

## Mise sur pied d'une architecture intelligente de prévention des accidents de la route par réseaux neuro-flous

[ An intelligent architecture of prevention of road accidents by neuro-fuzzy networks ]

S. PERABI NGOFFE<sup>1</sup>, S. NDJAKOMO ESSIANE<sup>1</sup>, S. SAMSON NYATTE<sup>1</sup>, FLORENCE OFFOLE<sup>2</sup>, and MENGATTA MENGOUNOU GHISLAIN<sup>1</sup>

<sup>1</sup>Département de Génie Industriel et Maintenance, Institut Universitaire de Technologie de Douala, Cameroon

<sup>2</sup>Département de technologie automobile, Faculté de Génie Industriel Université de Douala, Cameroon

---

Copyright © 2019 ISSR Journals. This is an open access article distributed under the *Creative Commons Attribution License*, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.

**ABSTRACT:** This paper proposes a neuro-fuzzy architecture that can be used in vehicles for the prevention of road accidents. The reaction time of a driver who is in an accident situation is predicted thanks to a network of neurons that admits the physiological and psychological parameters of the latter. To this neural network is associated a unit using the fuzzy logic which provides a modulated warning signal, for a prompt reaction of the driver. The results obtained at the output of the neural module show a match between the test and validation values whose best response is obtained with a correlation coefficient of around 0.98. The Matlab software was used to model our architecture and simulate certain scenarios. As a result, we obtained a ten-neuron network at the input layer and a neuron at the output layer. At the exit of the blur module, we observe the variation of the alert rate according to the anxiety, the inter-vehicle distance and the reaction time. The results show that, depending on the age, sex, accident history, driving experience and anxiety trait, the system calculates the reaction time and then proposes an appropriate warning signal. depending on the type of situation.

**KEYWORDS:** Road safety, collision warning, neural networks, fuzzy logic, anxiety, reaction time.

**RÉSUMÉ:** Ce papier propose une architecture neuro-floue pouvant être utilisée dans les véhicules pour les préventions des accidents de la route. Le temps de réaction d'un conducteur qui se trouve en situation d'accident est prédit grâce à un réseau de neurones qui admet en entrée les paramètres physiologiques et psychologiques de ce dernier. A ce réseau de neurones, est associé une unité utilisant la logique floue qui fournit un signal d'alerte modulé, pour une prompte réaction du conducteur. Les résultats obtenus à la sortie du module neuronal montrent une adéquation entre les valeurs de test et de validation dont la meilleure réponse est obtenue avec un coefficient de corrélation avoisinant 0.98. Le logiciel Matlab a été utilisé afin de modéliser notre architecture et simuler certains cas de figures. De ce fait, nous avons obtenu un réseau à dix neurones à la couche d'entrée et un neurone à la couche de sortie. À la sortie du module flou on observe belle et bien la variation du taux d'alerte en fonction de l'anxiété, la distance inter véhicule et du temps de réaction. Les résultats obtenus montrent qu'en fonction de l'âge, le sexe, l'historique d'accident, l'expérience de conduite et le trait d'anxiété le système calcul le temps de réaction puis propose un signal d'alerte adapté en fonction du type de situation.

**MOTS-CLEFS:** Prévention routière, avertissement de collision, réseaux de neurones, logique floue, anxiété, Temps de réaction.

## 1 INTRODUCTION

Au Cameroun les accidents de la route sont classés comme la deuxième cause majeure de décès après le paludisme. Ce fléau occasionne 10 milliards USD de pertes économiques, soit 2% du PIB des pays africains [1]. Une enquête de la banque mondiale, montre que le risque de voir cette tendance évoluer est de 80% d'ici 2020. De plus, elle affirme que les causes de ce fléau sont à majorité humaines. Cependant des travaux qui intègrent les causes humaines dans la prévention routière sont rares. Pourtant, avec l'avancée de l'intelligence artificielle, les paramètres intrinsèques des conducteurs peuvent être pris en compte dans la conception des systèmes de sécurité d'automobiles. Ainsi Zhang *et al* dans [2] utilisent la technique des RNA (Réseaux de neurones artificiels) à rétro propagation du gradient pour modéliser le comportement du conducteur lorsque les véhicules sont en files. Wei *et al*, développent un algorithme adaptif d'avertissement de collision arrière basé sur les RNA prenant en entrée les informations véhiculaires et la fatigue du conducteur pour améliorer en sortie les performances de freinage [3]. Les travaux cités ne prennent pas en compte l'anxiété et considère généralement que le temps de réaction est identique quel que soit la personne et son état psychologique. Pourtant dans [4-5] il est démontré l'existence d'une relation entre le taux d'accident, l'anxiété et le temps de réaction. Or l'anxiété est un paramètre qui dépend de l'état physiologique et psychologique du conducteur. Raison pour laquelle Taha reconnaît que les intentions d'un conducteur suivent généralement un processus de décision de Markov [6]. Schmidt-Daffy par contre démontre que le degré d'anxiété et la peur influencent le comportement au volant, ce qui pousse les conducteurs à conduire lentement afin d'assurer la sécurité [7].

Au-delà de l'anxiété l'émotion est un autre paramètre psycho-physiologique influençant la sécurité lors de la conduite ; raison pour laquelle Kamaruddin et al. Dans [8] établissent un modèle d'espace émotionnel basé sur l'analyse de la voix pour concevoir un système d'alerte. Les auteurs de [9-10], à l'aide d'un simulateur de conduite, analyse cet état émotionnel du conducteur afin d'établir une corrélation entre ce dernier et l'accroissement des accidents. Trick et al, par contre lie l'émotion à l'attention afin de relever leurs effets sur la conduite [11]. Scott-parker et al, abondent dans ce sens mais associe la nature du sexe et le statut psychologique, pour expliquer les risques d'accident [12].

