

Uma Nova Abordagem para Localização de Robô Móvel em Ambiente Virtual utilizando Mapas Topológicos a partir de Matriz de Co-ocorrência Estrutural em Imagens Omnidirecionais

José Jerovane da Costa Nascimento **, *
Suane Pires Pinheiro da Silva ***, * Pedro Igo Sousa Lucas **, *
Adriell G. Marques **, * Luís Fabrício de F. Souza ***, *
Pedro Pedrosa Rebouças Filho ***, ***, *

* *Laboratório de Processamento de Imagens, Sinais e Computação Aplicada (LAPISCO), CE,*

** *Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE), CE*

*** *Programa de Pós-Graduação em Engenharia de Teleinformática (PPGETI), CE*

**** *Programa de Pós-Graduação Ciência da Computação (PPGCC), CE*

Email: {jerovane.nascimento, suanepires, pedroigo.sl, adriell.gomes, fabricio.freitas,}@lapisco.ifce.edu.br pedrosarf@ifce.edu.br.

Resumo:

Na Robótica, a localização é uma tarefa essencial, permitindo que o robô navegue e assim realize suas atividades. Neste artigo, é proposta uma nova abordagem de localização e navegação para robôs móveis em ambiente virtual utilizando mapas topológicos e classificação com opção de rejeição a partir da Matriz de Co-ocorrência Estrutural (SCM) em imagens omnidirecionais. Para comprovar o alto desempenho da técnica considerada, é realizada uma análise entre diversos extratores de características e classificadores, estabelecidos na literatura. Parâmetros como tempo de processamento e precisão são calculados para demonstrar a confiabilidade e eficácia da abordagem, uma vez que essas propriedades são primordiais em sistemas embarcados. Com relação à abordagem proposta, o SCM obteve uma acurácia média de 99,27% e o menor tempo de extração, 0,0786 s, entre todos os extratores de características, mostrando-se um método expressivo nas atividades de localização e navegação. O SCM também alcançou 100% de precisão nos testes de navegação.

Abstract: In Robotics, location is an essential task, allowing the robot to navigate and thus carry out its activities. In this article, we propose a new approach to localization and navigation for mobile robots in a virtual environment using topological maps and classification with an option to reject from the Structural Co-occurrence Matrix (SCM) in omnidirectional images. To prove the high performance of the considered technique, an analysis is performed between several feature extractors and classifiers, established in the literature. Parameters such as processing time and accuracy are calculated to demonstrate the reliability and effectiveness of the approach, since these properties are paramount in embedded systems. Regarding the proposed approach, the SCM obtained an average accuracy of 99.27% and the shortest extraction time, 0.0786s, among all the feature extractors, proving to be an expressive method in the activities of location and navigation. SCM also achieved 100% accuracy in navigation tests.

Keywords:

Robô Móvel, Matriz de Co-ocorrência Estrutural, Visão Computacional, Imagem Omnidirecional, Mapas Topológicos, Opção de Rejeição.

1. INTRODUÇÃO

Cada vez mais, a Robótica Móvel vem sendo aplicada nas mais variadas soluções, consequência dos avanços alcançados nessa área. Em Raffik et al. (2021), robôs cortadores de ervas daninhas são utilizados para remover essas plantas indesejadas, com o objetivo de minimizar o uso de herbicidas no campo agrícola. Enquanto em Zhou et al. (2021), um robô é empregado para inspeção automática de túnel de cabos em ambiente complexo.

Para a localização e a navegação do robô móvel, o mapeamento do ambiente é um recurso amplamente utilizado. Os métodos de mapeamento são classificados como método geométrico, no qual o espaço de navegação é descrito através de um sistema de coordenadas, como em Jiang et al. (2017), método topológico, em que o ambiente de navegação corresponde a um grafo, como observado em Chin et al. (2016), e há ainda o método híbrido, correspondente ao uso simultâneo dos métodos geométrico e topológico, como em Akai and Ozaki (2015).

Para realizar a sua navegação, o robô necessita localizar-se no espaço, pois essa é uma função primordial. Portanto, dependendo do ambiente que será explorado por ele, existe uma diversidade de recursos tecnológicos que podem ser utilizados. Quando são considerados ambientes externos, o Sistema de Posicionamento Global (Global Positioning System - GPS) é uma ferramenta de navegação robusta e pode ser empregada para o reconhecimento de locais Saito and Kuroda (2013). Entretanto, esse recurso não é viável quando ambientes internos são considerados Diop et al. (2016) e, visto isso, outros métodos foram desenvolvidos. Para a localização de robôs móveis em ambientes internos, técnicas como Identificação por Radiofrequência (Radio Frequency Identification - RFID), Rede Local sem Fio (Wireless Local Area Network - WLAN), ultrassom, navegação por inércia e reconhecimento de imagem são algumas das mais aplicadas Song et al. (2011).

O uso de processos de reconhecimento de imagem na tarefa de navegação tem sido amplamente explorado, principalmente em áreas como visão computacional integrada com engenharia de controle e automação Bonin-Font et al. (2008), permitindo que o robô realize uma navegação visual. Dentre as vantagens desse tipo de navegação está o não comprometimento do seu desempenho por limite de frequência, como pode ocorrer ao usar o Bluetooth, ou por interferência sonora, como no ultrassom. Além disso, esse tipo de sistema não requer mudanças no ambiente.

As imagens obtidas por um sistema de navegação baseado em visão necessitam ser descritas e comparadas para efetuar as tarefas de mapeamento e localização. Para realizar a descrição, há abordagens fundamentadas em descritores locais, descritores globais e bolsa de palavras (Bag-of-Words - BoW) Li et al. (2016). Em Woo et al. (2011), um processo que combina descritores locais para reconhecer pedestres e veículos foi apresentado. Aldana-

Murillo et al. (2015) aplicou descritores locais no problema de localização baseada em aparência.

