



HAL
open science

Étude et modélisation des stratégies visuelles en situation de conduite automobile autonome

Damien Schnebelen

► **To cite this version:**

Damien Schnebelen. Étude et modélisation des stratégies visuelles en situation de conduite automobile autonome. Psychologie. Université de Nantes, 2020. Français. NNT: . tel-02938115

HAL Id: tel-02938115

<https://hal.science/tel-02938115>

Submitted on 16 Sep 2020

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.



THESE DE DOCTORAT DE

L'UNIVERSITE DE NANTES
COMUE UNIVERSITE BRETAGNE LOIRE

ECOLE DOCTORALE N° 603
Education, Langages, Interaction, Cognition, Clinique
Spécialité : Psychologie

Par

Damien SCHNEBELEN

Étude et modélisation des stratégies visuelles en situation de conduite automobile autonome

Thèse présentée et soutenue à Nantes, le 27 août 2020

Unité de recherche : Laboratoire des Sciences du Numérique de Nantes (LS2N)

Rapporteurs avant soutenance :

Jordan Navarro Maître de conférences à l'Université Lyon 2
Thierry Baccino Professeur des Universités à l'Université Paris 8

Composition du Jury :

Président : Prénom Nom Fonction et établissement d'exercice (9) (*à préciser après la soutenance*)

Examineurs : Jordan Navarro Maître de conférences à l'Université Lyon 2
Thierry Baccino Professeur des Universités à l'Université Paris 8
Céline Lemercier Professeur des Universités à l'Université Toulouse 2

Dir. de thèse : Franck Mars Directeur de Recherche au CNRS (Université de Nantes)

Invité(s)

Camilo Charron Maître de conférences à l'Université Rennes 2

Remerciements

Si le travail de doctorat est principalement solitaire, sa réussite est surtout le résultat d'une aventure collective. À ce titre, je souhaiterais remercier les personnes qui ont rendu ce doctorat plus facile, que ce soit scientifiquement ou humainement.

Je voulais d'abord remercier les personnes m'ayant aidé à mettre en œuvre les protocoles expérimentaux sur le simulateur. Je commence par Robert, qui m'a formé sur le simulateur de conduite alors que je n'y connaissais rien. Je voulais également rendre hommage au travail de Denis pour ses améliorations techniques sur le simulateur en fonction de mes besoins. Merci également à tous les participants ayant donné de leur temps pour participer aux expériences sans autre motivation que de faire avancer la recherche.

Cette thèse ne se serait pas bien déroulée sans un encadrement scientifique au top. Et franchement, je n'aurais pas pu espérer mieux dans ce domaine. En premier lieu, merci à Camilo de m'avoir aidé à « servir la science », surtout au travers de la mise en place de l'analyse statistique des données. Franck, merci encore d'avoir répondu présent à chacune de mes interruptions dans ton bureau, merci de m'avoir aiguillé lorsqu'il a fallu monter des expériences, analyser les résultats ou bien écrire ce manuscrit. Tu as été là à chacune de ces étapes, je ne l'oublierai pas.

D'autre part, je souhaiterais remercier toutes les personnes qui ont rendu ce doctorat riche en rencontres. D'abord, les collègues doctorants de l'équipe pour les moments d'échanges en courant ou en mangeant ! Aussi, les permanents de l'équipe PACCE pour leur bienveillance et leur accueil parfaits. Même au niveau du travail, ce doctorat m'a permis de rencontrer les autres membres du projet AutoConduct et de partir rendre visite à Otto Lappi en Finlande.

Enfin, je souhaiterais remercier chaudement ceux qui me suivent et me soutiennent sans faille, que ce soit mes amis d'école d'ingénieur, ma famille, ou celle qui partage ma vie. La réussite de ce doctorat est également la vôtre.

Table des matières

REMERCIEMENTS.....	I
TABLE DES MATIERES.....	III
LISTE DES FIGURES.....	VII
LISTES DES TABLEAUX.....	IX
<u>INTRODUCTION GENERALE</u>	1
<u>PARTIE A: ÉTAT DE L'ART - ACTIVITE DE CONDUITE</u>	7
A.1. DEFINITION DE L'ACTIVITE DE CONDUITE MANUELLE.....	7
A.1.1. MODELE DE RASMUSSEN (1983).....	7
A.1.2. MODELE DE MICHON (1985).....	8
A.1.3. SYNTHESE ET TRANSITION.....	10
A.2. MODIFICATIONS DE L'ACTIVITE DE CONDUITE INDUITE PAR L'AUTOMATISATION DES VEHICULES	11
A.2.1. NIVEAUX D'AUTOMATISATION EN CONDUITE AUTONOME	11
A.2.2. ACTIVITE DE CONDUITE AU NIVEAU 2 (SAE)	14
A.2.3. ACTIVITE DE CONDUITE AU NIVEAU 3 (SAE)	15
A.2.4. SYNTHESE ET TRANSITION.....	15
A.3. PHENOMENE DE SORTIE DE BOUCLE	16
A.3.1. DEFINITION (S).....	16
A.3.2. LIEN AVEC LA CONSCIENCE DE LA SITUATION	19
A.3.3. IMPACT DU PHENOMENE DE SORTIE DE BOUCLE SUR LES PERFORMANCES DE CONDUITE	20
A.3.4. ÉVOLUTION DU PHENOMENE DE SORTIE DE BOUCLE AU COURS DU TEMPS.....	25
A.3.5. INDUCTION EXPERIMENTALE DU PHENOMENE DE SORTIE DE BOUCLE.....	26
A.3.6. SYNTHESE ET TRANSITION.....	28
A.4. SYNTHESE DE LA PREMIERE PARTIE.....	29

<u>PARTIE B: ETAT DE L'ART – STRATEGIES VISUELLES</u>	31
B.1. CAS GENERAL	31
B.1.1. ATTENTION VISUELLE ET MOUVEMENTS OCULAIRES.....	31
B.1.2. STRATEGIES VISUELLES DEPENDANTES DE LA TACHE.....	32
B.2. VISION EN CONDUITE MANUELLE	34
B.2.1. CONDUITE SANS TACHE ANNEXE	34
B.2.2. CONDUITE AVEC TACHE ANNEXE : SUIVI D'UN VEHICULE.....	38
B.2.3. CONDUITE AVEC TACHE SECONDAIRE	39
B.2.4. CONTROLE DES STRATEGIES VISUELLES PAR L'APPRENTISSAGE	40
B.3. IMPACT DE L'AUTOMATISATION SUR LES STRATEGIES VISUELLES DES CONDUCTEURS.	41
B.4. LIEN ENTRE LES STRATEGIES VISUELLES ET LA SORTIE DE BOUCLE	43
B.5. SYNTHESE ET TRANSITION	45
 <u>PARTIE C: AXES DE TRAVAIL DU DOCTORAT</u>	 47
C.1. ÉQUILIBRE ENTRE LES PROCESSUS SENSORIMOTEURS ET TACTIQUES LORS DE LA SORTIE DE BOUCLE OPERATIONNELLE	48
C.2. DISTINCTION DES CONDUCTEURS EN CONDUITE MANUELLE ET AUTONOME : PRISE EN COMPTE DE LA DYNAMIQUE DU REGARD	49
C.3. PREDICTION DE LA SORTIE DE BOUCLE EN CONDUITE AUTONOME A PARTIR DES STRATEGIES VISUELLES	52
C.4. SYNTHESE DE LA DEMARCHE EXPERIMENTALE	53
 <u>PARTIE D: STRATEGIES VISUELLES DES CONDUCTEURS LORS D'UNE CONDUITE EN VIRAGES : INFLUENCE DE L'AUTOMATISATION ET DE LA VITESSE</u> 55	
D.1. SYNTHESE DE L'EXPERIMENTATION	55
D.1.1. CONTEXTE SCIENTIFIQUE ET HYPOTHESES	55
D.1.2. RESULTATS ET CONCLUSION.....	57
D.2. ARTICLE COMPLET	58

