

**UNIVERSIDADE FEDERAL DO AMAZONAS  
INSTITUTO DE CIÊNCIAS EXATAS E TECNOLOGIA  
CURSO DE SISTEMAS DE INFORMAÇÃO**

**JUAN MIGUEL DE ASSIS OLIVEIRA**

**CLASSIFICAÇÃO DO NÍVEL DE RUGOSIDADE USANDO  
SENSOR INERCIAL PARA ROBÔS TERRESTRES EM  
AMBIENTES EXTERNOS**

Itacoatiara – Amazonas

Junho – 2023

JUAN MIGUEL DE ASSIS OLIVEIRA

**CLASSIFICAÇÃO DO NÍVEL DE RUGOSIDADE USANDO  
SENSOR INERCIAL PARA ROBÔS TERRESTRES EM  
AMBIENTES EXTERNOS**

Monografia apresentada ao Instituto de Ciências Exatas e Tecnologia da Universidade Federal do Amazonas como parte dos requisitos necessários para a obtenção do título de Bacharel em Sistemas de Informação.

ORIENTADOR: PROF. DR. FELIPE GOMES DE OLIVEIRA

Itacoatiara – Amazonas

Junho – 2023

## Ficha Catalográfica

Ficha catalográfica elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).

Oliveira, Juan Miguel de Assis  
O48c Classificação do nível de rugosidade usando sensor inercial para robôs terrestres em ambientes externos / Juan Miguel de Assis Oliveira . 2023  
25 f.: il. color; 31 cm.

Orientador: Felipe Gomes de Oliveira  
TCC de Graduação (Sistemas de Informação) - Universidade Federal do Amazonas.

1. Classificação do nível de rugosidade. 2. Análise de terrenos. 3. Ambientes externos. 4. Aprendizado profundo. 5. Navegação autônoma. I. Oliveira, Felipe Gomes de. II. Universidade Federal do Amazonas III. Título



Ministério da Educação  
Universidade Federal do Amazonas  
Coordenação do Curso de Sistemas de Informação - ICET

## **FOLHA DE APROVAÇÃO**

**JUAN MIGUEL DE ASSIS OLIVEIRA**

### **CLASSIFICAÇÃO DO NÍVEL DE RUGOSIDADE USANDO SENSOR INERCIAL PARA ROBÔS TERRESTRES EM AMBIENTES EXTERNOS**

Monografia apresentada ao Instituto de Ciências Exatas e Tecnologia da Universidade Federal do Amazonas como parte dos requisitos necessários para a obtenção do título de Bacharel em Sistemas de Informação.

Aprovada em 27 de junho de 2023

#### **BANCA EXAMINADORA**

Prof. Dr. Felipe Gomes de Oliveira  
Universidade Federal do Amazonas

Prof. Esp. Alternei de Souza Brito  
Universidade Federal do Amazonas

Prof. Dr. Paulo Louzada Castro de Oliveira  
Universidade Federal do Amazonas

Folha de Aprovação assinada pelo Prof. Dr. Rainer Xavier de Amorim, responsável pela disciplina Trabalho de Conclusão de Curso (Período: 2022.2), onde atesta a defesa do aluno e a presença dos membros da banca examinadora.



Documento assinado eletronicamente por **Rainer Xavier de Amorim, Professor do Magistério Superior**, em 30/06/2023, às 18:24, conforme horário oficial de Manaus, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Alternei de Souza Brito, Professor do Magistério Superior**, em 01/07/2023, às 14:37, conforme horário oficial de Manaus, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Felipe Gomes de Oliveira, Professor do Magistério Superior**, em 01/07/2023, às 16:39, conforme horário oficial de Manaus, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site [https://sei.ufam.edu.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](https://sei.ufam.edu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **1574940** e o código CRC **288CF146**.

Rua Nossa Senhora do Rosário - Bairro Tiradentes nº 3836 - Telefone: (92) (92) 99318-2549  
CEP 69103-128 Itacoatiara/AM - [ccsiicet@ufam.edu.br](mailto:ccsiicet@ufam.edu.br)

Referência: Processo nº 23105.029165/2023-95

SEI nº 1574940

*À Deus e a minha família por sempre serem  
minha força na conquista de todos os meus  
objetivos.*

## AGRADECIMENTOS

Primeiramente a Deus, por me sustentar durante toda a trajetória, aos meus pais por serem o meu principal combustível e estarem sempre ao meu lado. Às minhas irmãs Vanessa, Vânia, Verônica e irmão José, pelo apoio incondicional em todas as etapas da vida acadêmica e por acreditarem nos meus sonhos.

Agradeço aos meus amigos de curso, em especial, ao Afrânio Viana, Cláudio Marzo e Josilene Vitória, onde juntos compartilharam os mesmos objetivos ao longo de 5 anos e sempre estiveram um pelo outro, sendo peça-chave para a conclusão da jornada. Aos meus professores da UFAM pela dedicação e paixão pelo ensino, deixando um legado para cada aluno egresso da instituição.

Não posso deixar de mencionar e agradecer o meu orientador, o professor Dr. Felipe pelo incentivo, paciência e compreensão durante as longas horas dedicadas ao estudo e à pesquisa. Sua presença e encorajamento foram uma força motriz em momentos desafiadores e, por isso, sou imensamente grato.

A todos vocês, meu mais sincero agradecimento. Vocês fizeram parte de uma das conquistas mais significativas da minha vida acadêmica e estarei eternamente grato por todo o suporte e incentivo fornecidos ao longo dessa jornada.

*“A vida é uma seqüência de encontros inéditos com o mundo, e portanto ela não se deixa traduzir em fórmulas de nenhuma espécie.”*

*Clóvis de Barros Filho*



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

Juan Miguel de Assis Oliveira<sup>1</sup>, Felipe Gomes de Oliveira<sup>1</sup>

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

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

**Resumo.** *Os robôs terrestres que operam em ambientes externos geralmente enfrentam terrenos acidentados e irregulares, o que pode representar desafios significativos para a sua navegação. 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 Convolutiva (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. Além disso, o impacto de diferentes condições do terreno e do robô é avaliado para compreender seu efeito durante a análise do terreno. 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, em relação a diferentes alturas, distâncias e formas de superfície, 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. Muitas aplicações podem ser encontradas atualmente em relação à navegação autônoma, como mineração (ANDROULAKIS et al., 2020), agricultura (BELOEV et al., 2021) e serviços de entrega (SEO; JUNG, 2023), entre outros.