Soluções baseadas em descritores globais não são capazes de tratar bem vários problemas visuais, tais como oclusões parciais ou rotações de câmera. Esses problemas foram estudados de forma mais intensa através do recente desenvolvimento dos descritores locais Garcia-Fidalgo and Ortiz (2015). Em Wang et al. (2015), uma técnica para determinar a posição do robô móvel utilizando o algoritmo SURF (do inglês, Speed Up Robust Feature) baseado em imagens de profundidade de um ambiente interno foi proposta. Boroş et al. (2009) aplicou Transformada de Características Invariante à Escala (Scale Invariant Feature Transform - SIFT) para resolver o problema de localização topológica global em ambientes internos.

Nos últimos anos, técnicas de aprendizagem de máquina em conjunto com métodos de visão computacional têm sido largamente aplicados em sistemas de navegação para robôs móveis, pois apresentam uma alta capacidade de aprender padrões complexos e tomar decisões baseadas em dados Yang et al. (2011). Em Charalampous et al. (2015), foi proposta uma técnica de planejamento de caminho local, incluindo o algoritmo de Máquinas de Vetores de Suporte (Support Vector Machines - SVM). Enquanto em Kasat and Thepade (2016), uma abordagem de classificação de imagens foi apresentada utilizando o classificador Bayesiano.

Ambientes virtuais vêm sendo utilizados de forma efetiva em pesquisas em diversos campos Ellis (1994). Esse tipo de recurso oferece como vantagem a possibilidade de moldar um ambiente, viabilizando a adição ou a remoção de estruturas e objetos, além de ser capaz de criar uma experiência mais estável e coordenada Cha et al. (2017), permitindo que sejam analisados problemas que, no ambiente real, não seriam praticáveis. Em Cha et al. (2017), um jogo interativo é projetado para operar um robô de telepresença em um ambiente de sala de aula virtual, objetivando facilitar a pesquisa em telepresença e, assim, melhorar o acesso à educação básica.

Neste artigo, uma nova abordagem para localização de robôs móveis em ambiente interno virtual é proposta, consistindo na utilização de mapas topológicos e no conceito de classificação com opção de rejeição a partir de atributos obtidos através da Matriz de Co-ocorrência Estrutural (Structural Co-occurrence Matrix - SCM), com base em imagens omnidirecionais. Uma comparação com outros extratores de características consolidados, como Matriz de Co-ocorrência de Níveis de Cinza (Gray-Level Co-occurrence Matrix - GLCM), Padrões Binários Locais (Local Binary Patterns - LBP), Momentos Estatísticos (ME), Transformada de Características Invariante à Escala (Scale Invariant Feature Transform - SIFT) e Características Robustas Aceleradas (Speed Up Robust Features - SURF), foi realizada para afirmar a eficiência da técnica em destaque, a SCM. Para a classificação dos atributos obtidos dos extratores de características, o Classificador

Bayesiano, o Perceptron de Múltiplas Camadas (Multi Layer Perceptron - MLP) e as Máquinas de Vetores de Suporte (Support Vector Machines - SVM) foram aplicados. Os filtros passa-alta Laplaciano e Sobel, além dos filtros passa-baixa Gaussiano e de Média foram incorporados à SCM para sua avaliação.

Através dos resultados, conclui-se que a SCM obteve uma acurácia média de 100% durante a navegação, com e sem opção de rejeição, além de conseguir o menor tempo entre os extratores de características considerados, realizando sua tarefa em 0,0786 s, o que contribui para tornar mais rápido o processo de localização e, conseqüentemente, a navegação do robô.

2. VISÃO GERAL DOS MÉTODOS DE EXTRAÇÃO DE CARACTERÍSTICAS

Para este trabalho, a região de interesse (Region Of Interest - ROI) equivale a toda imagem. A seguir, é apresentada uma visão geral das técnicas de extração de características utilizadas.

A Matriz de Co-ocorrência de Níveis de Cinza baseia-se no método desenvolvido pelo pesquisador Robert M. Haralick Haralick (1979) e tem como foco a análise de textura. Essa técnica é um processo estatístico de segunda ordem, que considera as co-ocorrências existentes entre pares de pixels, ou seja, os pixels são verificados em grupos, obedecendo a um critério previamente estabelecido Haralick (1979). GLCM é uma matriz quadrada que armazena as referências das intensidades relativas dos pixels da imagem analisada Haralick et al. (1973).

Padrões Binários Locais também é um algoritmo de extração de características para análise de textura, o qual foi desenvolvido por Timo Ojala Ojala et al. (2002). O operador LBP original associa um rótulo, representado por um número binário, para cada um dos pixels analisados. Para tanto, cada pixel vizinho do pixel em análise é considerado de acordo com um raio e um limiar específicos Ojala et al. (2002). O pixel vizinho que é igual ou excede o valor do limiar será rotulado com o dígito binário 1. Caso contrário, ele será rotulado como 0 (zero) Ojala et al. (2002).

Momentos são grandezas do tipo escalar que podem ser empregadas para descrever uma aplicação e, assim, extrair suas principais características Flusser et al. (2009). Momentos Estatísticos destacam-se como um método bastante aplicado para a extração de atributos em imagens, projetando a ordenação espacial dos pontos pertencente à imagem ou à superfície de interesse Gonzalez and Woods (2010). O conjunto de momentos de uma imagem digital geralmente corresponde às características globais da forma da imagem, ou seja, suas características geométricas.

