

Classificação de Sinais de Trânsito Usando Otimização por Colmeias e Random Forest

J. C. Silva¹, F. C. Farias¹, V. C. F. Lima¹, V. L. B. Silva¹, L. M. Seijas^{1,2}, C. J. A. Bastos-Filho¹

¹*Escola Politécnica de Pernambuco, Universidade de Pernambuco (UPE), Recife, Brazil
{jcs, fcf, vcfl, vlbs, carmelofilho}@ecomppoli.br*

²*Departamento de Computación, Facultad de Ciencias Exactas y Naturales,
Universidad de Buenos Aires, Argentina
lseijas@dc.uba.ar*

Resumo – Sinais de trânsito são de grande importância para organização da sociedade e o reconhecimento automático destes sinais está se apresentando como uma excelente ferramenta para diversas aplicações, principalmente em robótica, automação e tecnologias assistivas. Neste artigo, é apresentada uma proposta para resolver o problema de classificação de sinais de trânsito, em que as máscaras para extração de características foram obtidas usando-se o algoritmo de Otimização por colmeias (ABC) e o processo de classificação é realizado usando *Random Forest*. A abordagem apresenta custo computacional mais baixo do que as abordagens apresentadas no estado da arte. Experimentos preliminares em uma base de dados alemã mostram que os resultados são promissores.

Palavras Chave – *Classificação, Sinais de trânsito, Otimização por colmeias, Random Forest.*

I. INTRODUÇÃO

A sinalização de trânsito assume, nos dias de hoje, uma grande importância na organização da sociedade. Suas propriedades visuais são muito fortes, pois foram projetados para serem objetos facilmente identificáveis pelos seres humanos [1], [2]. Visando garantir a segurança de cada habitante e a correta circulação de pessoas e veículos, cada governo adota leis e tipos de sinalizações específicas [1].

O reconhecimento automático de placas de trânsito está se tornando uma área com muitas aplicações na indústria automotiva [3], como por exemplo, possibilitando que um motorista seja avisado sobre ações impróprias e situações potencialmente perigosas, o que consiste em uma tarefa essencial para um sistema inteligente de auxílio a motoristas [2], [4]. Para que seja possível o reconhecimento destas placas de sinalização, um método eficiente para detecção de placas e sinais de trânsito é indispensável.

Dadas as pesquisas recentes em Visão Computacional e os avanços recentes na área de tecnologia, a detecção e reconhecimento de sinais de trânsito já é uma realidade. No entanto, ainda existem grandes desafios a serem superados, pois esta tarefa ainda requer um grande esforço computacional. O estado da arte utiliza redes neurais artificiais convolucionais. Este tipo de rede apresenta alta acurácia, entretanto demanda um alto custo computacional. Como consequência, a implementação de redes neurais

convolucionais em sistemas de tempo real não é uma tarefa simples [5]. Por exemplo, o comitê de redes neurais convolucionais (CNN) usadas em [6] consegue uma acurácia de 99.46% superando o rendimento humano. Contudo, são necessárias 37 horas de treino em *hardware* dedicado (GPUs) utilizando a base de dados *German Traffic Sign Recognition Benchmark* (GTSRB).

Além disso, as placas de trânsito captadas, em forma de vídeo ou em imagens, possuem diferentes tipos de aparência, incluindo iluminação, cor ou sombras em diferentes dias, estações e climas [7], o que torna o problema de operação em tempo real mais complexo.

Na grande maioria dos casos, a detecção de sinais de trânsito é composta por duas fases, que são a detecção e o reconhecimento [8]. Na primeira etapa a imagem é editada para que apenas o local em que o sinal de trânsito aparece seja selecionado, como visto na Figura 1. Na segunda etapa, o algoritmo de reconhecimento utiliza essa região para identificação.

