura, utilizou-se o algoritmo de retro-propagação para o treinamento da rede. A função de

ativação escolhida para os neurônios foi a função sigmoide, sendo essa a mais comumente empregada [9]. A fim de evitar *overfitting* e proporcionar maior confiança estatística, usou-se o método *k*-Fold para divisão dos dados e sua separação entre dados de treino e teste. Sendo assim, os dados são divididos aleatoriamente em *k* subconjuntos mutuamente exclusivos. Dessa maneira, um subconjunto é usado para teste enquanto os outros *k* – 1 subconjuntos são usados para treino [10]. Esse procedimento foi realizado *k* vezes e, ao final, calcula-se a média do Erro Quadrático Médio (MSE) obtido para cada uma das *k* iterações. Com essa métrica, é avaliada a capacidade de generalização da rede e seu desempenho para estimar a perda de percurso para a configuração apresentada.

III. RESULTADOS

Esta Seção traz os resultados obtidos com a modelagem de perda de percurso empregando-se a nova proposta com rede neural. O modelo tradicional utilizado para comparação é o *log-distance* [11], para o qual foram encontrados os parâmetros que melhor ajustavam a curva aos dados coletados pelo avião. Sendo assim, um dos parâmetros encontrados nesse ajuste foi o expoente de perda de percurso (η). Em tal caso, o valor obtido foi de $\eta = 1,79$, estando coerente com os valores encontrados em [12].

Na Figura 2 é apresentado o comportamento dos modelos sobre os dados coletados. Tem-se que a rede neural se mostra mais competente para a modelagem da perda de percurso a partir dos dados obtidos. Com base na Tabela I, na qual são exibidos os valores calculados para os erros MSE em cada estratégia, afirma-se que a rede neural descreve com menor erro a perda de percurso quando em comparação com o modelo *log-distance*.

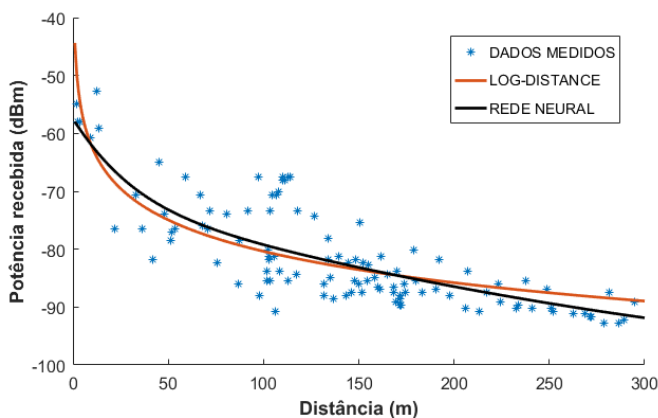


Fig. 2. Comparação da predição de perda de percurso entre a rede neural proposta e o modelo *log-distance*.

TABELA I
ANÁLISE DE DESEMPENHO ENTRE OS MÉTODOS.

Método	MSE
Rede Neural	25,893
Log-distance	29,811

IV. CONCLUSÕES

Este trabalho se dedicou a formular uma nova proposta para a predição da perda de percurso fazendo uso de uma rede neural artificial. Uma campanha de medições foi realizada com um VANT em região rural, coletando dados de RSSI e distância entre transmissor e receptor, a fim de fornecer dados para a modelagem.

Por meio dos resultados apresentados na Seção III, é possível verificar que, usando a distância e a potência recebida, a rede neural se mostrou capaz de descrever a perda de percurso com melhor desempenho quando em comparação com o modelo *log-distance*.

Como aprimoramento desse trabalho, indica-se a realização de novas campanhas de medições, a fim de enriquecer as comparações, proporcionando a análise também em outros cenários e condições de propagação, como a presença de obstáculos, vegetação, regiões alagadas, entre outras possibilidades.

REFERÊNCIAS

- [1] L. Gupta, R. Jain e G. Vaszkun, “Survey of important issues in UAV communication networks”, *IEEE Communications Surveys & Tutorials*, vol. 18, n° 2, pp. 1123–1152, 2015.
- [2] A. A. Khuwaja, Y. Chen, N. Zhao, M.-S. Alouini e P. Dobbins, “A survey of channel modeling for UAV communications”, *IEEE Communications Surveys & Tutorials*, vol. 20, n° 4, pp. 2804–2821, 2018.
- [3] C. Phillips, D. Sicker e D. Grunwald, “A survey of wireless path loss prediction and coverage mapping methods”, *IEEE Communications Surveys & Tutorials*, vol. 15, n° 1, pp. 255–270, 2013.
- [4] I. Popescu, I. Nafoarnita e P. Constantinou, “Comparison of neural network models for path loss prediction”, em *IEEE International Conference on Wireless And Mobile Computing, Networking And Communications*, vol. 1, 2005, pp. 44–49.
- [5] A. Bhuvaneshwari, R. Hemalatha e T. Satyasavithri, “Performance evaluation of dynamic neural networks for mobile radio path loss prediction”, em *IEEE Uttar Pradesh Section International Conference on Electrical, Computer and Electronics Engineering*, 2016, pp. 461–466.
- [6] Y. Liu, Y. Zhou e X. Li, “Attitude Estimation of Unmanned Aerial Vehicle Based on LSTM Neural Network”, em *IEEE International Joint Conference on Neural Networks*, 2018, pp. 1–6.
- [7] Dronecode, *Pixhawk 1 Flight Controller*, original document from 3D Robotics, 2019. endereço: https://docs.px4.io/en/flight_controller/pixhawk.html.
- [8] Ardupilot. (2019). SiK Radio — Advanced Configuration, endereço: <http://ardupilot.org/rover/docs/common-3dr-radio-advanced-configuration-and-technical-information.html>.
- [9] S. Haykin, *Redes neurais: principios e prática*. Bookman Editora, 2007.
- [10] S. Lawrence, C. Lee Giles e A. Chung Tsoi, “Lessons in Neural Network Training: Overfitting May be Harder than Expected.”, jan. de 1997, pp. 540–545.
- [11] T. S. Rappaport et al., *Wireless communications: principles and practice*. prentice hall PTR New Jersey, 1996, vol. 2.
- [12] R. Amorim, P. Mogensen, T. Sorensen, I. Z. Kovacs e J. Wigard, “Pathloss Measurements and Modeling for UAVs Connected to Cellular Networks”, em *2017 IEEE 85th Vehicular Technology Conference (VTC Spring)*, jun. de 2017, pp. 1–6.