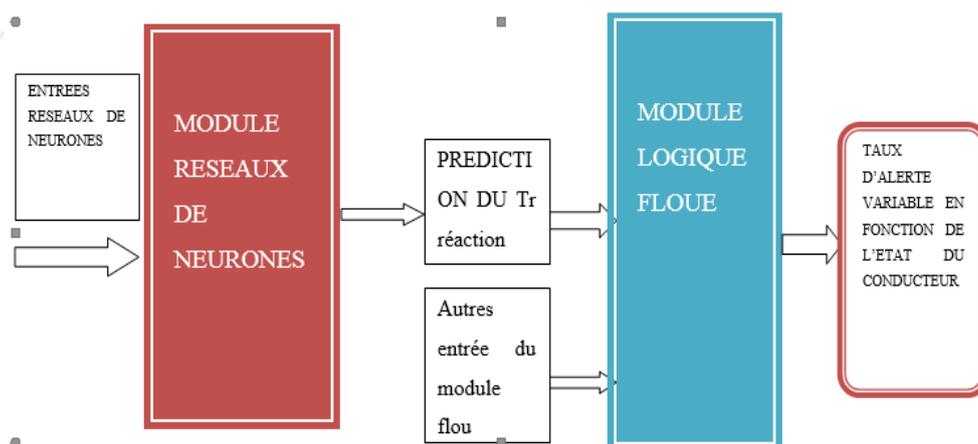
L'évitement d'une collision dépend du temps de réaction du conducteur. Or ce paramètre est fonction de l'âge, le sexe, l'état de fatigue, l'anxiété et l'expérience de conduite d'après une étude menée par le laboratoire de cyber psychologie de l'Université du Québec en Outaouais (UQO). L'estimation des variations de ce dernier en temps réel est fastidieuse avec les méthodes classiques. Ce qui amène les concepteurs à considérer sa valeur constante. Cependant les travaux de Johansson et Rummel estiment que ce temps varie de 0,4 à 2,7 secondes [13]. Dans [14-15] il est estimé à une valeur moyenne de 0,42s pour un écart-type 0,14 seconde dans un environnement réel. Face à un danger imprévu dû à un freinage extrême sa valeur est comprise entre 0,9 s et 1,1s. Pour les stimuli inattendus et attendus, Fambro et al, proposent les temps de réaction respectivement de 1,3s et 0,7s [16]. Plusieurs approches sont proposées pour estimer les retards de réaction du conducteur. Ozaki dans [17] présente une méthode graphique basé sur les différences de profils de vitesse et d'accélération. Ranjitkar et al. [18] appliquent cette méthode graphique pour analyser la stabilité et le comportement de la voiture suivante dans une file. Dans ce contexte ils estiment que le temps moyen de réaction de chaque conducteur varie de 1,27 à 1,55 secondes.

Afin de prévenir les conducteurs des accidents de manière adaptée pour qu'ils agissent à temps quel que soit leurs états physiologiques et psychologiques, nous proposons une architecture adaptative neuro-floue.

## 2 APPROCHE MÉTHODOLOGIQUE DE L'ARCHITECTURE PROPOSÉE

### 2.1 PRÉSENTATION DE L'ARCHITECTURE NEURO-FLOUE

Le synoptique de l'architecture proposée est présentée par la *figure 1*.



**Fig. 1. Approche méthodologique de l'architecture neuro-floue**

Cette architecture est composée d'un module de réseaux de neurones artificiel qui admet en entrée L'âge, le sexe, l'historique d'accidents, l'expérience de conduite et le trait d'anxiété afin de prédire le temps de réaction. Il est suivi d'un module conçu à base de la logique floue dont l'entrée est constituée du temps de réaction prédit précédemment, la distance inter véhicule et la vitesse. A la sortie, on obtient un signal d'alerte modulé permettant au conducteur d'agir de manière optimale. Le logigramme ci-dessous présente le fonctionnement de l'architecture proposée.

