



## Full Length Research Paper

# Détection et reconnaissance d'obstacles routiers pour la prévention des accidents sur les routes nationales au Sénégal

Amadou Dahirou GUEYE<sup>1\*</sup>, Papa Assane DIOP<sup>2</sup><sup>1</sup>Université Amadou Mahtar Mbow – Dakarr, Sénégal<sup>2</sup>Université Alioune Diop – Bambey, Sénégal

Received October 2024 – Accepted December 2024



\*Corresponding author. Amadou Dahirou GUEYE

Author(s) agree that this article remain permanently open access under the terms of the Creative Commons Attribution License 4.0 International License.

## Résumé:

La sécurité routière constitue une préoccupation majeure dans les pays subsahariens en général, et au Sénégal en particulier où des structures comme l'AGEROUTE (Agence de Gestion des ROUTES) et l'ANASER (Agence Nationale de Sécurité Routière) travaillent en étroite collaboration pour relever les défis sécuritaires sur les routes nationales, secondaires et classées au Sénégal. D'énormes d'efforts ont été consentis par l'état du Sénégal à travers ces structures pour diminuer les risques d'accidents qui s'élève entre 2015-2019 à 11 000 victimes. Dans la littérature, l'exploration recherche effectuée montre que peu de solutions sont issus de l'IA. Le but de ce travail est d'apporter des solutions innovantes dans le domaine de la sécurité routière par l'usage de l'IA à travers le deep learning et la science des données. Pour y parvenir, nous nous intéressons d'une part aux obstacles routiers qui posent le plus de risque : obstacles latéraux, animaux sauvages ; et d'autre part à l'état dégradant des panneaux de signalisations et des déformations sur les routes (fissure, nid de poule), la non-visibility des signalisations verticales et horizontales (ligne continue, ligne discontinue, ligne mixte, etc.). La méthodologie que nous avons adoptée consiste à utiliser l'apprentissage profond qui est un domaine de l'IA pour créer des systèmes et des modèles de reconnaissances basés sur le computer vision (vision par ordinateur). Pour la mise en place de notre jeu de données, nous avons travaillé avec les données de Kaggle et de l'AGEROUTE du Sénégal. Pour la détection des obstacles latéraux comme les arbres, les poteaux, les virages, nous avons obtenu un taux de précision de 90%. Pour la détection des animaux sauvages, le taux de précision est de 91, 23%. Pour le système de détection des panneaux de signalisation et des déformations routières, le taux de précision est de 95, 34%. Les solutions proposées sont déployées et testées sur des véhicules particuliers intégrant un dispositif constitué d'une caméra, d'un Raspberry PI et d'un capteur sonore. Les obstacles cités et autres objets cités sont détectés sur une distance donnée ; ce qui permet d'alerter le conducteur en temps réel.

**Mots clés:** Sécurité routière ; Détection ; Obstacle routier ; Intelligence artificielle ; Computer vision.

## Cite this article:

Amadou Dahiou Gueye and Papa Assane Diop (2024). Détection et reconnaissance d'obstacles routiers pour la prévention des accidents sur les routes nationales au Sénégal. Revue RAMReS – Sci. Appl. & de l'Ing., Vol. 6(2), pp. 30-35. ISSN 2630-1164.

## 1. Introduction

Dans les pays subsahariens, nous assistons d'année en année à une augmentation fulgurante des accidents plus particulièrement sur les différentes routes et en particulier sur les routes nationales en zone hors agglomération. Au Sénégal, les statistiques des accidents de la circulation indiquent pour l'année 2022, 19815 nombre d'accidents dont 31662 victimes, 30944 blessés et 718 morts [1]. Ainsi, de 2015 à 2022, le

nombre de décès dans les accidents passe de 569 à 718. Avec tous ces problèmes liés aux routes, la vidéosurveillance consiste un moyen nécessaire pour assurer la sécurité routière. La vidéosurveillance, communément appelée vidéo protection, est constituée de caméras et tout ce qui est utile pour enregistrer et exploiter les images afin de détecter les événements anormaux. L'objectif principal du traitement d'une image numérique est l'extraction d'informations et

l'amélioration de sa qualité visuelle afin de la rendre plus interprétable par un analyste humain ou une perception machine autonome.

