



دانشگاه مهندسی برق  
دانشگاه آزاد اسلامی واحد نجف آباد

پنجمین کنفرانس ملی مهندسی برق ایران - دانشگاه آزاد اسلامی واحد نجف آباد - ۸ و ۹ اسفند ۱۳۹۷

## مروری بر روش‌های تشخیص و شناسایی تابلوهای علائم ترافیکی با استفاده از روش‌های پردازش تصویر

بابک شیرانی<sup>۱\*</sup>، دکتر بهرنگ برکتین<sup>۲</sup>

<sup>۱</sup>دانشکده مهندسی کامپیوتر، واحد نجف آباد، دانشگاه آزاد اسلامی، نجف آباد، ایران

<sup>1</sup>shirani.babak@sco.iaun.ac.ir

<sup>۲</sup>دانشکده مهندسی کامپیوتر، واحد نجف آباد، دانشگاه آزاد اسلامی، نجف آباد، ایران

<sup>2</sup>behrang\_barekatin@iaun.ac.ir

چکیده - توسعه تکنولوژی اتومبیل‌های خودگردان و سیستم معاونت راننده در سال‌های اخیر باعث شده است که نگاه ویژه‌ای به این تکنولوژی در زمینه‌های مختلف کنند. موردی که باید به آن توجه کنند، کاهش تصادفات و خطرات و افزایش امنیت سرنشینان خودرو می‌باشد. از این رو یکی از این سیستم‌هایی که به این امر کمک می‌کند، سیستم تشخیص و شناسایی علائم ترافیکی در شرایط جوی و حالت‌های مختلف می‌باشد. در این مقاله سعی کرده‌ایم که روش‌های انجام شده در چند سال اخیر که بر روی چند دیتاست معروف که در این زمینه موجود است را با یکدیگر مقایسه کنیم. این روش‌ها در زمینه تشخیص و شناسایی تابلوهای علائم ترافیکی در جهت افزایش دقت این سیستم و دیگر پارامترها در شرایط مختلف می‌باشد.

کلید واژه- تشخیص علائم ترافیکی، سیستم معاونت راننده، شناسایی علائم ترافیکی

می‌گذارد. اگر اطلاعاتی که در مورد جاده و علائم ترافیکی به این سیستم داده شود، اطلاعات صحیحی نباشد، دقت سیستم افت کرده و نه تنها باعث افزایش امنیت نمی‌شود، بلکه بر عکس عمل کرده و باعث تصادف نیز می‌شود. از این رو باید با ارائه و پیاده‌سازی روش‌هایی، در صدد بهبود و توسعه این سیستم بود. سیستم TSR، تصاویر تابلوهای ترافیکی را توسط دوربین‌های نصب شده روی داشبورد اتومبیل دریافت می‌کند. حال چالش بسیار مهمی که بر سر راه این سیستم وجود دارد کاهش زمان دریافت تصاویر و پردازش و شناسایی نوع آن و برچسب‌گذاری می‌باشد که در عین حال باید از دقت بالا و مورد قبولی برخوردار باشد. به دلیل سرعت حرکت اتومبیل، ممکن

### ۱- مقدمه

امروزه سیستم‌های معاونت راننده (Advanced Driver Assistance System) (ADAS) به طور وسیعی در اتومبیل‌های خودران استفاده می‌شوند. به همین دلیل باعث شده است که مطالعات و آزمایشات گسترده‌ای در این زمینه انجام شود. یکی از مواردی که نقش بسزایی در این حوزه دارد سیستم شناسایی تابلوهای علائم ترافیکی (Traffic Sign Recognition) (TSR) می‌باشد. استفاده از این سیستم در کاهش خطرات بالقوه جاده‌ای و تصادفات و افزایش امنیت سرنشینان اتومبیل تاثیر بسزایی

هیستوگرام گرادیان جهت‌دار (HOG) [۲]، ویژگی Haar [۳] با انواع و سائزهای متفاوت، جهت شناسایی هرچه بهتر علائم ترافیکی به صورت همزمان و ترکیبی از آنها استفاده می‌کند.