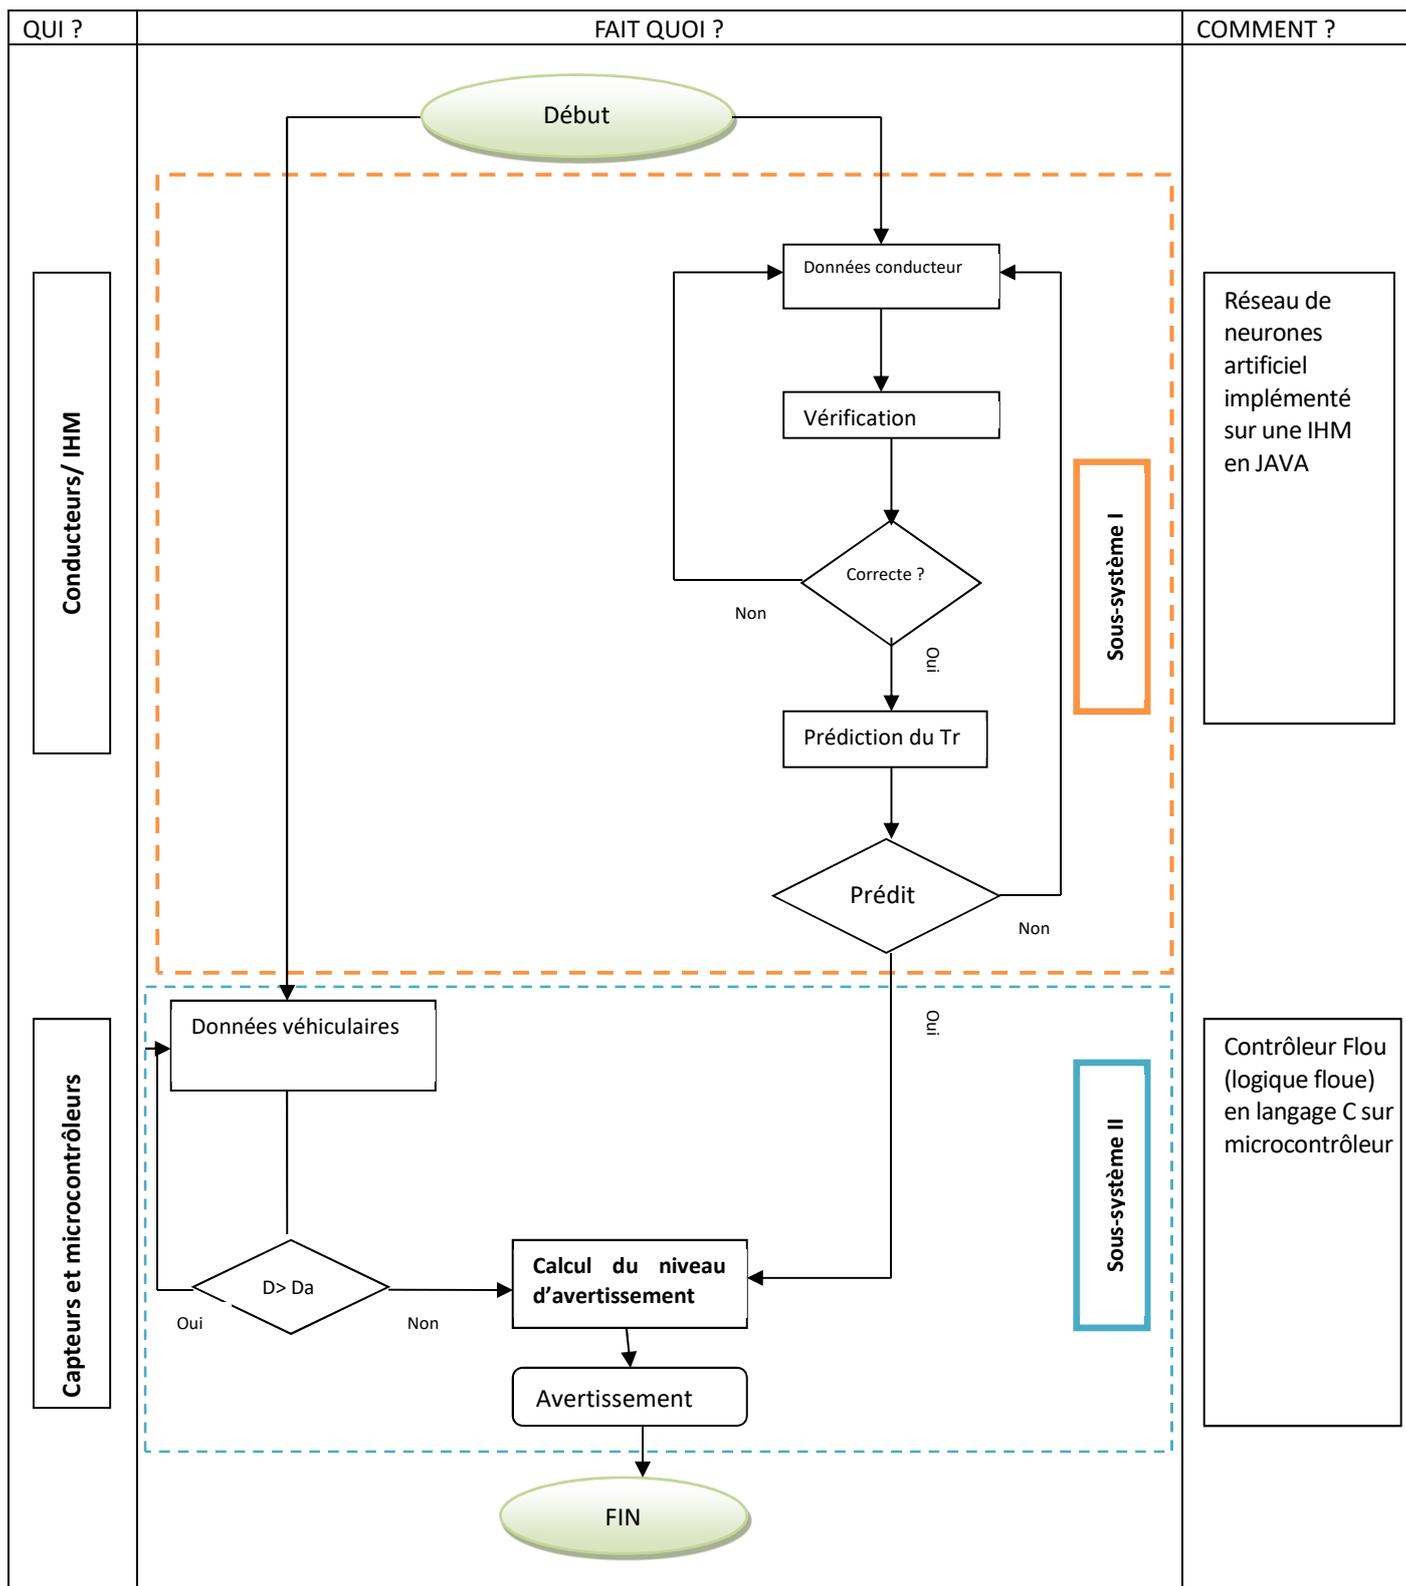


Fig. 2. Logigramme de fonctionnement de l'architecture

La **figure 3** présente la logique neuro-floue qui gouverne l'architecture proposée.

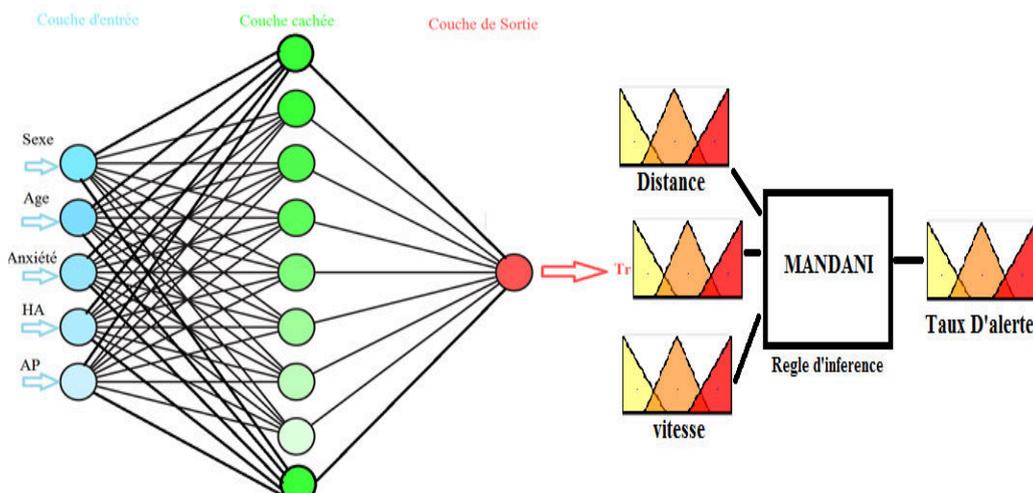


Fig. 3. Combinaison neuro-floue

Ici l'âge, le sexe, l'historique d'accident, l'expérience de conduite et le trait d'anxiété sont à l'entrée du module neuronal. L'évaluation de l'anxiété se fait par la méthode proposée par l'expert en psychologie Charles Donald Spielberger [19] qui soumet aux conducteurs une série d'assertions dont l'affirmation à l'une d'elles permet de supposer que le conducteur est anxieux :

## 2.2 MODÉLISATION DU MODULE RÉSEAU NEURO-FLOU

La base de données utilisée dans ce travail pour la modélisation de notre système est issue d'une étude effectuée à l'Université du Québec en Outaouais au laboratoire de cyber psychologie

### 2.2.1 MODÉLISATION DU MODULE RNA

Pour prédire le temps de réaction nous devons modéliser le réseau de neurones utilisé. Dans un premier temps, nous définissons le nombre de neurones optimal. Ensuite, nous procédons à la définition du nombre d'itérations optimal via le calcul de l'erreur quadratique moyenne. Enfin nous évaluons la performance du réseau en utilisant les parcelles de régression afin de valider notre modèle. Pour se faire le logiciel MATLAB a été utilisé en vue de valider la performance, de définir le meilleur nombre d'itérations, et d'effectuer les tests de toutes les combinaisons possibles pour obtenir un nombre de neurones optimal. Le modèle retenu comporte dix neurones à la couche cachée et un neurone à la sortie. Ce dernier subira un apprentissage supervisé avec une fonction d'activation de type sigmoïde et un algorithme de type perceptron de connectivité monocouche. La figure ci-dessous en est une illustration.