Des exemples d'images numériques sont celles acquises par des caméras numériques, des capteurs à bord de satellites ou d'avions, des équipements médicaux, des équipements de contrôle qualité industriel, etc [2]. L'utilisation de la vidéosurveillance nous permet d'utiliser la vision par ordinateur (Computer Vision) qui inclut beaucoup de modèles de classification d'obstacles routiers latéraux pour assurer la sécurité routière. Il existe dans la littérature des études orientées sur la détection d'obstacles [3] [4] [5]. Les modèles haar cascade sont des caractéristiques utilisées en vision par ordinateur pour la détection d'objets dans des images numériques. Très simples et très rapides à calculer, elles ont été utilisées dans le premier détecteur de visage en temps réel, celui de la méthode de Viola et Jones [6]. Après quelques années de travaux, ces modèles peuvent être utilisés pour d'autres objets de détection. Haar cascade est très utile sur la vidéosurveillance plus précisément sur le traitement d'images et de la vidéo.

Par ailleurs, Aujourd'hui, avec l'utilisation des réseaux neuronaux profonds dans la vision par ordinateur, l'apprentissage profond prend le pas sur l'apprentissage automatique en termes de vidéosurveillance. Dans cet article, nous avons choisi YOLOV4 pour la détection de trois types d'animaux sauvages : les vaches, les ânes et les chèvres.

Toujours, dans l'optique de la recherche de solutions pour réduire les accidents, nous nous sommes rapprochés d'une part des experts de l'AGERROUTE (Agence des Gestion des ROUTES) pour une étude de terrain, et d'autre part nous détaillons dans ce que suit la recherche exploratoire des travaux de recherche menés autour de la sécurité routière par l'usage de la machine learning et du deep learning.

Dans ce papier, nous montrons que les modèles de haar cascade peuvent présenter une méthode fiable sur la détection d'obstacles routiers latéraux. Cependant, le modèle haar cascade entraîné ne peut détecter qu'un seul type d'obstacle. Ainsi, nous proposons, dans un premier temps, un modèle de classification qui s'appuie sur haar cascade et qui détecte en même temps plusieurs types d'obstacles latéraux.

Dans un second temps, nous avons choisi YOLOV4 pour la détection de trois types d'animaux sauvages : les vaches, les ânes et les chèvres.

Enfin, nous nous sommes intéressés dans ce papier aux accidents de la route causés par le non-respect des panneaux de signalisations et des déformations sur les routes.

## 2. État de l'art

Dans cette section, nous présentons quelques travaux connexes en rapport avec les obstacles latéraux. Dans [7], le terme obstacle est pris pour obstacle dangereux. Il désigne tout objet latéral (par rapport à la chaussée), disposition ou ouvrage fixe, ponctuel ou continu, qui est susceptible d'aggraver, en cas de heurt, les conséquences d'une sortie accidentelle d'un véhicule de la chaussée, notamment en occasionnant un blocage ou en favorisant un retournement (tonneau) du véhicule [5]. Les obstacles peuvent être divisés par type [8] : les obstacles heurtés, les obstacles (arbres, poteaux électriques, murs, etc.), les risques accrus en courbe et les risques en fonction de la distance. Pour le modèle de classification, le classificateur en cascade de Haar est l'une des premières et des plus connues des méthodes de détection d'objet. Cette méthode, communément appelée méthode de Violas et Jones créée par Paul Violas et Michael Jones, fait partie des toutes premières méthodes capables de détecter efficacement et en temps réel des objets dans une image [9]. La méthode de Viola et Jones est basée sur une approche par recherche exhaustive sur l'ensemble de l'image, qui teste la présence de l'objet dans une fenêtre à toutes les positions et à plusieurs échelles. Cette approche est cependant extrêmement coûteuse en calcul. L'une des idées-clés de la méthode pour réduire ce coût réside dans l'organisation de l'algorithme de détection en une cascade de classifieurs.

Dans cette partie, nous allons aussi examiner les travaux sur la détection et la surveillance des animaux à l'aide de l'apprentissage profond, en particulier yolo (You Only Look Once). Au cours de la dernière décennie, les modèles de détection d'objets basés sur l'apprentissage profond ont gagné en importance dans le domaine de la recherche. Dans [10-12], on trouve un bon aperçu de l'état de l'art des modèles de détection d'objets basés sur l'apprentissage profond. Par exemple, dans [10], l'auteur nous montre qu'avec les progrès de l'intelligence artificielle, les réseaux neuronaux tels que les réseaux neuronaux convolutifs (CNN) ont souvent été utilisés dans le traitement des images. Par la suite, les modèles CNN sont confrontés à de nombreux problèmes d'exécution, de performance, de déploiement, etc. Dans [13], un autre réseau d'apprentissage profond, à savoir le réseau neuronal à convolution régionale plus rapide (R-CNN plus rapide) pour la détection et le suivi d'objets, est examiné. Dans la littérature, on trouve d'autres types d'algorithmes tels que SSD [14], F-CNN [15]. Dans cet article, nous choisissons l'algorithme de détection par apprentissage profond Yolov4 qui est beaucoup plus rapide et plus efficace en termes de détection. Ces algorithmes ont souvent été utilisés dans la vidéosurveillance pour la détection d'objets.