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).

Uma navegação eficiente consiste na realização de um deslocamento considerando o melhor gerenciamento de recursos tais como: distância, consumo de energia e tempo. Uma navegação segura consiste em realizar o deslocamento sem qualquer risco à integridade do robô, durante a movimentação. No entanto, o ambiente onde ocorre a navegação impactará diretamente no desempenho da tarefa, tendo em vista as características do robô (WAIBEL et al., 2022)(OLIVEIRA et al., 2021)(OLIVEIRA et al., 2019).

Os sensores utilizados em Robótica, na etapa de percepção, podem ser definidos como exteroceptivos e proprioceptivos. Os sensores exteroceptivos coletam informações do ambiente externo, ao redor do robô, como LiDAR (do inglês, *Light Detection e Ranging*), câmeras e sensores ultrassônicos. Por outro lado, sensores proprioceptivos fornecem informações sobre o condição do robô, como *encoders*, torque e IMU (do inglês, *Inertial Measurement Unit*). Uma IMU é um sensor que normalmente mede três grandezas primárias: aceleração, velocidade regular e, em alguns casos, intensidade do campo magnético (OLIVEIRA et al., 2021).

Em relação à análise de terreno para navegação de robôs terrestres, os sensores IMU podem medir a vibração do robô e associá-la à superfície irregular que gerou a medida de vibração. Essa medida de vibração é uma estimativa confiável da rugosidade da superfície para robôs terrestres em terrenos não estruturados. Nesse sentido, a investigação dos sensores IMU, por meio das medidas de vibração, é fundamental para a navegação autônoma em ambientes externos.



**Figura 1. Robô móvel adquirindo medidas inerciais durante a navegação em ambiente externo.**

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, foi apresentado uma abordagem para classificar o nível de rugosidade de terrenos externos irregulares usando medições inerciais de um robô terrestre com rodas, como pode ser visto na Figura 1. Apresentou-se uma estratégia baseada em uma representação de medição inercial bidimensional, passada como entrada para uma Rede Neural Convolutiva (CNN), que aprende e descreve as melhores características corres-

pondentes aos diferentes níveis de rugosidade em cenários externos. 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.

O restante do artigo está organizado da seguinte maneira. A Seção 2 apresenta alguns conceitos básicos e discute os trabalhos relacionados. A Seção 3 apresenta o método de pesquisa utilizado, enquanto a Seção 4 mostra os resultados e as discussões. A Seção 5 apresenta as conclusões e os trabalhos futuros.

## 2. Fundamentação Teórica

Nesta seção, é apresentada uma revisão dos conceitos utilizados como objeto de estudo.

### 2.1. Conceitos Relacionados

#### 2.1.1. Redes Neurais Convolucionais

As Redes Neurais Convolucionais (CNN) são uma poderosa arquitetura de aprendizado profundo comumente usada em aplicações de Visão Computacional. Os modelos CNN são fortemente aplicados em problemas de classificação e regressão do mundo real devido à sua capacidade de representar características significativas, permitindo resultados precisos através da realização de uma operação conhecida como convolução, a qual é aplicada em, pelo menos, uma camada de sua arquitetura (GOODFELLOW; BENGIO; COURVILLE, 2016).

As CNNs são compostas por várias camadas, cada uma com uma função específica na extração de características, conforme pode ser observado na Figura 2. A camada convolucional (do inglês, *Convolutional layer*) aplica operações de convolução usando filtros, multiplicando e somando os valores para gerar mapas de características. Como ajuda ao treinamento, geralmente é utilizado a função de ativação ReLU, entre as camadas de convolução e pooling. Em seguida, a etapa de pooling reduz a dimensionalidade dos dados preservando as características relevantes. Em uma CNN, é comum também possuir uma técnica chamada *Dropout*, cuja função é impedir que os outros neurônios se tornem excessivamente dependentes de um conjunto específico de recursos de entrada. Depois disso, camadas dense ou totalmente conectadas (do inglês, *Fully connected layer*), aprendem representações não lineares complexas combinando as características extraídas anteriormente, onde cada unidade está conectada a todas as unidades da camada anterior para um processamento abrangente e refinado (URTNASAN et al., 2018).

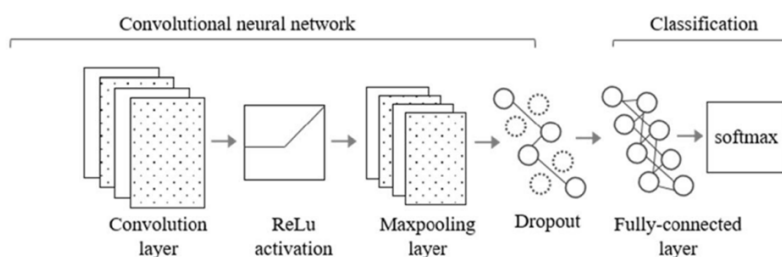


Figura 2. Arquitetura de uma CNN (Adaptado de (URTNASAN et al., 2018))

Embora as CNNs sejam comumente aplicadas para lidar com dados de imagem, sua estrutura e operações podem ser adaptadas para lidar com outros tipos de dados bidimensionais. Nesse caso, a entrada da CNN seria uma matriz ou tabela, onde cada elemento representa um valor ou característica específica (CHEN; RASTOGI; NORRIS, 2021).

### **2.1.2. Classificação de Terrenos**

A classificação de terrenos é fundamental para a navegação eficiente e segura de robôs terrestres com rodas, pois fornece parâmetros do modelo relacionados ao terreno, como coeficientes de deslizamento, melhorando a estimativa de orientação, localização e uso de energia. Esse conceito visa categorizar os terrenos em classes distintas com base em características específicas, aprimorando o planejamento e controle das atividades robóticas em cenários de exploração autônoma e navegação.

Para realizar a classificação de terrenos, são coletados dados sensoriais, como imagens, dados de profundidade e informações de textura, além de outros sensores embarcados no robô. Esses dados são processados e analisados utilizando técnicas de aprendizado de máquina, visão computacional e processamento de sinais para extrair informações relevantes sobre as características do terreno. Dessa forma, existem duas abordagens na classificação de terrenos: exteroceptivas e proprioceptivas. A abordagem exteroceptiva analisa recursos visuais do ambiente externo, como iluminação, mapeamento e temperatura, enquanto a classificação proprioceptiva utiliza características de vibração geradas pelas interações físicas entre o terreno e o robô móvel (LV et al., 2020).

