



# Aprendizado de máquina para controle autônomo de trajetória de veículos aéreos não tripulados

Patrick de Carvalho T. R. Ferreira  
Faculdade de Engenharia Elétrica e de Computação  
UNICAMP  
p175480@dac.unicamp.br

Prof<sup>a</sup>. Dr<sup>a</sup>. Esther Luna Colombini  
Instituto de Computação  
UNICAMP  
esther@ic.unicamp.br

**Resumo**—Técnicas de controle tradicionais para quadricópteros encontram, inevitavelmente, problemas ao se confrontar com a natureza não-linear do problema e dificuldades para compensação de imperfeições dos sensores. A necessidade de adaptação a esse tipo de dinâmica torna este problema particularmente adequado para a aplicação de redes neurais. Entretanto, sem uma estimativa de qualidade e de alta-frequência da localização do robô no espaço, estes algoritmos tendem a falhar. Neste sentido, este projeto propõe um modelo de localização baseado em odometria inercial. A rede neural desenvolvida neste projeto foi treinada de forma a atender a demanda por algoritmos eficientes para navegação autônoma em ambientes externos - situação menos frequente na literatura - e sem a necessidade constante de *features* da imagem. Dada a abordagem puramente inercial, o algoritmo apresenta baixo tempo de resposta (5ms - 200Hz) e é capaz de operar técnicas de localização para aprimorar o controle do veículo aéreo autônomo individualmente, ou em conjunto com algum dos vários algoritmos de navegação visual já publicados. Nos testes, a regressão operada pela rede apresentou desvio RMSE de 0,39m e apresentou uma trajetória próxima da referência percorrida pelo objeto, tendo o sistema demonstrado robustez em suas execuções.

**Palavras-Chave**—drones, UAV, deep learning, dataset

Agradecimentos ao CNPq e PIBIC por proporcionar suporte a esta pesquisa.

## I. INTRODUÇÃO

A crescente popularidade dos veículos aéreos não tripulados (UAVs) é um indicador do impacto que esta tecnologia terá nos próximos anos na sociedade, movimentando USD2,07 bilhões globalmente até 2022, de acordo com [1]. Entretanto, para executar tarefas de alto nível, os UAVs devem ter a capacidade de navegar com segurança pelo seu ambiente de operação, um problema parcialmente resolvido para ambientes externos devido à integração de sensores de Sistemas de Posicionamento Global (GPS). No entanto, nos casos em que é necessário um sistema de posicionamento mais preciso ou em ambientes onde GPS não operam com qualidade, é necessário dotar o UAV de outros sensores proprioceptivos e exteroceptivos a fim de que uma navegação bem-sucedida no ambiente possa ocorrer. Em trajetos *indoor* ou em serviços de entrega, por exemplo, alguns metros de erro já descaracterizam completamente o objetivo e impedem, portanto, a utilização exclusiva de GPS.

Tentativas de implementar técnicas de controle tradicionais para quadricópteros encontram, inevitavelmente, problemas ao se confrontar com a natureza não-linear do problema [2] e dificuldades para compensação de comportamentos anômalos dos sensores. A necessidade de adaptação, junta-

mente com a exigência de se lidar com esse tipo de dinâmica, torna este problema particularmente adequado para a aplicação de redes neurais e/ou lógica *fuzzy*. Entretanto, esses modelos dependem de um bom estimador de posição para que a navegação final do robô seja de qualidade. Este processo, que pode ser realizado por meio do cálculo da odometria, é a base para uma navegação de sucesso. Nos últimos anos, métodos baseados em redes neurais tem sido empregados no cálculo da odometria mas a maior parte desses estima a posição em frequências muito mais baixas do que as desejadas por um controlador.