• از Alternating direction method of (ADMM) (multipliers) جهت حل روش پیشنه‌پادی به صورت موثر، استفاده شده است.

این مقاله برای پیاده سازی و استخراج ویژگی‌ها از دیتاست GTSRB [۴] استفاده کرده است و نتایج بدست آمده خود را با روش‌ها و کارهایی که قبلاً روی دیتاست‌هایی مانند BelgiumTSC [5] و LISA [6]، پیاده سازی شده، مقایسه کرده است. نتایج بدست آمده را می‌توان در جدول ۱ و ۲ مشاهده کرد.

جدول ۱- دقت شناسایی [۱] روی دیتاست BelgiumTSC و LISA

Method/Data set	BelgiumTSC	LISA Data set
LDA [4]	93.98%	62.59%
SRGE [7]	96.58%	79.08%
M <sup>2</sup> -tMTL	96.90%	80.75%

جدول ۲- جزئیات محاسبات M<sup>2</sup>-tMTL [۱] روی GTSRB

Method/Details	Hardware platform	Training Time	Recognition Accuracy
M <sup>2</sup> -tMTL	Cori5-4590(3.3Ghz),no graphics card	0.5 hours	98.27%

با توجه به این مقاله می‌توان گفت روش پیشنهادی [۱] دقت بالایی در شناسایی علائم ترافیکی در شرایط مختلف مانند تارشدگی، شدت روشنایی متفاوت و گرفتگی‌های جزئی تابلو دارا می‌باشد.

مقاله [۸] در سال ۲۰۱۶ یک روش محاسباتی را برای شناسایی تابلوهای ترافیکی ارائه کرد. آنها یک راه حل بهبود یافته جهت طبقه بندی انواع علائم ترافیکی با استفاده از رویکرد طبقه بندی مبتنی بر الگوریتم ELM [۹] ارائه کردند. روش این مقاله را می‌توان به دو دسته کلی تقسیم کرد:

۱- استخراج ویژگی عکس‌های ورودی و هیستوگرام گرادیان جهت‌دار (HOG) [۲]  
 نوع HOG (HOGv) که در این مقاله ارائه شده است دو مزیت اصلی نسبت به توصیفگرهای HOG معمولی دارد، اول

است تصاویر با تارشدگی، به این سیستم منتقل شوند. از بین بردن این تارشدگی و شناسایی صحیح از مزیت‌های روش پیاده‌سازی این سیستم می‌باشد. یکی دیگر از مشکلات موجود به دلیل شباهت تابلوها از نظر شکل و رنگ به وجود می‌آید که سیستم باید قادر به تفکیک آنها از یکدیگر باشد. از دیگر چالش‌های دیگری که این سیستم با آن مواجه می‌شود، می‌توان به چرخش و تغییرات زاویه دید، گرفتگی تابلو توسط سایه درختان یا ساختمان‌ها و شرایط جوی مانند گرد و خاک، مه آلودگی، شدت نور اشاره کرد.

تابلوهای ترافیکی که در سطح جاده‌ها استفاده می‌شود حاوی علائم و بعضاً دارای متن می‌باشند. این تابلوها از لحاظ شکل، اندازه و رنگ، متنوع می‌باشند. از این رو دیتاست‌هایی که در این حوزه استفاده می‌شوند، تابلوها را به چندین دسته طبقه‌بندی می‌کنند. در این مقاله ما مشخصات چند دیتاست معروف که در کارهای اخیر از آن برای انجام آزمایشات و پیاده سازی به صورت گسترده استفاده شده است را معرفی می‌کنیم. از جمله این دیتاست‌ها می‌توان به موارد زیر اشاره کرد:

- German TSR benchmark (GTSRB)
- Belgium Traffic Sign Classification Data set (BelgiumTSC)
- LISA Traffic Sign Data set

ما در بخش ۲ مروری بر کارهای انجام شده خواهیم داشت و در بخش ۳ یک نتیجه‌گیری کلی خواهیم کرد.