Ao considerar a rugosidade do terreno como uma das características relevantes, o aprendizado profundo pode ser usado para analisar e classificar diferentes tipos de terreno com base em seus níveis de rugosidade. O nível de rugosidade de um terreno é uma medida da irregularidade da superfície do terreno. Essa rugosidade é determinada pela variação das alturas e declives ao longo da área do terreno (OLIVEIRA; CAMPOS; MACHARET, 2020). Por exemplo, áreas com alta rugosidade podem ser identificadas como terrenos mais acidentados, o que pode exigir uma navegação mais cuidadosa ou a escolha de rotas alternativas. Da mesma forma, áreas com baixa rugosidade podem ser classificadas como terrenos mais planos e propícios para uma navegação mais eficiente (WAIBEL et al., 2022).

### **2.1.3. Sensores Inerciais**

Os sensores inerciais, como acelerômetros, giroscópios e magnetômetros, são dispositivos cruciais para medir o movimento e orientação de um objeto. Eles permitem determinar a posição, aceleração linear e angular do objeto em movimento, fornecendo informações precisas sobre velocidade e direção, mesmo em ambientes adversos (WAIBEL et al., 2022).

A IMU (Unidade de Medição Inercial) é comumente utilizada no contexto da análise de terrenos na área da Robótica. Trata-se de um dispositivo composto por acelerômetros, giroscópios e, em alguns casos, magnetômetros, que se combinam para me-

dir a posição, orientação e movimento de um objeto. Os acelerômetros mensuram a aceleração linear do objeto em relação aos três eixos espaciais (x, y, z), enquanto os giroscópios detectam variações nas taxas de rotação, fornecendo informações sobre a velocidade angular em cada um dos eixos espaciais (*roll, pitch e yaw*) (OLIVEIRA; CAMPOS; MACHARET, 2020). A IMU utiliza os dados dos acelerômetros e giroscópios para estimar a orientação e monitorar mudanças na taxa de rotação ao longo do tempo.

#### **2.1.4. Navegação Autônoma**

A navegação autônoma é a capacidade de um sistema robótico ou veículo mover-se de forma independente em um ambiente desconhecido, utilizando sensores e algoritmos para tomar decisões em tempo real. Esse sistema é capaz de realizar o planejamento de rotas, evitar obstáculos, adaptar-se às mudanças no ambiente e alcançar com precisão um objetivo pré-determinado, tudo sem a necessidade de intervenção humana.

Em resumo, a navegação autônoma envolve uma série de desafios técnicos, como o mapeamento e a localização simultânea (SLAM, do inglês, *Simultaneous Localization and Mapping*), que permite ao robô construir um mapa do ambiente enquanto se localiza dentro dele (KACHURKA et al., 2022). Além disso, a fusão de dados de diferentes sensores, como câmeras, sonares e lasers, é essencial para obter uma representação unificada e precisa do ambiente (WAIBEL et al., 2022).

#### **2.1.5. Validação Cruzada**

A técnica de Validação Cruzada (do inglês, *Cross-Validation*) é uma abordagem amplamente utilizada na área de aprendizado de máquina e estatística para avaliar e validar a performance de modelos preditivos. Na Validação Cruzada, o conjunto de dados é dividido em subconjuntos distintos de treinamento e teste. O modelo é treinado nos subconjuntos de treinamento e avaliado nos subconjuntos de teste. Essa divisão é repetida várias vezes, de forma que cada subconjunto de dados seja utilizado tanto para treinamento quanto para teste em diferentes iterações. Os resultados são então agregados para fornecer uma medida mais robusta e confiável da performance do modelo (WONG; YEH, 2020).

Uma das formas mais comuns de Validação Cruzada é a chamada K-fold Cross-Validation, onde o conjunto de dados é dividido em k subconjuntos de tamanhos iguais (ou quase iguais). O modelo é treinado em k-1 subconjuntos e testado no subconjunto restante. Esse processo é repetido k vezes, de forma que cada subconjunto seja utilizado como conjunto de teste uma vez. Os resultados obtidos em cada iteração são então combinados, geralmente através de média ou mediana, para fornecer uma estimativa final do desempenho do modelo (HASTIE; TIBSHIRANI; FRIEDMAN, 2009).

## **2.2. Trabalhos Relacionados**

A navegação autônoma é uma tarefa importante para robôs terrestres, que executam diferentes aplicações, tais como: busca e salvamento (ULLOA et al., 2021), segurança e vigilância (LEE; 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) e (SCHILLING et al., 2017). 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. O processo é dividido em duas etapas principais: estimativa local e global. Na estimativa local, o robô utiliza sensores exteroceptivos embarcados, como câmeras e sensores LiDAR, para capturar informações sobre o terreno circundante. Na estimativa global, o robô utiliza informações de mapas topográficos ou modelos digitais de elevação, para obter uma visão ampla do terreno, fornecendo dados de declividade e rugosidade. 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%.

Os autores de (SCHILLING et al., 2017) introduziram uma abordagem para classificação de terrenos, combinando dados fornecidos por uma câmera e um sensor LiDAR. Na abordagem proposta, os autores calculam características geométricas de nuvens de pontos LiDAR e extraem rótulos semânticos pixel a pixel de uma rede totalmente convolucional. As características geométricas e visuais são fundidas através de um modelo de classificação Random Forest, classificando os custos de transitabilidade em três classes: *i*) seguro; *ii*) arriscado; e *iii*) obstáculo. Os experimentos foram realizados utilizando um robô terrestre de quatro rodas, aplicado em ambientes urbanos e *off-road*, em condições de verão e inverno. Os resultados obtidos mostram que o desempenho da classificação melhora significativamente quando a Random Forest combina características, alcançando acurácia acima de 94%.

