

Identificação do Estado do Trânsito Através da Análise de Aglomerados Utilizando um Classificador Fuzzy

Adriane de O. Medeiros, Inguerson D'Avila P. Martins, Diego da S. Froner

Escola de Ciências Exatas e Tecnologia – Centro Universitário do Norte (Uninorte) –
Manaus – AM – Brasil

{medeirs.a, inkemartins3}@gmail.com, diego.froner@uninorte.com.br

Abstract. *The growth in the fleet of vehicles has encouraged the development of systems to assist in traffic management, highlighting those using intelligent information obtained through computer vision. Current proposals also fail to use or recognition and individual counting vehicles or classifiers that were wrong in predictions when traffic status was in transition. This paper presents a fuzzy classification of vehicular traffic using to estimate the flow macroscopic approach of the crowds analysis. The classifier showed an accuracy of 89.9%, correctly classifying roads that had occlusions and climatic variations.*

Keywords: *Traffic Conditions, Crowds Analysis, Fuzzy Classifier.*

Resumo. *O aumento da frota de veículos tem incentivado o desenvolvimento de sistemas que auxiliem na gestão do tráfego, destacando-se aqueles que utilizam informações inteligentes obtidas através de visão computacional. As propostas atuais apresentam falhas ao utilizarem ou reconhecimento e contagem individual de veículos ou classificadores que erraram em predições quando o estado do trânsito estava em transição. Este artigo apresenta uma proposta de classificação fuzzy do tráfego de veículos utilizando para a estimativa do fluxo a abordagem macroscópica da análise de aglomerados. O classificador apresentou uma acurácia de 89,9%, classificando corretamente vias que apresentaram oclusões e variações climáticas.*

Palavras-chave: *Estado do Trânsito, Aglomerados, Classificador Fuzzy.*

1. Introdução

A visão computacional é uma área de pesquisa que possibilita a execução de tarefas inteligentes, através da extração de informações relevantes realizada por técnicas de processamento e análise de imagens [Shapiro e Stockman 2001]. Dentre outras aplicabilidades é possível: reconhecer faces; detectar mudanças analisando imagens de satélite e auxiliar no diagnóstico de doenças a partir da análise de imagens dos exames [Milano e Honorato 2010].

O crescimento da frota de veículos aumenta significativamente, seja por conta do crescimento da renda da população local ou pela precariedade do serviço de transporte público oferecido [Resende e Souza 2009]. A abordagem tradicional utilizada é inferir o estado do trânsito através de reconhecimento e contagem individual dos veículos utilizando técnicas de visão computacional [Sobral *et al.* 2013]. No entanto, tais sistemas estão expostos a falhas quando há um aumento na concentração de veículos, mudanças repentinas ou graduais de iluminação, sombras, perda de foco e imagens de baixa resolução [Chan e Vasconcelos 2005].

Como solução alternativa encontra-se a análise de aglomerados, campo de estudo da visão computacional, que permite a extração de dados de um aglomerado, como densidade, velocidade, direção e localização [Zhan *et al.* 2008]. Sendo possível modelar aplicações para gerenciamento de multidão, detecção de anomalias, criação de ambientes inteligentes, entre outras [Jacques Junior *et al.* 2010].

Na literatura há trabalhos que utilizam análise de aglomerados para a extração das características do trânsito [Sobral *et al.* 2013; Derpanis e Wildes 2011; Chan e Vasconcelos 2005]. No entanto, os algoritmos de classificação utilizados para predição apresentaram falsos positivos principalmente em estados de transição. Segundo Sobral *et al.* (2013), a presença de falsos positivos na classificação do estado do trânsito pode ser explicada pela qualidade dos métodos de análise de aglomerados empregados, porém admite que a fronteira entre um estado e outro é imprecisa.