## ۲- مروری بر کارهای گذشته

مقاله [۱] در سال ۲۰۱۶ یک ساختار درختی چند منظوره (Multi-Modal tree structure) را با استفاده از Multi-Task Learning که به اختصار به آن M<sup>2</sup>-tMTL می‌گویند، برای انتخاب ویژگی‌های بصری جهت شناسایی علائم ترافیکی ارائه کرده‌اند. الگوریتم این مقاله به دلیل اینکه از یک ساختار درختی جهت مدل‌سازی همبستگی سلسله مراتبی (hierarchical correlations) و از یادگیری چند منظوره (Multi-Task Learning) استفاده می‌کند قادر است علائم ترافیکی شبیه به یکدیگر را شناسایی و طبقه‌بندی کند. این مقاله را می‌توان در سه قسمت خلاصه کرد:

- برای اولین بار از روش ساختار درختی MTL جهت شناسایی علائم ترافیکی استفاده کرده است و همبستگی سلسله مراتبی را مدل‌سازی کردند.
- از ویژگی‌های چند منظوره مانند هیستوگرام رنگ،

تشخیص تابلو و شنا سایی تابلو ارائه کردند. روش مقاله [۱۱] از فیلتر رنگی (Hue Saturation Value (HSV) و Graph embedding Discriminant Analysis (GGDA) [۱۲]، استفاده کرده است. روش HSV به گونه‌ای اعمال شده است که تابلوهای ترافیکی مربوطه را به درستی تشخیص دهد. در طول آموزش داده‌هایی که توسط دوربین نصب شده در جلوی اتومبیل گرفته شده است، شامل تصاویری با شدت نورهای متفاوت می‌باشد. فیلم‌های گرفته شده توسط این دوربین جهت پردازش لحظه‌ای و فریم به فریم، به کامپیوتر اتومبیل انتقال داده می‌شود. این مقاله برای شناسایی علائم از GGDA استفاده کرده است و روش خود را روی انواع علائم از جمله تابلوهای محدودیت سرعت، راهنمای مسیر و علائم عابر پیاده آزمایش کرده اند.

مراحل کلی پیاده‌سازی، به صورت زیر می‌باشد:

۱- انتخاب ناحیه مورد نظر تصویر:

به جهت کاهش هزینه محاسبات باید تا حد ممکن سعی شود، حداقل تعداد پیکسل انتخاب شود. از این رو این مرحله مورد اهمیت قرار دارد. جهت رسیدن به این امر، حدود ده درصد از بالای عکس را حذف کردند. زیرا معتقد هستند که اکثر علائم موجود در عکس‌هایی که از فاصله نزدیک به اتومبیل گرفته شده‌اند، در قسمت پایین عکس قرار دارند.

۲- قطعه‌بندی رنگی HSV :

[۱۱] برای تشخیص علائم در تصاویر، از اطلاعات رنگی استفاده می‌کند. تصاویر RGB به دلیل این که تحت تاثیر شرایط نور می‌باشند، نمی‌توان از آن استفاده کرد. از این رو آنها از فضای رنگی HSV استفاده کرده‌اند.

۳- استخراج اجزا چسبیده به پیش‌زمینه:

[۱۱] برای حذف نویز در تصاویر، اجزای متصل به ناحیه پیش‌زمینه‌ای که استخراج کرده‌اند را، پیدا می‌کنند. تابلوهای ترافیکی به دلیل شرایط محیط، ممکن است قابل مشاهده نباشند، به همین دلیل آنها جهت تابلوهای ترافیکی را نرمالیزه می‌کنند. این مقاله با استفاده از bounding box [۱۱]، اجزای چسبیده به پیش‌زمینه را استخراج می‌کند و سپس از آن به عنوان تصاویر تست در مرحله شناسایی استفاده می‌کنند.