Diferentes abordagens usam sensores proprioceptivos para análise do terreno, como em (WALAS; KANOULAS; KRYCZKA, 2016). Em (WALAS; KANOULAS; KRYCZKA, 2016), os autores propuseram uma abordagem de classificação de terreno usando sensores de força/torque, montados nos tornozelos de um robô humanoide. Através dos experimentos realizados em cinco diferentes tipos de terreno, foram alcançadas taxas de identificação de precisão e recall de 95%. Além disso, os autores introduziram um método para determinar o tamanho ideal do passo, equilibrando o consumo de energia e a estabilidade da locomoção, considerando o tipo de terreno identificado. Nos experimentos, durante a aquisição de dados, foi utilizado o robô humanoide WALK-MAN de tamanho real, navegando em cinco diferentes tipos de terreno.

Diferentes estratégias combinam sensores exteroceptivos e proprioceptivos, a fim de alcançar as vantagens relacionadas a cada tipo de sensor. Em (CHEN; RASTOGI; NORRIS, 2021) é apresentada uma nova abordagem de classificação de terreno baseada em propriocepção. O método proposto usa sensores embarcados comumente disponíveis em veículos terrestres (UGVs) e emprega um modelo de CNN unidimensional. Para aumentar a precisão, o modelo é ainda mais aprimorado pela fusão com uma CNN baseado em visão, permitindo a classificação com base na aparência do terreno. Os resultados experimentais demonstram a eficácia dos modelos de fusão, atingindo uma taxa de precisão superior a 93%, sob diferentes condições de iluminação e movimento.

Outro trabalho combinando sensores exteroceptivos e proprioceptivos foi proposto por (OLIVEIRA et al., 2021). Os autores introduziram uma abordagem combinando os sensores IMU e LiDAR. Para a análise do terreno, considerando medidas inerciais,

foram utilizadas características de nível de rugosidade e de inclinação, que combinadas por meio de regressão quadrática geraram uma medida de custo de navegação. O custo de navegação inercial é fundido com informações geométricas, fornecidas pelo sensor laser, para gerar um mapa de custo de navegação 3D. Para estimar o nível de rugosidade, os autores combinaram aceleração linear e velocidade angular, fornecendo uma assinatura de terreno inercial da superfície. Através do modelo de classificação Random Forest e das assinaturas inerciais do terreno, obteve-se uma precisão de 95,4%, em relação a cinco diferentes terrenos.

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. Várias estratégias têm sido apresentadas usando medições inerciais para avaliação de terreno, como (BAI; GUO; ZHENG, 2019), (CSÍK et al., 2021) e (OLIVEIRA et al., 2017).

Em (BAI; GUO; ZHENG, 2019) é proposto um método de classificação de terreno baseado em medições tridimensionais de vibração, para robôs móveis. Diferentes características são extraídas dos sinais de vibração, como amplitude, frequência e energia. Esses recursos são combinados em um conjunto de dados tridimensional, considerando diferentes tipos de terreno, incluindo areia, pastagem, concreto e cascalho. É utilizado o modelo de classificação Backpropagation Neural Network, cuja técnica permite ajustar os pesos e os bias de uma rede neural com base no erro calculado entre as saídas previstas e as saídas desejadas. O modelo é treinado com o conjunto de dados proposto onde resultados obtidos alcançaram uma taxa de precisão acima de 88,99%, demonstrando sua robustez.

Csík et al. (2021) alcançaram uma taxa de precisão acima de 90% no uso de sensores inerciais para coleta e classificação de terrenos acidentados. O algoritmo de classificação usa recursos de domínio de frequência extraídos de janelas de tamanho fixo e emprega redes neurais Multi-Layer Perceptron (MLP) como classificadores. Ao dividir o sinal em janelas de tamanho fixo, torna-se possível analisar características de frequência em diferentes intervalos de tempo e identificar padrões temporais relevantes. A combinação desses recursos com MLPs resulta em uma representação mais discriminativa dos dados.

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, como concreto, pavimento hexagonal, pavimento retangular, pavimento quadrático e pavimento de pedra, representando terrenos irregulares. Os resultados alcançados demonstraram um processo de classificação do terreno eficiente, com precisão média acima de 80%.

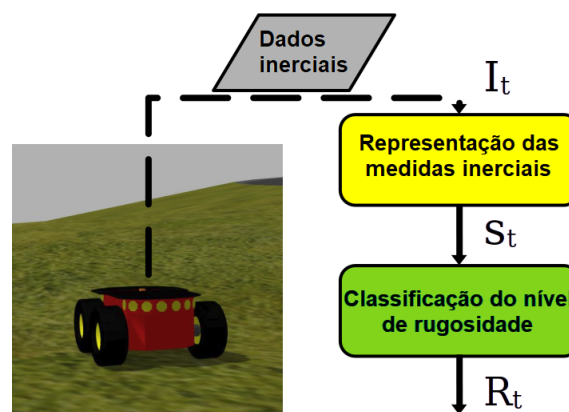
Este trabalho é de particular importância, pois introduz uma abordagem inovadora para a classificação do nível de rugosidade, usando medições inerciais, através de uma CNN. É importante mencionar que a abordagem proposta aprende a melhor representação de características inerciais usando aprendizado profundo. Além disso, o presente trabalho

propõe uma intensa investigação sobre o impacto de diferentes condições do terreno e sua influência durante a navegação de um robô terrestre e os efeitos na análise do terreno em ambientes externos.

### 3. Metodologia

Na navegação autônoma em ambientes externos, utilizando robôs terrestres com rodas, a análise do terreno é uma tarefa primordial. Uma das abordagens mais utilizadas consiste em usar sensores inerciais para capturar dados de vibração do terreno onde o veículo está se movendo. Uma estimativa de custo de navegação eficiente pode melhorar a capacidade de navegação em ambientes desconhecidos e irregulares.

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, que podem ser vistos na Figura 4.



**Figura 3. A metodologia proposta para a classificação do nível de rugosidade do terreno.**

Na primeira etapa (Representação de medidas inerciais), 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 representadas como uma representação bidimensional do terreno. Em seguida, na segunda etapa (Classificação do nível de rugosidade), a representação bidimensional do terreno é passada para uma Rede Neural Convolutacional (CNN), para aprender a melhor representação do nível de rugosidade, fornecendo uma classificação eficiente do nível de irregularidade, a partir de medidas.