Este trabalho apresenta uma metodologia para realizar a classificação de sinais de trânsito utilizando técnicas de Visão Computacional e Algoritmos de Enxames, visando encontrar um conjunto de máscaras adequadas para extração das características. Estas características serão repassadas para o classificador com o objetivo de se alcançar taxas semelhantes ou superiores ao estado da arte, mas, sobretudo, com o intuito de evitar erros e fragilidades ocorridos em trabalhos realizados anteriormente sem que com isso aumente o custo computacional. Na abordagem proposta neste artigo, o processo de classificação é realizado pelo algoritmo *Random Forest* [9]. A base utilizada é a *German Traffic Sign Recognition Benchmark* [10][11], pois fornece uma vasta quantidade de imagens coletadas. Uma ampla variedade de trabalhos já utilizaram esta base [5][6], servindo assim como uma boa base comparativa de desempenho para a nossa proposta.



Figura 1. Exemplo de via comum de circulação das pessoas com placas de trânsito [6].

II. TRABALHOS RELACIONADOS

O algoritmo de otimização por colmeias (Artificial Bee Colony, ABC) [12], [13], [14], [15] foi proposto por Karaboga, 2005, e é inspirado no comportamento coletivo de enxames de abelhas durante a busca por alimentos. No ABC, o comportamento é mapeado por meio de 3 componentes essenciais: fontes de alimento, abelhas operárias e abelhas não operárias (exploratórias e seguidoras). As soluções do problema são representadas pelas fontes de alimento e as abelhas são os agentes de busca pela solução.

O *Random Forest* é uma alternativa interessante para processos de classificação e regressão, e têm sido amplamente utilizado para problemas correlacionados. Em [16][17][18], os classificadores *Random Forests* são abordados. Estes classificadores têm uma estrutura em árvores, em que cada árvore é inicializada de forma aleatória. Os nós dessas árvores são binários, ou seja, só existem duas possibilidades de resposta.

Em [19][20], o problema de classificação de placas é abordado com emprego de *Extreme Learning Machines* e *Support Vector Machine* (SVM) discriminando características convolucionais. Os resultados para acurácia superam 98%, mesmo nos piores relatos. São apresentados relatos de erros devido a imagens borradas e movimentação da câmera no momento do registro da imagem. Este é um ponto importante, pois pode atrapalhar a aplicação em tempo real.

Em [21], são apresentados resultados para uma rede neural convolucional com acurácia de 99,22%. Entretanto, esta abordagem demanda de alto poder de processamento e pode não ser viável para aplicação em microcontroladores e *Field Programmable Gate Array* (FPGA).

Alguns trabalhos de detecção de placas foram apresentados em competição organizada pelos autores da *German Traffic Sign Recognition*. Em [22], o sistema de detecção de placas de trânsito foi dividido em três partes: detecção, acompanhamento e classificação. Na detecção todas as imagens são editadas e alteradas para um tamanho fixo. Em seguida, são usados filtros de Kalman para restringir a atuação do sistema apenas à área em que a placa está contida, assim ajudando na classificação. Na etapa de classificação, o sistema usou alguns tipos de classificadores, como SVM, redes neurais *multilayer perceptron* (MLP), redes neurais com funções de

base radiais, entre outros. Como resultado, o sistema obteve uma taxa de 92,4% de acerto na classificação das placas.

Em [23], foram coletadas 1300 imagens de placas de trânsito usando uma câmera com resolução 640x480 para cada imagem. Primeiramente, as imagens foram convertidas de coloridas para uma escala de cinza. Para classificação foram utilizados 15 algoritmos como MLP, árvores de decisão, *Random Forest* e as imagens divididas em 6 classes. Como resultado, foi obtida acurácia de 97% usando redes neurais com funções de base radiais.

Em [24], o sistema foi dividido em três partes: segmentação, detecção e reconhecimento. Na segmentação, o principal objetivo é isolar a placa de trânsito do fundo da imagem, para isso o sistema usou algumas técnicas que mudam a saturação das imagens. Na detecção, o sistema executa uma comparação das assinaturas das placas (distância do centro para as extremidades). Na parte de reconhecimento, foi usado o SVM com kernel gaussiano com o vetor de entrada sendo um bloco de tamanho normalizado de 31x31 pixels em escala de cinza. Como resultado, obteve-se 95,5% de acerto utilizando 36000 placas de trânsito espanholas divididas em 193 classes.