Dans cette section, nous faisons aussi une étude de recherche exploratoire de l'utilisation de l'IA pour la sécurité routière de manière générale pour ensuite

proposer un modèle de détection applicable à la sécurité routière au Sénégal.

En 2017, J D Zhao [16] a conçu un système de reconnaissance de panneaux de signalisation à l'aide de Matlab. Il étudie l'identification des panneaux de signalisations routières à partir d'images vidéo. La méthode d'extraction des caractéristiques des panneaux de signalisation est étudiée pour former un échantillon de panneaux de signalisations, à l'aide d'un classificateur SVM (Support Vecteur Machine) pour classer les panneaux. Les résultats expérimentaux ont démontré que le système était robuste et précis dans la détection et la reconnaissance d'objets. Le modèle ne prend pas en charge la nature exacte des panneaux c'est-à-dire si on a un panneau de virage à gauche ou à droite, le modèle dit panneau de danger. Ce problème souligné peut être complexe car ça revient à créer des sous-classes dans chaque type de panneaux.

Aussi en 2017, un système de reconnaissance des panneaux routiers est conçu pour système d'aide à la conduite qui interprète les panneaux pour le conducteur. Cette reconnaissance dépend de la détection et de la classification [17]. Ayant recours à Opencv qui une technique pour la vision par ordinateur, Naina P Botekar a eu de bonnes performances pour la reconnaissance des panneaux grâce à ces résultats expérimentaux.

### 3. Méthodologie

#### 3.1. Modèle de classification proposé

Le modèle proposé comporte de plusieurs sous modèles car pour chaque obstacle routier il nous faut un modèle à part entière. De ce fait pour utiliser le haar cascade, il y'a une étape importante qui est la collecte de données (images). Les images ainsi collectées doivent être de deux types : images positives et images négatives. Les images positives doivent contenir les obstacles. Les images négatives sont des images ne contenant pas d'obstacle.

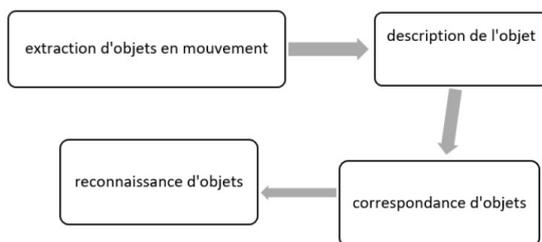


Figure 1 : Schéma fonctionnel pour la reconnaissance d'objets

#### 3.2. Approche de détection basée sur Yolo

Dans [18], l'architecture Yolov4 est composée de plusieurs parties. L'entrée vient en premier et c'est essentiellement ce que nous avons comme ensemble

d'images d'entraînement qui seront transmises au réseau - elles sont traitées par lots en parallèle par le GPU. Viennent ensuite l'épine dorsale et le cou qui se chargent de l'extraction et de l'agrégation des caractéristiques. Le cou et la tête de détection peuvent être considérés comme un ensemble de détecteurs d'objets.

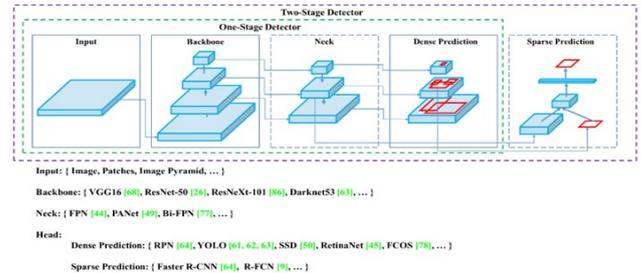


Figure 2 : Détecteur d'objets

## 4. Construction de notre modèle

### 4.1. Extraction de caractéristiques de l'obstacle

Dès que la base d'images constituée, on peut extraire les caractéristiques définies par Viola et Jones dans leurs articles [6]. Les cascades de Haar créent les caractéristiques qu'il utilise en appliquant sur l'image un filtre carré de 24x24. Il s'agit des filtres présentés sur l'image ci-dessous. Les caractéristiques sont obtenues en soustrayant la somme des pixels de l'image couverts par la zone blanche du filtre à la somme des pixels couverts par la zone bleue. Ce processus génère énormément de caractéristiques étant donné que le filtre est appliqué sur toute l'image. Viola et Jones évoquent un nombre de caractéristiques supérieur à 180 000 dans leur article pour une image de 384 par 288 [6].