Transformada de Características Invariante à Escala consiste em um descritor de pontos-chaves criado por David G. Lowe Lowe (2004). Algumas das principais características dessa técnica é manter-se constante às variações de escala e de rotação, além de sofrer pouca modificação quando há alteração na iluminação ou no ponto de vista da imagem Lowe (2004). Os atributos extraídos através desse descritor são bem distintos, o que torna possível compará-los com um grande banco de dados formado por várias imagens Lowe (2004).

Características Robustas Aceleradas é um descritor de pontos-chaves idealizado por Herbert Bay Bay et al. (2008). Esse método tem como característica fundamental especificar pontos estratégicos em imagens. SURF é uma técnica considerada uma otimização da SIFT, sendo sua implementação mais eficaz e rápida Bay et al. (2008). É robusta à ruídos e invariante à rotação. Para a detecção dos pontos-chaves, SURF utiliza uma aproximação da matriz Hessiana e realiza seu processo em duas etapas fundamentais: o detector e o descritor Rebouças Filho et al. (2015).

A Matriz de Co-ocorrência Estrutural representa um método baseado em estatísticas de co-ocorrência e é direcionado para a análise estrutural de sinais discretos, admitindo conexões existentes entre estruturas de baixo nível de dois sinais discretos n -dimensionais Ramalho et al. (2016). Sua característica principal é apresentar um conhecimento prévio sobre as imagens analisadas, ressaltando a detecção de detalhes. Em um histograma bidimensional, a SCM fornece as co-ocorrências entre as estruturas dos sinais de entrada, armazenando em uma matriz as diferenças entre estruturas de dois sinais de entrada Ramalho et al. (2016).

O fluxo de aplicação da SCM para extração de atributos em imagem é demonstrado no quadro 1b da Figura 1. A imagem de entrada é representada pelo bloco f e será comparada com outra imagem $k(f)$, a qual corresponde a uma função da imagem de entrada após a aplicação de um filtro k . Feita a comparação, uma matriz com as diferenças estruturais entre as imagens é obtida. Então, um histograma bidimensional dessa matriz é gerado e, a partir desse histograma, os atributos são extraídos. P expressa o nível de similaridade exigido entre a intensidade dos pixels de f e $k(f)$.

3. VISÃO GERAL DOS MÉTODOS DE APRENDIZAGEM DE MÁQUINA

A partir dos atributos extraídos, a etapa de classificação pode ser realizada. Uma breve descrição das técnicas de aprendizagem de máquina empregadas é apresentada nesta seção.

O Classificador Bayesiano é considerado um método estatístico, sendo aplicado na classificação de objetos de acordo com a probabilidade de cada um desses pertencer a uma determinada classe Koutroumbas and Theodoridis (2008). Essa técnica de aprendizagem de máquina é do tipo supervisionada e baseia-se na Teoria da Decisão de Bayes Koutroumbas and Theodoridis (2008). O Classificador Bayesiano distribui as amostras de acordo com o valor da probabilidade a posteriori, calculada a partir dos valores das densidades condicionais e das probabilidades a priori Koutroumbas and Theodoridis (2008).

O Perceptron Múltiplas Camadas consiste em um conjunto de perceptrons e é destinado à resolução de problemas não-linearmente separáveis Haykin (2008). Esse método inicia-se na camada de entrada, onde o vetor formado pelos dados a serem processados é exposto à rede, produzindo impulsos que se propagarão sucessivamente nas camadas seguintes, conhecidas como camadas ocultas. Através desse processo, uma solução final é apresentada na camada de saída, a partir das informações contidas no vetor inserido na entrada Haykin (2008).

Máquinas de Vetores de Suporte são baseadas na Teoria da Aprendizagem Estatística criada por V. N. Vapnik Vapnick (1998). Essa técnica tem como principal objetivo classificar através de superfícies que aumentem a distância entre as classes. Originalmente, o algoritmo SVM foi projetado para resolver problemas binários, logo, sua aplicação em problemas multiclassificações torna-se complexo. Desse modo, abordagens como um-contra-um Duan and Keerthi (2005) e um-contra-todos Duan and Keerthi (2005) são exemplos de variações do método SVM para a aplicação em questões multiclassificações.

4. METODOLOGIA

Na Figura 1 é apresentado um fluxograma da abordagem proposta. Como mostrado nessa figura, o passo inicial consiste na captura da imagem para, em seguida, serem aplicados os extratores de características. Com isso, é possível realizar o reconhecimento do ambiente a partir dos vetores de atributos obtidos na etapa de extração de características, pois eles serão utilizados como entrada para que os métodos de aprendizagem de máquina cumpram sua tarefa de classificação. Porém, os classificadores podem entregar resultados incoerentes. Para solucionar essa questão, esses resultados podem ser melhorados empregando informações presentes no mapa topológico e, conseqüentemente, otimizar a localização e a navegação do robô.

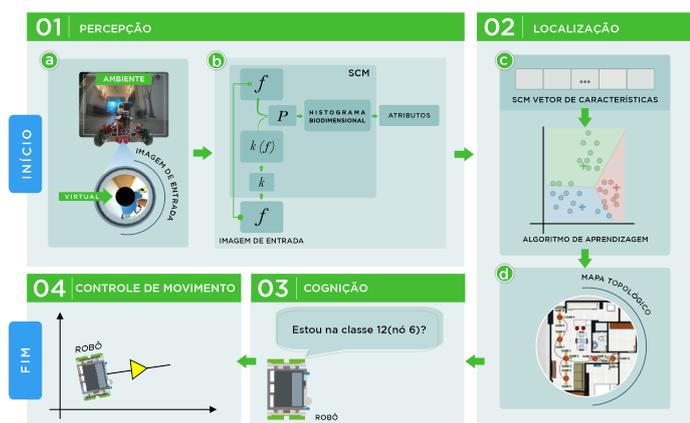


Figura 1. Fluxograma da abordagem proposta para a navegação de robôs móveis.