۴- پس زمینه (background)

۵- شناسایی با استفاده از GGDA

دیتاست‌هایی که در مقاله [۱۱] استفاده شده است به شرح

زیر می‌باشد:

- GTSRB
- Swedish Traffic Sign Dataset (STSD) [13]
- LISA Dataset

اینکه هر دو کنتراست حساس و غیرحساس گرادیان جهت‌دار را شامل می‌شود و دوم اینکه هر سلول هیستوگرام جهت‌دار بر روی چهار بلوک هم‌سایه خود نرمالیزه می‌شود. این نرمالیزه کردن بر اساس تجزیه و تحلیل مولفه اصلی (PCA)، باعث کاهش اطلاعات اضافی می‌شود.

۲- آموزش یک طبقه‌بند واحد به وسیله یادگیری ماشین (extreme learning machine)

الگوریتم ELM یک روش یادگیری برای شبکه عصبی feedforward با یک لایه مخفی (SFNN) (single-hidden-layer feedforward neural networks) می‌باشد. یکی از مزیت‌های این الگوریتم این است که وزن ورودی بین لایه‌های ورودی و لایه مخفی به صورت تصادفی انتخاب می‌شود و تنها وزن بین لایه مخفی و لایه خروجی آموزش می‌بیند در نتیجه تنظیمات لایه به لایه انجام نمی‌شود. مزیت دیگر این الگوریتم این است که قواعد وزن خروجی در دل تابع هزینه گنجانده شده است.

الگوریتم ELM، ۲ عمل را در گره‌های مخفی انجام می‌دهد. یکی ضرب داخلی و دیگری عمل kernel. بنابراین الگوریتم‌های آموزش مربوطه، ELM و kernel ELM می‌باشد. الگوریتم ELM وزن‌های ورودی را به صورت تصادفی انتخاب می‌کند و kernel ELM مجموعه‌ای از kernelها را به صورت تصادفی انتخاب می‌کند.

مزیت الگوریتم ارائه شده توسط این مقاله این می‌باشد که هم صحت مورد قبول و هم هزینه محاسباتی خوبی در آموزش و شناسایی علائم دارا می‌باشد.

آنها از سه دیتاست زیر برای آزمایشات و پیاده‌سازی روش خود استفاده کرده‌اند:

- German TSR benchmark
- BelgiumTSC
- The state of traffic and infrastructure (revised MASTIF) data set [10]

نتایج بدست آمده این مقاله را می‌توانید در جدول ۳ مشاهده کنید.

جدول ۳- نتایج بدست آمده [۸] روی دیتاست BTSC

Method	Recognition Rate	Training Time	Recognition Time
Kernel ELM based	98.62%	10.3s/dataset	1.46ms/frame
ELM based	98.38%	50.3s/dataset	1.42ms/frame

مقاله [۱۱] در سال ۲۰۱۸، روشی در دو قسمت کلی

کنتراست تصاویر می‌باشد. به دلیل اینکه فضای رنگی HSV برای قطعه‌بندی تصاویر مناسب می‌باشد، ابتدا تصاویر را از قالب RGB به فضای رنگی HSV منتقل می‌کنند و سپس کانال V که مربوط به روشنایی می‌باشد را استخراج می‌کنند و به مقادیر هیستوگرام اعمال می‌کنند [۱۹]. همچنین این مرحله شامل عملیات معرفی شده می‌باشد و مرز تصاویر در این مرحله مشخص می‌شود و سایز تصویر را کاهش می‌دهد.

در مرحله طبقه‌بندی و برچسب‌گذاری تصاویر، از شبکه‌های عصبی کانولوشن و چند لایه استفاده کردند. برای کاهش محاسبات، عملگر pooling را به کار گرفته‌اند.