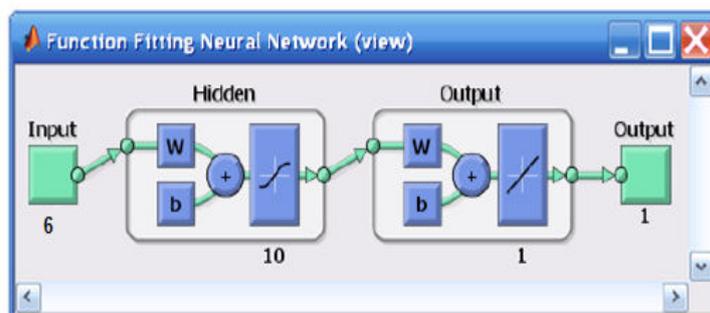


Fig. 4. Modélisation du réseau neuronal

Les valeurs d'entrées ont été normalisées en utilisant l'équation (1) :

$$X_{norm} = (N_{max} - N_{min}) \left[ \frac{X - X_{min}}{X_{max} - X_{min}} \right] + N_{min} \quad (1)$$

Avec  $X_{norm}$  la valeur normalisée ;

$N_{max}$  la borne superieur de l'intervalle de normalisation

$N_{min}$  la borne inferieur de l'intervalle de normalisation

$X$  : la valeur à normaliser

$X_{min}$  et  $X_{max}$  respectivement la plus petite valeur et la plus grande valeur des jeux de donnees

Pour évaluer l'efficacité de la prédiction, l'erreur quadratique moyenne (**EQM**) a été utilisée comme mesure de l'erreur moyenne, pondérée par le carré de l'erreur.

Si  $\hat{Y}$  Est un vecteur de  $n$  Prédications et  $Y$  celui des valeurs observées correspondant aux entrées de la fonction qui a généré les prédictions, l'EQM est estimée par l'équation (2) :

$$EQM = \frac{1}{n} \sum_{i=1}^n (\hat{Y}_i - Y_i)^2 \quad (2)$$

### 2.2.2 MODÉLISATION DU MODULE À LOGIQUE FLOUE

La méthode utilisée ici est l'implication de MAMDANI avec une Déffuzification par la méthode des centres de gravité (COG).

Nous considérons les variables d'entrées et de sorties suivantes :

#### ❖ En entrée :

- Le temps de réaction (Tr)
- La distance entre deux véhicules.
- La vitesse du véhicule.

#### ❖ En sortie :

- Le pourcentage d'alerte

Les fonctions d'appartenances choisies ont de formes triangulaires

#### ➤ Fuzzification

##### • Le temps de réaction (en seconde)

Univers du discours : [0.4 2.7] ;

Variable linguistique : Tr,

Valeurs linguistiques = {petit ; moyen ; grand} avec petit = [0.4 0.7 1] ; moyen= [0.8 1.25 1.7] et grand= [1.5 2.1 2.7].

##### • La distance en mètre

Univers du discours : [10 22]

Variable linguistique : Distance

Classe d'appartenance = {très proche ; proche ; loin} avec très proche = [10 12.5 15] ; proche= [13.95 16.4 19] et loin= [16.71 18.71 21.71].

• **Vitesse en Km/h**

Univers du discours : [5 20]

Variable linguistique : vitesse

Classe d'appartenance = {faible ; moyenne ; élevée}

Avec faible = [5 7.283 9.565]; moyenne= [8.261 10.87 13.48] et élevée = [12.17 16.09 20].

• **Le coefficient d'alerte**

Univers du discours : [0,5 1]

Variable linguistique : Alerte

Classe d'appartenance = {bas ; moyen ; haut} avec bas = [0.5 0.6806 0.896]; moyen= [0.568 0.75 0.9808] et haut= [0.603 0.797 1].

La base de règles utilisées est celle fournie par l'expert en psychologie Stéphane BOUCHARD [19] et présentée au tableau 1. L'exploitation de ce tableau permet d'extraire le coefficient d'alerte. Ainsi, un conducteur âgé de « 25 ans » qui roule à une vitesse de « 50 Km/h » a un coefficient égal à 60/100 s'il est « anxieux » et 80/100 s'il ne l'est pas.

**Tableau 1. Base de connaissance fournie par Stéphane BOUCHARD**

Anxieux		Age (ans)		
		20 → 35	35 → 45	45 → 60
Vitesse (Km/h)	Non Anxieux	50	55	60
	< 40	70	75	80
	40 → 60	80	85	90
	> 60	90	95	100

➤ **Inférence floue**

Nous avons défini au total 27 règles d'inférences pour nos trois entrées dont un extrait est présenté au tableau suivant.

**Tableau 2. Extrait des règles d'inférences**

```

1. If (Tr is petit) and (Distance is tresproche) and (vitesse is elevee) then (Alerte is haut) (1)
2. If (Tr is petit) and (Distance is tresproche) and (vitesse is faible) then (Alerte is haut) (1)
3. If (Tr is petit) and (Distance is tresproche) and (vitesse is moyenne) then (Alerte is haut) (1)
4. If (Tr is petit) and (Distance is tresproche) and (vitesse is elevee) then (Alerte is haut) (1)
5. If (Tr is petit) and (Distance is proche) and (vitesse is faible) then (Alerte is moyen) (1)
6. If (Tr is petit) and (Distance is proche) and (vitesse is moyenne) then (Alerte is haut) (1)
7. If (Tr is petit) and (Distance is proche) and (vitesse is elevee) then (Alerte is haut) (1)
8. If (Tr is petit) and (Distance is loin) and (vitesse is faible) then (Alerte is bas) (1)
9. If (Tr is petit) and (Distance is loin) and (vitesse is moyenne) then (Alerte is bas) (1)
10. If (Tr is petit) and (Distance is loin) and (vitesse is elevee) then (Alerte is haut) (1)
    
```