<u>PARTIE E: PREDICTION DU MODE DE CONDUITE A PARTIR DES STRATEGIES VISUELLES DES CONDUCTEURS EN CONTEXTE AUTOROUTIER</u>	<u>87</u>
E.1. SYNTHESE DE L'EXPERIMENTATION	87
E.1.1. CONTEXTE SCIENTIFIQUE ET HYPOTHESES	87
E.1.2. PRINCIPAUX RESULTATS ET CONCLUSIONS.....	88
E.2. ARTICLE COMPLET	89
<u>PARTIE F: ESTIMATION DU PHENOMENE DE SORTIE DE BOUCLE A PARTIR DES STRATEGIES VISUELLES DES CONDUCTEURS EN CONDUITE AUTONOME</u>	<u>109</u>
F.1. SYNTHESE DE L'EXPERIMENTATION	109
F.1.1. CONTEXTE SCIENTIFIQUE ET QUESTIONS DE RECHERCHES.....	109
F.1.2. RESULTATS PRINCIPAUX ET DISCUSSION	110
F.2. ARTICLE COMPLET	111
<u>PARTIE G: DISCUSSION GENERALE ET PERSPECTIVES</u>	<u>137</u>
G.1. ADAPTATION DES STRATEGIES VISUELLES A L'AUTOMATISATION DE LA CONDUITE	137
G.1.1. POINT DE VUE STATIQUE	138
G.1.2. POINTS DE VUE DYNAMIQUE.....	141
G.1.3. SYNTHESE ET TRANSITION.....	143
G.2. ESTIMATION DE LA SORTIE DE BOUCLE A PARTIR DES STRATEGIES VISUELLES EN CONDUITE AUTONOME	144
G.3. CHOIX METHODOLOGIQUES : APPORTS ET LIMITES	146
G.3.1. APPORTS.....	146
G.3.2. LIMITES.....	148
G.4. PERSPECTIVES.....	150
<u>RETROSPECTIVE DE LA DIFFUSION DES TRAVAUX</u>	<u>152</u>
<u>ANNEXE : PRINCIPE DE L'ALGORITHME DE SORTIE DE BOUCLE</u>	<u>153</u>
<u>BIBLIOGRAPHIE</u>	<u>156</u>

Liste des figures

Figure A-1 : Niveaux de contrôles d'un opérateur humain selon Rasmussen (1983) ; modèle SRK.....	8
Figure A-2 : Organisation hiérarchique des niveaux de l'activité de conduite selon Michon (1985).....	9
Figure A-3 : Activité de conduite selon Michon (1985) adapté au niveau 2 d'automatisation (SAE).	14
Figure A-4 : Activité de conduite selon Michon (1985) adapté au niveau 3 d'automatisation (SAE).	15
Figure A-5 : Niveaux de conscience de la situation dans le modèle d'Endsley (1995)	19
Figure A-6 : Impact d'une tâche secondaire (TS) et de sa nature (auditive-visuelle ; visuomotrice ; cognitive-auditive) sur le temps de reprise en main.	23
Figure A-7 : Différences de temps de reprise en main selon la durée d'automatisation.	25
Figure B-1 : Prises d'informations visuelles d'un participant dans Hayhoe et al. (2003).....	33
Figure B-2 : Coordination visuomotrice en conduite manuelle dans l'expérience de Land & Lee (1994) ...	35
Figure B-3 : Localisation des points d'anticipation regardés lors du contrôle de trajectoire.....	36
Figure B-4 : Différence d'exploration visuelle en fonction de l'expérience des conducteurs.	40
Figure B-5 : Distribution du regard par rapport au point tangent dans l'étude de Mars & Navarro (2012)	42
Figure C-1 : Découpage de la scène visuelle en 13 aires d'intérêts.....	50
Figure C-2 : Visualisation théorique d'une matrice de transition avec N aires d'intérêts.	51
Figure D-1 : Driving simulator setup: the driving scene is displayed on three screens.	63
Figure D-2 : Geometry of the curves used for data analysis.	64
Figure D-3 : Visualization of the GF reference on raw data.....	66
Figure D-4 : Threshold calculation.	67
Figure D-5 : Schematic view of the driving scene during the Approach (A) and the Cornering (B) of the bend.....	69
Figure D-6 : Segmentation of eye-movements using Naïve Segmented Linear Regression algorithm.....	70
Figure D-7 : Characterization of gaze polling.	71
Figure D-8 : Gaze distributions as a function of the driving condition (blue: active, red: passive) and bend section (A: Approach, B: Cornering).....	72
Figure D-9 : Gaze distributions as a function speed (red: 60 km/h, blue: 75 km/h, black: 90 km/h), bend section (A,C: Approach, B,D: Cornering) and driving conditions (A,B : active driving, C,D: passive driving).	74