پس از انجام این مراحل ویژگی‌های تصاویر علائم ترافیکی را که به بردار یک بعدی تبدیل کرده‌اند، به عنوان لایه ورودی و وزن آن در شبکه در نظر می‌گیرند. آنها برای پیاده‌سازی فاز شناسایی، یادگیری عمیق با کتابخانه Keras [۲۰] را به کار گرفته‌اند. کتابخانه Keras یک شبکه عصبی با سطح بالا می‌باشد. آنها شش ساختار متنوع را برای شبکه عصبی خود طراحی کرده‌اند که هر کدام را امتحان کرده و به نتیجه خوبی دست یافته‌اند.

به دلیل اینکه خروجی به مقدار داده‌ها و یک سری پارامترها بستگی دارد، باید یک ساختار اکتشافی را پیاده‌سازی کنند، به همین دلیل ساختار شبکه طراحی شده باید با داده‌ها مرتبط باشد.

در این مقاله برای پیاده‌سازی روش خود از دیتاست GTSRB استفاده کرده‌اند. نتایج کلی که با پیاده‌سازی شش ساختار متنوع شبکه عصبی طراحی شده روی دیتاست ذکر شده به دست آورده‌اند طبق جدول ۸ می‌باشد.

این شش ساختار طراحی شده به ترتیب شماره، شبکه عصبی آن بزرگ‌تر شده است و می‌توان این نتیجه را گرفت که هرچه شبکه بزرگ‌تر باشد نتایج بهتری می‌توان گرفت.

جدول ۸- نتایج روش [۱۵] روی دیتاست GTSRB

Architecture no	1	2	3	4	5	6
Accuracy(%)	95	95.5	97.2	96.1	98.1	99.24

ما در جدول ۹، ۱۱ روشی که برای شناسایی علائم ترافیکی در انواع تابلوها بر روی دیتاست GTSRB در چند سال

- RUG Dataset [14]

نتایج به دست آمده طبق مقاله [۱۱] به شرح جدول‌های ۴ و ۵ و ۶ می‌باشد:

جدول ۴- نتایج روش [11] GGDA روی دیتاست GTSRB

Sign	Prohibitory	Mandatory	Danger	Others	All
Accuracy	100%	100%	98.38%	97.14	99.12

جدول ۵- نتایج روش [11] GGDA روی دیتاست STSD

Sign	Prohibitiv	Mandatory
Accuracy	96.94%	95.21

جدول ۶- نتایج روش [11] GGDA روی دیتاست LISA

Sign	STOP	Warning	Speed
Accuracy	99.36%	98.73%	98.89

جدول ۷- نتایج روش [11] GGDA روی دیتاست RUG

Sign	Pedestrian crossing	Bikes	Intersection
Accuracy(%)	99.81	99.89	99.24
Time(msec)	106	97.6	91

مقاله [۱۵] در سال ۲۰۱۸، رویکرد شبکه‌های عصبی کانولوشن (Convolution neural network) (CNN) [۱۶] را، عملیات اضافی در مقایسه با کارهای دیگر مثل نرمال‌سازی دسته‌بندی [۱۷] و حذف تصادفی [۱۸]، جهت شناسایی علائم ترافیکی ارائه کردند. مزیت این عملیات این می‌باشد که مدلی جهت آموزش بهتر و طبقه‌بندی دقیق‌تر ارائه می‌کند. آنها رویکرد خود را در دو فاز اساسی ارائه کرده‌اند که به شرح زیر می‌باشد:

۱- پیش پردازش

۲- طبقه‌بندی علائم

برای مرحله پیش پردازش از مقادیر نرمال شده هیستوگرام در کانال v استفاده شده است. این امر جهت بهبود

اخیر پیاده سازی شده است را با یکدیگر مقایسه کرده ایم.  
در ادامه ما چند دیتاست معروف که برای علائم ترافیکی  
موجود می باشد را ذکر کرده ایم. این دیتاست ها عبارت هستند از:

- German TSR Benchmark [4]
- KU1 Belgium Traffic Sign Classification Data set (belgiumTSC) [5]
- Swedish Sign Data set (STS Data set) [13]
- RUG traffic Sign Image Database (RUG Data set) [14]
- LISA Traffic Sign Data set (LISA Data set) [6]

جدول ۹- نتایج تعدادی از روش‌های پیاده سازی شده روی دیتاست GTSRB

Method/subsets	Speed limits	Other prohibition	Derestriction	Mandatory	Danger	Unique	Overall
Kernel ELM based [8]	99.54%	100%	98.33%	99.94%	98.96%	99.95%	99.56%
Hierarchical SVM [21]	N/A	N/A	98.89%	99.94%	99.03%	99.90%	99.52%
Committee of CNN [22]	99.47%	99.93%	99.72%	99.89%	99.07%	99.22%	99.46%
Human best [4]	98.32%	99.87%	98.89%	100%	99.21%	100%	99.22%
ELM based [8]	99.14%	99.80%	96.94%	99.77%	97.81%	99.90%	99.09%
Human average [4]	97.63%	99.93%	98.89%	99.72%	98.67%	100%	98.84%
Multi-Scale CNN [23]	98.61%	99.93%	98.89%	97.18%	98.67%	98.63%	98.31%
Random forests [24]	95.95%	99.13%	87.50%	99.27%	92.08%	98.73%	96.14%
LDA [4]	95.37%	96.80%	85.83%	97.18%	93.73%	98.63%	95.68%
SRGE [7]	97.68%	99.24%	97.23%	98.54%	97.31%	99.51%	98.19%
M <sup>2</sup> -tMTL [1]	98.33%	98.97%	98.71%	97.26%	97.23%	99.61%	98.27%

### ۳- نتیجه گیری

امروزه کاربرد سیستم‌های معاونت راننده به گونه‌ای افزایش پیدا کرده است که توانسته نظر محققان زیادی را در زمینه‌های مختلف این سیستم به خود جلب کند. یکی از این زمینه‌هایی که نقش بسزایی در افزایش امنیت سرنشینان اتومبیل دارد، سیستم شناسایی علائم ترافیکی می‌باشد. از این رو این محققین با ارائه روش‌های متفاوت خود، سعی بر افزایش دقت و کارایی این سیستم داشته‌اند. این سیستم باید قادر به شناسایی انواع علائم ترافیکی با شرایط متفاوت و با حداکثر سرعت پردازش ممکن، باشد تا بتوان از آن در اتومبیل‌های خود ران استفاده کرد. ما در این مقاله سعی بر آن داشته‌ایم که چند کار اخیر مهمی که در این زمینه انجام شده است را از زوایای مختلف بررسی کرده و با یکدیگر مقایسه کنیم.