#### 3.1. Representação das Medidas Inerciais

Inicialmente, durante a navegação do robô terrestre com rodas, dados inerciais ( $I_t$ ) são adquiridos por um sensor IMU, capturados no instante  $t$ . As medidas inerciais adquiridas são representadas por uma janela móvel de tamanho fixo. Para a abordagem proposta, a janela móvel é definida para representar 100 medições inerciais, ou seja, o tamanho da janela ( $w$ ) é 100, conforme definido na equação 1.



$$I_t = \{i_{t-1}, i_{t-1}, i_{t-1}, \dots, i_{t-w}\} \quad (1)$$

onde  $i$  corresponde a uma medida inercial, no instante  $t$ , com tamanho de janela  $w$ . Cada medida inercial é composta pela aceleração linear, velocidade angular e orientações, conforme definido na equação 2. É importante mencionar que, para a aceleração linear são considerados os três eixos:  $x$ ,  $y$  e  $z$ . Para a velocidade angular são considerados os três eixos:  $x$ ,  $y$  e  $z$ . Já para as orientações são considerados os quatro eixos:  $x$ ,  $y$ ,  $z$  e  $w$ , resultando em dez medições.

$$i_t = \{la_t^X, la_t^Y, la_t^Z, av_t^X, av_t^Y, av_t^Z, or_t^X, or_t^Y, or_t^Z, or_t^W\} \quad (2)$$

onde  $i_t$  corresponde a uma medida inercial, adquirida no instante  $t$ .  $la_t^X$ ,  $la_t^Y$  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.

Nesse sentido, para cada dado inercial na janela móvel, são feitas as dez medidas inerciais mencionadas relacionadas à rugosidade da superfície atual, onde o robô está se movendo. Assim, para gerar a assinatura bidimensional do terreno ( $S$ ), as primeiras dez medidas inerciais são definidas na primeira linha da representação bidimensional. As segundas dez medições inerciais são definidas na segunda linha da representação bidimensional. As terceiras dez medidas inerciais são definidas na terceira linha da representação bidimensional, e assim sucessivamente, até a última medida inercial, conforme pode ser visualizado na equação 3.

$$S_t = \left\{ \begin{array}{l} \{la_1^X, la_1^Y, la_1^Z, av_1^X, av_1^Y, av_1^Z, or_1^X, or_1^Y, or_1^Z, or_1^W\} \\ \{la_2^X, la_2^Y, la_2^Z, av_2^X, av_2^Y, av_2^Z, or_2^X, or_2^Y, or_2^Z, or_2^W\} \\ \{la_3^X, la_3^Y, la_3^Z, av_3^X, av_3^Y, av_3^Z, or_3^X, or_3^Y, or_3^Z, or_3^W\} \\ \vdots \\ \{la_w^X, la_w^Y, la_w^Z, av_w^X, av_w^Y, av_w^Z, or_w^X, or_w^Y, or_w^Z, or_w^W\} \end{array} \right\} \quad (3)$$

### 3.2. Classificação do Nível de Rugosidade

A partir da assinatura bidimensional do terreno ( $S$ ) gerada na subseção anterior, um processo de aprendizado é empregado para avaliar a relação entre  $S$  e os níveis de rugosidade ( $R$ ), em diferentes tipos de superfícies. Para isso, é utilizado a CNN como arquitetura de aprendizado profundo, para melhorar a capacidade de compreensão relacionada a terrenos externos.

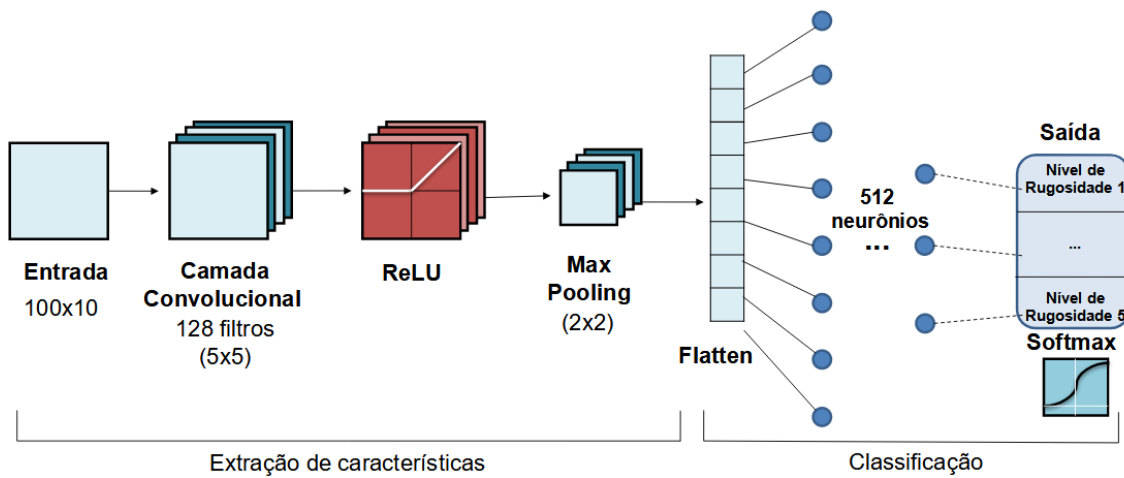
O modelo proposto consiste em uma camada convolucional com 128 filtros de tamanho (5x5). A primeira camada usa a função de ativação ReLU (equação 4) e a função de inicialização de peso HeUniform (equação 5). Após a camada convolucional, uma camada MaxPooling é adicionada com um tamanho de pooling de (2x2), para reduzir a dimensionalidade espacial dos dados. Em seguida, uma camada Flatten é usada

para converter a saída da camada convolucional 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.

$$f(k) = \max(0, k) \quad (4)$$

$$f(h) = \sqrt{\frac{6}{N_{in}}} \quad (5)$$

onde  $N_{in}$  é o número de entradas que entram no neurônio.



**Figura 4. Arquitetura da CNN proposta**

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. A arquitetura CNN proposta foi utilizada devido ao eficiente processo de aprendizado de recursos e à ampla utilização em aplicações relacionadas no contexto de análise de terreno (CHEN; RASTOGI; NORRIS, 2021) (OLIVEIRA; CAMPOS; MACHARET, 2020).