Em [25], é proposto um sistema de visão computacional para detecção e reconhecimento de sinais de trânsito. Ele utiliza *Ada-Boost* e uma modelagem Bayesiana na classificação. O classificador é treinado utilizando 4000 amostras de 23 classes, com amostras por classe variando de 30 a 600. O desempenho foi testado utilizando 1700 imagens como conjunto de teste, A taxa de classificação obtida nesse sistema foi 94% de acerto.

Em [26], é apresentado um sistema de detecção de sinais de trânsito da Europa e Estados Unidos utilizando redes neurais. O sistema global, incluindo detecção e classificação, alcança um desempenho de 89% para os sinais Americanos e 90% para as placas Européias, utilizando 281 sinais de trânsito.

Em [27], é proposto um sistema de detecção e classificação de sinais de trânsito baseado em um algoritmo de três passos, composto por segmentação de cor, reconhecimento de forma e uma rede neural. O objetivo principal desse sistema é detectar e classificar todos os sinais de trânsito presentes nas estradas italianas. O sistema considerou o sistema RGB na segmentação de cores e dois métodos para detecção de formas, que correspondem ao reconhecimento de padrões e detecção de bordas. O conjunto de sinais utilizados foram divididos em categorias de acordo com as cores e formas. Somente resultados qualitativos foram apresentados.

III. PROPOSTA

Atrelados a estes resultados do estado da arte, este artigo propõe um sistema capaz de obter taxas de acerto altas com custo computacional mais baixo. Pretende-se demonstrar que é possível utilizar algoritmos de otimização bioinspirados para definir máscaras para extração de características e posterior classificação de sinais de trânsito. Para definir as máscaras, é proposta a utilização do ABC, que é um algoritmo que tem como inspiração o comportamento das colônias de abelhas e apresenta boa capacidade de busca em amplitude, bem como apresenta boa capacidade de busca em profundidade.

A estratégia adotada para a extração das características foi a utilização de n máscaras mxm , onde n é o número total de máscaras e m é a quantidade de linhas (e colunas) das máscaras.

0.12	0.45	0.22
0.46	0.21	0.87
0.67	0.53	0.15

0.25	0.63	0.95
0.21	0.38	0.22
0.11	0.74	0.02

0.07	0.66	0.63
0.91	0.72	0.39
0.83	0.37	0.65

0.32	0.84	0.93
0.73	0.82	0.75
0.37	0.46	0.63

Figura 2. Exemplo de máscaras para a configuração com $n=4$, $m=3$ e valores iniciais aleatórios.

Ao convoluir as máscaras com a imagem, são geradas características que são posteriormente utilizadas como descritores da imagem. *A priori*, máscaras aleatórias poderiam gerar características que levassem a classificação das imagens, porém essas máscaras podem ser escolhidas de forma que consigam gerar características que melhor representem os padrões desejados. Com este intuito, o ABC foi empregado para encontrar o conjunto de máscaras que seriam utilizadas no processo de extração de características. As máscaras foram inicializadas aleatoriamente com distribuição uniforme no intervalo $[0,1]$. A Figura 2 mostra um exemplo de valores de inicialização. Cada abelha do algoritmo corresponde a uma possível solução para o problema, ou seja, um conjunto de máscaras otimizadas. Ao final do processo de otimização, o indivíduo com o melhor *fitness* representará a solução que será utilizada na extração de características das imagens. Para a obtenção do conjunto de máscaras, foi considerada a função objetivo descrita em (1).

$$f1 = 0,5 C + 0,5 H, \tag{1}$$

em que C é a soma das correlações entre as máscaras, e H é a soma das entropias de cada máscara. A correlação foi escolhida para que as máscaras não extraíssem as mesmas informações e, a partir da entropia, tentou-se buscar máscaras menos aleatórias. Os pesos que multiplicam cada componente da função foram escolhidos de forma que a influência seja equilibrada e foram determinados em experimentos preliminares.

