

Classificação de Fluxo de Dados para Visão Computacional Embarcada

Fernando Morgado Pires Neto¹, Guilherme Pina Cardim¹

¹Departamento de Computação – Universidade Estadual de Londrina (UEL)
Caixa Postal 10.011 – CEP 86057-970 – Londrina – PR – Brasil

Abstract. *The automated guided vehicles (AGV) are a type of industrial robot that helps to improve logistics and mobility in its area. They contain several sensors, such as depth cameras, that assist them to see and locate themselves in the environment. AGVs must have the ability to quickly respond to events happening in their surroundings, and to achieve that, they must process the data coming from their sensors in real time. This project seeks to investigate state-of-the-art algorithms in Embedded Computer Vision for fast classification of the presence of obstacles in the scene, and aims to be a starting point for future projects that may want to optimize them.*

Resumo. *Os veículos guiados automatizados (automated guided vehicles - AGV) são uma categoria de robô industrial que ajudam a melhorar a logística e mobilidade do setor. Eles contêm sensores, como câmeras de profundidade, que os ajudam a enxergarem e se localizarem no ambiente. Os AGVs devem responder rapidamente aos eventos que acontecem ao seu redor e, para isso, necessitam processar os dados de seus sensores em tempo real. O presente projeto visa investigar o estado da arte de algoritmos na área de Visão Computacional Embarcada para classificação rápida da presença de obstáculos na cena, e almeja ser um ponto de partida para projetos futuros que queiram otimizá-los.*

1. Introdução

Os desenvolvimentos tecnológicos modernos têm potencializado diversas áreas da vida cotidiana, sendo o setor industrial um dos mais beneficiados. As novas tecnologias que surgiram focaram em melhorias no processo produtivo – ponto-chave para o crescimento econômico das indústrias [10].

Dentre essas tecnologias, uma que se destaca são os *automated guided vehicles* (AGV). O AGV é um robô industrial que possui sensores capazes de situarem sua posição no espaço e, desta forma, fazer com que ele seja capaz de se movimentar de forma autônoma [5]. Assim, ele é capaz de trazer melhorias para a logística do ambiente onde ele é instalado, o que proporciona redução de custos e otimiza o processo de automação da indústria.

Devido aos requisitos de se trabalhar em um ambiente industrial, os AGVs devem ser precisos e seguros. Todas as suas ações devem ser processadas em tempo real, para dar ao robô a capacidade de responder rapidamente aos eventos que acontecem ao seu redor [12]. Esta peculiaridade torna esta categoria de robô um grande desafio tecnológico, devido à necessidade de otimizar cada um dos seus aspectos, tanto do lado do *hardware* como do *software*.

A maioria dos AGVs modernos utiliza uma câmera de profundidade para criar uma imagem virtual precisa do ambiente e identificar possíveis obstáculos. No entanto, essa configuração requer um *hardware* robusto para processar o fluxo de dados proveniente desse sensor. Por conta disso, o projetista do sistema deve saber balancear o desempenho do algoritmo de processamento com gasto energético do robô, para que seus outros sistemas continuem funcionando normalmente [5].

Objetiva-se então, através do presente projeto, realizar um estudo da literatura para analisar os melhores algoritmos de Visão Computacional Embarcada para classificação de obstáculos em tempo real.

A divisão deste documento se dará da seguinte forma: a Seção 2 traz mais informações sobre os conceitos que serão abordados no projeto; a Seção 3 mostra os objetivos pretendidos com o desenvolvimento do trabalho; a Seção 4 apresenta os processos e etapas que serão realizados durante a execução do projeto; a Seção 5 exhibe o cronograma proposto para divisão de atividades do projeto; por fim, a Seção 6 traz os resultados pretendidos ao final do desenvolvimento, e as possíveis contribuições que este trabalho irá proporcionar.

2. Fundamentação Teórico-Metodológica e Estado da Arte

Nas subseções a seguir, estarão descritos os principais conceitos que serão abordados ao decorrer deste projeto, bem como a revisão literária das técnicas e metodologias utilizadas.

2.1. Visão Computacional

A visão computacional é o campo de estudo que busca utilizar métodos estatísticos para destrinchar os dados obtidos de imagens em modelos matemáticos [3]. Ainda nessa área, há também o estudo dos componentes embarcados, que possui um foco maior no *hardware* empregue na captação, transmissão e processamento da imagem. Dessa forma, ela busca aumentar a eficiência dos componentes utilizados ao analisar todo o fluxo de dados obtido através da aquisição da imagem, até as operações que serão realizadas [8].

Dentre algumas técnicas de visão computacional, destacam-se as de processamento antes de a imagem ser analisada pelos algoritmos de classificação. A conversão de canais RGB para outros sistemas de cores, análise individual de banda e filtragem de pixels são algumas das técnicas utilizadas no tratamento dos dados oriundos da câmera [3]. Através delas, é possível extrair apenas as informações necessárias do *frame* e diminuir o custo computacional requerido para processar o fluxo de dados.