➤ **Défuzzification**

La méthode utilisée est le COG défini par (5)

Avec  $\mu(y)$  la valeur d'appartenance associée à une valeur  $y$

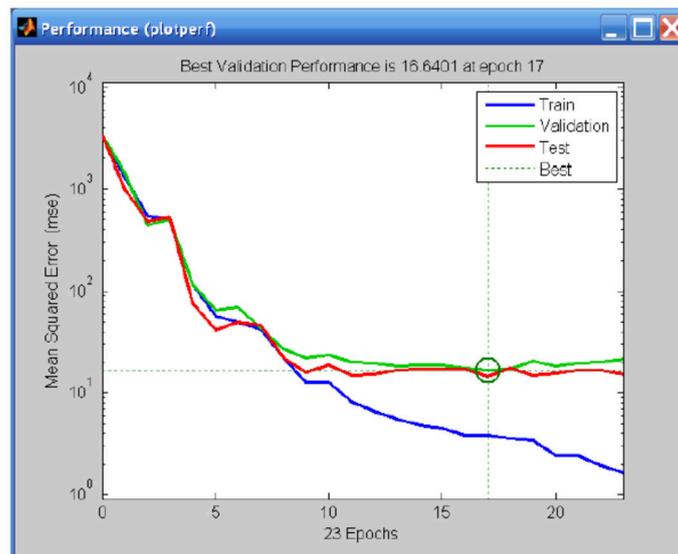
$$sortie = \frac{\int y\mu(y) dy}{\mu(y) dy} \tag{5}$$

Ou  $u$  désigne l'univers du discours.

**3 RÉSULTATS ET DISCUSSIONS**

**3.1 VALIDATION DU MODULE NEURONAL**

Un échantillon de 49 données a été reparti de la manière suivante : 70% en données d'entraînement 30% des données de test et 30% des données de validation. L'EQM permet d'évaluer l'efficacité de la prédiction La figure ci-dessous présente les erreurs d'une formation, les erreurs de validation et les erreurs de test.



**Fig. 5. Erreur quadratique entre l'estimateur de référence et l'estimateur après nombre d'itérations**

L'erreur la plus petite est obtenu après 17 itérations, valeur après laquelle l'erreur de l'ensemble d'entraînements décroît pendant celles de validation et de test semble croître. Nous pouvons donc estimer que le meilleur indice de performance est obtenu à partir de la 17<sup>ème</sup> itération d'où le choix d'un réseau de 10 neurones et 17 itérations.

La figure 6 présente les différentes parcelles de régressions durant chaque étape du processus. Ces parcelles affichent les sorties du réseau par rapport à des cibles pour des ensembles d'entraînement, de validation et de test. La dernière parcelle (All) donne la valeur totale de de régression égale à 0,93153 qui est un coefficient dit « rigide » qui laisse entrevoir une bonne prédiction car proche de la valeur 1 cette valeur serait améliorée si la base de données était plus grande.

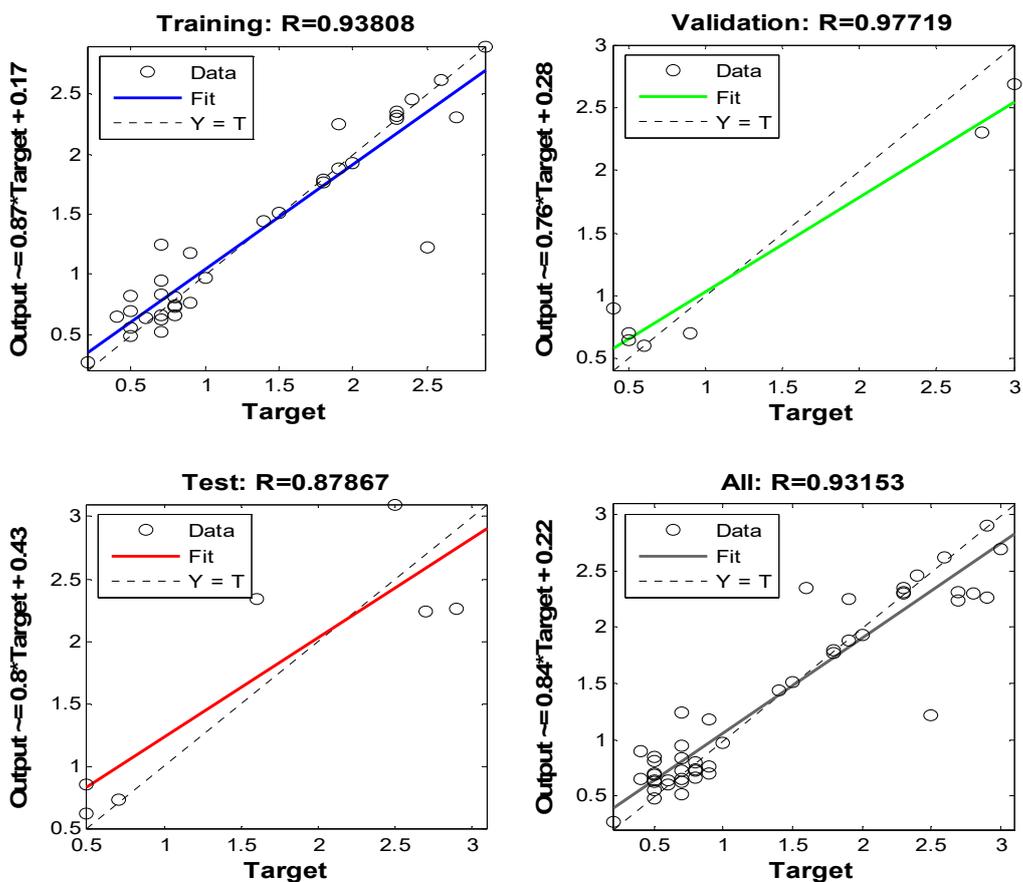
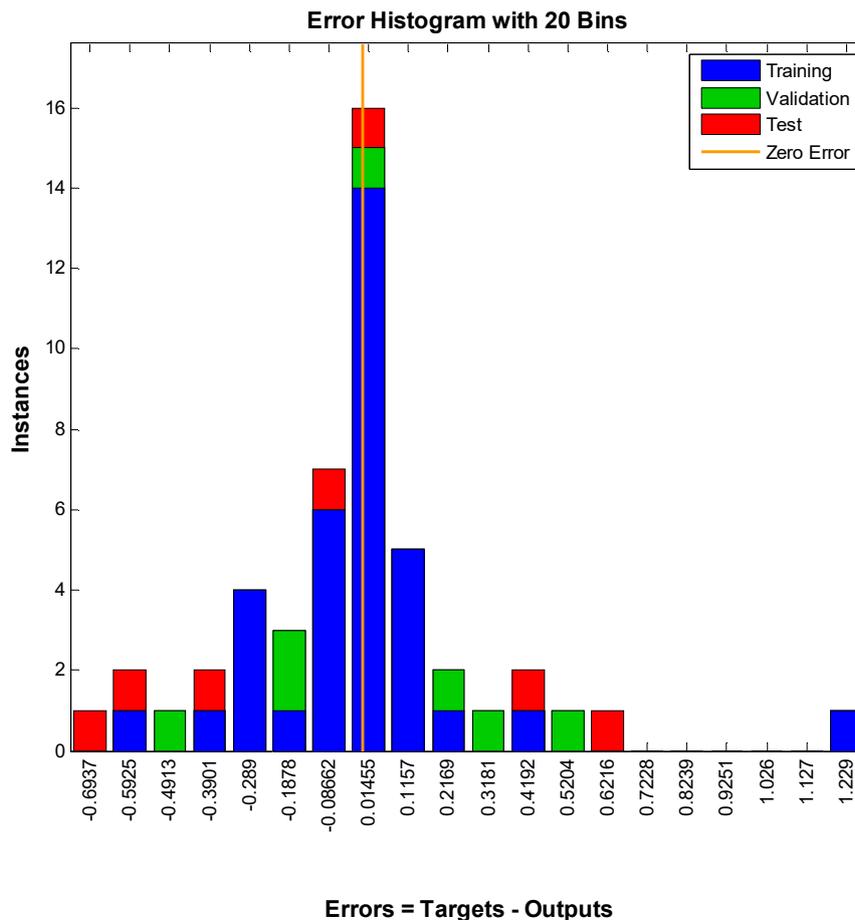