Na Figura 2, um robô móvel foi equipado com uma câmera omnidirecional, a qual possui uma lente que captura imagens em 360°. Um apartamento foi o ambiente interno escolhido para realização desse trabalho. Esse tipo de ambiente foi adotado por apresentar características que contribuem para o reconhecimento e a navegação do robô. As imagens do ambiente virtual foram adquiridas com o auxílio de simuladores que possibilitaram a modelagem do ambiente com campo de visão omnidirecional. Os simuladores Sketchup J (2013) e V-Ray Li-zhen (2010) foram empregados, de forma conjunta, para modelar o ambiente.

O mapa topológico do robô está organizado em nós, os quais foram numerados de 1 a 6. A captura das imagens foi efetuada em locais estratégicos nas posições das classes numeradas de 1 a 15, determinando as possíveis trajetórias para o robô durante sua locomoção. O mapa topológico com os nós e as classes, assim como a vista em perspectiva



Figura 2. Robô equipado com câmera omnidirecional.

do apartamento são mostrados nas Figuras 3(a) e 3(b), respectivamente.

Na etapa de extração de características, utilizaram-se Momentos Estatísticos de ordem 0, 1, 2 e 3. Para a GLCM, a distância $D = 1$ e a direção $\theta = 0$ foram configuradas. Quanto ao método LBP, foi aplicada a sua versão com padrões uniformes, com o objetivo de reduzir a dimensionalidade do problema. O número de atributos retornados por cada extrator de características foi 10, 14, 59 e 8, respectivamente, para Momentos Estatísticos, GLCM, LBP e SCM.

Para a etapa de classificação, os hiperparâmetros para SVM e MLP foram selecionados através das técnicas de validação cruzada (em inglês, cross-validation) com 10 folds e de busca em grade (em inglês, grid search). Os kernels linear e RBF (do inglês, Radial Basis Function) foram utilizados para o classificador SVM, bem como foi adotado o intervalo [2-2, 211] para a busca de seus hiperparâmetros, definido com base no estudo apresentado em Hsu et al. (2003). A rede MLP foi treinada com base no método Levenberg-Marquardt e com um intervalo de neurônios de 1 a 50 na camada oculta. Para o classificador Bayesiano, adotou-se a função de densidade de probabilidade Gaussiana, também conhecida como função normal.



Figura 3. Mapa topológico do ambiente: (a) vista superior e (b) vista em perspectiva.

Para realizar os testes de navegação, um total de 10 rotas variadas foram consideradas no apartamento. Os comandos usados para mover o robô, bem como o ponto inicial e final de cada rota são apresentados na Tabela 1.

Tabela 1. Comandos para mover o robô e os pontos inicial e final utilizados no teste de navegação. Seguir em frente (SF), virar à esquerda (VE), virar à direita (VD) e girar 180 graus (G180).

Rota	Classe Inicial	Comandos	Classe Final
1	8	SF, SF, SF	4
2	1	SF, SF, VD	9
3	5	SF e VD, SF, SF	12
4	5	SF, SF, SF e VD, VE	10
5	8	SF, SF e VE, SF, SF	12
6	13	SF, SF e VE, SF, G180, SF	1
7	8	SF, SF, VE, SF, SF	12
8	9	VD, SF, SF e VE, SF, G180, SF e VE	3
9	2	SF, SF e VD, VD, SF, SF e VE	3
10	12	G180, SF, SF e VE, SF, G180, SF, SF, SF	10

Para um melhor entendimento da tarefa de navegação, a rota 5 é exemplificada na Figura 4. Na execução dessa rota, o robô inicia na classe 8 (nó 1), quando dois comandos para seguir em frente são enviados, sendo também emitido, de forma consecutiva, um comando para virar à esquerda. Para concluir, após virar à esquerda, o robô recebe, em sequência, mais dois comandos para seguir em frente, chegando ao seu destino, o qual corresponde à classe 12 (nó 6).

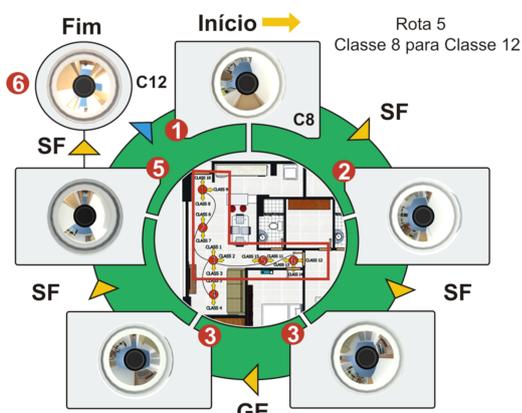


Figura 4. Demonstração da rota 5.

A opção de rejeição consiste em um método que descarta uma amostra quando ela não é considerada confiável, de acordo com um critério pré-estabelecido Gamelas Sousa et al. (2015). Embora os classificadores mostrem um desempenho convincente, algumas previsões gerariam uma resposta mais adequada se fossem descartadas ou se uma outra regra de definição fosse adotada. Logo, a opção de rejeição pode ser utilizada para melhorar o desempenho do classificador na tarefa de tomada de decisão, aumentando sua precisão Gamelas Sousa et al. (2015). Em Ganeshkumar et al. (2017), a opção de rejeição é empregada para reduzir taxas falsas de detecção na execução da decodificação de eletroencefalograma (EEG) de imagens motoras. Enquanto em Marinho et al. (2017), informações do mapa topológico são usadas automaticamente para otimizar o

modo de decisão dos classificadores para a tarefa de localização e, conseqüentemente, de navegação do robô.