Para a aplicação dos algoritmos de aprendizado supervisionado de redes neurais, é necessário que haja um grande conjunto de dados provenientes de amostras do sistema, juntamente com as saídas desejadas para cada instante, um *dataset*. Em pesquisa anterior dos autores, foi desenvolvido um *dataset* para navegação visual-inercial de robôs autônomos, contendo amostras coletadas por sensores embarcados em um drone AR Parrot com giroscópio, acelerômetro, magnetômetro, câmeras global shutter e rolling shutter, sinais de atuação dos motores e afins. O *dataset* foi coletado sob diferentes trajetórias de voo e com o controle de posição de referência calculado por um sistema de posicionamento por imagem externo Vicon, cuja taxa de amostragem opera em cerca de 250Hz. Através destes dados, uma rede neural foi desenvolvida a fim de se obter um algoritmo de localização espacial que pode ser aplicado para operar em conjunto com diversas outras técnicas, inclusive de controle do UAV.

Neste projeto de pesquisa desenvolvemos um modelo de rede neural para estimar a odometria inercial. O modelo recebe como entrada,  $X(t)$ , leituras de uma unidade de medição inercial (IMU) contendo acelerômetro e giroscópio, emitindo como saída uma predição da variação da pose,  $\hat{y}(t)$ , em que o UAV estará no instante de tempo  $t + 1$  contendo os 3 eixos translacionais (x, y, z) e a rotação em quatérnio (w, x, y, z). O algoritmo informa a pose com baixo tempo de resposta (taxa de atualização de 200Hz), a fim de possibilitar sua utilização para navegação e/ou controle, corrigindo erros típicos como *offset* translacional de métodos como PID, por exemplo, que inviabilizam a condução autônoma deste tipo de veículo.

## II. MÉTODOS

A arquitetura desenvolvida utiliza como dados de entrada as leituras de sensores puramente inerciais de uma IMU, a qual fica acoplada ao UAV. Por não fazer uso de qualquer tipo de análise visual, a carga de processamento é menor, permitindo taxas de atualização do estado atual do UAV de até 200Hz e funcionamento em **circuitos embarcados** para navegação autônoma. A desvantagem da utilização de um método de odometria inercial em relação aos métodos de odometria visual é o inerente acúmulo de erros ao longo do trajeto. Porém, é possível demonstrar que este erro acumulado ao longo do tempo pode ser mantido definitivamente pequeno sob uma trajetória **finita**, desde que se encontre uma função de mapeamento adequada.

Seja  $f(t)$  uma função que descreve a leitura, por parte dos sensores, de qualquer grandeza derivativa temporal em ordem  $n$  da posição do veículo, seja de referencial angular ou translacional, tal que

$$f(t) = d^n P(t)/dt^n + e(t), \quad (1)$$

onde  $P(t)$  é a grandeza posicional a ser recuperada pela rede e  $e(t)$ , o erro associado à medição. Então existe uma função

$$F(t) = P(t) + E(t) \quad (2)$$

que nos retorna a variável de posição a ser mensurada, juntamente com um erro que é limitado para qualquer tempo  $t$  finito, como demonstrado a seguir.

Sejam estas funções tais que:

$$f(t) : \mathfrak{R} \mapsto \mathfrak{R}, \forall t \in Re \quad (3)$$

$$P(t) : \mathfrak{R} \mapsto \mathfrak{R}, \forall t \in Re \quad (4)$$

$$e(t) : \mathfrak{R} \mapsto \mathfrak{R}, \forall t \in Re \quad (5)$$

$$\int f(t)dt = \int (dP(t)/dt + e(t))dt \quad (6)$$

$$= \int dP(t)/dtdt + \int e(t)dt \quad (7)$$

Pelo Teorema Fundamental do Cálculo:

$$\int f(t)dt = P(t) + E'(t) + C = P(t) + E(t) \quad (8)$$

$$\int f(t)dt = F(t) \quad (9)$$

Logo, pela equação 8, evidencia-se que existe uma relação capaz de mapear qualquer componente da posição do veículo a partir de suas derivadas lidas pelos sensores sob um erro finito, para um tempo  $t$  também finito. Portanto, se existe função que mapeia o sistema de odometria inercial almejado, o Teorema da Aproximação Universal [3] garante que uma rede neural pode reproduzir tal função com erro indefinidamente pequeno, se forem proporcionados neurônios e treinamento suficientes à mesma. Para grandezas derivativas de segunda ordem (em relação à posição), como a aceleração, por exemplo, chega-se à mesma conclusão ao aplicar o segundo termo da equação 6 duas vezes ( $n$  vezes, qual seja a ordem da derivada em relação à posição).