No âmbito de embarcados, há o estudo preliminar dos componentes que serão utilizados para a aquisição e processamento dos dados. Para captura de imagem, as câmeras são as melhores opções. Elas são leves, não consomem muita energia, e possibilitam coletar uma quantidade abundante de informações acerca do ambiente [12]. Para o processamento dos dados, em um sistema embarcado, o ideal é possuir um hardware dedicado para analisar o fluxo de dados oriundos da câmera [8].

2.2. Classificação de Fluxo de Dados

A Classificação de Fluxo de Dados é uma categoria de aprendizado incremental para altas taxas de transmissão de dados, que resolve problemas que possuem tempo

limitado de processamento e memória, e onde só há a possibilidade de análise única do dado recebido. Além disso, ela deve ser adaptativa, tendo em vista que boa parte de suas aplicações são feitas em ambientes não-estacionários, onde os dados recolhidos podem mudar com o tempo [2]. O uso dessa categoria torna-se, então, oportuno, pois se encaixa com a problemática e cenário previstos para um AGV.

2.2.1. Seleção dos algoritmos

Para a seleção dos algoritmos de classificação de fluxo de dados, devem ser considerados os seguintes requisitos [1] [2]:

1. Processar apenas um exemplo e inspecioná-lo apenas uma única vez;
2. Utilizar uma quantidade limitada de memória;
3. Estar pronto para classificar a qualquer momento;
4. Estar preparado para se ajustar ao desvio de conceito¹

Essas características garantem que o algoritmo se adapte a qualquer ambiente que ele for instalado, enquanto produz um resultado preditivo consistente. Os algoritmos de *Machine Learning* (ML) são os que mais se enquadram nessa categoria. Dentre aqueles que se adéquam a classificação de fluxo de dados, idealmente, para o uso no presente projeto, evidencia-se o *One Class Classification* (OCC) [14].

O algoritmo OCC produz uma resposta binária, e detecta dados que fogem do padrão apresentado nas classes utilizadas para treino [6]. No caso, ele seria treinado com cenas que não possuem obstáculos e, ao surgirem elementos no *frame*, apontaria a divergência (presença de obstáculo). Por conta disso, ele possui um rápido processamento e, devido ao seu grande uso em aplicações e na literatura, já existem diversas implementações em bibliotecas e *frameworks* [7].

Contudo, devido a natureza do problema presente neste projeto, e a robustez apresentada pelos algoritmos de ML, seu uso nesta situação pode ser considerado como *over-killing*². Dessa forma, a utilização de técnicas estatísticas para a classificação do fluxo de dados pode ser uma alternativa aos modelos de ML [4].

Métodos como o ARIMA (*Autoregressive Integrated Moving Average*) e CUSUM (*Cummulative Sum*) já são consolidados na literatura, e ambos resultam em uma resposta de detecção de anomalia similar ao algoritmo de ML apresentado anteriormente. Enquanto o primeiro utiliza de um modelo auto-regressivo de média móvel [13], o segundo analisa de forma sequencial a soma acumulativa do parâmetro dado ao algoritmo [11]. Pretende-se, então, realizar um estudo comparativo entre os três algoritmos citados para verificar qual dos três se desempenha melhor no cenário apresentado.

2.3. Metodologia para comparação dos algoritmos

Para analisar o resultado obtido dos algoritmos, e também compreender o impacto no sistema embarcado, se faz necessário uma metodologia que estude a relação do *software* com o *hardware*. Com essa finalidade, o estudo de *Four-Way Performance*

¹Quando os dados analisados mudam com o tempo de maneira imprevista

²Uso a mais do que o necessário de algo para um determinado fim

Trade-Off [9] é o que mais se aproxima da comparação pretendida por este projeto. Essa análise consiste em obter os dados de eficiência temporal, consumo de energia, desempenho preditivo e uso de memória de um algoritmo, parâmetros estes que contemplam o impacto do algoritmo tanto o lado de *hardware* como de *software*.

Sendo assim, a metodologia apresentada se torna adequada para o estudo de desempenho de um algoritmo em um sistema embarcado, o que condiz com o cenário apresentado pelo presente projeto.

3. Objetivos

3.1. Objetivo Geral

Analisar e classificar os melhores algoritmos para Visão Computacional Embarcada para classificação de obstáculos em tempo real.

3.2. Objetivos Específicos

- Estudar a literatura em busca do estado da arte nas áreas de Visão Computacional Embarcada e Classificação de Fluxo de Dados
- Verificar a melhor combinação de sensores e sistemas para solucionar o problema apresentado
- Comparar os diferentes tipos de algoritmos utilizados para análise de fluxo de dados
- Compreender as técnicas de processamento de imagem
- Apresentar resultados conclusivos dos testes que sirvam de base para pesquisas futuras na área

4. Procedimentos Metodológicos / Métodos e Técnicas

A metodologia do projeto pode ser descrita conforme as etapas presentes nas seguintes subseções.

4.1. Levantamento bibliográfico

Durante essa etapa, serão realizadas as pesquisas que servirão de base teórica para o desenvolvimento do projeto. Além disso, aqui serão feitas as análises e escolhas de algoritmos e componentes que serão utilizados para solucionar a problemática apresentada.