Considerando a fronteira imprecisa entre os conjuntos do estado do trânsito, o presente trabalho tem o objetivo de utilizar o classificador *fuzzy* para predizer o estado do fluxo em leve, médio ou pesado, extraíndo as características do tráfego através da análise de aglomerados. Segundo Miranda (2014), a vantagem do classificador *fuzzy* está na sua capacidade de tratar as incertezas presentes nos dados, já Simões *et al.* (2001) o destacou quanto ao baixo custo computacional e robustez perante a erros.

A base de vídeos utilizada foi a pública UCSD¹, disponibilizada pela Universidade de San Diego e utilizada em trabalhos relacionados. Após a extração de características os resultados foram agrupados em conjuntos para treino e teste do classificador. Após o término dos testes foi gerada a matriz de confusão contendo os resultados da classificação, estes foram analisados levando em conta as particularidades do classificador, e a partir da quantidade de falsos positivos os resultados foram comparados com trabalhos relacionados.

Este artigo está estruturado da seguinte forma: na Seção 2 é descrito o referencial teórico, contendo conceitos importantes para o entendimento do trabalho; na Seção 3 são apresentados os trabalhos relacionados, na Seção 4 é descrita a metodologia proposta, na Seção 5 é apresentada uma discussão dos resultados obtidos pelo classificador *fuzzy* e, por fim, na Seção 6, estão as considerações finais.

2. Referencial Teórico

A análise de aglomerados é um conjunto de técnicas de visão computacional que buscam extrair informações de imagens ou vídeos que apresentam agrupamento de grande número de objetos ou pessoas [Zhan *et al.* 2008]. Segundo Zhan *et al.* (2008) e Jacques Junior *et al.* (2010), existem duas principais abordagens para a análise de aglomerados: microscópica e macroscópica. Na abordagem microscópica os objetos são analisados individualmente e essa informação é utilizada para inferir o comportamento do aglomerado. Na abordagem macroscópica o aglomerado é analisado como uma única unidade que contém atributos como densidade, velocidade e direção.

Os métodos desenvolvidos para extrair a estimativa da densidade de objetos podem ser vistos nas seguintes categorias: métodos baseados em pixel, que obtêm características do objeto de interesse utilizando técnicas de subtração de fundo ou detecção de borda; métodos baseados em textura, onde quanto mais fina a textura maior a densidade e quanto mais grossa menor a densidade; métodos baseados em objetos, que

¹ Disponível em: <http://svcl.ucsd.edu/projects/traffic>

dependem da identificação individual do objeto de interesse na cena [Zhan *et al.* 2008]. Outra característica da análise de aglomerados é o rastreamento, que consiste em identificar a posição do mesmo objeto em uma sequência de quadros [Zhan *et al.* 2008]. A técnica de rastreamento comumente citada é o fluxo ótico [Jacques Junior *et al.* 2010], podendo ser utilizado para diferentes aplicações como interpretação de cena, acompanhamento de objetos, estimativa da velocidade etc. [Oliveira Neto e Gomes 2009].

Classificadores *fuzzy* permitem trabalhar com a incerteza e imprecisão presente nas informações de entrada, onde é possível para cada resultado expressar o grau de pertinência deste com os conjuntos de valores de saída [Zadeh 1965]. A Figura 1 exhibe o diagrama de funcionamento dos classificadores *fuzzy*.




Figura 1. Diagrama do Classificador Fuzzy.

A etapa de fuzzificação consiste na conversão dos valores de entrada numéricos em valores linguísticos e na criação das funções de pertinência para tais variáveis de entrada [Mamdani 1973]. As funções de pertinência além de determinar os limites de cada conjunto *fuzzy*, permitem definir o grau de atribuição de um valor a tais conjuntos, variando de 1 - associação total – até 0 – nenhuma associação.

A base de regras é formada por um conjunto de proposições fuzzy, estas são divididas em: termos antecedentes, que são constituídos da atribuição dos valores linguísticos às variáveis de entrada; e os consequentes, constituídos da atribuição dos valores linguísticos às variáveis de saída. A

Figura 2 exhibe a estrutura de uma proposição no contexto do trabalho proposto, com os antecedentes formados pelas variáveis linguísticas velocidade e densidade, recebendo os valores alta e baixa respectivamente, o consequente é formado da atribuição do valor leve à única variável de saída, o estado do trânsito.

