

Classificação do Nível de Rugosidade usando Sensor Inercial para Robôs Terrestres em Ambientes Externos

Juan Miguel de Assis Oliveira¹, Felipe Gomes de Oliveira¹

¹Instituto de Ciências Exatas e Tecnologia – Universidade Federal do Amazonas (ICET/UFAM) – Itacoatiara – Amazonas – Brasil

juanmigueloliveira@gmail.com, felipeoliveira@ufam.edu.br

Resumo. *Este artigo propõe uma técnica de classificação do nível de rugosidade de robôs terrestres usando sensores inerciais, durante sua navegação em ambientes externos. Para isso, é proposta uma abordagem baseada em uma Rede Neural Convolucional (CNN) para classificar o nível de terrenos irregulares no deslocamento de robôs com rodas. A metodologia proposta consiste em duas etapas principais: i) Representação de medidas inerciais; e ii) Classificação do nível de rugosidade. Para validar a abordagem proposta, experimentos simulados e reais foram realizados, alcançando resultados precisos e confiáveis, mesmo em diferentes circunstâncias de superfície. Nos experimentos simulados e reais, a abordagem proposta obteve, respectivamente, precisão superior a 96,0% e 88,0%.*

1. Introdução

O avanço tecnológico vem impulsionando o desenvolvimento da Robótica, possibilitando que os robôs sejam utilizados em atividades que exijam grande capacidade de locomoção. Os robôs móveis têm sido objeto de crescente interesse nos últimos anos, tanto na comunidade acadêmica quanto na industrial, principalmente no que diz respeito à navegação autônoma [Seo and Jung 2023] [Beloiev et al. 2021] [Androulakis et al. 2020]. A navegação autônoma enfrenta um desafio significativo quando se trata de usar robôs terrestres com rodas em ambientes externos. Além de evitar possíveis obstáculos, terrenos irregulares e desconhecidos representam uma grande dificuldade para uma movimentação eficiente e segura [Oliveira et al. 2017].

A classificação do nível de irregularidade de um terreno externo contribui para uma melhor navegação em aspectos de eficiência e segurança, visto que nem sempre é possível obter um mapeamento do ambiente e extrair tais informações que auxiliariam durante a navegação. A indicação de níveis de rugosidade a partir dos sinais inerciais consiste em uma das estratégias mais eficientes para estimar o grau de dificuldade de navegação em um determinado terreno [Oliveira et al. 2019].

Neste artigo, é apresentada uma abordagem para classificar o nível de rugosidade de terrenos externos irregulares usando medições inerciais de um robô terrestre com rodas, através de uma CNN. Os experimentos foram realizados em cenários simulados e reais. Os resultados mostram que a abordagem de classificação do nível de rugosidade proposta é precisa mesmo em diferentes terrenos e condições de aquisição.

2. Trabalhos Relacionados

A navegação autônoma é uma tarefa importante para robôs terrestres, que executam diferentes aplicações, tais como: busca e salvamento [Cruz Ulloa et al. 2021],

segurança e vigilância [Lee and Shih 2022] e gerenciamento de recursos industriais [Fragapane et al. 2020]. Para análise de terreno, muitos trabalhos usam sensores exteroceptivos, como em [Waibel et al. 2022]. Em [Waibel et al. 2022], os autores levam em consideração diferentes características do terreno, incluindo rugosidade, inclinação e textura na estimativa do custo de navegação. As características do terreno são utilizadas para calcular as métricas de custo de navegação, tais como: rugosidade local e declividade. Essas métricas são combinadas usando a filtragem Bayesiana de fusão de dados. Os resultados obtidos validam a estratégia proposta, alcançando acertos acima de 90%.

Um dos sensores mais utilizados, para análise de terreno, é a IMU, captando dados de vibração diretamente da superfície irregular, onde o robô terrestre está se movendo. Os autores de [Oliveira et al. 2017] apresentaram uma abordagem de classificação de terreno invariante à velocidade, o que significa que é independente da velocidade do robô. Para o processo de classificação, os autores utilizaram apenas dados de aceleração fornecidos por uma Unidade de Medida Inercial (IMU). Um classificador SVM, com função de base radial como função kernel, é usado. Os experimentos foram realizados em diferentes tipos de terreno, incluindo superfícies com níveis de rugosidade distintos, alcançando precisão média acima de 80%.

Este trabalho é de particular importância, pois introduz uma abordagem inovadora para a classificação do nível de rugosidade, usando medições inerciais, através de uma CNN. É importante mencionar que a abordagem proposta aprende a melhor representação de características inerciais usando aprendizado profundo. Mais detalhes sobre o presente trabalho podem ser encontrado no artigo [Oliveira et al. 2023].