## 4. Resultados e Discussões

Nesta seção, é apresentado os resultados e discussões referentes ao modelo treinado a partir da CNN, utilizando imagens e informações da base de referência. A seção está dividida em três partes: (i) apresentação da montagem experimental para a aquisição dos dados, (ii) experimentos simulados e (iii) experimentos reais com a comparação da classificação obtida por meio do modelo de CNN com outras abordagens, respectivamente.

### 4.1. Montagem Experimental

Os experimentos foram divididos em análises reais e simuladas. Em experimentos reais foi utilizado um Pioneer 3-AT, um robô terrestre móvel projetado para aplicações externas. O robô terrestre foi equipado com uma IMU, composta por acelerômetro e giroscópio, medindo dados inerciais a 10 Hz. Os dados inerciais foram adquiridos por um

Arduino Mega 2560 integrado com um *laptop* Dell com CPU Intel Core<sup>TM</sup> i5-4200U e memória principal de 8 GiB DDR3-1600, conforme pode ser visto na Figura 5. 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 apoiar o desenvolvimento dos experimentos e o simulador Gazebo para simulações visuais.




**Figura 5. Robô móvel usado nos experimentos reais. Adicionalmente, destacam-se o acelerômetro, Arduino Mega 2560 e Laptop, acoplados no robô Pioneer P3-AT (OLIVEIRA et al., 2017).**

#### 4.2. Avaliação da classificação do nível de rugosidade: Simulação


Os experimentos avaliam a precisão da abordagem proposta, para classificação do nível de rugosidade. Para isso, foram realizados experimentos simulados e reais.

Neste experimento, foram executadas etapas simuladas, onde diferentes deformações de superfície 3D controladas foram criadas e integradas ao simulador Gazebo, conforme apresentado na Figura 6. O conjunto de dados adquirido é composto por 3 conjuntos de medições inerciais variando aspectos de deformação como altura, distância e forma.

Para entender o impacto de diferentes deformações superficiais na análise do terreno, utilizando sensores inerciais, foram considerados os aspectos: (i) altura; (ii) distância; e (iii) forma. O aspecto da deformação da altura, consiste em como a altura da deformação está relacionada ao terreno plano, como pode ser observado na Figura 7a. O aspecto distância deformação, consiste em quão distante uma deformação está de outra deformação, como na Figura 7b. Por fim, o aspecto da deformação da forma, consiste em diferentes formas de deformação na superfície onde o robô está se movendo, conforme mostrado na Figura 7c.



**Figura 6.** Aquisição de dados inerciais no processo de simulação. As medidas inerciais foram capturadas em diferentes aspectos da deformação controlada.



**Figura 7.** Os diferentes aspectos de deformação considerados para avaliar a análise do terreno usando um sensor inercial. As Figuras 7a, 7b e 7c referem-se, respectivamente, à altura, distância e forma das deformações superficiais.

Neste experimento, cada aspecto de deformação foi avaliado individualmente. Os dados inerciais foram adquiridos variando cada aspecto de deformação, como: altura, com os valores de 1cm, 2cm, 3cm, 4cm e 5cm; distância, com os valores de 1cm, 2cm, 3cm, 4cm e 5cm; e formato em triangular, quadrado, pentagonal, hexagonal, heptagonal e circular. A avaliação da precisão foi realizada comparando a abordagem proposta de classificação de rugosidade baseada em CNN com duas técnicas de comparação, uma baseada em representação no domínio do tempo com classificador SVM (OLIVEIRA et al., 2017) e outra baseada em representação no domínio da frequência com classificador Random Forest (OLIVEIRA et al., 2021).

Os hiperparâmetros da CNN propostos foram definidos através do grid search framework, variando os parâmetros: (i) número de filtros, com os valores 32, 64 e 128; (ii) tamanho do filtro, com os valores (3x3), (5x5) e (7x7); (iii) tamanho do lote, com os valores 16, 32 e 64; (iv) tamanho da camada densa, com valores 256, 512 e 1024; taxa de aprendizado ( $\nu$ ), com valores 0,001 e 0,0001; e algoritmo otimizador ( $\nu_i$ ), com Adam, SGD e RMSprop. Para encontrar os melhores hiperparâmetros foram avaliadas mais de 300 combinações diferentes de parâmetros, ou seja, mais de 300 arquiteturas CNN diferentes. Vale ressaltar que as classes, saída da CNN, estão relacionadas com o nível de rugosidade dos diferentes tipos de terreno.

Para a avaliação da precisão do nível de rugosidade, considerando o aspecto da deformação da altura, os valores de altura foram definidos como 1cm, 2cm, 3cm, 4cm e

5cm. Enquanto isso, os aspectos de distância e forma foram fixados em 3cm e formato triangular, respectivamente. Para a avaliação da precisão do nível de rugosidade, considerando o aspecto da deformação da distância, os valores de distância foram definidos como 1cm, 2cm, 3cm, 4cm e 5cm. Já os aspectos de altura e forma foram fixados em 3cm e formato triangular, respectivamente. Para a avaliação da precisão do nível de rugosidade, considerando o aspecto da deformação da forma, foram definidas as opções de forma nos formatos triangular, quadrado, pentagonal, hexagonal, heptagonal e circular. Enquanto isso, os aspectos de altura e distância foram fixados em 3cm e 3cm, respectivamente.

**Tabela 1. Resultados para classificação do nível de rugosidade em experimentos simulados. Este experimento apresenta precisão para a abordagem proposta e as duas técnicas de comparação, quanto à variação da irregularidade do terreno.**

	Acurácia (%)		
	Altura	Distância	Forma
SVM (WANG et al., 2017)	0.945	0.927	0.938
Random Forest (OLIVEIRA et al., 2021)	0.961	0.947	0.977
<b>Método Proposto</b>	0.987	0.962	0.999

O treinamento do modelo de classificação é realizado a partir de um conjunto de medidas inerciais de entrada e a etapa de teste diz respeito a outro conjunto de medidas inerciais de entrada, desde que seja aplicado o protocolo 5-fold de validação cruzada. A partir dos resultados obtidos observados na Tabela 1, é possível verificar que a abordagem de classificação do nível de rugosidade proposta supera as técnicas de comparação. Adicionalmente, é possível verificar que o aspecto da deformação que mais impactou negativamente foi a distância entre deformações em terrenos externos. 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).

### 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, como pode ser observado na Figura 8. 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.