O motor de inferência acessa a base de regras para a definição dos valores de saída *fuzzy*, entre os motores existente encontra-se o Mamdani desenvolvido por Mamdani (1973), tendo como característica requerer tanto o antecedente quanto o consequente em valores de variáveis linguísticas.




Figura 2. Estrutura de uma Proposição Fuzzy.

A defuzzificação utiliza métodos para avaliar as diversas respostas fornecidas pela base de regras e converte esse resultado em valor numérico [Pedrycz e Gomide 1998]. Quando utilizado o controlador Mamdani, esses valores são transformados novamente em valores linguísticos, podendo apresentar graus de pertinência em mais de uma classe, ou conjunto *fuzzy* de saída.

A matriz de confusão é um dos métodos de avaliação de acurácia mais utilizado, exibindo o número de classificações corretas, que constam na diagonal principal da mesma, contra o número de classificações preditas [Prucole 2006]. A acurácia é a porcentagem definida pela razão entre o número de classificações corretas e o número total de classificações. No entanto, considerando que as funções de pertinência podem associar total ou parcialmente um valor a uma classe, a acurácia também pode ser definida em termos de grau de ambiguidade, descrita pela proximidade dos graus de pertinência de um valor pertencer a duas ou mais classes [Antunes e Lignau 2005].

3. Trabalhos Relacionados

Os trabalhos que utilizam análise de aglomerados para a extração das características do trânsito, foram observados em: Chan e Vasconcelos (2005), sendo utilizado o classificador estatístico *Support Vector Machine* (SVM), obtendo uma acurácia de 94,5%; Derpanis e Wildes (2011) propuseram um método para Chan e Vasconcelos (2005) melhorar o custo computacional, sendo utilizado o classificador *K-Nearest Neighbor* (K-NN) que obteve uma acurácia de 95,3%. Em Sobral *et al.* (2013), foi utilizada a segmentação e rastreamento de objetos e o classificador de redes neurais *MultiLayer Perceptrons* (MLP), obtendo uma acurácia de 94,5%. Os trabalhos citados utilizaram a base de vídeos UCSD. A eficácia dos métodos propostos é realizada pela comparação das matrizes de confusão exibida na Tabela 1.

Tabela 1. Matriz de Confusão dos Trabalhos Relacionados.

Estado Real do Trânsito	Classificações Preditas dos Trabalhos Relacionados								
	Classificador MLP (Sobral <i>et al.</i> 2013)			Classificador K-NN (Derpanis e Wildes 2011)			Classificador SVM (Chan e Vasconcelos 2005)		
	Baixa	Média	Alta	Baixa	Média	Alta	Baixa	Média	Alta
Leve (165)	162	3	0	163	1	1	164	1	0
Médio (45)	1	38	6	1	40	4	2	39	4
Alto (44)	0	4	40	1	4	39	0	7	37

Sobral *et al.* (2013) justifica o surgimento de falsos positivos nas predições apontando possíveis erros na rotulação do estado do trânsito de certos vídeos, além de discutir sobre o uso de melhores técnicas para extrair as características do trânsito. Derpanis e Wildes (2011) relatam dificuldades do algoritmo em diferenciar a via e veículos porque ambos chegam a possuir cores semelhantes, o que leva ao surgimento de falsos positivos. Chan e Vasconcelos (2005) por também utilizarem a textura como método de extração de características podem ter apresentado as mesmas dificuldades de Derpanis e Wildes (2011).

4. Método de Pesquisa

O método de pesquisa constituiu-se basicamente de duas partes, a extração de características e a aplicação do algoritmo *fuzzy* para a classificação do estado do trânsito. A base de dados adotada é UCSD, com 254 vídeos, duração média de 5 segundos e *region of interest* (ROI) definida em 190x140 *pixels*, contendo informações do nível de congestionamento e clima. Para implementação das técnicas de análise de aglomerados e construção do classificador fuzzy, foram utilizadas as bibliotecas de

código aberto OpenCV² e Fuzzylite³, respectivamente. A Figura 3 exibe o diagrama do método proposto.