Em um cenário de aplicação real, o algoritmo poderá ser executado em paralelo a **outro** algoritmo baseado em GPS ou navegação visual, tendo assim que manter o controle do veículo apenas até que o método de maior precisão atualize a pose do UAV. Desta forma, zeramos periodicamente o erro acumulado na navegação inercial e mantemos a alta taxa de atualização sob um erro baixo.

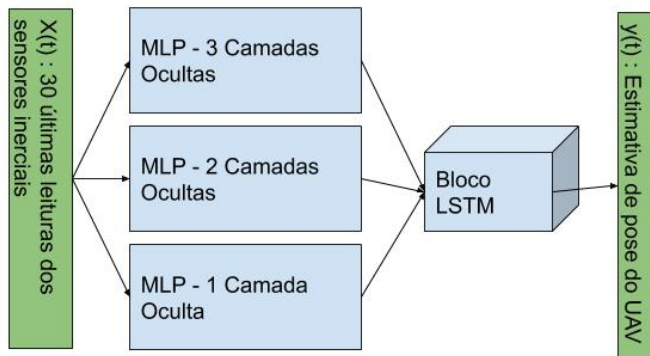


Figura 1. Unidade recorrente básica da arquitetura desenvolvida.

O modelo final de arquitetura obtido com esta pesquisa conta com uma unidade base chamada de unidade neural recorrente básica. São usadas duas destas unidades na rede operando com defasagem de 30 leituras entre si, a fim de promover consistência [4] para as saídas atuais em relação às previsões anteriores. Isto permite ao modelo corrigir as estimativas de pose atuais ao reparar o erro de previsões anteriores, de forma a descontar ou mitigar o erro acumulado da odometria.

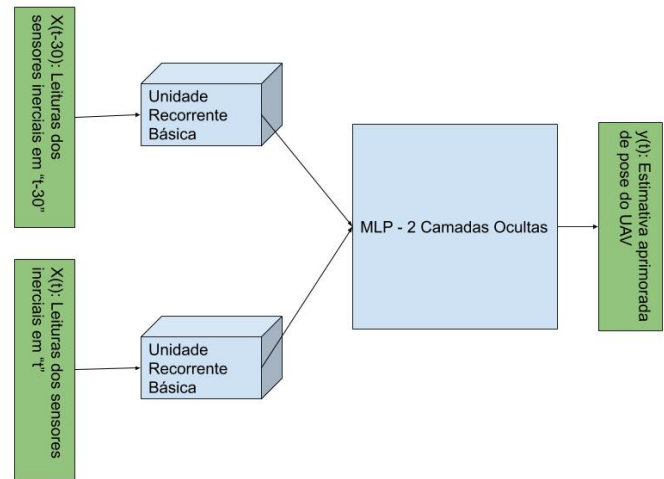


Figura 2. Arquitetura completa da rede neural odométrica.

Adicionar camadas em série com um número de neurônios maior que o necessário, além de demandar mais *samples* do dataset para que o modelo fique bem ajustado, pode dificultar a rede neural a encontrar um mapeamento adequado, conforme retrato na conhecida publicação da ResNet [5]. A fim de manter o modelo leve e sem redundâncias, foram utilizados *multilayer perceptrons* (MLP) com diferentes números de camadas, todas prealimentando um bloco *long-short term memory* (LSTM) que recebe as entradas da série temporal em  $X(t)$  (um pacote com as 30 últimas leituras da IMU), para a unidade básica. Com o modelo da unidade básica recorrente treinado e capaz de, sozinho, realizar previsões acerca do deslocamento do UAV, é necessário apenas treinar a MLP final do modelo (figura 2), que será responsável por analisar a estimativa de deslocamento atual em relação às estimativas passadas e corrigir eventuais distorções que possam ter ocorrido nas mesmas.