<i>Figure D-10 : Gaze strategies adopted per participant in the Approach (A) and Cornering (B) section. ...</i>	<i>75</i>
<i>Figure D-11 : LAFs mean duration (A,B), cumulative duration (in percent of total duration; C,D) and gaze polling frequency (E,F) as a function of speed and driving condition for the Approach (A,C,E) and Cornering (B,D,F) sections.</i>	<i>76</i>
<i>Figure D-12 : BIC values as a function of the number of components of the model for the Approach (a) and Cornering (b) sections.</i>	<i>83</i>
<i>Figure D-13 : View of the Gaussian Mixture Model on the gaze distribution for the approach section. ...</i>	<i>84</i>
<i>Figure D-14 : View of the Gaussian Mixture Model on the gaze distribution for the cornering section. ...</i>	<i>85</i>
<i>Figure E-1 : Driving simulator environment.....</i>	<i>93</i>
<i>Figure E-2 : Pictograms displayed on the HMI.....</i>	<i>94</i>
<i>Figure E-3 : Division of the driving environment in 13 areas of interest.....</i>	<i>96</i>
<i>Figure E-4 : Estimations (markers) of the automation state from: A, PRC only; B, static indicators only; C, dynamic indicators only; D, static and dynamic indicators.</i>	<i>99</i>
<i>Figure E-5 : Visualisation of exiting AOIs (blue) and AOIs (orange) for manual and automated driving.</i>	<i>102</i>
<i>Figure F-1 : Driving simulator setup</i>	<i>117</i>
<i>Figure F-2 : Pictograms displayed on the HMI.....</i>	<i>118</i>
<i>Figure F-3 : Division of the driving environment into 13 areas of interest</i>	<i>120</i>
<i>Figure F-4 : Four sequential steps of data analysis.....</i>	<i>123</i>
<i>Figure F-5 : MW scores reported by the participants according to the outcome in the critical case.</i>	<i>124</i>
<i>Figure F-6 : Visual indicators relevant for MW score prediction.</i>	<i>126</i>
<i>Figure F-7 : Correlation plots between the (real) MW score and the predictions of the MW score by PLS regressions on the training dataset (A) and the validation dataset (B).</i>	<i>128</i>
<i>Figure F-8 : Residuals from the PLS regression models for the training (left) or validation (right) datasets.</i>	<i>135</i>
<i>Figure Annexe : Principe de l'algorithme de sortie de boucle</i>	<i>154</i>

Listes des tableaux

<i>Tableau A-1 : Niveaux d'automatisation des véhicules adapté de SAE (2016).....</i>	<i>12</i>
<i>Tableau A-2 : Niveaux du conducteur dans la boucle de conduite selon Merat et al. (2019).....</i>	<i>18</i>
<i>Tableau C-1 : Synthèse de la démarche expérimentale.....</i>	<i>53</i>
<i>Tableau D-1 : Initial parameters of the Gaussian Mixture Model with 4 components.....</i>	<i>83</i>
<i>Tableau D-2 : Final parameters of the model with 4 components in the Approach section.....</i>	<i>84</i>
<i>Tableau D-3: Final parameters of the model with 4 components in the cornering section.....</i>	<i>85</i>
<i>Tableau E-1 : Distribution of visual attention for manual and automated drives.</i>	<i>98</i>
<i>Tableau E-2 : PLS regression coefficients per visual indicator.</i>	<i>101</i>
<i>Tableau F-1 : Optimal number of components, number of selected visual indicators and mean square error of prediction (for both training and validation datasets) as a function of the time window.</i>	<i>125</i>
<i>Tableau F-2 : Coefficients of the PLS regression and correlation coefficients between the MW score and the visual indicators (* $p < 0.05$; ** $p < 0.01$).....</i>	<i>127</i>

Introduction Générale

Conduire un véhicule est une tâche usuelle pour bon nombre de français, 7 Français sur 10 utilisant leur véhicule quotidiennement pour aller travailler (Insee Focus N° 143, 2019). Pour autant, la tâche de conduite revêt une apparente difficulté : c'est une tâche dynamique, dans laquelle l'environnement de conduite change à chaque instant. Le conducteur doit ainsi constamment maîtriser son véhicule (c'est-à-dire maintenir son véhicule dans la voie et ajuster sa vitesse), mais il doit également porter son attention sur les mouvements d'autres usagers de la route pour anticiper leur comportement (autres véhicules, piétons, cyclistes, etc.). À cela s'ajoute la nécessité pour lui de respecter le code de la route, et donc d'adapter son comportement aux différents panneaux rencontrés au cours de son trajet. Par exemple, lors de l'approche d'une intersection, le comportement visuel des conducteurs diffère selon le type d'intersection, la densité du trafic, et la familiarité des participants avec l'intersection (Lemonnier et al., 2020).

Dès lors, lorsque le conducteur est défaillant dans l'une des sous-tâches indiquées ci-dessus, des accidents sont susceptibles de se produire. Même aujourd'hui, avec des véhicules de plus en plus équipés (ceintures de sécurité, airbags, ABS, pare-chocs mieux conçus, etc.), les chiffres d'accidentologie et de la mortalité routière sont préoccupants. Selon le rapport de la sécurité routière (ONISR, 2020), plus de 58 000 accidents corporels ont été constatés sur les routes françaises en 2019, pour un total d'un peu moins de 3500 morts.

Dès les années 70, l'erreur humaine apparaît comme la principale cause d'accident, causant un peu plus de 90 % des accidents dans l'Indiana (Treat et al., 1979). Des études plus récentes ont montré que la part d'erreur humaine dans les causes d'accident reste stable dans le meilleur des cas (88 % selon Dingus et al., 2016), mais peut également être plus importante (94 % selon NHTSA, 2008 ; 97 % selon Otte et al., 2009). Ces chiffres en augmentation peuvent être liés à une plus forte distraction au volant, causée par de nouveaux usages technologiques. Par exemple, l'usage du téléphone portable en conduisant multiplie par 4 la probabilité d'avoir un accident (McEvoy et al., 2005 ; Redelmeier & Tibshirani, 1997). Plus particulièrement, le fait d'écrire un message multiplie cette probabilité par 20 ! (Kidd & McCartt, 2015)

INTRODUCTION GENERALE

De ce fait, déléguer la tâche de conduite à des automates a clairement un intérêt du point de vue de la sécurité routière. Hayes (2011) évoque ainsi une mortalité réduite de 99 % si le parc automobile américain se composait uniquement de véhicules totalement autonomes. Au niveau européen, il est également attendu que le déploiement des véhicules autonomes impacte positivement la sécurité routière (European Transport Safety Council, 2016). Mais au-delà du seul aspect sécuritaire, les perspectives positives de l'arrivée des véhicules autonomes sur nos routes ne manquent pas : les véhicules autonomes (sous réserve de suffisamment de véhicules communiquant entre eux) fluidifieraient le trafic routier (Anderson et al., 2014), ayant pour conséquence de diminuer les temps de trajet (Cyganski et al., 2015), la consommation d'essence (de 30 % environ) et le temps passé dans les embouteillages de 15 % (Fagnant & Kockelman, 2015). D'autre part, la conduite autonome permettrait de favoriser la mobilité de certaines populations moins (voire pas) capables de conduire leur véhicule de façon sûre, comme les seniors ou les personnes en situation de handicap (Harper et al., 2016).