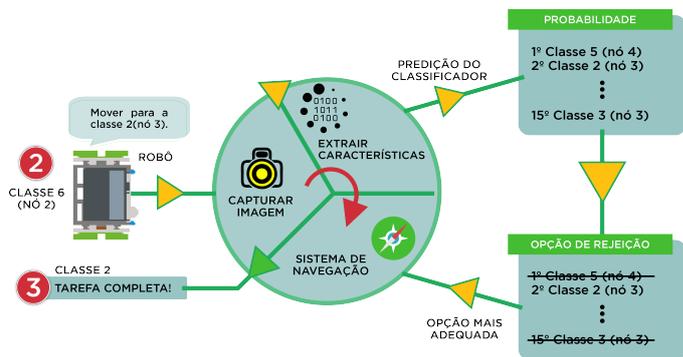


Figura 5. Situação hipotética em que o classificador prevê que existe uma maior probabilidade de a posição atual ser um lugar longe do real.

Com o objetivo de facilitar a compreensão da operação com opção de rejeição na abordagem proposta, uma situação hipotética é representada na Figura 5. O robô está em um local correspondente à classe 6 (nó 2) e recebe comandos para mover-se para a classe 2 (nó 3). Após o robô alcançar seu destino, o classificador prevê que existe uma alta probabilidade de o local atingido tratar-se da classe 5 (nó 4) e uma segunda maior probabilidade de ser a classe 2 (nó 3), o que consiste em um erro de localização. Se o robô utilizasse alguma informação extra, como uma vizinhança entre os nós do mapa topológico, poderia evitar a primeira opção da classificação, já que não é possível alcançar o nó 4 diretamente da posição de partida (nó 2). Nesse contexto, a opção de rejeição descarta a primeira probabilidade retornada pelo classificador e, então, escolhe a sugestão seguinte, segundo o critério de vizinhança do mapa topológico.

O banco de dados utilizado é formado de 50 imagens por classe, totalizando 750 imagens, todas com uma resolução de 800 × 600 pixels. Ele encontra-se disponível em http://lapisco.ifce.edu.br/?page_id=228. Para verificar o desempenho de cada classificador e compará-los, através de um critério consolidado, foram consideradas duas métricas de avaliação: Acurácia (Acc) e F1-Score (F1S).

5. RESULTADOS

De início, o comportamento dos extratores de características nas imagens é avaliado em conjunto com os classificadores. Logo após, os testes de navegação são executados. Os resultados do teste de navegação representam a média dos valores de 10 execuções efetuadas em cada rota. Os valores médios, juntamente com seus desvios-padrões, de Acurácia e F1-Score são mostrados na Tabela 2. Os descritores SIFT e SURF foram tratados individualmente. O processamento foi realizado em um iMac 2.5GHz, com processador Core i5 e 4GB de memória RAM.

Tabela 2. F1-Score (F1s) E Acurácia (Acc) Obtidos Pelos Extratores De Características E Classificadores.

Extrator	Classificador	Configuração	F1S (%)	Acc (%)
SCM-Med	Bayes	Normal	99.27±0.58	99.27±0.58
	MLP		98.27±0.90	98.27±0.90
	SVM	Linear	93.41±2.16	93.20±2.33
RBF		98.08±0.91	98.07±0.91	
SCM-Gau	Bayes	Normal	95.64±0.92	95.47±0.88
	MLP		92.85±3.41	92.20±4.47
	SVM	Linear	88.88±2.19	88.60±2.38
RBF		93.14±2.13	93.00±2.11	
SCM-Lap	Bayes	Normal	98.41±1.13	98.40±1.14
	MLP		95.31±1.39	95.27±1.39
	SVM	Linear	93.56±1.11	93.53±1.14
		RBF	95.03±1.03	95.00±1.05
SCM-Sob	Bayes	Normal	99.00±0.71	99.00±0.72
	MLP		97.28±1.25	96.67±2.31
	SVM	Linear	97.54±1.07	97.53±1.09
RBF		97.63±0.93	97.60±0.95	
ME	Bayes	Normal	98.80±0.34	98.39±0.14
	MLP		89.46±2.80	89.44±2.84
	SVM	Linear	96.49±0.22	96.44±0.30
RBF		97.03±0.35	96.34±0.26	
GLCM	Bayes	Normal	90.11±3.17	88.00±3.91
	MLP		91.76±5.20	89.33±6.63
	SVM	Linear	96.49±3.29	96.33±3.31
		RBF	92.49±3.10	92.00±2.81
LBP	Bayes	Normal	100.00±0.0	100.00±0.0
	MLP		97.42±3.00	97.00±3.67
	SVM	Linear	99.69±0.98	99.67±1.05
RBF		100.00±0.0	100.00±0.0	
SIFT			97.92±1.64	98.01±1.59
SURF			88.22±2.75	88.13±2.70

Como apresentado na Tabela 2, LBP foi o extrator de características que obteve os maiores valores de Acurácia e F1-Score, alcançando 100% quando combinado ao Classificador Bayesiano e à técnica SVM (RBF), e 99.69% quando associado à técnica SVM (Linear), sendo o mesmo valor para ambas as métricas. SCM vem em seguida, atingindo 99.27% e 99.00% em suas versões com o filtro de Média e de Sobel, respectivamente, ambas em conjunto com o Classificador Bayesiano. Todos os valores encontram-se destacados em negrito na Tabela 2. Dentre os classificadores, o Classificador Bayesiano sobressai-se por conseguir os melhores resultados tanto em Acurácia quanto em F1-Score em combinação com quase todos os extratores de características, exceto à GLCM.

Tabela 3. acurácia (acc), tempo de treino, tempo de teste e tempo de extração para todas as combinações.