### III. RESULTADOS

O modelo é treinado até a convergência (momento de crescimento do erro da validação cruzada) e é realizada a previsão da posição do UAV para os 3 eixos espaciais translacionais ( $x$ ,  $y$ ,  $x$ ) e sua rotação em quatérnio ( $q_w$ ,  $q_x$ ,  $q_y$ ,  $q_z$ ), sempre em função das leituras dos sensores inerciais. Foram utilizadas no treino as sequências do dataset produzido na pesquisa anterior, e a sequência “room-1” do dataset inercial [6] da *Technische Universität Mün-*

chen (TUM). Neste teste, foi utilizada a sequência “room-2” do dataset da TUM.




Figura 3. Trajetória 2D percorrida sobre os eixos X e Y.

A figura 3 apresenta a trajetória percorrida sobre os eixos X e Y, que consiste em diversas voltas dentro do circuito de gravação do *dataset*. Ao observar aproximadamente o ponto  $(X=0,75; Y=0,5)$ , é possível encontrar o fim da trajetória real percorrida pelo veículo (em azul) e a estimativa do fim da trajetória pela saída da rede (em laranja). Nota-se mais uma vez que, embora tenham ocorrido oscilações durante a trajetória, o erro acumulado foi pequeno, tendo a rede sido capaz de identificar suas próprias saídas errôneas e reajustar a trajetória, mostrando a robustez proporcionada por este método de realimentação em encadeamento duplo para um sistema que é puramente inercial.

A análise do gráfico evidencia que a estratégia de realimentar a entrada da rede com suas últimas saídas foi bem sucedida, por promover precisão da regressão e, principalmente, exatidão, que é relativa às medidas de tendência central especialmente prejudicadas em abordagens odométricas baseadas em sensores inerciais. É perceptível que o erro **acumulado** (quando a trajetória é encerrada) nos eixos x e y após mais de 1 minuto de trajetória é da ordem de 0,5m, um bom valor para uma regressão puramente inercial. As tabelas I e II apresentam os erros computados.

A métrica de erro utilizada é o *Absolute Trajectory Error* [6] (ATE, equação 10), que é o RMSE da diferença dos pontos da trajetória de referência

$(p_i)$  para a trajetória calculada  $(\hat{p}_i)$ , alinhada com uma pose T SE[6] ótima.

$$ATE = \min_{T \in SE} \sqrt{\frac{1}{|I_{gt}|} \sum_{i \in I_{gt}} \|T\hat{p}_i - p_i\|^2} \quad (10)$$

Todas as poses rastreadas onde a referência (*ground truth*) está disponível são usadas, o que corresponde aos índices  $I_{gt}$ . Para a maioria das sequências, corresponde ao início e o final, mas para algumas sequências há dissimetria da referência.

Tabela I  
ANÁLISE ESTATÍSTICA DE DESEMPENHO DO MODELO

Desvio	Medida [m]
Máximo	1,122574
Médio	0,341654
Mediana	0,321175
Mínimo	0,007435
RMSE ATE	0,385799

O RMSE ATE foi de 0,385799m, enquanto que o desvio máximo foi de 1,122574m, valores consideravelmente pequenos para uma regressão odométrica com este tempo de trajeto (cerca de 140m de trajetória com duração de mais de 1 minuto[6]).

Tabela II  
COMPARAÇÃO COM OUTROS MÉTODOS DE ODOMETRIA

Algoritmo	RMSE ATE [m]
OKVIS	0,11
ROVIO	0,33
VINS	0,07
Modelo Proposto	0,39

Para uma análise quantitativa do desempenho da rede, a tabela I mostra alguns desvios estatísticos obtidos pela análise do ATE, comparando a trajetória de referência com aquela fornecida pela rede.

A tabela II traz uma comparação do RMSE ATE do modelo proposto nesta pesquisa com alguns dos métodos de odometria visual-inercial mais difundidos para robôs aéreos, sendo eles: OKVIS[7], VINS[8] e ROVIO[9]. Não será realizada neste momento uma abordagem frequentista (ou de inferência clássica) acerca da equivalência entre as médias, mas nota-se que elas possuem mesma **ordem de grandeza**. É admissível que este modelo abra mão

de certa precisão na estimativa odométrica, já que o objetivo é atingir alta frequência de operação para que possa ser utilizado de maneira embarcada para navegação e/ou controle de UAVs.