Fig. 6. Affichage des sorties du réseau par les parcelles de régression

A partir des courbes d'erreur de la **figure 5** nous déduisons l'histogramme des erreurs suivant. Les barres bleues représentent des données d'entraînement, les barres vertes représentent des données de validation et les barres rouges représentent des données de test.



**Fig. 7. Distribution de l'erreur à travers les données de formation, de validation et de test**

L'histogramme nous donne une indication des points de données où la prédiction est significativement plus mauvaise que la majorité de données. On peut observer que la majorité des erreurs se situent entre -0,6 et 0,6 les erreurs d'entraînements étant majoritaire.

En conclusion les résultats montrent bien, d'après l'histogramme des erreurs précédent, que l'erreur est minimisée à chaque fois ce qui montre une fidélité dans la prédiction du temps de réaction du conducteur.

### 3.2 VALIDATION DES RÈGLES FLOUES

La figure ci-dessous présente une simulation du contrôleur flou sous Matlab après défuzzification des variables d'entrées à partir des 27 règles pour une extraction du coefficient de l'alerte adapté au conducteur.

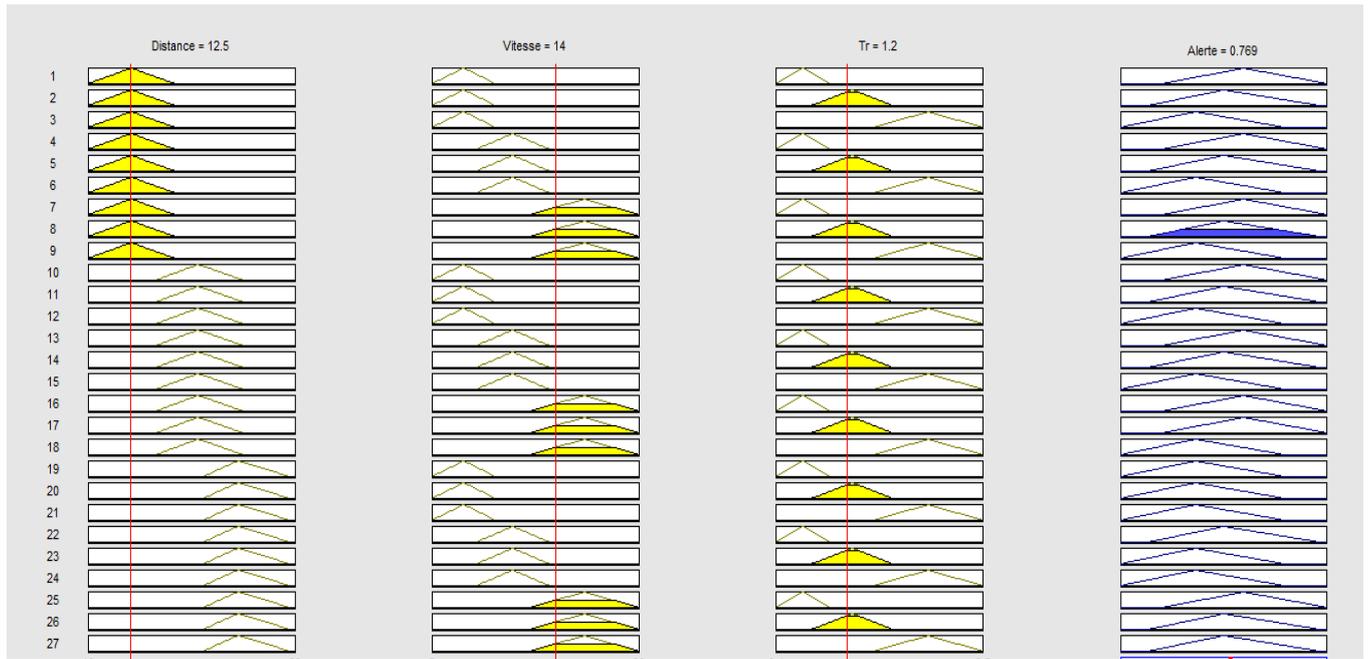


Fig. 8. Défuzzification

Nous pouvons remarquer que pour un chauffeur considéré comme anxieux avec un temps de réaction de 1.2 secondes qui s'approche dangereusement d'un véhicule proche de 12,5m avec une vitesse de 14Km/H recevra une alerte de 0.769. Les figures 9 et 10 présentent présente le comportement de l'alerte quand varie la distance et vitesse inter véhiculaire pour un temps de réaction donné (1.2 s).