Figura 3. Diagrama do Método Proposto

Extração das características. As características definidas para análise do tráfego foram a velocidade e a densidade, sendo utilizada para a extração de ambas a abordagem macroscópica da análise de aglomerados. A densidade foi extraída aplicando o método baseado em pixel através do algoritmo de subtração de fundo Multi-Layer proposto por Yao e Odobez (2007), onde as regiões que apresentam maior diferença de textura entre a imagem atual e o plano de fundo indica os objetos de interesse na cena. A partir da máscara de primeiro plano, resultante da subtração de fundo, foi realizada a contagem dos pixels não-nulos para estimativa da densidade. A

Figura 4 exibe a máscara de primeiro plano para alguns dos vídeos utilizados.



Figura 4. Máscara de Primeiro Plano para Diferentes Graus de Congestionamento.

Para extrair a velocidade foi aplicado o algoritmo de fluxo óptico Kanade-Lucas-Tomasi (KLT), união das técnicas propostas no trabalho de Lucas e Kanade (1981) para cálculo de fluxo óptico e de Shi e Tomasi (1994) onde são rastreados pontos de interesse a cada quadro do vídeo. A Figura 5a exibe dois quadros de um mesmo vídeo, a Figura 5b exibe o resultado do rastreamento. A estimativa da velocidade é calculada pela razão entre a soma das distâncias percorridas de cada veículo e o tempo do vídeo.



Figura 5. Rastreamento dos Pontos de Interesse em Quadros Distintos.

² Disponível em: <http://www.fuzzylite.com/downloads/>

³ Disponível em: <http://opencv.org/downloads.html>

Construção do classificador *Fuzzy*. Um total de cinco valores linguísticos representam as variáveis de velocidade e densidade: baixa, moderadamente média, média, moderadamente alta e alta. A Tabela 2 exibe a correspondência dos intervalos de valores de entrada para os valores linguísticos estabelecidos. A conversão dos valores de entrada em valores linguísticos foi realizada através de distribuição de frequência, adotando para cada classe de intervalos um valor linguístico específico. A Figura 6a e Figura 6b mostram as funções de pertinência para as variáveis de densidade e velocidade, utilizada em ambas funções do tipo trapezoidal.

Tabela 2. Distribuição dos Valores Linguísticos de Entrada.

Intervalos de Valores Numéricos		Valores Linguísticos Correspondentes
Densidade	Velocidade	
[146;23301]	[0,2;18,1]	Baixa
[23302;46457]	[18,2;27,1]	Moderadamente Média
[46458;58035]	[27,2;36,1]	Média
[58036;81191]	[36,2;54,1]	Moderadamente Alta
[81192;104348]	[54,2;81,2]	Alta

Para a geração da base de regras foi utilizado o algoritmo *dataSqueezer*, que obtém as regras a partir de um conjunto de treino, quando comparado por Cios *et al.* (2006) com outros geradores, mostrou-se em média o mais rápido, gerando regras compactas, compreensíveis e robustas. O sistema *fuzzy* foi constituído de 70 regras e o motor de inferência escolhido foi o Mamdani, com classe de saída chamada de estado do trânsito e valores linguísticos: leve, médio e pesado. A função de pertinência é do tipo triangular, com escala de pertinência de 0 a 1, conforme exibida na

Figura 7.

Treino e teste do classificador. Para treino e teste foram adotados os mesmos passos de Sobral *et al.* (2013), Derpanis e Wildes (2011) e Chan e Vasconcelos (2005), onde foram formados 4 conjuntos, contendo cada um os 254 vídeos da base UCSD, organizados de tal modo que 75% foram reservados para treinamento e 25% para testes. Para cada conjunto de treinamento foi gerado uma base de regras *fuzzy* e aplicado no conjunto teste correspondente.