### 4.2. Construction modèle pour la détection des animaux

Nos données représentent une collection d'images de trois types d'espèces animales sauvages : les vaches, les chèvres et les ânes. Ces données ont été acquises via des sites de recherche Google, dans une ferme au Sénégal, plus précisément à Niague, qui élève des vaches. Après la collecte, nous avons renommé les images en utilisant un code python pour rendre le renommage plus rapide. Avant de renommer, nous avons effectué une étape essentielle qui consiste à supprimer les images non pertinentes. Ensuite, un problème se pose, car les images acquises sur les sites web et les images prises par un appareil photo dans une ferme n'ont pas la même taille. Nous devons donc redimensionner toutes les images pour qu'elles aient la même taille, à savoir 671 x 480. Enfin, nous avons étiqueté les images. Nous avons utilisé labelImg, un outil d'annotation d'images open source. Nous avons 1000 images pour chaque type d'animal, soit 3000 images au total.

### 4.3. Approche reconnaissance des panneaux et des déformations

Par rapport aux déformations, dans ce papier nous gérons les nids de poule qui constituent un danger potentiel pour les routes sénégalaises, et les panneaux déformés. Zhe Xu & Chaoqian Bao [19] proposent une méthode de gradation hybride adaptative basée sur aberration chromatique de trois composantes de couleur, changer le poids fixe qui est utilisé pour améliorer segmentation des couleurs à un poids mutatif qui change avec les changements d'éclairage. L'amélioration l'algorithme peut mieux segmenter les panneaux de signalisation en cas de mauvaise conditions d'éclairage que les autres algorithmes de segmentation des couleurs et peut bien gérer les interférences d'arrière-plan en utilisant 3 niveaux de gris de mélange, y compris les rouges niveaux de gris, niveaux de gris bleus et niveaux de gris de saturation. Par ailleurs, nous comptons proposer un algorithme d'ajustement d'éclipse amélioré pour renforcer la détection des déformés et abrités panneaux de signalisation et augmenter le taux de détection des circulaires panneaux de signalisation. Comme l'environnement des panneaux de signalisation est une sortie naturelle.

### 5. Résultats

Pour le modèle de détection des obstacles latéraux Les vidéos ont été enregistrés à partir d'une caméra sur la route de Kaolack. Comme le montre la figure 2, nous avons ainsi fait des captures d'images à chaque temps bien déterminé afin de pouvoir évaluer le modèle.

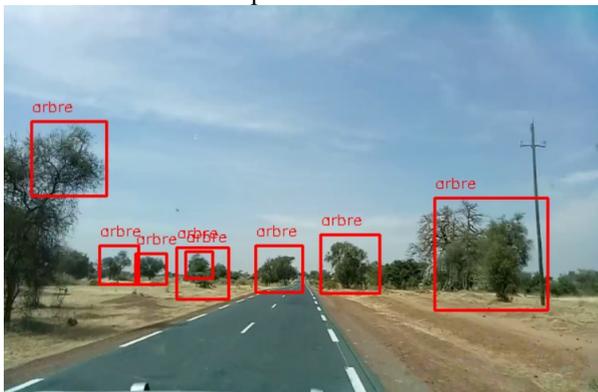


Figure3. Courbes ROC pour comparaisons

La figure 10 montre le ROC pour la classification d'obstacles (arbres). La précision AUC est de 78% première courbe dont la valeur d'échelle est de 1.1. On voit ici la valeur d'échelle qui présente une meilleure AUC est 1.25.