Após esse processo de otimização das máscara, é feito o processo de extração das características. As características geradas para o conjunto de imagens são então repassadas ao

classificador. *Random Forest* é um comitê baseado em um conjunto de árvores de decisão e foi selecionado neste trabalho por possuir rápido treinamento e conseguir lidar com grande conjunto de dados e características através do *bagging* e *bootstrapping*. O *bagging* acontece quando vários classificadores processam a mesma amostra. Para decisão, ocorre uma votação para definir a classe. O *bootstrapping* [28] é uma técnica utilizada para diminuir a variância dos modelos. Para isto, cada classificador utiliza uma parte do banco de dados para realizar o treinamento.

A detecção e reconhecimento automático de sinais de trânsito é uma tarefa importante para os sistemas avançados de assistência à motoristas. Uma das dificuldades relacionadas com os algoritmos para reconhecimento de sinais de trânsito é a limitada capacidade de memória e processamento das aplicações em tempo real. Estas restrições fazem com que as complexas redes neurais como as CNN sejam difíceis ou inviáveis de implementar [29]. Em nossa proposta uma vez encontradas as máscaras com o algoritmo ABC e realizada a convolução com as imagens, a classificação é realizada com o algoritmo *Random Forest*. Este tem demonstrado um alto rendimento para implementações em tempo real com o objetivo de reconhecimento de sinais de trânsito, como se pode observar em [30]. Neste trabalho a precisão e o tempo de classificação são comparados para as técnicas SVM, MLP e *Random Forest*, resultando esta última como sendo a mais rápida e precisa.

IV. EXPERIMENTOS

O objetivo neste trabalho é a classificação dos sinais de trânsito presentes nas imagens, logo a etapa de detecção foi facilitada utilizando uma base que já possui uma indicação da região de interesse. Nos experimentos foram utilizadas 42 classes da *German Traffic Sign Recognition Benchmark* (GTSRB), que é uma base de dados contendo mais de 50.000 imagens de sinais de trânsito alemães com variação de ambiente. Pode-se resumir o experimento nas etapas apresentadas na Figura 3.

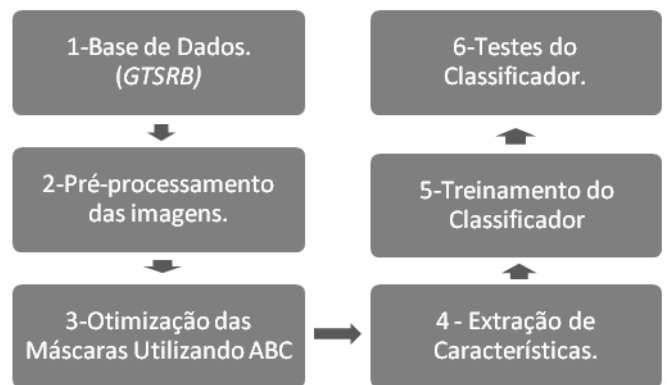


Figura 3. Diagrama com as etapas do Experimento.

- **Base de Dados:** A base de dados utilizada é a GTSRB. Esta base foi utilizada em uma competição, em que os melhores resultados foram obtidos

utilizando diretamente redes neurais convolucionais e *Random Forests*;

- **Pré-processamento:** Nesta fase as imagens foram convertidas para tons de cinza e redimensionadas para o tamanho de 30x30 pixels. As imagens também passaram por uma equalização de histograma com o objetivo de realçar diferenças de tonalidades e aumentar o nível de detalhes perceptíveis;
- **Otimização da Máscaras:** Antes de extrair as características das imagens pré-processadas, é realizada uma otimização das máscaras utilizando o algoritmo ABC. Nos experimentos foram utilizadas 42 máscaras, com dimensões de 5x5. No ABC, um conjunto de máscaras foram inicializadas de forma aleatória e mapeadas como a posição de cada abelha do enxame. Com o final da execução, a abelha com o melhor *fitness* foi selecionada como a representação do melhor conjunto de máscaras para o processo de extração de características. O número de iterações nas execuções foi de 10.000 para cada uma das 30 execuções. Foram utilizadas 30 abelhas e 1 fonte de comida nesta abordagem inicial;
- **Extração de Características:** Nesta etapa são realizadas operações de convolução da imagem com o conjunto de máscaras selecionadas pelo ABC. Esse processo retornou um conjunto de características para cada imagem da base. Essas características foram utilizadas como entradas para o treinamento e testes com o classificador;
- **Treinamento do Classificador:** As características são submetidas ao algoritmo de classificação *Random Forest*, que é treinado utilizando o conjunto de treino da GTSRB que possui 39.209 imagens. São realizados experimentos com diferentes quantidades de árvores no *Random Forest*. Essa quantidade pode variar de 200 a 1000 árvores;
- **Testes do Classificador:** Para avaliar os resultados do classificador, são utilizadas as imagens disponibilizadas no conjunto de Testes da GTSRB. Esse conjunto possui 12.630 imagens.