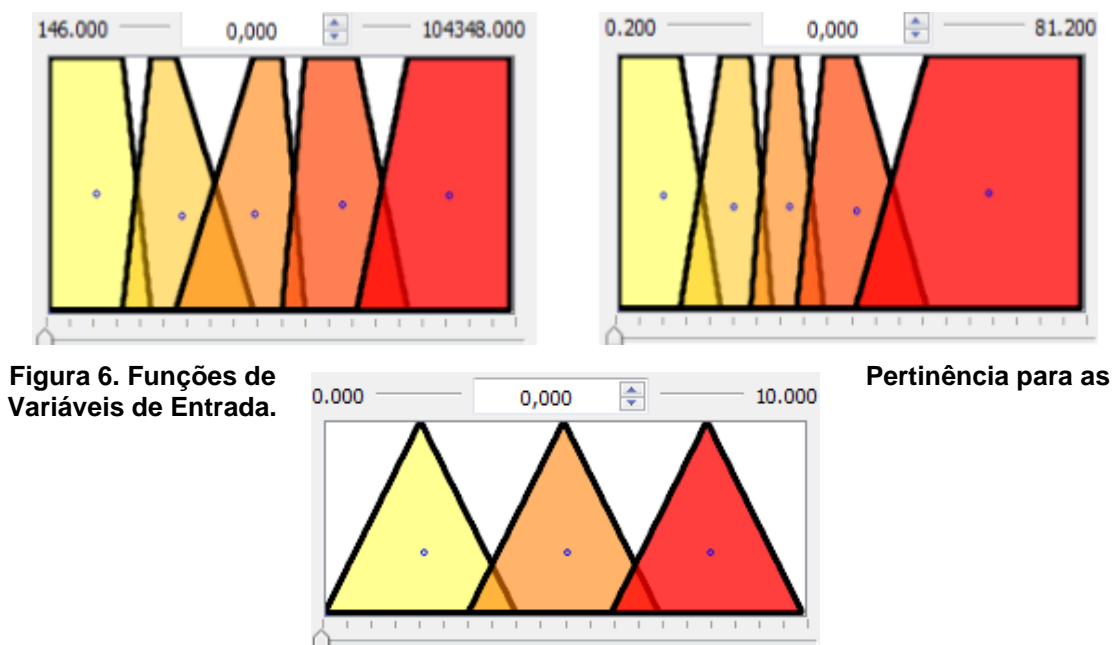


Figura 6. Funções de Variáveis de Entrada.

Pertinência para as

Classe Correta	Grau de Pertinência em Leve	Grau de Pertinência em Médio	Grau de Pertinência em Pesado	Classe Predita
----------------	-----------------------------	------------------------------	-------------------------------	----------------

Figura 7. Funções de Pertinência da Variável de Saída.

5. Resultados e Discussão

Os testes realizados no classificador *fuzzy* ocorreram em todos os vídeos da base utilizada, com acurácia calculada pela razão do número de vídeos corretamente classificados pelo total de vídeos, logo: $acurácia = 237/254 = 0,899$. Ou seja, o índice de acerto foi de 89,9%. A matriz de confusão dos resultados é exibida na Tabela 3.

A diagonal principal da Tabela 3 exibe a quantidade de predições corretas, para o estado do trânsito leve, a acurácia foi de 98,2%, para médio, foi de 88,8% e para pesado, foi de 79,5%. A acurácia dos resultados que obtiveram grau de pertinência total a classe que pertencem foi de 38,2%, sendo 43% para o estado do trânsito leve, 26,7% para médio e 31,2%, para pesado.

Tabela 3. Matriz de Confusão do Classificador *Fuzzy*.