Pour autant, l'émergence des véhicules autonomes est confrontée à de nombreux verrous législatifs et éthiques. Législatifs d'une part car la réglementation ancienne de 1968 (convention de Vienne) désigne le conducteur comme responsable en cas d'accident. Ceci ne peut pas s'appliquer directement si le conducteur délègue totalement la conduite à son véhicule. Des amendements (mars 2016) laissent cependant entrevoir une issue favorable à une automatisation grandissante des véhicules, avec l'autorisation de modules autonomes, mais toujours utilisés sous le contrôle du conducteur (UNECE, 2016). D'autre part, les législations doivent autoriser les véhicules autonomes à rouler sur route ouverte pour permettre l'évaluation des technologies existantes dans des situations de conduite naturelle. C'est le cas depuis mi-2015 en France chez Peugeot (Groupe PSA, 2019). Récemment, avec le véhicule autonome comme partie prenante du plan Nouvelle France Industrielle (gouvernement.fr, 2017), des dispositions favorisant les expérimentations sur route ouverte sont prises au travers de la loi PACTE (economie.gouv.fr, 2018). À ces aspects législatifs s'ajoutent les aspects éthiques, notamment selon le comportement du véhicule à adopter lorsqu'une collision est inévitable. Ces aspects éthiques ne se trancheront pas de manière universelle, chaque société ayant sa façon d'approcher le problème (Awad et al., 2018).

Malgré ces contraintes, le véhicule autonome fait l'objet de recherches poussées, notamment au niveau technologique (capteurs, aides à la conduite, fusion de données, etc.). En fonction de ces différentes avancées technologiques, le partage de tâche entre l'homme et l'automate a évolué, allant d'un stade où l'homme est seul en charge de la tâche de

conduite, à un stade où l'automate en est le seul responsable (niveau théorique pas encore atteint). Entre ces deux extrêmes, différents niveaux de partage des tâches existent (SAE International, 2016). Aux premiers niveaux (SAE 1 et 2), le conducteur bénéficie d'assistances à la conduite, comme l'aide au maintien dans la voie ou le régulateur de vitesse, mais reste responsable de la conduite. En revanche, à des niveaux d'automatisation plus élevés, l'automate est responsable de la tâche de conduite dans certaines conditions. Lorsque ces conditions ne sont pas remplies, le conducteur doit reprendre le contrôle dans un temps imparti. À l'issue de ce temps et si le conducteur n'a pas repris le contrôle, soit la main est redonnée au conducteur (niveau 3), soit le véhicule se met en sécurité (niveau 4).

Dans tous les cas, dès lors que la conduite est suffisamment automatisée (SAE niveau 2 et plus), le conducteur est, par définition, au moins partiellement hors de la boucle de contrôle du véhicule. En d'autres termes, le conducteur devient superviseur de la tâche de conduite plutôt qu'acteur, avec un degré de supervision dépendant du niveau d'automatisation du véhicule. Ce changement de rôle est à l'origine du phénomène de sortie de boucle (Merat et al., 2019), concept central de ce travail de doctorat. Le phénomène est surtout évoqué dans la littérature par ses conséquences sur les performances de conduite.

Dans le cas d'une reprise en main, les temps de réaction à un obstacle apparu sur la route de manière impromptue sont plus longs si le conducteur était en conduite autonome qu'en conduite manuelle (Zeeb et al., 2015). De même, la qualité de l'évitement est moins bonne dans le cas de la conduite automatisée, avec un temps de stabilisation d'environ 45 s (Merat et al., 2014). Ces changements dans le cadre de la reprise en main sont d'autant plus importants que la durée passée en conduite autonome est importante (Bourrelly et al., 2019). Mais même en absence de reprise en main, les comportements des conducteurs changent en conduite autonome, avec notamment une exploration plus importante de la scène visuelle au détriment d'informations centrales potentiellement utiles au contrôle du véhicule (Mars & Navarro, 2012). Le phénomène de sortie de boucle est donc un phénomène impactant la sécurité des conducteurs de véhicule autonome.

Récemment, Merat et al. (2019) proposent une définition opérationnelle de la sortie de boucle adaptée à la conduite autonome (SAE niveau 3 et +) : un conducteur hors de la boucle n'a pas le contrôle physique du véhicule et ne surveille pas assez l'environnement de conduite. Cette définition suggère que l'activité visuelle du conducteur sur la route permet d'accéder à son état dans la boucle de conduite, de manière relative : soit le conducteur a

INTRODUCTION GENERALE

assez surveillé, soit non. Ainsi, à partir de l'analyse de ses stratégies visuelles en conduite autonome, il serait possible de déduire son état dans la boucle de conduite.

Le travail de thèse s'est construit dans cette optique. Dans un premier temps, il vise à appréhender les conséquences de l'automatisation sur les stratégies visuelles dans différents contextes routiers (route à virage, autoroute). Pour ce faire, des comparaisons de comportement visuel entre la conduite manuelle (où les coordinations visuomotrices permettant le guidage du véhicule sont essentielles) et autonome (où ces coordinations ne sont plus nécessaires) ont été menées. Dans un second temps, les stratégies visuelles des conducteurs en conduite autonome ont été liées à un score de sortie de boucle, afin de mettre en place un modèle de prédiction de la sortie de boucle.

En plus de l'analyse d'indicateurs visuels « statiques » (indicateurs d'attention sur des aires d'intérêts, distribution angulaire du regard), la dynamique des prises d'informations visuelles a été intégrée de manière originale. En effet, les transitions entre des aires d'intérêts ont été analysées, notamment pour traiter de l'équilibre entre les stratégies visuelles permettant de guider le véhicule et les processus d'anticipation visuelle (sur route à virage).

L'aspect modélisation des stratégies visuelles a également été au cœur du travail de doctorat. En effet, une modélisation des prises d'informations visuelles entre les aires d'intérêt a été effectuée sous forme de chaîne de Markov, et a servi dans un modèle de prédiction de la sortie de boucle (régressions PLS). D'autre part, sur route à virage, une modélisation de la distribution angulaire sous forme de modèle de mélange gaussien a été mise en œuvre.

Ce manuscrit est organisé en six parties distinctes. Tout d'abord (parties A et B), un état de l'art de la littérature existante a été réalisé. Le but de cet état de l'art est d'inscrire le travail de thèse dans le contexte scientifique lié à l'activité de conduite et aux stratégies visuelles déployées par les conducteurs. Il présente également les conséquences de la délégation de la conduite à l'automate sur ces deux aspects. Après cette phase de contextualisation, les axes de travail du doctorat sont présentés en partie C. Ensuite, les parties D, E et F traitent des contributions expérimentales et méthodologiques du doctorat, chaque partie se référant à un article scientifique publié ou en cours de publication. Enfin, la discussion générale sur les travaux ainsi que les différentes perspectives associées sont développées dans la partie G.

INTRODUCTION GENERALE

Partie A: État de l'art - Activité de conduite

La première partie de cet état de l'art est dédiée à l'activité de conduite. Il permet dans un premier temps de définir le cadre théorique propre à la conduite manuelle (section A.1), puis de montrer dans quelle mesure ce cadre est modifié en considérant une conduite automatisée (section A.2). Enfin (section A.3), on discutera de la cause de ces modifications : le phénomène de sortie de boucle.