V. RESULTADOS E DISCUSSÕES

Na Figura 4 estão apresentados gráficos do tipo boxplot para os resultados de acurácia quando o sistema utiliza máscaras aleatórias para extração de características. Pode-se perceber que ao adotar essa estratégia sem a intervenção de um algoritmo de otimização, a acurácia é menor do que 13%. Pode-se observar que a quantidade de árvores utilizadas no classificador interferem na taxa de classificação. Nos casos em que se tinha maior número de árvores, foram obtidos os maiores valores de acurácia.




Figura 4. Taxa de classificação para o *Random Forest* com máscaras aleatórias sem otimização.

Com a utilização do algoritmo ABC, foi possível encontrar um conjunto de máscaras visando minimizar a função objetivo. A Figura 5 mostra a curva de convergência do processo de otimização. Pode-se perceber que ao utilizar 10.000 iterações o algoritmo ainda não chegou a se estabilizar, mas o valor do *fitness* está suficientemente baixo. O processo de convergência ainda estava apresentando melhorias significativas ao longo das iterações, e aparentemente a quantidade de iterações não foi suficiente para o mesmo convergir. Isto pode indicar que com um número maior de iterações, as taxas do classificador possam melhorar.

Depois de encontrar as máscaras utilizando o ABC, foi feita a extração de características das imagens para o treinamento do *Random Forest*. Foram treinados três classificadores, onde cada um tinha uma quantidade diferente de árvores (100, 500 e 1000). As acurácias resultantes para cada um dos três casos estão apresentadas na Figura 6.

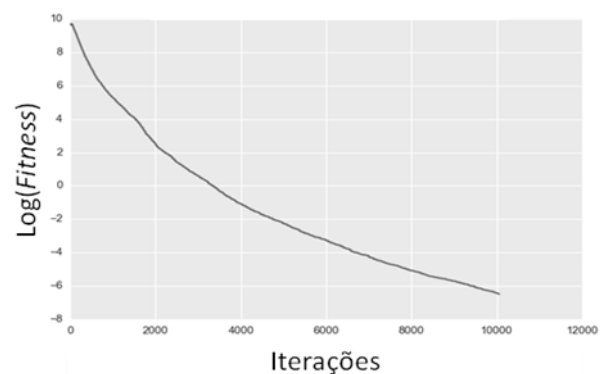


Figura 5. Curva de convergência do ABC para 10.000 iterações.




Figura 6. Taxa de classificação para o *Random Forest* com máscaras otimizadas.

A taxa de acerto base do sistema com a adição das análises de correlação e entropia foi próximo a 87,5%. Já utilizando máscaras aleatórias, os resultados foram inferiores a 20%. Desta forma, o algoritmo de enxames se mostrou válido na medida em que possibilita uma melhor extração de características das imagens de estudo. Essas características obtidas foram utilizadas no treinamento do *Random Forest* e possibilitaram uma correta classificação das imagens de teste com taxas de classificação promissoras, que tentaremos melhorar em trabalhos futuros.

A Tabela 1 mostra a porcentagem de erro de outros trabalhos da literatura utilizando a base de dados GTSRB.

Técnica	Erro(%)
Comitê de CNNs	0.85
MLP/ HOG	4.55
Máscaras de Convolação/ <i>Random Forest</i> (Proposta)	12.50
MLP/HAAR	12.92

Tabela 1. Porcentagens de erro sobre GTSRB [31].