Classificações Corretas	Classificações Preditas		
	Leve	Médio	Pesado
Leve(165)	162	3	0
Médio(45)	1	40	4
Pesado(44)	0	9	35

Mesmo apresentando baixas taxas de pertinência total a classe em que pertencem, aproximadamente 40% dos resultados de cada classe foram associados com pertinências entre 0,7 e 0,9. Ou seja, ainda que não tenham recebido valor de pertinência total para suas devidas classes, os resultados apresentaram baixa ambiguidade, ou dúvida de associação, com outras classes.

No entanto, graus de pertinência próximos entre duas classes foram gerados resultando em predições equivocadas como se pode observar em alguns casos na Tabela 4, onde fluxos foram preditos em classes errôneas por apresentarem pertinência maior porém próxima de sua classe correta, fato que caracteriza um resultado ambíguo. Resultados ambíguos podem demonstrar erros na rotulação do estado do trânsito em vídeos ou estados em início ou fim de transição.

Além disso, foram classificados incorretamente vídeos que apresentaram clima chuvoso com pingos de água na lente da câmera, esses erros foram cometidos devido à dificuldade de extrair as características nessas condições, alguns desses vídeos podem ser observados na Figura 8. Nos vídeos testados, em apenas 20% o clima aparece sem variações de luminosidade, os restantes estão em clima chuvoso (31%) ou nublado (49%), o que demonstra robustez dos métodos de extração de características empregados e consequente classificação dos estados do trânsito.

Tabela 4. Classificações Incorretas Geradas Por Graus de Pertinência Próximos.

Leve	0,493	0,621	0,000	Médio
Médio	0,000	0,511	0,568	Pesado
Médio	0,000	0,480	0,549	Pesado



Figura 8. Vídeos com Pingos de Água na Lente da Câmera.

O total de classificações incorretas foram 17, apresentando maior número de falsos positivos na classificação do estado do trânsito pesado. Conforme exibida na Tabela 5, em comparação com o classificador MLP obtivemos o mesmo número de falsos positivos na predição do estado do trânsito em leve, porém piorando na classificação do mesmo estado se comparado com o KNN e o SVM. Para a classificação do estado do trânsito médio, diminuimos o número de falsos positivos se comparado com Sobral *et al.* (2013) e Chan e Vasconcelos (2005) e igualamos com Derpanis e Wildes (2011). Ao classificar o estado do trânsito pesado, não obtivemos melhorias.

Tabela 5. Comparação do Número de Falsos Positivos dos Classificadores.

Falsos Positivos	Classificadores			
	MLP	K-NN	SVM	<i>Fuzzy</i>
Leve	3	2	1	3
Médio	7	5	6	5
Pesado	4	5	7	9

6. Considerações Finais

O classificador *fuzzy* apresentou uma acurácia de 89,9%, demonstrando certa robustez, visto que a base utilizada é composta em sua maioria de vídeos com clima nublado ou chuvoso. Em comparação com classificadores de trabalhos anteriores, o pior número de falsos positivos foi na predição do estado do trânsito pesado, devido a ambiguidade em classificações e falhas na extração de características em vídeos com pingos de água na lente da câmera.

A aprendizagem efetiva do classificador *fuzzy* depende de sucessivos testes para geração de regras corretas. É importante lembrar que em classificadores *fuzzy*, valores de pertinência não são probabilidades, logo, é possível obter um refinamento do resultado ao consultar o segundo melhor resultado. Considerando os resultados obtidos,

uma proposta para trabalhos futuros seria a construção de um classificador híbrido, com *fuzzy* e redes neurais ou algoritmos genéticos para analisar o nível de aprendizado e adaptação que os mesmos venham a obter.