A.1. Définition de l'activité de conduite manuelle

Comme évoqué dans l'introduction générale, la tâche de conduite est une tâche complexe effectuée sous différentes contraintes temporelles. Par exemple, la tâche de conduite regroupe toutes les actions allant du choix d'un itinéraire à l'arrêt (peu de contraintes temporelles) au contrôle manuel du volant et des pédales lorsque le véhicule est en mouvement (contraintes temporelles fortes). Plusieurs modèles théoriques ont été développés dans la littérature pour tenter de hiérarchiser les différentes tâches du conducteur, et de représenter leurs interactions. Dans le cadre de cet état de l'art, nous présenterons tout d'abord (section A.1.1) le modèle de Rasmussen qui définit la réalisation d'une tâche cognitive selon des comportements basés sur des habiletés, règles et connaissances de l'opérateur. Par la suite (section A.1.2), le modèle de l'activité de conduite selon Michon sera développé et comparé au modèle de Rasmussen. Ce modèle segmente l'activité de conduite en 3 boucles d'informations : stratégique, tactique et opérationnelle.

A.1.1. Modèle de Rasmussen (1983)

Le modèle de Rasmussen (également appelé modèle SRK pour **S**kills-**R**ules-**K**nowledge) est un modèle général qui décrit le contrôle d'une activité cognitive par un opérateur (Rasmussen, 1983). Le comportement de l'opérateur est défini par trois niveaux organisés de manière hiérarchique : le niveau des connaissances, le niveau des règles et le niveau des habiletés (voir Figure A-1).

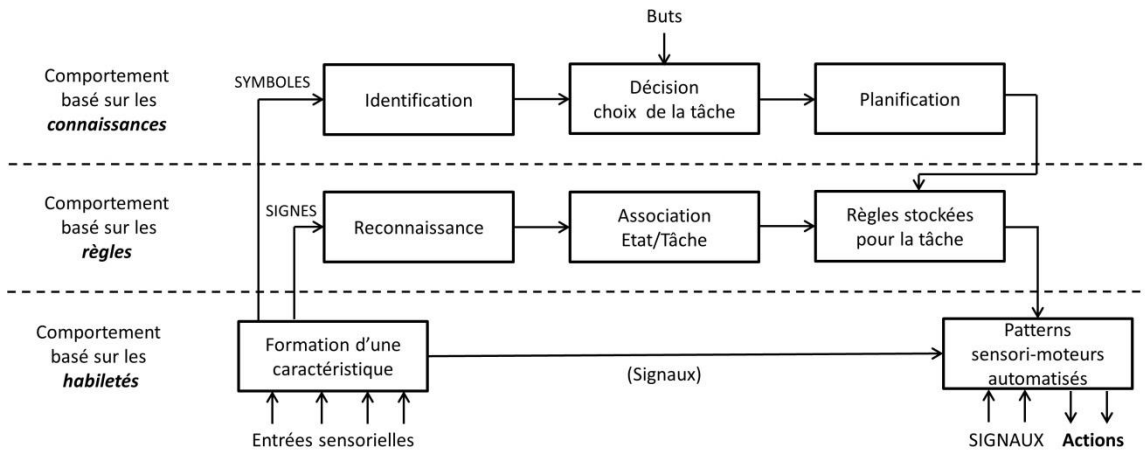


Figure A-1 : Niveaux de contrôles d'un opérateur humain selon Rasmussen (1983) ; modèle SRK

Les comportements basés sur les habiletés s'effectuent majoritairement sans contrôle conscient, via des processus sensorimoteurs « automatisés ». Appliqués à la tâche de conduite, ils sont en charge du contrôle du véhicule sur la voie dans des conditions normales de conduite, qui ont été apprises lors de l'enseignement de la conduite : une fois la tâche apprise, les habiletés du conducteur lui permettent de conduire tous les véhicules.

Les comportements basés sur les règles se caractérisent par l'usage de procédures pour définir la séquence d'actions à adopter. Ces règles sont apprises par l'opérateur avec son expérience de la tâche, mais peuvent également être transmises. Dans ce cas, les conducteurs peuvent expliciter les règles. Par exemple, dans le cas de la conduite sur autoroute et en présence d'un véhicule arrêté sur la bande d'arrêt d'urgence, le conducteur peut changer de voie et se déporter (si possible) sur sa gauche.

En l'absence de règles établies, les prises de décisions des opérateurs se font en fonction de leurs connaissances sur le sujet et de leurs buts généraux.

Dans le cadre du modèle de Rasmussen (1983), l'apprentissage d'une tâche par un opérateur consiste en un transfert d'un mode de contrôle de haut niveau cognitif (connaissances, règles) vers un mode de contrôle reposant sur des routines d'actions de plus en plus automatisées (habiletés).

A.1.2. Modèle de Michon (1985)

Contrairement au modèle de Rasmussen qui propose une hiérarchie de processus cognitifs, d'autres chercheurs optent plutôt pour une classification hiérarchique de l'activité de conduite elle-même (Allen et al., 1971 ; Hollnagel & Woods, 1995 ; Michon, 1985 ; Ranney, 1994). Le modèle le plus repris dans la littérature est celui de Michon (1985), dans lequel

A.1. DEFINITION DE L'ACTIVITE DE CONDUITE MANUELLE

3 niveaux de tâches distincts et interagissant entre eux décrivent l'activité de conduite : le niveau stratégique, le niveau tactique et le niveau opérationnel (cf Figure A-2).




Figure A-2 : Organisation hiérarchique des niveaux de l'activité de conduite selon Michon (1985)

Au niveau stratégique, le plan général du trajet d'un point A à un point B est mis en place : le conducteur est notamment en charge du choix de l'itinéraire en fonction de ses contraintes (temps de trajet, arrêts à prévoir, autres passagers dans la voiture, trafic à l'heure du trajet, etc.). De ces plans généraux dérive une liste de critères (itinéraire, marges de sécurité et vitesse à respecter, etc.) interprétés par le niveau tactique. La mise en place des plans généraux se fait sous contrainte temporelle longue, mais demande des ressources cognitives importantes.

Le niveau tactique est celui du contrôle des manœuvres : il s'agit pour le conducteur d'analyser la situation de conduite immédiate, d'anticiper sa projection à court terme pour prendre des décisions conformes aux critères dérivés des plans généraux. Pour cela, le conducteur se base sur des informations issues de l'environnement (voir partie B) et est soumis à des contraintes temporelles plus fortes qu'au niveau stratégique (secondes).

Une fois la manœuvre décidée au niveau tactique, son exécution est déléguée rapidement au niveau opérationnel. C'est donc au niveau opérationnel que sont régulés à la fois le contrôle latéral (position sur la voie) et longitudinal (vitesse) du véhicule en mettant en œuvre des boucles perception-action très rapide (millisecondes).

Considérons par exemple qu'un conducteur soit en retard à un rendez-vous. Au niveau stratégique, il va prioriser son temps de trajet, par exemple prendre les voies les plus rapides. Au niveau tactique, le conducteur va donc avoir tendance à prioriser les dépassements d'autres véhicules et à rouler à vitesse élevée. Après inspection de la scène de

conduite actuelle et l'anticipation de celle à venir (niveau tactique), le conducteur effectuera, au niveau opérationnel, les manœuvres de changement de voie.