## مراجع

- [1] X. Lu, Y. Wang, X. Zhou, Z. Zhang, and Z. Ling, "Traffic sign recognition via multi-modal tree-structure embedded multi-task learning," *IEEE Transactions on Intelligent Transportation Systems*, vol. 18, pp. 960-972, 2017.
- [2] N. Dalal and B. Triggs, "Histograms of oriented gradients for human detection," in *Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on*, 2005, pp. 886-893.
- [3] R. Lienhart and J. Maydt, "An extended set of haar-like features for rapid object detection," in *Image Processing. 2002. Proceedings. 2002 International Conference on*, 2002, pp. I-I.
- [4] 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, 2012/08/01/ 2012.
- [5] R. Timofte, K. Zimmermann, and L. Van Gool, "Multi-view traffic sign detection, recognition, and 3D localisation," *Machine vision and applications*, vol. 25, pp. 633-647, 2014.
- [6] A. Møgelmoose, M. M. Trivedi, and T. B. Moeslund, "Vision-Based Traffic Sign Detection and Analysis for Intelligent Driver Assistance Systems: Perspectives and Survey," *IEEE Trans. Intelligent Transportation Systems*, vol. 13, pp. 1484-1497, 2012.
- [7] K. Lu, Z. Ding, and S. Ge, "Sparse-representation-based graph embedding for traffic sign recognition," *Traffic*, vol. 31, p. 32, 2012.
- [8] Z. Huang, Y. Yu, J. Gu, and H. Liu, "An efficient method for traffic sign recognition based on extreme learning machine," *IEEE transactions on cybernetics*, vol. 47, pp. 920-933, 2017.
- [9] G.-B. Huang, Q.-Y. Zhu, and C.-K. Siew, "Extreme learning machine: theory and applications," *Neurocomputing*, vol. 70, pp. 489-501, 2006.
- [10] I. Filkovic, "Traffic sign localization and classification methods: an overview," ed.
- [11] A. Gupta and A. Choudhary, "A Framework for Real-time Traffic Sign Detection and Recognition using Grassmann Manifolds," in *2018 21st International Conference on Intelligent Transportation Systems (ITSC)*, 2018, pp. 274-279.
- [12] M. T. Harandi, C. Sanderson, S. Shirazi, and B. C. Lovell, "Graph embedding discriminant analysis on Grassmannian manifolds for improved image set matching," in *Computer Vision and Pattern Recognition (CVPR), 2011 IEEE Conference on*, 2011, pp. 2705-2712.
- [13] F. Larsson and M. Felsberg, "Using Fourier descriptors and spatial models for traffic sign recognition," in *Scandinavian Conference on Image Analysis*, 2011, pp. 238-249.
- [14] C. Grigorescu and N. Petkov, "Distance sets for shape filters and shape recognition," *IEEE transactions on image processing*, vol. 12, pp. 1274-1286, 2003.
- [15] K. S. Boujemaa, I. Berrada, A. Bouhoute, and K. Boubouh, "Traffic sign recognition using convolutional neural networks," in *Wireless Networks and Mobile Communications (WINCOM), 2017 International Conference on*, 2017, pp. 1-6.
- [16] Y. LeCun, B. Boser, J. S. Denker, D. Henderson, R. E. Howard, W. Hubbard, et al., "Backpropagation applied to handwritten zip code recognition," *Neural computation*, vol. 1, pp. 541-551, 1989.
- [17] S. Ioffe and C. Szegedy, "Batch normalization: Accelerating deep network training by reducing internal covariate shift," *arXiv preprint arXiv:1502.03167*, 2015.
- [18] G. E. Hinton, N. Srivastava, A. Krizhevsky, I. Sutskever, and R. R. Salakhutdinov, "Improving neural networks by preventing co-adaptation of feature detectors," *arXiv preprint arXiv:1207.0580*, 2012.
- [19] I. Melekhov, J. Kannala, and E. Rahtu, "Image patch matching using convolutional descriptors with euclidean distance," in *Asian Conference on Computer Vision*, 2016, pp. 638-653.
- [20] M. Haloi, "Traffic sign classification using deep inception based convolutional networks," *arXiv preprint arXiv:1511.02992*, 2015.
- [21] G. Wang, G. Ren, Z. Wu, Y. Zhao, and L. Jiang, "A hierarchical method for traffic sign classification with support vector machines," in *Neural Networks (IJCNN), The 2013 International Joint Conference on*, 2013, pp. 1-6.
- [22] D. CireşAn, U. Meier, J. Masci, and J. Schmidhuber, "Multi-column deep neural network for traffic sign classification," *Neural networks*, vol. 32, pp. 333-338, 2012.
- [23] P. Sermanet and Y. LeCun, "Traffic sign recognition with multi-scale convolutional networks," in *Neural Networks (IJCNN), The 2011 International Joint Conference on*, 2011, pp. 2809-2813.
- [24] F. Zaklouta, B. Stanculescu, and O. Hamdoun, "Traffic sign classification using kd trees and random forests," in *Neural*

*Networks (IJCNN), The 2011 International Joint Conference on, 2011, pp. 2151-2155.*