3. Metodologia

Neste artigo é proposta uma abordagem para classificar o nível de rugosidade de terrenos irregulares, estimando o quão difícil é navegar em uma determinada superfície. Para isso, é proposto uma metodologia composta por duas etapas principais, que serão mais bem detalhadas nas próximas subseções. As etapas são: *i*) Representação das medidas inerciais e *ii*) Classificação dos níveis de rugosidade.

3.1. Representação das Medidas Inerciais

Na primeira etapa, um conjunto de dados inerciais, adquiridos durante o movimento do robô terrestre, é selecionado para representar uma assinatura do terreno. As medidas inerciais mencionadas são definidas como uma representação bidimensional do terreno (S_t), conforme a equação 1.

$$S_t = \left\{ \left\{ \begin{aligned} & \{la_1^X, la_1^Y, la_1^Z, av_1^X, av_1^Y, av_1^Z, or_1^X, or_1^Y, or_1^Z, or_1^W\} \\ & \{la_2^X, la_2^Y, la_2^Z, av_2^X, av_2^Y, av_2^Z, or_2^X, or_2^Y, or_2^Z, or_2^W\} \\ & \{la_3^X, la_3^Y, la_3^Z, av_3^X, av_3^Y, av_3^Z, or_3^X, or_3^Y, or_3^Z, or_3^W\} \\ & \vdots \\ & \{la_w^X, la_w^Y, la_w^Z, av_w^X, av_w^Y, av_w^Z, or_w^X, or_w^Y, or_w^Z, or_w^W\} \end{aligned} \right\} \right\} \quad (1)$$

onde la_t^X , la_t^Y e la_t^Z , correspondem à aceleração linear em eixos x , y e z , respectivamente. av_t^X , av_t^Y e av_t^Z , simbolizam à velocidade angular nos eixos x , y e z , respectivamente.

Enquanto isso, or_t^X , or_t^Y , or_t^Z e or_t^W representam a orientação nos eixos x , y , z e w , respectivamente.

3.2. Classificação do Nível de Rugosidade

Em seguida, na segunda etapa, a representação bidimensional do terreno é passada para uma Rede Neural Convolutiva (CNN), para aprender a melhor representação do nível de rugosidade, fornecendo uma classificação eficiente do nível de irregularidade, a partir de medidas inerciais. O modelo proposto da CNN é apresentado na Figura 1.




Figura 1. Arquitetura da CNN proposta.

O modelo proposto consiste em uma camada convolutiva com 128 filtros de tamanho (5x5), com função de ativação ReLU e camada MaxPooling de tamanho (2x2). Em seguida, uma camada Flatten é usada para converter a saída da camada convolutiva em um vetor unidimensional com 512 neurônios, chamado de camada totalmente conectada, preparando os dados para a etapa de classificação. Para o processo de classificação é utilizada uma função Softmax para calcular as probabilidades de cada classe, retornando a classe com maior probabilidade. Durante a etapa de treinamento, o algoritmo de otimização RMSprop é utilizado com uma taxa de aprendizado de 0,0001. O processo de treinamento é conduzido em 10 épocas com um tamanho de lote de 16.

4. Resultados e Discussões

4.1. Montagem Experimental

Os experimentos foram divididos em análises reais e simuladas. Para os experimentos reais foi utilizado um robô móvel terrestre Pioneer P3-AT, equipado com uma IMU, composta por acelerômetro e giroscópio, medindo dados inerciais a 10 Hz. Nos experimentos simulados foi utilizado o *Google SketchUp*, um *software* de modelagem 3D para criação de deformações superficiais controladas. Também foi utilizado o *framework* ROS, para o desenvolvimento dos experimentos e o simulador Gazebo para simulações visuais.

4.2. Avaliação da classificação do nível de rugosidade: Simulação

Neste experimento, foram executadas etapas simuladas, onde diferentes deformações de superfície 3D controladas foram criadas e integradas ao simulador Gazebo, conforme apresentado na Figura 2(a). A partir dos resultados obtidos observados na Tabela 1(b), é possível verificar que a abordagem de classificação do nível de rugosidade proposta supera as técnicas de comparação. É importante destacar que as técnicas de comparação foram selecionadas devido aos resultados muito significativos obtidos em trabalhos relacionados na literatura [Oliveira et al. 2017] [Oliveira et al. 2021].




Figura 2. Experimento 2. A Figura 2(a) representa a aquisição de dados em simulação. Enquanto a Tabela 1(b) apresenta os resultados para a classificação do nível de rugosidade em simulação.

4.3. Avaliação da classificação do nível de rugosidade: Cenário Real

No experimento do mundo real, foi utilizado um conjunto de dados de medidas inerciais, composto por cinco diferentes níveis de rugosidade em cinco terrenos externos do mundo real. O mencionado conjunto de dados inerciais foi capturado usando um robô Pioneer P3-AT, acoplado a um sensor IMU [Oliveira et al. 2021]. No conjunto de dados inerciais apresentado, foram realizadas três execuções, cada uma utilizando três velocidades (aproximadamente 0,4, 0,6 e 0,8 m/s), resultando em nove conjuntos de dados inerciais.