Referências

- Antunes, A. F. B.; Lingnau, C. (2005) – “Determinação da acurácia temática de dados oriundos da classificação digital de objetos por meio de lógica fuzzy”. Em: Simpósio Brasileiro de Sensoriamento Remoto (SBSR), p. 3451-3459.
- Chan, A. e Vasconcelos, N. (2005) - “Classification and Retrieval of Traffic Video Using Auto-Regressive Stochastic Processes”. Em: IEEE Intelligent Vehicles Symposium (IV), p. 771–776.
- Cios, K. J.; Kurgan, L. A.; e Dick, S (2006) – “Highly Scalable and Robust Rule Learner: Performance Evaluation and Comparison”. Em: IEEE Transactions on Systems, Man, and Cybernetics, p. 32-53.
- Derpanis, K. G.; Wildes, R. P. (2011) - “Classification of Traffic Video Based on a Spatiotemporal Orientation Analysis”. Em: IEEE Workshop on Applications of Computer Vision (WACV), p. 606–613.
- Junior, J. C. S. J.; Musse, S. R.; Jung, C. R. (2010) - “Crowd Analysis Using Computer Vision Techniques”. Em: IEEE Signal Processing Magazine, v. 27, n. 5, p. 66 – 77.
- Lucas, B. D.; Kanade, T. (1981) - “An Iterative Image Registration Technique with an Application to Stereo Vision”. Em: IEEE International Joint Conference on Artificial Intelligence (IJCAI), p. 674–679.
- Mamdani, E. H. (1973) - “Applications of fuzzy algorithms for control of simple dynamic plant”. Em: Proceedings of the Institution of Electrical Engineers, v. 121, n. 12, p. 1585-1588.
- Milano, D.; Honorato, L. B. (2010) - “Visão Computacional”. 80f. Monografia (Bacharel em Ciência da Computação) - Universidade Estadual de Campinas, São Paulo.
- Miranda, M. A. (2014) - “Reconhecimento De Frutas Por Visão Computacional Utilizando Um Classificador Fuzzy Embarcado”. 38f. Monografia (Especialização em Engenharia Elétrica com Ênfase em Sistemas Inteligentes Aplicados à Automação) - Instituto Federal Do Espírito Santo, Vitória.
- Neto, V. J. de O. e Gomes, D. M. (2009) - “Comparação de métodos para localização de fluxo óptico em sequencias de imagens”. Monografia (Bacharel em Ciência da Computação) – Universidade Federal de Ouro Preto, Minas Gerais.
- Pedrycz W.; Gomide, F. (1998) - “An Introduction to Fuzzy Sets: Analysis and Design”, Cambridge, MIT Press, 1ª edição.
- Prucol, E. S. (2006) - “Avaliação de Combinações de Classificadores Fuzzy”. 68f. Dissertação (Mestrado em Engenharia Civil) - Universidade Federal do Rio de Janeiro, Rio de Janeiro.
- Resende, P. T. V e Souza, P. R. (2009) - “Mobilidade urbana nas grandes cidades brasileiras: Um estudo sobre os impactos do congestionamento”. Em: Simpósio de Administração da Produção, Logística e Operações Internacionais (Simpoi).

- Shapiro, L.; Stockman, G. (2001) - “Visão Computacional”, Nova Jersey, Prentice Hall, 1.^a edição.
- Shi, J.; Tomasi C. (1994) - “Good Features to Track”. Em: IEEE Computer Vision and Pattern Recognition Conference (CVPR), p. 593–600.
- Simões, S. A.; Costa, R. H. A.; Andrade, C. T. M. (2001) - “Utilizando um classificador Fuzzy para a Seleção Visual de Laranjas”. Em: Workshop de Computação (WorkComp), p 113-117.
- Sobral, A.; Oliveira, L.; Schnitman, L.; Souza, F. (2013) - “Highway traffic congestion classification using holistic properties”. Em: International Conference on Signal Processing, Pattern Recognition and Applications (IASTED).
- Yao, J. e Odobez, J. (2007) - “Multi-layer background subtraction based on color and texture”. Em: IEEE Computer Vision and Pattern Recognition Conference (CVPR), p. 1–8.
- Zadeh, L. A. (1965) - “Fuzzy Sets”. Em: Information and Control, v.8, p. 338-353.
- Zhan, B., Monekosso, N. D., Remagnino, P, Velastin, S. A. (2008) - “Crowd analysis: a survey”. Em: Springer-Verlag Machine Vision and Applications, p. 345-357.