Classificador	Acc (%)	Tempo de treino (s)	Tempo de teste (s)	Tempo de extração (s)
SCM - Média				
Bayes (Normal)	99.3±0.6	0.005±0.002	68.6±19.9	
MLP	98.3±0.9	71.592±16.226	122.6±16.0	0.0810±0.0059
SVM (Linear)	93.2±2.3	33.645±6.219	30.0±0.2	
SVM (RBF)	98.1±0.9	0.515±0.025	44.6±4.8	
SCM - Gaussiano				
Bayes (Normal)	95.5±0.9	0.004±0.002	62.7±18.7	
MLP	92.2±4.5	27.147±12.423	122.8±9.7	0.0800±0.0055
SVM (Linear)	88.6±2.4	126.455±26.234	31.0±0.4	
SVM (RBF)	93.0±2.1	1.114±0.059	42.2±3.5	
SCM - Laplaciano				
Bayes (Normal)	98.4±1.1	0.005±0.001	58.0±9.3	
MLP	95.3±1.4	8.222±2.374	122.8±19.2	0.0793±0.005
SVM (Linear)	93.5±1.1	28.382±8.283	32.0±3.0	
SVM (RBF)	95.0±1.0	0.417±0.032	44.6±5.9	
SCM - Sobel				
Bayes (Normal)	99.0±0.7	0.003±0.002	64.6±19.5	
MLP	96.7±2.3	17.546±4.871	118.0±12.3	0.0786±0.0055
SVM (Linear)	97.5±1.1	5.616±1.481	32.5±3.9	
SVM (RBF)	97.6±0.9	0.433±0.033	42.8±5.2	
ME				
Bayes (Normal)	98.4±0.1	0.005±0.014	841.9±836.3	
MLP	89.4±2.8	1.506±0.029	320.4±5.2	0.1621±0.0344
SVM (Linear)	96.4±0.3	0.255±0.012	286.2±284.3	
SVM (RBF)	96.3±0.3	2.646±0.024	1126.3±1118.8	
GLCM				
Bayes (Normal)	88.0±3.9	0.008±0.002	320.6±71.9	
MLP	89.3±6.6	76.414±36.718	620.5±82.7	0.0997±0.0126
SVM (Linear)	96.3±3.3	1.510±0.310	152.7±26.2	
SVM (RBF)	92.0±2.8	0.157±0.008	160.8±2.2	
LBP				
Bayes (Normal)	100.0±0.0	0.013±0.005	743.4±202.0	
MLP	97.0±3.7	109.314±39.586	537.5±28.0	0.2012±0.0086
SVM (Linear)	99.7±1.1	0.167±0.007	187.3±5.4	
SVM (RBF)	100.0±0.0	0.157±0.009	206.5±3.7	
SIFT	98.0±1.6	4.114±0.143	538267.1±	0.3321±0.0198
SURF	88.1±2.7	2.029±1.858	322849.6±	0.2564±0.0265
			362856.0	

Como o problema em questão trata-se de uma aplicação real, é importante também destacar o custo computacional demandado. Na Tabela III, a acurácia, o tempo de treinamento, o tempo de teste e o tempo de extração são apresentados, uma vez que são parâmetros essenciais na avaliação de sistemas embarcados. O Classificador Bayesiano foi o mais rápido no treinamento, conquistando os menores tempos em conjunto com todos os extratores de características. As melhores marcas em tempo de treinamento desse classificador foram de 0.003s, quando combinado com SCM-Sobel, de 0.004s, quando associado com SCM-Gaussiano, e de 0.005s, em conjunto com SCM-Média e SCM-Laplaciano. Na etapa de teste, SVM (Linear) destaca-se por cumprir essa tarefa no melhor tempo em combinação com todos os extratores de características, sendo seus menores valores 30µs, 31µs, 32µs e 32.5µs junto com SCM-Média, SCM-Gaussiano, SCM-Laplaciano e SCM-Sobel, respectivamente.

Figura 6. Acurácia média do teste de navegação, com e sem opção de rejeição, obtida pela combinação entre os classificadores e extratores de características.

Observando a última coluna da Tabela III, constata-se que os menores tempos de extração estão vinculados à SCM, realizando sua tarefa em 0.0786s, 0.0793s, 0.0800s e 0.0810s em suas versões com o filtro de Sobel, Laplaciano, Gaussiano e de Média, respectivamente. Em contrapartida, SIFT e SURF retornaram os maiores tempos de extração, com os valores de 0.3321s e 0.2564s, nessa ordem. Todos os valores de tempo ressaltados encontram-se destacados em negrito na Tabela III.

Posterior ao processamento isolado de cada imagem, os métodos considerados foram aplicados para a realização

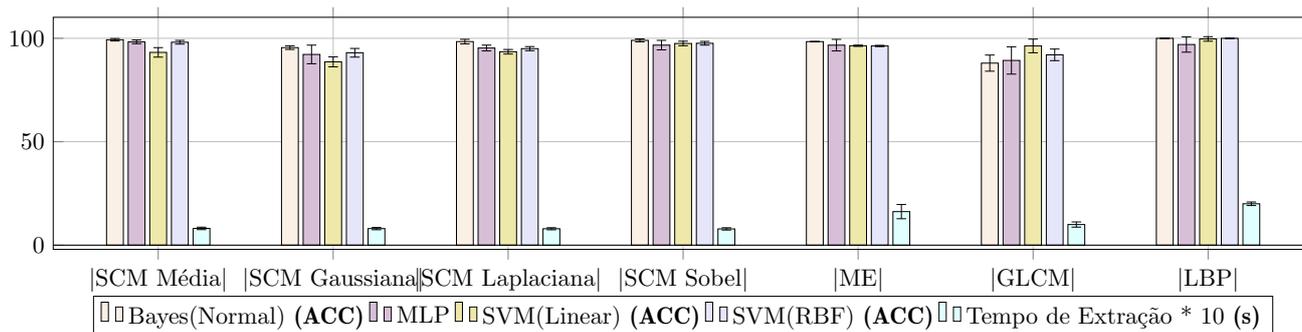


Figura 6. Acurácia e tempo de extração das combinações de extratores da tabela 3

dos testes de navegação. Os resultados dos testes de navegação são mostrados na Figura 6. É importante ressaltar que uma rota é apontada como correta quando o sistema de navegação, o qual é baseado em visão, identifica todos os pontos (classes) do percurso.