Pour le modèle de détection des animaux sauvages, en ce qui concerne l'environnement d'apprentissage, nous avons utilisé Google Colab Pro pour entraîner nos données [20]. Nous avons partitionné notre ensemble de données (1000 images par classe) pour avoir un ensemble de données d'entraînement (80%) et un ensemble de données de test (20%). Nous nous sommes retrouvés avec :

- Un ensemble de données d'apprentissage (80%),
- un ensemble de données de test (20 %),

Après l'entraînement, un graphique est généré. Le graphique nous montre l'évolution de la précision moyenne (mAP) du modèle et de la fonction de perte

en fonction des itérations. La figure 4 montre qu'après 1000 itérations, mAP = 72%, puis à 1200 itérations, mAP = 98%, puis à 2500 itérations, mAP = 99% et dans toutes les itérations restantes, mAP est égal à environ 98%. Nous constatons également que la fonction de perte continue à diminuer jusqu'à la fin de l'apprentissage pour atteindre 0,466. Ce graphique nous montre les résultats d'une manière globale alors que nous avons trois (3) classes. La figure 4 suivante nous donnera en détail les résultats obtenus.

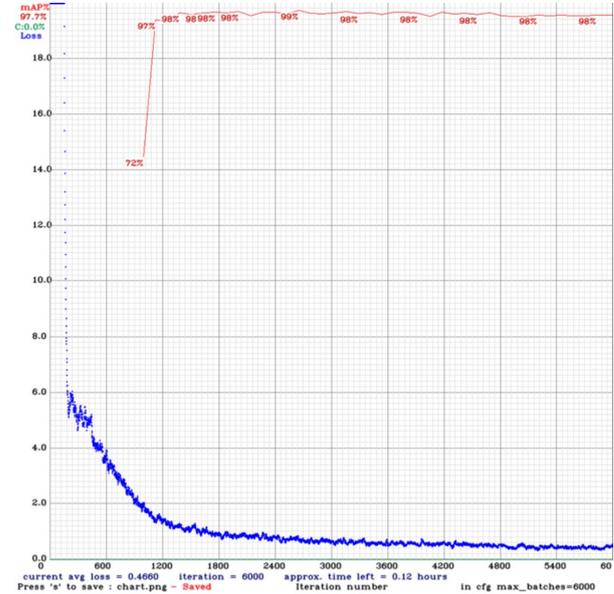


Figure 4 : courbe représentant l'évolution de la mAP et de la fonction de perte en fonction des itérations

Par ailleurs, notre approche consiste à combiner les modèles de détection de panneaux et des déformations, ce qui fait on a un seul modèle de détection. On combine les labels des panneaux de signalisation et les déformations.

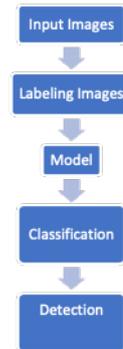


Figure 5 : Système de détection

Le modèle ainsi créé sera apte de détecter en premier temps les panneaux de signalisations et d'autre part les déformations ou l'état dégradant de la route comme les nids de poule, les fissures.



Figure 6 : Image de détection de panneau

La figure 7 est obtenue à partir de la détection de notre modèle qui détecte bien le nid de poule trouvant au milieu de la route.



Figure 7 : image de détection de nid de poule

## 6. Conclusion

Les obstacles latéraux routiers constituent de plus en plus un problème au cours des années avec l'augmentation des voitures. En premier temps, nous avons présenté les différents types d'obstacles latéraux routiers afin de proposer dans un premier temps une solution basée sur la classification haar cascade en vidéo-surveillance. Avec cette méthode, nous avons pu détecter les obstacles en ayant le soin de choisir le facteur d'échelle.

Ensuite, nous avons proposé une approche basée sur le modèle Yolov4 pour détecter les animaux sauvages tels que les vaches, les chèvres et les ânes qui traversent les routes, en particulier dans les zones non urbaines.

Enfin nous avons proposé une approche basée sur yolov8 pour détecter les panneaux ainsi que certaines déformations à savoir : nid de poule. Avec cette approche, une étude de performance du modèle est ainsi faite pour valider notre travail en montrant les différentes courbes de la fonction perte. Dans la perspective du travail, on propose une intégration de sous-classe de panneaux pour élargir la possibilité de détection ainsi que d'augmenter certaines déformations.