Os métodos comparados supracitados têm frequência de operação entre 3Hz e 100Hz, mesmo quando operados em uma unidade Intel NUC[10], um dispositivo de 500g e 65W de potência de alimentação, inviável para grande parte dos UAVs do mercado. Já o modelo proposto consegue manter taxas de operação acima de 200Hz durante todos os experimentos executando em uma Nvidia Jetson Nano (um dispositivo de 140g com consumo entre 5W e 10W, mais adequado para um UAV), se mostrando uma contribuição relevante para este tipo de aplicação. Operando em paralelo a um método de localização - mesmo que lento - por odometria visual ou GPS, seria possível zeramos periodicamente o erro acumulado na navegação inercial e mantermos a alta taxa de atualização do sistema como um todo sob um erro baixo.

#### IV. CONCLUSÃO

Neste trabalho, propusemos um modelo de rede neural baseado em redes recorrentes para a estimativa, em alta frequência, de odometria inercial. Como principal contribuição deste trabalho destacamos o baixo tempo de resposta do sistema proposto sem perda significativa de acurácia. Desta forma, um agente que utilize o sistema como base para correção de seu controle poderá ser capaz de responder as perturbações externas (inerente a cenários reais) com mais agilidade, possibilitando uma navegação contínua quando operado em conjunto com sistemas de posicionamento absoluto, como GPS ou navegação visual. Os testes realizados com dados provenientes de datasets que contemplam informações extraídas de cenários reais demonstraram o bom desempenho do modelo proposto, com resultados animadores.

#### REFERÊNCIAS

- [1] Grand View Research. *Commercial Drone Market Analysis By Product, By Application And Segment Forecasts To 2022 Aerial Photography, Mapping, Surveying etc.* 2016. URL: <http://www.grandviewresearch.com/industry-analysis/globalcommercial-drones-market> (acesso em 03/04/2018).
- [2] Gordon Wyeth, G D. Buskey e Jonathan Roberts. “Flight control using an artificial neural network”. Em: (abr. de 2019).
- [3] Anastasis Kratsios. “Characterizing the Universal Approximation Property”. Em: *arXiv:1910.03344 [cs, math, stat]* (ago. de 2020). arXiv: 1910.03344. URL: <http://arxiv.org/abs/1910.03344>.
- [4] Vikas Verma et al. “Interpolation Consistency Training for Semi-Supervised Learning”. Em: *arXiv:1903.03825 [cs, stat]* (mai. de 2019). arXiv: 1903.03825. URL: <http://arxiv.org/abs/1903.03825> (acesso em 02/10/2020).
- [5] Kaiming He et al. “Deep Residual Learning for Image Recognition”. Em: *arXiv:1512.03385 [cs]* (dez. de 2015). arXiv: 1512.03385. URL: <http://arxiv.org/abs/1512.03385>.
- [6] D. Schubert et al. “The TUM VI Benchmark for Evaluating Visual-Inertial Odometry”. Em: *International Conference on Intelligent Robots and Systems (IROS)*. 2018.
- [7] Stefan Leutenegger et al. “Keyframe-based visual-inertial odometry using nonlinear optimization”. en. Em: *The International Journal of Robotics Research* 34.3 (mar. de 2015), pp. 314–334. ISSN: 0278-3649.
- [8] Tong Qin, Peiliang Li e Shaojie Shen. “VINS-Mono: A Robust and Versatile Monocular Visual-Inertial State Estimator”. Em: *IEEE Transactions on Robotics* 34.4 (ago. de 2018). arXiv: 1708.03852, pp. 1004–1020. ISSN: 1552-3098, 1941-0468.
- [9] Michael Bloesch et al. “Iterated extended Kalman filter based visual-inertial odometry using direct photometric feedback”. en. Em: *The International Journal of Robotics Research* 36.10 (set. de 2017), pp. 1053–1072. ISSN: 0278-3649. (Acesso em 01/10/2020).
- [10] Jeffrey Delmerico e Davide Scaramuzza. “A Benchmark Comparison of Monocular Visual-Inertial Odometry Algorithms for Flying Robots”. Em: *2018 IEEE International Conference on Robotics and Automation (ICRA)*. Mai. de 2018, pp. 2502–2509.