De acordo com a Figura 6, SCM-Média e SCM-Sobel alcançaram uma acurácia média de 100% nos testes de navegação, sem e com opção de rejeição, quando associado ao Classificador Bayesiano. Observa-se ainda que a opção de rejeição, aumentou, na maioria das vezes, ou manteve o valor da acurácia em todas as combinações, como no conjunto SCM-Média com SVM (Linear), que tinha uma acurácia média de 60% e atingiu 100% com a opção de rejeição, e SCM-Gaussiana com Classificador Bayesiano, o qual aumentou de 91% para 100% a sua acurácia média quando considerada a opção de rejeição. Esse fato demonstra que a opção de rejeição traz confiabilidade e eficiência para o processo de localização e navegação do robô.

6. CONCLUSÃO

Neste artigo, é proposta uma nova abordagem para localização de robôs móveis em ambiente interno simulado, utilizando mapas topológicos e classificação com opção de rejeição em atributos provenientes da Matriz de Co-ocorrência Estrutural (SCM). As imagens empregadas são derivadas de uma câmera omnidirecional e passam por um processo de transformação, através do uso de simuladores, para representarem um ambiente virtual. Ademais, também foi realizado um estudo entre vários modelos de extratores de características e classificadores firmados na literatura.

Obedecendo os mesmos critérios aplicados em Marinho et al. (2017) e considerando os resultados obtidos com a utilização da abordagem proposta, SCM comprova-se como uma alternativa poderosa para a tarefa de localização e consequentemente navegação de robôs móveis, alcançando um tempo de extração de 0.0786s, o menor valor entre todos os extratores de características analisados, contribuindo, portanto, para a otimização do processo.

Apesar da técnica LBP ter atingido 100% de Acurácia e F1-Score, SCM torna-se superior por apresentar os melhores tempos de extração e proporcionar os menores tempos de treino e de teste quando combinado ao Classificador Bayesiano e ao método SVM (Linear), respectivamente, o que torna insignificante a diferença de 0.73% entre seu

melhor valor, correspondente a 99.27%, e o melhor valor da técnica LBP nas métricas de avaliação consideradas. A opção de rejeição também provou ser uma técnica valiosa, aumentando a eficiência do sistema e firmando a sua confiabilidade.

Para trabalhos futuros, ambientes externos bem como outros ambientes internos podem ser explorados com o robô. Além disso, sugere-se a utilização de imagens derivadas de outras fontes, com resoluções diferentes, como o sensor Microsoft Kinect, e, ainda, a aplicação de outros métodos de aprendizagem de máquina, como a Floresta de Caminhos Ótimos (do inglês, Optimum Path Forest - OPF) Nunes et al. (2014), e a incorporação de outros filtros à SCM.

REFERÊNCIAS

- Akai, N. and Ozaki, K. (2015). A navigation method based on topological magnetic and geometric maps for outdoor mobile robots. In *2015 IEEE/SICE International Symposium on System Integration (SII)*, 352–357. IEEE.
- Aldana-Murillo, N.G., Hayet, J.B., and Becerra, H.M. (2015). Evaluation of local descriptors for vision-based localization of humanoid robots. In *Mexican Conference on Pattern Recognition*, 179–189. Springer.
- Bay, H., Ess, A., Tuytelaars, T., and Van Gool, L. (2008). Speeded-up robust features (surf). *Computer vision and image understanding*, 110(3), 346–359.
- Bonin-Font, F., Ortiz, A., and Oliver, G. (2008). Visual navigation for mobile robots: A survey. *Journal of intelligent and robotic systems*, 53(3), 263–296.
- Boroş, E., Roşca, G., and Iftene, A. (2009). Using sift method for global topological localization for indoor environments. In *Workshop of the Cross-Language Evaluation Forum for European Languages*, 277–282. Springer.
- Cha, E., Greczek, J., Song, A., and Matarić, M.J. (2017). My classroom robot: Exploring telepresence for k-12 education in a virtual environment. In *2017 26th IEEE international symposium on robot and human interactive communication (RO-MAN)*, 689–695. IEEE.
- Charalampous, K., Kostavelis, I., and Gasteratos, A. (2015). Thorough robot navigation based on svm local planning. *Robotics and Autonomous Systems*, 70, 166–180.
- Chin, W.H., Loo, C.K., Seera, M., Kubota, N., and Toda, Y. (2016). Multi-channel bayesian adaptive resonance associate memory for on-line topological map building. *Applied Soft Computing*, 38, 269–280.