Des parallèles entre le modèle de Rasmussen et le modèle de Michon existent dans la littérature (Donges, 1999 ; Hale et al., 1990), avec chacun des niveaux de l'activité de conduite de Michon reflétant les niveaux de contrôle cognitif de Rasmussen. Ainsi, le niveau opérationnel (avec des patterns d'actions automatisées) correspondrait au niveau basé sur les compétences, le niveau tactique au niveau des comportements basés sur les règles et le niveau stratégique à celui des comportements basés sur les connaissances. Pour autant, cette superposition est directement applicable pour des conditions de conduite normales et un conducteur expérimenté uniquement.

D'autres modélisations de la tâche de conduite existent dans la littérature, certains distinguant par exemple 4 niveaux de contrôles (Hollnagel et al., 2003 ; Mars, 2016). La distinction principale vis-à-vis du modèle de Michon concerne la séparation du niveau tactique en deux sous-niveaux dépendant la nature consciente (ou non) des processus mentaux. Ainsi, le niveau tactique implicite concerne directement la mise en place de routines d'actions facilitant les coordinations visuomotrices au niveau opérationnel. Au niveau tactique explicite, le conducteur applique des règles sous contrôle conscient. Pour autant, dans le cadre de ce travail de doctorat, nous nous référerons au modèle de Michon, qui regroupe ces deux aspects dans un niveau tactique unique.

A.1.3. Synthèse et transition

La précédente section a permis d'appréhender l'activité de conduite comme une activité hiérarchique à plusieurs niveaux. Après inspection de deux modèles hiérarchiques, on considérera dans la suite du manuscrit l'activité de conduite comme une activité à 3 niveaux (stratégique, tactique et opérationnel) alimentés d'entrées environnementales (dont la nature est discutée dans la partie B). La prochaine section permet d'établir, parmi les niveaux cités ci-dessus, lesquels sont affectés par la délégation de la conduite à un automate.

A.2. Modifications de l'activité de conduite induite par l'automatisation des véhicules

Aujourd'hui, la conduite est déjà fréquemment assistée par des systèmes automatiques, avec par exemple le régulateur de vitesse adaptatif (ou *adaptive cruise control* en anglais ; ACC ; Beiker, 2012). Dans ce cas-là, le conducteur reste responsable de la tâche de conduite, mais il ne contrôle cependant pas la vitesse du véhicule lorsque le système est actif. On diffère donc déjà de la tâche de conduite originelle, pour laquelle le contrôle latéral (position du véhicule sur la voie) et longitudinal (contrôle de la vitesse du véhicule) du véhicule est assuré par le conducteur. Ces variations relativement à la tâche de conduite simple sont regroupées sous forme de niveaux d'automatisation, dont les règles régissent le partage des tâches entre l'homme et l'automate. Dans le cas général d'une interaction homme-machine, Sheridan and Verplank (1978) distinguent 10 niveaux de partage des tâches. Le cas spécifique de la conduite autonome, avec 6 niveaux d'automatisation, est présenté en section A.2.1. Enfin, l'activité de conduite des « conducteurs » en conduite autonome de niveau 2 et 3 (SAE) est développée dans les sections A.2.2 et A.2.3 respectivement.

A.2.1. Niveaux d'automatisation en conduite autonome

Dans la littérature, plusieurs niveaux d'automatisation ont été proposés par différentes administrations : le BAST (Allemagne ; Gasser et al., 2012), la NHTSA (États-Unis ; NHTSA, 2013) et la SAE International, anciennement Society of Automotive Engineers (SAE International, 2014). Si, de fait, les propositions concernant les niveaux d'automatisation diffèrent dans leur forme (noms, numéros, etc.), ils se regroupent sur le fond, les niveaux de partage des tâches étant similaires. Pour autant, la taxonomie SAE la plus récente (SAE International, 2016) étant la plus reprise dans la littérature, on se référera dans la suite du manuscrit à ces niveaux d'automatisation. Ces 6 niveaux d'automatisation sont résumés dans le Tableau A-1 et développés plus en détail dans les paragraphes suivants.

Niveau 0 : pas d'automatisation

Le niveau 0 correspond à la conduite non automatisée, dans lequel le conducteur est en charge de toutes les tâches relevant de la conduite (contrôle latéral et longitudinal du véhicule ; surveillance continue de l'environnement de conduite)

ÉTAT DE L'ART - ACTIVITE DE CONDUITE

Niveau SAE	Nom SAE	Contrôle du véhicule	Surveillance continue de l'environnement de conduite	Utilisation de l'automate	Mode de repli
0	Pas d'automatisation	Conducteur	Conducteur		
1	Conduite Assistée	Conducteur & Automate	Conducteur	Certains contextes routiers	
2	Automatisation partielle	Automate	Conducteur	Certains contextes routiers	
3	Automatisation conditionnelle	Automate	Automate	Certains contextes routiers	Conducteur
4	Automatisation élevée	Automate	Automate	Certains contextes routiers	Automate
5	Automatisation complète	Automate	Automate	Partout	Automate

Tableau A-1 : Niveaux d'automatisation des véhicules adaptés de SAE (2016).

Les niveaux diffèrent d'abord selon le responsable du contrôle du véhicule (latéral et/ou longitudinal) et de la surveillance continue de l'environnement de conduite. Dès lors que la conduite est autonome (SAE niveau 3 et +), les niveaux s'établissent en fonction des conditions d'utilisation de l'automate, puis du mode de repli (c'est à dire du responsable lorsque l'on sort du domaine d'utilisation de l'automate).

Niveau 1 : conduite assistée

Au niveau 1, le conducteur délègue une partie du contrôle du véhicule à l'automate (latéral ou longitudinal), mais reste en charge de la supervision de la scène de conduite. On distingue donc deux cas d'usages de niveaux 1 : soit le conducteur contrôle le volant et ne gère plus la vitesse du véhicule (appelé parfois niveau 1 longitudinal), soit le conducteur garde le contrôle de la vitesse mais lâche le volant (niveau 1 latéral). Du point de vue technique, des automates types régulateurs de vitesse adaptatifs ou systèmes de maintien automatique dans la voie sont utilisés aux niveaux 1. Ces types d'automates de bas niveau ne s'appliquent pas dans tous les contextes routiers (milieu urbain par exemple).

Niveau 2 : automatisation partielle

Au niveau 2, le contrôle latéral et longitudinal est délégué à l'automate, avec le conducteur chargé de surveiller l'environnement de conduite. Techniquement, le niveau 2 est constitué de l'activation simultanée de niveau 1 latéral et longitudinal : les capteurs utilisés ne captent que l'information nécessaire pour maintenir le véhicule dans la voie (lignes blanches notamment) et gérer la vitesse (distance par rapport au véhicule de devant) et ne communiquent pas entre eux. De fait, l'automate n'a pas de représentation globale de la

A.2. MODIFICATIONS DE L'ACTIVITE DE CONDUITE INDUITE PAR L'AUTOMATISATION DES VEHICULES

scène de conduite : l'automate sert d'assistance à la conduite, la conduite étant supervisée de manière continue par le conducteur.