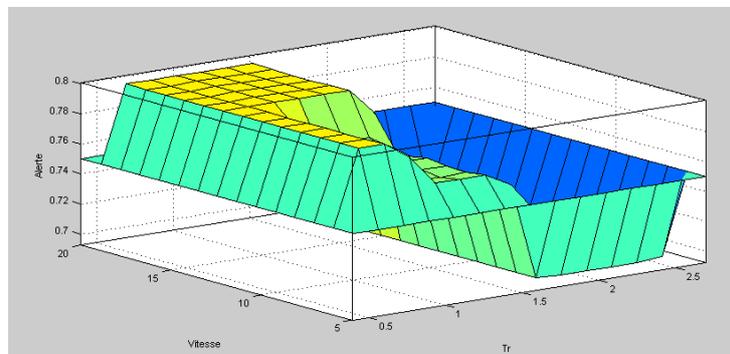


Fig. 9. Variation du niveau d'Alerte en fonction de la vitesse et du Tr

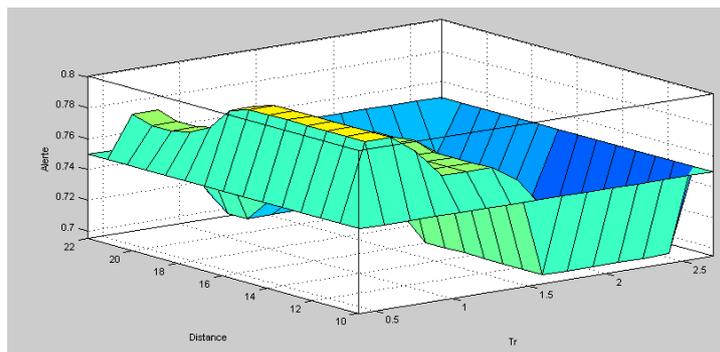


Fig. 10. Variation du niveau d'alerte en fonction du Tr et de la distance

### 3.3 VALIDATION DU SYSTÈME NEURO-FLOU

La validation de notre architecture va se faire par rapport aux résultats obtenus par Chang et al. [20] qui présente une architecture semblable à la nôtre mais sans tenir compte des paramètres humain mais plutôt environnementaux et véhiculaires. Nous supposons que, pour se rapprocher du cas de [20], notre conducteur a 40 ans et non anxieux avec un temps de réaction égale à 1.2s. la figure 11 ci-dessous présente la mise ensemble de nos deux modules et nous permet de simuler les résultats du tableau 3.

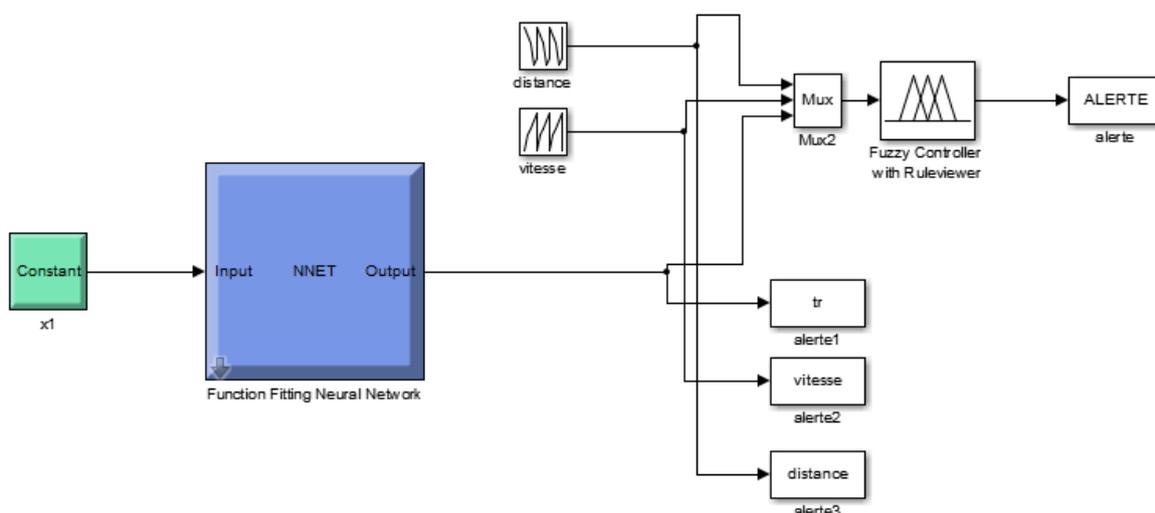


Fig. 11. Module neuro-flou

Tableau 3. Comparaison entre l'architecture de Chang et celle proposée

Distance	Vitesse	Valeur d'alerte [20]	Alerte de notre système
m	km/h	%	%
21.1	6	0.623	0.693
19.3	10	0.71	0.696
17.5	12	0.808	0.741
12.5	14	0.885	0.769
13.8	16	0.797	0.769

Ces résultats montrent une adéquation avec l'architecture de Chang et celle proposée pour des personnes non anxieuses et jeunes ceci se traduit par un coefficient de corrélation de 0.88 qui est une valeur proche de 1.

Les courbes ci-dessous présentent la variation de l'alerte en fonction des entrées du Contrôleur flou.

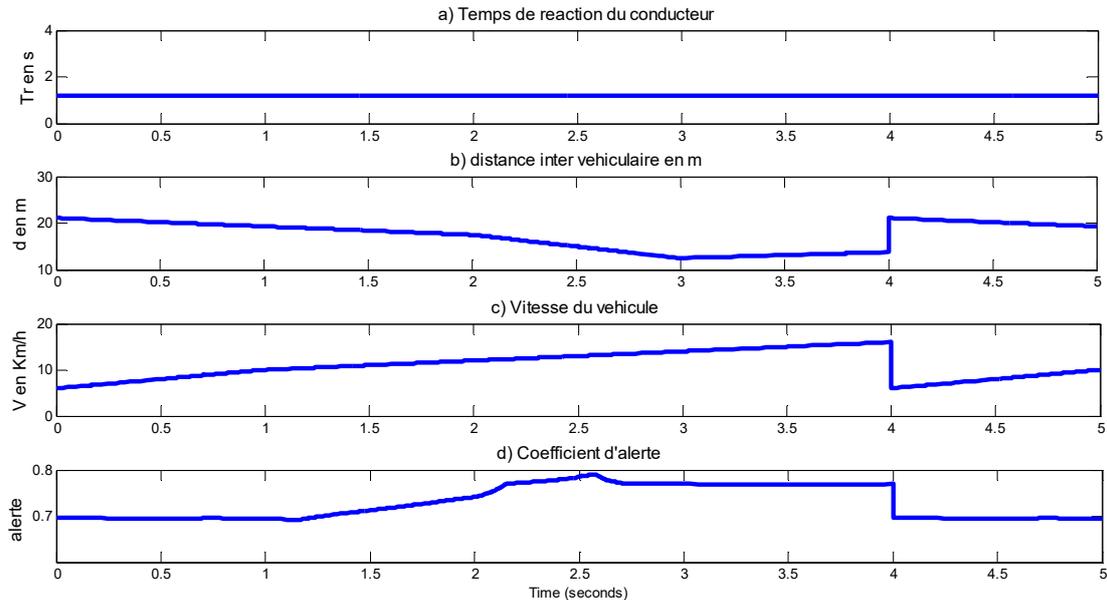


Fig. 12. Variation de l'Alerte en fonction du  $T_r$  et de la vitesse et de la distance