- Diop, M., Ong, L.Y., Lim, T.S., and Lim, C.H. (2016). A computer vision-aided motion sensing algorithm for mobile robot's indoor navigation. In *2016 IEEE 14th International Workshop on Advanced Motion Control (AMC)*, 400–405. IEEE.
- Duan, K.B. and Keerthi, S.S. (2005). Which is the best multiclass svm method? an empirical study. In *International workshop on multiple classifier systems*, 278–285. Springer.
- Ellis, S.R. (1994). What are virtual environments? *IEEE Computer Graphics and Applications*, 14(1), 17–22.
- Flusser, J., Zitova, B., and Suk, T. (2009). *Moments and moment invariants in pattern recognition*. John Wiley & Sons.
- Gamelas Sousa, R., Rocha Neto, A.R., Cardoso, J.S., and Barreto, G.A. (2015). Robust classification with reject option using the self-organizing map. *Neural Computing and Applications*, 26(7), 1603–1619.
- Ganeshkumar, M., Ang, K.K., and So, R.Q. (2017). Reject option to reduce false prediction rates for eeg-motor imagery based bci. In *2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 2964–2967. IEEE.
- Garcia-Fidalgo, E. and Ortiz, A. (2015). Vision-based topological mapping and localization methods: A survey. *Robotics and Autonomous Systems*, 64, 1–20.
- Gonzalez, R.C. and Woods, R.E. (2010). *Digital Image Processing*. Prentice Hall.
- Haralick, R.M. (1979). Statistical and structural approaches to texture. *Proceedings of the IEEE*, 67(5), 786–804.
- Haralick, R.M., Shanmugam, K., and Dinstein, I.H. (1973). Textural features for image classification. *IEEE Transactions on systems, man, and cybernetics*, (6), 610–621.
- Haykin, S. (2008). *Neural networks and learning machines*. Prentice Hall.
- Hsu, C.W., Chang, C.C., Lin, C.J., et al. (2003). A practical guide to support vector classification.
- J, G. (2013). *Sketchup Pro 2013 Step by Step*. GetPro Books.
- Jiang, R., Yang, S., Ge, S.S., Wang, H., and Lee, T.H. (2017). Geometric map-assisted localization for mobile robots based on uniform-gaussian distribution. *IEEE Robotics and Automation Letters*, 2(2), 789–795.
- Kasat, N.R. and Thepade, S.D. (2016). Novel content based image classification method using lbg vector quantization method with bayes and lazy family data mining classifiers. *Procedia Computer Science*, 79, 483–489.
- Koutroumbas, K. and Theodoridis, S. (2008). *Pattern recognition*. Academic Press.
- Li, W., Dong, P., Xiao, B., and Zhou, L. (2016). Object recognition based on the region of interest and optimal bag of words model. *Neurocomputing*, 172, 271–280.
- Li-zhen, X. (2010). Vray render 3ds max scene rendering techniques. *Coal Technology*.
- Lowe, D.G. (2004). Distinctive image features from scale-invariant keypoints. *International journal of computer vision*, 60(2), 91–110.
- Marinho, L.B., Almeida, J.S., Souza, J.W.M., Albuquerque, V.H.C., and Rebouças Filho, P.P. (2017). A novel mobile robot localization approach based on topological maps using classification with reject option in omnidirectional images. *Expert Systems with Applications*, 72, 1–17.
- Nunes, T.M., Coelho, A.L., Lima, C.A., Papa, J.P., and De Albuquerque, V.H.C. (2014). Eeg signal classification for epilepsy diagnosis via optimum path forest—a systematic assessment. *Neurocomputing*, 136, 103–123.
- Ojala, T., Pietikainen, M., and Maenpaa, T. (2002). Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on pattern analysis and machine intelligence*, 24(7), 971–987.
- Raffik, R., Mayukha, S., Hemchander, J., Abishek, D., Tharun, R., and Deepak Kumar, S. (2021). Autonomous weeding robot for organic farming fields. In *2021 International Conference on Advancements in Electrical, Electronics, Communication, Computing and Automation (ICAECA)*, 1–4. doi:10.1109/ICAECA52838.2021.9675563.
- Ramalho, G.L.B., Ferreira, D.S., Rebouças Filho, P.P., and de Medeiros, F.N.S. (2016). Rotation-invariant feature extraction using a structural co-occurrence matrix. *Measurement*, 94, 406–415.
- Rebouças Filho, P.P., Moreira, F.D.L., Xavier, F.G.d.L., Gomes, S.L., Santos, J.C.d., Freitas, F.N.C., and Freitas, R.G. (2015). New analysis method application in metallographic images through the construction of mosaics via speeded up robust features and scale invariant feature transform. *Materials*, 8(7), 3864–3882.
- Saito, T. and Kuroda, Y. (2013). Mobile robot localization using multiple observations based on place recognition and gps. In *2013 IEEE International Conference on Robotics and Automation*, 1548–1553. IEEE.
- Song, Z., Jiang, G., and Huang, C. (2011). A survey on indoor positioning technologies. In *International conference on theoretical and mathematical foundations of computer science*, 198–206. Springer.
- Vapnick, V.N. (1998). *Statistical learning theory*. Wiley, New York.
- Wang, Z., Hwang, Y.S., Kim, Y.k., Lee, D.H., and Lee, J. (2015). Notice of removal: Mobile robot indoor localization using surf algorithm based on lrf sensor. In *2015 54th annual conference of the society of instrument and control engineers of Japan (SICE)*, 1122–1125. IEEE.
- Woo, J.W., Lim, Y.C., and Lee, M. (2011). Dynamic obstacle identification based on global and local features for a driver assistance system. *Neural Computing and Applications*, 20(7), 925–933.
- Yang, H., Shao, L., Zheng, F., Wang, L., and Song, Z. (2011). Recent advances and trends in visual tracking: A review. *Neurocomputing*, 74(18), 3823–3831.
- Zhou, Y., Wang, X., Chen, Y., Jiang, X., Wang, C., Yuan, J., and Wu, C. (2021). Automatic inspection method of cable tunnel in complex environment based on quadruped robot. In *2021 IEEE 3rd International Conference on Frontiers Technology of Information and Computer (ICFTIC)*, 599–603. doi:10.1109/ICFTIC54370.2021.9647084.