4.2. Coleta de dados

Após a escolha dos componentes de *hardware*, serão feitas as coletas das imagens dos ambientes de chão de fábrica, com e sem obstáculos. Essas imagens servirão de base para as análises que serão feitas nas próximas etapas.

4.3. Pré-processamento das imagens

Utilizando as técnicas de visão computacional, as imagens capturadas serão processadas para eliminar dados excedentes, e armazenar características dos *frames* de forma que possam ser analisados por modelos matemáticos. Essa etapa garante que a mesma sequência de imagens será analisada nas etapas de classificação do fluxo de dados.

4.4. Etapa de análise e classificação dos algoritmos

Com os dados pré-processados, serão executados os algoritmos de classificação escolhidos em um cenário industrial, com e sem a presença de obstáculos, e em um sistema embarcado com características similares àquelas encontradas em AGVs.

4.5. Análise dos dados

Os dados coletados na etapa anterior serão analisados utilizando a metodologia de *Four-Way Performance Trade-Off* [9], através dos resultados de eficiência temporal, consumo de energia, desempenho preditivo e uso de memória dos algoritmos utilizados.

4.6. Redação do projeto final

Toda a informação adquirida durante o desenvolvimento do projeto será redigida na forma do Trabalho de Conclusão de Curso, onde também estarão expostos os resultados as etapas de teste e análise dos dados.

5. Cronograma de Desenvolvimento

A execução deste projeto entre os meses está exposta na tabela abaixo segundo as atividades descritas nas subseções da seção anterior.

	set	out	nov	dez	jan	fev	mar	abr	mai
Atividade 1	X	X							
Atividade 2			X						
Atividade 3			X	X					
Atividade 4					X	X			
Atividade 5							X	X	
Atividade 6								X	X

6. Contribuições e/ou Resultados Esperados

Espera-se que, ao final do projeto, obtenha-se um relatório comparativo com os dados coletados. Desta forma, será possível analisar se os algoritmos escolhidos tiveram um bom desempenho na classificação de obstáculos e, assim, escolher aquele que mais se destaca nesta aplicação. O presente projeto visa, então, ajudar na escolha dos algoritmos de visão computacional embarcada, e também contribuir como base para futuros projetos que desejarem otimizar esses algoritmos para tais aplicações.

7. Espaço para assinaturas

Londrina, 12 de setembro de 2022.

Fernando M. P. Neto

Aluno

Guilherme P. Cardim

Orientador

Referências

- [1] Bifet, A., Holmes, G., Kirkby, R., and Pfahringer, B. Moa: Massive online analysis. *Journal of Machine Learning Research*, (11):1601–1604, 2010.
- [2] Dariusz Brzezinski and Jerzy Stefanowski. *Stream Classification*. 01 2016.
- [3] David Forsyth and Jean Ponce. *Computer vision: A modern approach*. Prentice hall, 2011.
- [4] Mohamed Medhat Gaber, Arkady Zaslavsky, and Shonali Krishnaswamy. Mining data streams: A review. *SIGMOD Rec.*, 34(2):18–26, June 2005.
- [5] Jian Kang, Jeisung Lee, Hyukmin Eum, Chang-Ho Hyun, and Mignon Parks. An application of parameter extraction for agv navigation based on computer vision. In *2013 10th International Conference on Ubiquitous Robots and Ambient Intelligence (URAI)*, pages 622–626. IEEE, 2013.
- [6] Shehroz S Khan and Michael G Madden. A survey of recent trends in one class classification. In *Irish conference on artificial intelligence and cognitive science*, pages 188–197. Springer, 2009.
- [7] Shehroz S. Khan and Michael G. Madden. One-class classification: taxonomy of study and review of techniques. *The Knowledge Engineering Review*, 29(3):345–374, 2014.
- [8] Branislav Kisacanin, Shuvra S Bhattacharyya, and Sek Chai. *Embedded computer vision*. Springer Science & Business Media, 2008.
- [9] Jessica Fernandes Lopes, Everton Jose Santana, Victor G Turrisi da Costa, Bruno Bogaz Zarpelão, and Sylvio Barbon Junior. Evaluating the four-way performance trade-off for data stream classification in edge computing. *IEEE Transactions on Network and Service Management*, 17(2):1013–1025, 2020.
- [10] Brazilian National Confederation of Industry. Industry 4.0: A new challenge for brazilian industry. *CNI Indicators*, 17(2):1–16, 2016.
- [11] Ritesh Srivastava and Veena Mittal. Most preferable combination of explicit drift detection approaches with different classifiers for mining concept drifting data streams. *International Journal of Data Science*, 4(3):196–214, 2019.
- [12] Kristof Van Beeck, Tinne Tuytelaars, Davide Scaramuzza, and Toon Goedemé. Real-time embedded computer vision on uavs. In *European Conference on Computer Vision*, pages 3–10. Springer, 2018.
- [13] Ky M Vu. *The ARIMA and VARIMA time series: their modelings, Analyses and Applications*. AuLac Technologies Inc., 2007.
- [14] Kapil K Wankhade, Snehlata S Dongre, and Kalpana C Jondhale. Data stream classification: a review. *Iran Journal of Computer Science*, 3:239–260, 2020.