O objetivo deste experimento é avaliar a precisão do processo proposto de classificação do nível de rugosidade, onde cada terreno representa um nível de rugosidade. Nesta avaliação, o mesmo ambiente e velocidade são mantidos, e um conjunto de dados inerciais (por exemplo, *run 1*, conforme visto na Figura 2, que é uma referência à execução do treinamento) é usado para treinar o modelo de classificação do nível de rugosidade, enquanto outros dois conjuntos de dados inerciais (por exemplo, *run 2* e *run 3*) são usados para testar o modelo. Nesse sentido, foi utilizada a mesma arquitetura de rede

neural convolucional (CNN) definida e validada por meio dos experimentos simulados na subseção anterior. Foram utilizadas técnicas de comparação, nomeadamente Random Forest (OLIVEIRA et al., 2021), Ada Boosting (DUTTA; DASGUPTA, 2017) e SVM (WANG et al., 2017). Ao realizar essa avaliação, pretende-se estimar a eficácia do processo de classificação proposto e identificar o modelo de classificação mais confiável para prever com precisão os níveis de rugosidade em diferentes terrenos.



**Figura 8. Cinco diferentes tipos de terrenos do cenário real.**

Durante a condução do treino, convenciou-se descartar combinações específicas de treinamento e teste, como (*run 1*, Teste 1), (*run 2*, Teste 2) e (*run 3*, Teste 3), exatamente para evitar qualquer possibilidade de reutilização dos mesmos dados, como pode observado na Tabela 2. Essa prática garante que os resultados obtidos sejam confiáveis e imparciais, refletindo adequadamente o desempenho do modelo em dados inéditos.

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, como é possível observar na Tabela 2. A partir da Tabela 2, em relação aos resultados obtidos, 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.

**Tabela 2. Resultados de cada treino e teste para a classificação do nível de rugosidade.**

<b>Método</b>	<b>Velocidade</b>	<b>Teste</b>				
Random Forest (OLIVEIRA et al., 2021)	<b>0.4</b>	<b>Treino</b>	<b>run 1</b>	<b>run 1</b>	<b>run 2</b>	<b>run 3</b>
			run 1	-	0.946	0.908
			run 2	0.954	-	0.913
	<b>0.6</b>	<b>Treino</b>	run 3	0.960	0.955	-
			<b>run 1</b>	<b>run 1</b>	<b>run 2</b>	<b>run 3</b>
			run 1	-	0.953	0.949
	<b>0.8</b>	<b>Treino</b>	run 2	0.961	-	0.946
			run 3	0.964	0.953	-
			<b>run 1</b>	<b>run 1</b>	<b>run 2</b>	<b>run 3</b>
Ada Boosting (DUTTA; DASGUPTA, 2017)	<b>0.4</b>	<b>Treino</b>	run 1	-	0.816	0.933
			run 2	0.784	-	0.777
			run 3	0.923	0.812	-
	<b>0.6</b>	<b>Treino</b>	<b>run 1</b>	<b>run 1</b>	<b>run 2</b>	<b>run 3</b>
			run 1	-	0.837	0.786
			run 2	0.888	-	0.849
	<b>0.8</b>	<b>Treino</b>	run 3	0.519	0.503	-
			<b>run 1</b>	<b>run 1</b>	<b>run 2</b>	<b>run 3</b>
			run 1	-	0.839	0.802
<b>0.6</b>	<b>Treino</b>	run 2	0.886	-	0.869	
		run 3	0.782	0.793	-	
		<b>run 1</b>	<b>run 1</b>	<b>run 2</b>	<b>run 3</b>	
<b>0.8</b>	<b>Treino</b>	run 1	-	0.712	0.772	
		run 2	0.619	-	0.638	
		run 3	0.802	0.782	-	
SVM (WANG et al., 2017)	<b>0.4</b>	<b>Treino</b>	<b>run 1</b>	<b>run 1</b>	<b>run 2</b>	<b>run 3</b>
			run 1	-	0.933	0.891
			run 2	0.903	-	0.870
	<b>0.6</b>	<b>Treino</b>	run 3	0.878	0.889	-
			<b>run 1</b>	<b>run 1</b>	<b>run 2</b>	<b>run 3</b>
			run 1	-	0.893	0.848
	<b>0.8</b>	<b>Treino</b>	run 2	0.871	-	0.866
			run 3	0.864	0.873	-
			<b>run 1</b>	<b>run 1</b>	<b>run 2</b>	<b>run 3</b>
<b>0.6</b>	<b>Treino</b>	run 1	-	0.751	0.843	
		run 2	0.779	-	0.779	
		run 3	0.863	0.758	-	
<b>Método Proposto</b>	<b>0.4</b>	<b>Treino</b>	<b>run 1</b>	<b>run 1</b>	<b>run 2</b>	<b>run 3</b>
			run 1	-	0.983	0.939
			run 2	0.988	-	0.945
	<b>0.6</b>	<b>Treino</b>	run 3	0.940	0.935	-
			<b>run 1</b>	<b>run 1</b>	<b>run 2</b>	<b>run 3</b>
			run 1	-	0.992	0.982
	<b>0.8</b>	<b>Treino</b>	run 2	0.988	-	0.986
			run 3	0.947	0.963	-
			<b>run 1</b>	<b>run 1</b>	<b>run 2</b>	<b>run 3</b>
<b>0.6</b>	<b>Treino</b>	run 1	-	0.840	0.975	
		run 2	0.832	-	0.831	
		run 3	0.982	0.839	-	

## 5. Conclusão

Neste artigo foi proposto uma abordagem para classificar o nível de rugosidade de terrenos externos irregulares usando medições inerciais de um robô terrestre com rodas. Além disso, foi apresentado uma exploração rigorosa focada em comparar a abordagem proposta com outras técnicas de classificação, e como os efeitos de diferentes aspectos do terreno podem influenciar na navegação do robô terrestre e na análise do terreno.

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. Ao contrário de outras metodologias, a abordagem proposta demonstra robustez e atinge alta precisão, mesmo em diferentes deformações do terreno, e viabilidade para navegação autônoma real em ambientes externos, uma vez que os experimentos foram realizados em cenários reais e simulados. Adicionalmente, através da investigação dos impactos relacionados aos aspectos da superfície e da análise do terreno, utilizando sensor inercial, foi possível demonstrar que a distância entre as deformações da superfície afeta fortemente o desempenho da análise do terreno.