Ainsi, en réalisant une simulation dans Matlab pour le cas d'un jeune agé de 30 ans non anxieux ayant un temps de réaction de 1,2 secondes on peut constater que lorsque la distance décroît et que la vitesse croît le coefficient d'alerte croît progressivement. Si par contre ces grandeurs varient dans le même sens mais peu le coefficient d'alerte est presque constant.

#### 4 CONCLUSION

Dans cette étude il était question de proposer une architecture intelligente de prévention des collisions par réseaux neuro flou prenant en compte les paramètres physiologiques et psychologiques du conducteur pour prédire son temps de réponse et afin d'adapter le niveau d'alerte. L'anxiété a été évalué en utilisant la méthode et les données du psychologue Charles Donald Spielberger. Ces données ont été utilisés pour déterminer le temps de réaction des conducteurs à travers un réseau neuronal. En utilisant les données de Bouchard, la détermination du coefficient d'alerte a été effectué en utilisant un contrôleur flou. Il en résulte après simulation que le temps de réaction est estimé avec une erreur minimale acceptable et que le coefficient d'alerte varie de manière adéquate en fonction de la distance inter véhiculaire pour un temps de réaction donné.

#### REFERENCES

- [1] ATLAS Magazine. L'insecurité routiere dans le monde, 2017. <http://www.atlas-mag.net/article/linsecurite-routiere-dans-le-monde>, (juillet 2017).
- [2] Zhang, L., et al. Driver Car-Following Behavior Modeling using Neural Network Based on Real Traffic Experimental Data. in 15th World Congress on Intelligent Transport Systems and ITS America's 2008 Annual Meeting, New York 2008.
- [3] Wei, Z., et al. "An Adaptive Vehicle Rear-End Collision Warning Algorithm Based on Neural Network, in Information and Management Engineering", M. Zhu, Editor, Springer Berlin Heidelberg. p. 305-314, 2011.
- [4] J. Taylor et al. "The relation between driving anxiety and driving skill". Journal of psychology vol. 37, N°1, March 2008.
- [5] Pourabdian, S. and H. Azmoon, "The Relationship between Trait Anxiety and Driving Behavior with Regard to Self-reported Iranian Accident Involving Drivers" International journal of preventive medicine, vol 4, N°10, pp.1115-1121, october 2013.
- [6] Taha T., Miro J.V., Dissanayake G., Wheelchair driver assistance and intention prediction using POMDPs. Intelligent Sensors, Sensor Networks and Information, ISSNIP 3<sup>rd</sup> International Conference, pp. 449-454, 2007.
- [7] Schmidt-Daffy M., "Fear and anxiety while driving: Differential impact of task demands, speed and motivation". Transportation Research Part F: Traffic Psychology and Behaviour, 16, pp. 14-28, 2013.
- [8] Kamaruddin N., Wahab A., "Driver behavior analysis through speech emotion understanding", IEEE Intelligent Vehicles Symposium (IV) 2010, pp. 238-243, 2010.

- [9] Barnard, Megan Patricia and Chapman, Peter "Are anxiety and fear separable emotions in driving?: laboratory study of behavioural and physiological responses to different driving environments", *Accident, Analysis and Prevention*, vol 86, pp. 99-107, 2016.
- [10] Barnard, Megan Patricia and Chapman, Peter "The effects of instruction and environmental demand on state anxiety, driving performance and autonomic activity: Are ego-threatening manipulations effective?" *Transportation Research Part F: Traffic Psychology and Behaviour*, vol 55, pp.123-135, 2018.
- [11] Trick L.M., Brandigampola S., Enns J.T., "How fleeting emotions affect hazard perception and steering while driving: The impact of image arousal and valence" *Accident Analysis & Prevention*, vol 20, pp.222-229, 2012.
- [12] Scott-Parker B., Watson B., King M.J., Hyde M.K., "A further exploration of sensation seeking propensity, reward sensitivity, depression, anxiety, and the risky behavior of young novice drivers in a structural equation model" *Accident Analysis & Prevention*, pp.1-7, 2012.
- [13] Jinglei Zhang, Xiaoyuan Wang, Cuicui Yu, Zhenxue Liu, Haibo Wang "Development of a Prediction Method for Driver's Propensity", *Procedia Engineering* vol 137, pp. 161 – 170, 2016.
- [14] Johansson, G., and K. Rummel. "Drivers' Brake Reaction Time". *Human Factors* Vol. 13, No. 1, pp. 23-27, 1971.
- [15] T. Magister, R. Krulec, M. Batista, and L. Bogdanoviæ. The Driver Reaction Time Measurement Experiences. *Proceedings of Innovative Automotive Technology (IAT'05) Conference*, Bled, Slovenia, 2005.
- [16] Fambro, D. B., R. J. Koppa, D. L. Picha, and K. Fitzpatrick. "Driver Perception-Brake Response in Stopping Sight Distance Situations", In *Transportation Research Record 1628*, TRB, National Research Council, Washington, D.C., pp. 1–7, 1998.
- [17] Ozaki, H. *Reaction and Anticipation in the Car-Following Behavior.*, Proc., 12th International Symposium on the Theory of Traffic Flow and Transportation, Berkeley, Calif., 1993.
- [18] Ranjitkar, P., T. Nakatsuji, Y. Azuta, and G. S. Gurusinghe. "Stability Analysis Based on Instantaneous Driving Behavior Using Car-Following Data. In *Transportation Research Record: Journal of the Transportation Research Board*, No. 1852, Transportation Research Board of the National Academies, Washington, D.C., pp. 140–151, 2003.
- [19] Nora Belghazi, *Système adaptatif multicritère d'avertissements véhiculaires basé sur le comportement des conducteurs, mémoire, université du Québec en Outaouais*, 2015.
- [20] Chang, T.H., et al., Onboard measurement and warning module for irregular vehicle behavior. *IEEE Transactions on Intelligent Transportation Systems*, 2008. 9(3): p. 501- 513