VI. CONCLUSÕES

A classificação de sinais de trânsito é um desafio de visão computacional de relevância industrial, contudo, já há trabalhos sendo desenvolvidos na área trazendo resultados surpreendentes. A combinação de algoritmos de enxames para a criação de extratores de características em combinação com classificadores baseados em comitês (ensembles) é interessante e traz resultados promissores, não superando, apesar de se aproximar razoavelmente, das taxas de classificação obtidas por trabalhos relacionados.

No entanto, o método aqui proposto traz vantagens em relação ao custo computacional e a possibilidade de ser melhorado em trabalhos futuros, através do estudo das influências de cada parâmetro.

A abordagem, se melhorada, pode possibilitar futura implementação em sistemas embarcados, servindo de apoio a pessoas com deficiências visuais parciais, ou como um facilitador da aprendizagem para novos condutores de veículos.

REFERENCES

- [1] F. Santos. "Reconhecimento automático de sinalização vertical de trânsito a partir de dados vídeo de um sistema de mapeamento móvel," 77 f. Dissertação (Mestrado em Engenharia Geográfica) - Departamento de Engenharia Geográfica, Geofísica e Energia, Universidade de Lisboa, Lisboa. 2013.
- [2] F. Silva, A. Artero, M.S.V. R. Barbosa, "Uma metodologia para Detectar e Reconhecer Placas de Sinalização de Trânsito". São Paulo, 2010.
- [3] A. Martinovic, "Real-time detection and recognition of traffic signs", in International Convention on Information and Communication Technology, Electronics and Microelectronics, pp. 247-252, 2010.
- [4] X. Baró, "Traffic sign recognition using evolutionary adaboost detection and forest ECOC classification," in IEE Trans. On Intelligent Transportation System, pp. 113-126, 2009.
- [5] M. Mathias, R. Timofte, R. Benenson, and L. V. Gool, "Traffic sign recognition - how far are we from the solution?" in Proceedings of IEEE International Joint Conference on Neural Networks (IJCNN 2013), August 2013.
- [6] D. Ciresan, U. Meier, J. Masci, and J. Schmidhuber, "Multi-column deep neural network for traffic sign classification," Neural Networks, vol. 32, pp. 333-338, 2012.
- [7] C. Y. Fang, S. W. Chen, C. S. Fuh, "Road-sign detection and tracking," in Proceedings of the IEEE Vehicular Technology, vol. 52, no. 5, pp. 1329-1341, 2003.
- [8] R. Timofte, K. Zimmermann, L. Van Gool, "Multi-view traffic sign detection, recognition, and 3D localization," in Applications of Computer Vision (WACV), 2014 Workshop on. IEEE, 2014, pp. 1-8.
- [9] L. Breiman, "*Random Forests*", Machine Learning, vol. 45, no 1, 2001, pp. 5-32.
- [10] J. Stallkamp, M. Schlipsing, J. Salmen, C. Igel, "The German Traffic Sign Recognition Benchmark: A multi-class classification competition," in Proc. Int. Jt. Conf. Neural Networks, pp. 1453-1460, 2011.
- [11] S. Houben, J. Stallkamp, J. Salmen, M. Schlipsing, C. Igel, "Detection of Traffic Signs in Real-World Images: The German Traffic Sign Detection Benchmark," in International Joint Conference on Neural Networks (submitted), 2013.
- [12] E. Garoudja, K. Kara, "Parameters Extraction of Photovoltaic Module for Long-Term Prediction Using Artificial Bee Colony Optimization," in 3rd International Conference on Control, Engineering & Information Technology, 2015.
- [13] B. Basturk, D. Karaboga, "An artificial bee colony (abc) algorithm for numeric function optimization", in IEEE Swarm Intelligence Symposium, 2006, Indianapolis, Indiana, USA.
- [14] D. Karaboga, B. Akay, "Solving large scale numerical problems using artificial bee colony algorithm, in: Sixth International Symposium on Intelligent and Manufacturing Systems Features", in Strategies and Innovation (Sakarya, Turkiye), October 14-17, 2008.
- [15] D. Karaboga, B. Gorkemli, C. Ozturk, "A comprehensive survey: artificial bee colony (ABC) algorithm and applications," in Artificial Intelligence Review, 2012.
- [16] E. Scornet, G. Biau, JP Vert, "Consistency of random forests," Technical Report, 2014.
- [17] A. Bosch, A. Zisserman, X. Muñoz, "Image Classification using Random Forests and Ferns," in Proceedings of the IEEE Computer Vision, 2007.
- [18] M. B. Kursu, "Robustness of Random Forest-based gene selection methods," in BMC bioinformatics, vol. 15, no.1, pp. 1-8, 2014.
- [19] Y. Zeng, X. Xu, Y. Fang, and K. Zhao, "Traffic Sign Recognition Using Extreme Learning Classifier with Deep Convolutional Features," in international conference on intelligence science and big data engineering (IScIDE 2015), Suzhou, China, June 14-16, 2015.