Por fim, nessa linha de estudo, futuras pesquisas podem ser conduzidas tendo como base inicial, a técnica de classificação de terrenos usando os sensores inerciais e a CNN. Como trabalho futuro, pretende-se aumentar a análise do 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. et al. Concepts for development of autonomous coal mine shuttle cars. *IEEE Transactions on Industry Applications*, v. 56, n. 3, p. 3272–3280, 2020.
- BAI, C.; GUO, J.; ZHENG, H. Three-dimensional vibration-based terrain classification for mobile robots. *IEEE Access*, v. 7, p. 63485–63492, 2019.
- BELOEV, I. et al. Artificial intelligence-driven autonomous robot for precision agriculture. *Acta Technologica Agriculturae*, v. 24, n. 1, p. 48–54, 2021. Disponível em: <https://doi.org/10.2478/ata-2021-0008>.
- CHEN, Y.; RASTOGI, C.; NORRIS, W. R. A cnn based vision-proprioception fusion method for robust ugv terrain classification. *IEEE Robotics and Automation Letters*, v. 6, n. 4, p. 7965–7972, 2021.
- CSÍK, D. et al. Inertial sensor-based outdoor terrain classification for wheeled mobile robots. In: *2021 IEEE 19th International Symposium on Intelligent Systems and Informatics (SISY)*. [S.l.: s.n.], 2021. p. 159–164.
- DUTTA, A.; DASGUPTA, P. Ensemble learning with weak classifiers for fast and reliable unknown terrain classification using mobile robots. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, v. 47, n. 11, p. 2933–2944, Nov 2017. ISSN 2168-2216.



FRAGAPANE, G. I. et al. Increasing flexibility and productivity in industry 4.0 production networks with autonomous mobile robots and smart intralogistics. *Annals of Operations Research*, v. 308, p. 125–143, 2020.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. [S.l.]: MIT Press, 2016. 254,330-331 p. <<http://www.deeplearningbook.org>>.

HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. *The elements of statistical learning: data mining, inference and prediction*. 2. ed. Springer, 2009. Disponível em: <<http://www-stat.stanford.edu/~tibs/ElemStatLearn/>>.

KACHURKA, V. et al. Weco-slam: Wearable cooperative slam system for real-time indoor localization under challenging conditions. *IEEE sensors journal*, IEEE, New York, v. 22, n. 6, p. 5122–5132, 2022. ISSN 1530-437X.

LEE, M.-F. R.; SHIH, Z.-S. Autonomous surveillance for an indoor security robot. *Processes*, v. 10, n. 11, 2022. ISSN 2227-9717. Disponível em: <<https://www.mdpi.com/2227-9717/10/11/2175>>.

LV, W. et al. Feature-temporal semi-supervised extreme learning machine for robotic terrain classification. *IEEE transactions on circuits and systems. II, Express briefs*, IEEE, v. 67, n. 12, p. 3567–3571, 2020. ISSN 1549-7747.

OLIVEIRA, F.; CAMPOS, M. F.; MACHARET, D. Three-dimensional mapping with augmented navigation cost through deep learning. In: *Anais Estendidos do XII Simpósio Brasileiro de Robótica e XVII Simpósio Latino Americano de Robótica*. Porto Alegre, RS, Brasil: SBC, 2020. p. 97–108. ISSN 0000-0000. Disponível em: <[https://sol.sbc.org.br/index.php/sbirlars/\\_estendido/article/view/14958](https://sol.sbc.org.br/index.php/sbirlars/_estendido/article/view/14958)>.

OLIVEIRA, F. G. et al. Augmented vector field navigation cost mapping using inertial sensors. In: *2019 19th International Conference on Advanced Robotics (ICAR)*. [S.l.: s.n.], 2019. p. 388–393.

OLIVEIRA, F. G. et al. Three-dimensional mapping with augmented navigation cost through deep learning. *Journal of Intelligent & Robotic Systems*, Springer Science and Business Media LLC, v. 101, n. 3, fev. 2021. Disponível em: <<https://doi.org/10.1007/s10846-020-01304-y>>.

OLIVEIRA, F. G. et al. Speed-invariant terrain roughness classification and control based on inertial sensors. *2017 Latin American Robotics Symposium (LARS) and 2017 Brazilian Symposium on Robotics (SBR)*, p. 1–6, 2017.

SCHILLING, F. et al. Geometric and visual terrain classification for autonomous mobile navigation. In: *2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. [S.l.: s.n.], 2017. p. 2678–2684.

SEO, S.; JUNG, H. A robust collision prediction and detection method based on neural network for autonomous delivery robots. *ETRI Journal*, Wiley, v. 45, n. 2, p. 329–337, mar. 2023. Disponível em: <<https://doi.org/10.4218/etrij.2021-0397>>.

ULLOA, C. C. et al. Autonomous thermal vision robotic system for victims recognition in search and rescue missions. *Sensors*, v. 21, n. 21, 2021. ISSN 1424-8220. Disponível em: <<https://www.mdpi.com/1424-8220/21/21/7346>>.

URTNASAN, E. et al. Automated detection of obstructive sleep apnea events from a single-lead electrocardiogram using a convolutional neural network. *Journal of medical systems*, Springer US, New York, v. 42, n. 6, p. 104–8, 2018. ISSN 0148-5598.

WAIBEL, G. G. et al. How rough is the path? terrain traversability estimation for local and global path planning. *IEEE Transactions on Intelligent Transportation Systems*, v. 23, n. 9, p. 16462–16473, 2022.

WALAS, K.; KANOULAS, D.; KRYCZKA, P. Terrain classification and locomotion parameters adaptation for humanoid robots using force/torque sensing. In: *2016 IEEE-RAS 16th International Conference on Humanoid Robots (Humanoids)*. [S.l.: s.n.], 2016. p. 133–140.

WANG, S. et al. Road-terrain classification for land vehicles: Employing an acceleration-based approach. *IEEE Vehicular Technology Magazine*, v. 12, n. 3, p. 34–41, Sept 2017. ISSN 1556-6072.

WONG, T.-T.; YEH, P.-Y. Reliable accuracy estimates from k-fold cross validation. *IEEE transactions on knowledge and data engineering*, IEEE, v. 32, n. 8, p. 1586–1594, 2020. ISSN 1041-4347.