Os resultados alcançados neste experimento mostram que a abordagem de classificação do nível de rugosidade baseada em CNN apresenta maior precisão do que os métodos de comparação. Neste experimento foi demonstrado que a abordagem de classificação do nível de rugosidade baseada na CNN proposta supera os outros modelos para todas as velocidades. O modelo de classificação proposto alcança uma precisão média de 95.5% com um desvio padrão de 0.023 a uma velocidade de 0.4 m/s. Da mesma forma, a uma velocidade de 0.6 m/s, a precisão média é de 97.6% com um desvio padrão de 0.017. Por fim, para uma velocidade de 0.8 m/s, a precisão média é de 88.3% com um desvio padrão de 0.073. Esses resultados fornecem percepções valiosas sobre o desempenho dos modelos de classificação, destacando a precisão superior do modelo proposto de CNN em todos os cenários e enfatizando o impacto das variações de velocidade nos resultados da classificação.

5. Conclusão

Neste artigo foi proposta uma abordagem para classificar o nível de rugosidade de terrenos externos irregulares usando medições inerciais de um robô terrestre com rodas. Experimentos reais e simulados envolvendo diferentes ambientes externos e aspectos de superfície mostraram que as classificações dos níveis de rugosidade obtidas são confiáveis e precisas, considerando os resultados obtidos. A abordagem proposta demonstra robustez e atinge alta precisão, mesmo em diferentes deformações do terreno.

Como trabalho futuro, pretende-se expandir a análise de terreno, com base em sensores inerciais, em relação a diferentes tipos de veículos terrestres e incluir mais aspectos de superfície na avaliação do terreno. Adicionalmente, pretende-se avaliar a relação entre a velocidade do robô terrestre e a variância nas medidas inerciais, bem como a relação entre o tamanho do robô e a variância nas medidas inerciais. Também é pretendido investigar a fusão de diferentes sensores inerciais e seu impacto na redução da imprecisão.

Referências

- Androulakis, V., Sottile, J., Schafrik, S., and Agioutantis, Z. (2020). Concepts for development of autonomous coal mine shuttle cars. *IEEE Transactions on Industry Applications*, 56(3):3272–3280.
- Beloiev, I., Kinaneva, D., Georgiev, G., Hristov, G., and Zahariev, P. (2021). Artificial intelligence-driven autonomous robot for precision agriculture. *Acta Technologica Agriculturae*, 24(1):48–54.
- Cruz Ulloa, C., Prieto Sánchez, G., Barrientos, A., and Del Cerro, J. (2021). Autonomous thermal vision robotic system for victims recognition in search and rescue missions. *Sensors*, 21(21).
- Fragapane, G. I., Ivanov, D. A., Peron, M., Sgarbossa, F., and Strandhagen, J. O. (2020). Increasing flexibility and productivity in industry 4.0 production networks with autonomous mobile robots and smart intralogistics. *Annals of Operations Research*, 308:125–143.
- Lee, M.-F. R. and Shih, Z.-S. (2022). Autonomous surveillance for an indoor security robot. *Processes*, 10(11).
- Oliveira, F. G., Neto, A. A., Borges, P., Campos, M. F. M., and Macharet, D. G. (2019). Augmented vector field navigation cost mapping using inertial sensors. In *2019 19th International Conference on Advanced Robotics (ICAR)*, pages 388–393.
- Oliveira, F. G., Neto, A. A., Howard, D., Borges, P., Campos, M. F. M., and Macharet, D. G. (2021). Three-dimensional mapping with augmented navigation cost through deep learning. *Journal of Intelligent & Robotic Systems*, 101(3).
- Oliveira, F. G., Santos, E. R. S., Neto, A. A., Campos, M. F. M., and Macharet, D. G. (2017). Speed-invariant terrain roughness classification and control based on inertial sensors. *2017 Latin American Robotics Symposium (LARS) and 2017 Brazilian Symposium on Robotics (SBR)*, pages 1–6.
- Oliveira, J. M. A., Macharet, D. G., and Oliveira, F. G. (2023). Roughness level classification using inertial data for wheeled robots in outdoor terrains. In *2023 Latin American Robotics Symposium (LARS), 2023 Brazilian Symposium on Robotics (SBR), and 2023 Workshop on Robotics in Education (WRE)*, pages 343–348.
- Seo, S. and Jung, H. (2023). A robust collision prediction and detection method based on neural network for autonomous delivery robots. *ETRI Journal*, 45(2):329–337.
- Waibel, G. G., Löw, T., Nass, M., Howard, D., Bandyopadhyay, T., and Borges, P. V. K. (2022). How rough is the path? terrain traversability estimation for local and global path planning. *IEEE Transactions on Intelligent Transportation Systems*, 23(9):16462–16473.