- [20] Y. Sun, "Research on Traffic Sign Classification Algorithm Based on SVM," in *International Journal of Hybrid Information Technology*, vol. 8, no. 5, pp. 273–282, 2015.
- [21] J. Stallkamp, M. Schlipsing, J. Salmen, and C. Igel, "Man vs computer: Benchmarking machine learning algorithms for traffic sign recognition," *Neural Networks*, vol. 32, pp. 323–332, 2012.
- [22] C. G. Keller, C. Sprunk, C. Bahlmann, J. Giebel, and G. Barattoff, "Real-time recognition of U.S. speed signs," in *Proceedings of the IEEE Intelligent Vehicles Symposium*, 2008, pp. 518–523.
- [23] A. S. Muhammad, N. Lavesson, P. Davidsson, and M. Nilsson, "Analysis of speed sign classification algorithms using shape based segmentation of binary images," in *Proceedings of the International Conference on Computer Analysis of Images and Patterns*, 2009, pp. 1220–1227.
- [24] S. Maldonado Bascon, J. Acevedo Rodriguez, S. Lafuente Arroyo, A. Caballero, and F. Lopez-Ferreras, "An optimization on pictogram identification for the road-sign recognition task using SVMs," *Computer Vision and Image Understanding*, vol. 114, no. 3, pp. 373–383, 2010.
- [25] C. Bahlmann, Y. Zhu, V. Ramesh, M. Pellkofer, and T. Koehler, "A system for traffic sign detection, tracking, and recognition using color, shape, and motion information", in *Proceedings of the IEEE Intelligent Vehicles Symposium*, 2005, pp. 255–260.
- [26] F. Moutarde, A. Bargeton, A. Herbin, and A. Chaussois, "Robust onvehicle real-time visual detection of american and european speed limit signs with a modular traffic signs recognition system," in *Proceedings of the IEEE Intelligent Vehicles Symposium*, 2007, pp. 1122–1126.
- [27] A. Broggi, P. Cerri, P. Medici, P. P. Porta, and G. Ghisio, "Real time road signs recognition," in *Proceedings of the IEEE Intelligent Vehicles Symposium*, 2007, pp. 981–986.
- [28] C. T. Min, T. M. Lim, M. Andreas. "A Study on the Bootstrapping Architectures for Scalable Private Reappearing Overlay Network", in *Information Technology: New Generations (ITNG)*, 2013, pp. 552 - 557.
- [29] F. Zaklouta and B. Stanculescu, "Real-time traffic-sign recognition using tree classifiers," *IEEE Trans. Intell. Transp. Syst.*, vol. 13, no. 4, pp. 1507–1514, Dec. 2012.
- [30] Greenhalgh, J.; Mirmehdi, M., "Traffic sign recognition using MSER and Random Forests," in *Signal Processing Conference (EUSIPCO)*, 2012 *Proceedings of the 20th European*, pp.1935-1939, 27-31 Aug. 2012
- [31] D. Ciresan, U. Meier, J. Masci, and J. Schmidhuber, "A committee of neural networks for traffic sign classification," in *Proc. IJCNN*, 2011, pp. 1918–1921.