Plusieurs modèles d'automates de niveau 2 ont déjà été introduits sur le marché, comme la Tesla Autopilot (Dikmen & Burns, 2016 ; Endsley, 2017) ou la Mercedes Distronic Plus System (Singh et al., 2019). Dans ces modèles, le conducteur doit cependant garder les mains sur le volant (même s'il n'effectue pas d'actions lorsque le mode autonome est activé).

Niveau 3 et 4 : automatisation conditionnelle et élevée

Au niveau 3, les véhicules sont autonomes : ils sont équipés de capteurs communiquant entre eux pour permettre d'avoir une représentation détaillée (autres véhicules, réglementation en vigueur, détection des lignes, dépassements, etc.) de la scène de conduite (via des capteurs lidars notamment) pour permettre d'ajuster la dynamique du véhicule (fusion des données et prise de décision). De ce fait, les contrôles du véhicule comme la surveillance continue de l'environnement de conduite sont assurés par l'automate. Pour autant, l'activation de l'automate ne peut s'effectuer que dans certains contextes routiers, par exemple sur autoroute. En dehors de ces contextes spécifiques, le conducteur redevient responsable de la conduite.

De fait, un problème se pose si l'automate est activé (niveau 3 et 4) mais que les conditions d'utilisation de l'automate ne sont plus remplies à un instant t (par exemple, lorsque le véhicule sort de la zone géographique dans laquelle l'automatisation est permise). Dans ce cas, le mode de repli entre en action. Au niveau 3, le conducteur doit impérativement reprendre le contrôle dans le temps imparti par l'automate. En cas d'échec, la conduite autonome est de toute façon désactivée, ce qui peut être source d'accident. Au niveau 4, si le conducteur ne reprend pas le contrôle, l'automate dispose d'un programme lui permettant de mettre le véhicule (et son conducteur) en sécurité. Par exemple, si le conducteur ne reprend pas la main sur autoroute, la mise en sécurité pourrait consister à mettre le véhicule sur la bande d'arrêt d'urgence.

Ainsi, au niveau 3, bien que le conducteur ne doive plus surveiller l'environnement de conduite de manière continue, il doit cependant être capable de reprendre le contrôle du véhicule à tout instant : le mode de repli revient au conducteur. En revanche, au niveau 4, le mode de repli revient à l'automate.

Les véhicules de niveau 3-4 sont attendus avant 2030 selon les principaux constructeurs (Chan, 2017 ; ERTRAC Task Force, 2015), ce qui concorde avec les attentes temporelles des futurs utilisateurs (Kyriakidis et al., 2015 ; Underwood & Firmin, 2014).

Niveau 5 : automatisation complète

Au niveau 5, l'automate gère l'ensemble des tâches de conduite, dans toutes les situations possibles. Il n'y a plus de « conducteur » humain dans le véhicule. Selon Walker et al. (2001), les véhicules autonomes de niveau 5 pourraient être déployés sur les routes d'ici 2030, même si cela reste une projection incertaine.

Dans la suite de cette partie, on s'intéressera particulièrement aux conséquences d'une automatisation de niveau 2 et 3 sur l'activité de conduite. En effet, bien que le contrôle du véhicule soit automatique, le conducteur doit rester impliqué de manière totale (niveau 2) ou partielle (niveau 3) dans la supervision de la scène de conduite.

A.2.2. Activité de conduite au niveau 2 (SAE)

Au niveau 2, le contrôle latéral et longitudinal du véhicule est automatisé, mais le conducteur se doit de surveiller l'environnement de conduite. De ce fait, le conducteur n'effectue plus de contrôle moteur sur la dynamique du véhicule (pas d'appui sur les pédales ou de contrôle manuel du volant) : il n'acquiert ni ne transmet plus d'informations au niveau opérationnel comme illustré sur la Figure A-3. En revanche, du fait de sa surveillance continue de l'environnement de conduite, il conserve le contrôle tactique.

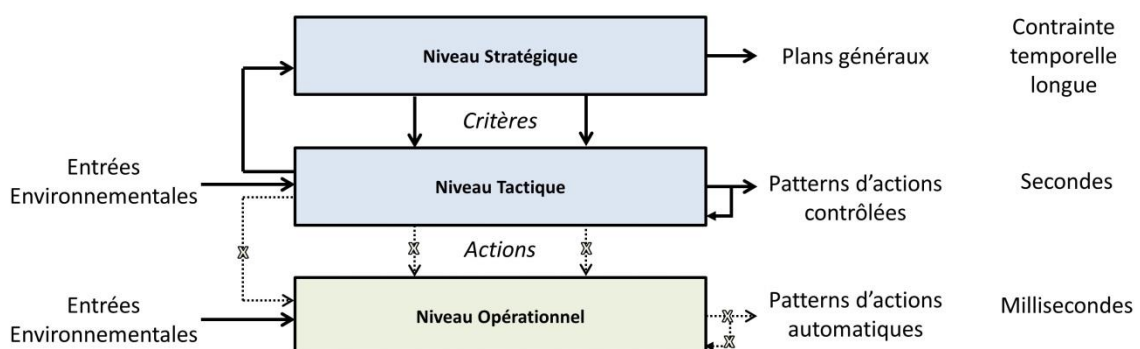


Figure A-3 : Activité de conduite selon Michon (1985) adapté au niveau 2 d'automatisation (SAE).

Le niveau opérationnel est géré uniquement par l'automate (en vert), ce qui coupe les flux d'informations associés (symboles x). Le conducteur reste en charge des aspects tactiques et stratégiques.

A.2.3. Activité de conduite au niveau 3 (SAE)

Au niveau 3, la tâche de conduite du conducteur se restreint au niveau stratégique, c'est-à-dire à la définition des plans généraux du trajet (itinéraire, style de conduite, etc.). L'automate gère le niveau tactique et le niveau opérationnel (voir Figure A-4).




Figure A-4 : Activité de conduite selon Michon (1985) adapté au niveau 3 d'automatisation (SAE).

La délégation de la conduite à un automate de niveau 3 impacte à la fois le niveau opérationnel et le niveau tactique (en vert). Le conducteur reste en charge des aspects stratégiques.