## REFERENCES

- [1] Agence Nationale de la sécurité routière au Sénégal ANASER, Source : DTR/BNSP/POLICE/GENDARMERIE
- [2] M. I. Ramadhani, A. E. Minarno et E. B. Cahyono, «Vehicle Classification using Haar Cascade Classifier Method in Vehicle Classification using Haar Cascade Classifier Method in», KINETIK, vol. III, n° %11, pp. 57-64, 2018.
- [3] G. DUPRE, «Traitement des obstacles latéraux», 2002.
- [4] O. MANE, «Les Accidents de la Circulation dans la Commune de Mbour au Sénégal : Etat des lieux et propositions de solutions», 2019.
- [5] Y. Wei, Y. Li et S. Hu, «On-road Obstacle Detection based on Stereovision Analysis», Proceedings of the 2007 IEEE, pp. 958-962, August 2007.
- [6] P. Viola et M. Jones, «Rapid Object Detection using a Boosted Cascade of Simple Features», 2001.
- [7] Setra, «Traitement des obstacles latéraux», Paris, 2002.
- [8] H. Treve, «Obstacles in urban areas», 2008.
- [9] M. I. Ramadhani, A. E. Minarno et E. B. Cahyono, «Vehicle Classification using Haar Cascade Classifier Method in Vehicle Classification using Haar Cascade Classifier Method in», KINETIK, vol. III, n° %11, pp. 57-64, 2018.
- [10] Li, Z., Wang, J.: An improved algorithm for deep learning YOLO network based on Xilinx ZYNQ FPGA. In: 2020 International Conference on Culture-oriented Science & Technology (ICCST). pp. 447-451 (2020). <https://doi.org/10.1109/ICCST50977.2020.00092>.
- [11] Kumar, P.S., Sakthivel, V.P., Raju, M., Sathya, P.D.: A Comprehensive Review on Deep Learning Algorithms and its Applications. In: 2021 Second International Conference on Electronics and Sustainable Communication Systems (ICESC). pp. 1378-1385 (2021). <https://doi.org/10.1109/ICESC51422.2021.9532767>.
- [12] Abdullahi Madey, A.S., Yahyaoui, A., Rasheed, J.: Object Detection in Video by De-tecting Vehicles Using Machine Learning and Deep Learning Approaches. In: 2021 Inter-national Conference on Forthcoming Networks and Sustainability in AIoT Era (FoNeS-AIoT). pp. 62-65 (2021). <https://doi.org/10.1109/FoNeS-AIoT54873.2021.00023>.
- [13] Lee, K.B., Shin, H.S.: An Application of a Deep Learning Algorithm for Automatic Detection of Unexpected Accidents Under Bad CCTV Monitoring Conditions in Tunnels. In: 2019 International Conference on Deep Learning and Machine Learning in Emerging Applications (Deep-ML). pp. 7-11 (2019). <https://doi.org/10.1109/Deep-ML.2019.00010>.
- [14] He, H.: Yolo Target Detection Algorithm in Road Scene Based on Computer Vision. In: 2022 IEEE Asia-Pacific Conference on Image Processing, Electronics and Computers (IPEC). pp. 1111-1114 (2022). <https://doi.org/10.1109/IPEC54454.2022.9777571>.
- [15] Maity, M., Banerjee, S., Sinha Chaudhuri, S.: Faster R-CNN and YOLO based Vehi-cle detection: A Survey. In: 2021 5th International Conference on Computing Methodologies and Communication (ICCMC). pp. 1442-1447 (2021). <https://doi.org/10.1109/ICCMC51019.2021.9418274>.
- [16] Zhao, J.D., Bai, Z.M., Chen, H.B.: Research on Road Traffic Sign Recognition Based on Video Image. In: 2017 10th International Conference on Intelligent Computation Technology and Automation (ICICTA). pp. 110-113 (2017). <https://doi.org/10.1109/ICICTA.2017.31>.
- [17] Botekar, N.P., Mahalakshmi, M.N.: Development of road sign recognition for ADAS using OpenCV. In: 2017 International Conference on Intelligent Computing and Control (I2C2). pp. 1-4 (2017). <https://doi.org/10.1109/I2C2.2017.8321941>.

[18] YOLOv4 model architecture,  
<https://iq.opengenus.org/yolov4-model-architecture/>, last  
accessed 2022/09/26.  
[19] (PDF) Detection for Deformed and Sheltered Circular  
Traffic Signs,  
[https://www.researchgate.net/publication/281707031\\_Detecti  
on\\_for\\_Deformed\\_and\\_Sheltered\\_Circular\\_Traffic\\_Signs](https://www.researchgate.net/publication/281707031_Detection_for_Deformed_and_Sheltered_Circular_Traffic_Signs),  
last accessed 2023/07/27.

[20] Ali, I., Khan, A., Waleed, M.: A Google Colab Based  
Online Platform for Rapid Estimation of Real Blur in Single-  
Image Blind Deblurring. In: 2020 12th International Con-  
ference on Electronics, Computers and Artificial Intelligence  
(ECAI). pp. 1–6 (2020).  
<https://doi.org/10.1109/ECAI50035.2020.9223244>.