Au niveau 3, le conducteur n'est pas chargé de surveiller l'environnement de conduite de manière continue, mais doit être capable de reprendre le contrôle à tout moment. Il peut également s'engager dans des tâches secondaires. Dans une enquête menée auprès de plus de 5000 participants, Kyriakidis et al. (2015) ont montré une volonté d'utiliser le temps de conduite pour dormir, téléphoner, répondre à ses mails, regarder un film, lire un livre, manger, discuter avec les passagers et observer les paysages en conduite autonome. Dans une expérimentation sur simulateur de conduite, Carsten et al. (2012) ont montré que les conducteurs s'engageaient surtout dans des tâches de lecture et de visionnage de films en conduite autonome, alors qu'ils ne le faisaient pas du tout en conduite manuelle. Cette tendance à l'engagement des conducteurs dans des tâches secondaires a été confirmée à la fois sur simulateur de conduite (Jamson et al., 2013) et sur route ouverte (Llaneras et al., 2013).

A.2.4. Synthèse et transition

L'activité de conduite manuelle nécessite des processus qui sont organisés selon 3 niveaux (stratégique, tactique et opérationnel). Plus le niveau d'automatisation augmente, plus la tâche de conduite est déléguée à l'automate, ce qui altère les flux d'informations au niveau opérationnel (niveaux 2 et 3) et au niveau tactique (niveau 3). Par conséquent,

L'automatisation sort le conducteur des boucles de contrôle opérationnelles et tactiques : c'est le phénomène de sortie de boucle.

A.3. Phénomène de sortie de boucle

Dans cette section, le phénomène de sortie de boucle sera présenté en détail. Tout d'abord, la section A.3.1 reviendra sur les définitions du phénomène de sortie de boucle utilisées dans la littérature, et ses différents liens avec le concept de conscience de la situation introduit par Endsley (1995) (voir section A.3.2). La section A.3.3 revient sur les conséquences du phénomène de sortie de boucle sur la performance de conduite lors d'une situation de reprise en main (véhicules autonomes de niveaux 3). Ensuite, l'évolution temporelle du phénomène de sortie de boucle sera développée dans la partie A.3.4. Enfin, la partie A.3.5 développe les différents procédés expérimentaux permettant d'induire la sortie de boucle chez les participants.

A.3.1. Définition (s)

L'origine du terme « sortie de boucle » découle de l'analogie avec l'automatique des systèmes, dont les activités sont régies par plusieurs boucles de contrôles. Cette analogie est parfaitement cohérente avec l'activité de conduite, dans la mesure où celle-ci peut être modélisée de manière hiérarchique par trois niveaux de contrôles : opérationnel, tactique et stratégique (cf. section précédente). Avec ce modèle de l'activité de conduite, « sortir de la boucle » peut avoir a priori plusieurs significations : suffit-il d'être hors de la boucle opérationnelle pour être en sortie de boucle ? Faut-il sortir à la fois de la boucle opérationnelle et tactique pour considérer le conducteur comme hors de la boucle ? L'objectif de cette section est d'arriver à une définition opérationnelle de la sortie de boucle, que l'on pourra utiliser dans la suite du manuscrit.

Les premières notions de sortie de boucle apparaissent dans les années 70 dans le domaine de l'aviation (Meilander, 1972), où le pilotage automatique de l'avion s'est vite développé. Suite aux premiers résultats, notant que les pilotes réagissent plus vite aux changements de dynamiques de l'appareil lorsqu'ils contrôlent manuellement l'avion que lors du pilotage automatique (Wickens, 2002 ; Wickens & Kessel, 1979, 1981), un premier cadre théorique sur la sortie de boucle a été développé (Endsley & Kiris, 1995 ; Kaber & Endsley, 1997).

Dans ce cadre, «lorsqu'un opérateur est sorti d'une boucle de contrôle du fait de la délégation d'une partie de ses fonctions à un automate, la supervision de l'état du système par l'opérateur peut être réduite». De ce fait, les opérateurs sont plus enclins à faire des erreurs dues aux limitations de l'automatisation, comparée à une utilisation manuelle. Dans cette optique, le phénomène de sortie de boucle est considéré uniquement par rapport aux conséquences qu'il entraîne chez la performance de pilote suite à la délégation du contrôle à l'automate.

En conduite automobile, les performances du conducteur en sortie de boucle ont également été étudiées, en considérant un conducteur hors de la boucle dès lors qu'il ne contrôle plus physiquement le véhicule (Brookhuis et al., 2001). Cette sortie de boucle serait consécutive au changement de rôle du conducteur, d'acteur de la conduite à superviseur de l'automate et de la scène de conduite (Strand et al., 2014). Cependant, en plus de l'aspect physique de la sortie de boucle, d'autres études (Louw & Merat, 2017 ; Merat et al., 2014 ; Radlmayr et al., 2014) y intègrent également un aspect cognitif, un conducteur hors de la boucle ne surveillant pas suffisamment l'automate et/ou la route.

Une première définition opérationnelle de la sortie de boucle est proposée par Kienle et al. (2009). Pour les auteurs, un conducteur sorti de la boucle «n'a pas à tout moment conscience du véhicule et de la situation de conduite car il ne surveille pas ni ne prend de décisions quant à la tâche de conduite. De plus, il n'alimente plus les boucles de contrôles de la tâche de conduite». Dans cette définition, les aspects physiques et cognitifs de la sortie de boucle ne sont pas distingués, l'alimentation des boucles de contrôles pouvant se faire à partir d'informations visuelles et/ou d'entrées physique (mains sur le volant par exemple). Récemment, Merat et al. (2019) a réuni une large communauté scientifique pour tenter de mettre en place une définition commune de la sortie de boucle. Cette définition distingue trois niveaux du conducteur dans la boucle (dans la boucle, sur la boucle et hors de la boucle) en fonction de l'activité du conducteur (a-t-il le contrôle physique du véhicule ? surveille-t-il la scène de conduite ?). Les différents niveaux sont présentés sur le Tableau A-2.

	Dans la boucle (in-the-loop)	Sur la boucle (on-the-loop)	Hors de la boucle (Out-of-the-loop)	
Contrôle physique du véhicule	Oui	Non	Non	Oui
Supervision de la scène de conduite	Oui	Oui	Non	Non

Tableau A-2 : Niveaux du conducteur dans la boucle de conduite selon Merat et al. (2019)

Cette définition est générale et s'adapte à tous les niveaux d'automatisation : pour les faibles niveaux d'automatisation, dans lequel le conducteur reste (au moins partiellement) physiquement en charge de la conduite (SAE niveau 0-1), le conducteur est dans la boucle s'il surveille l'environnement de conduite. Dans le cas contraire (distraction visuelle ponctuelle par exemple), le conducteur est considéré hors de la boucle.

Plus particulièrement, pour les véhicules à haut niveau d'automatisation (niveaux SAE 2+), le conducteur est sur la boucle s'il supervise la scène de conduite, et hors de la boucle sinon. Cette définition dépend du comportement du conducteur plus que du niveau d'automatisation : au niveau 2, même si le conducteur doit surveiller l'environnement de conduite (cf section A.2.2), il peut choisir de le faire (auquel cas il sera considéré dans la boucle) ou non (auquel cas il sera considéré hors de la boucle). Au niveau 3, une supervision continue de l'environnement de conduite n'est pas exigée de la part du conducteur, et donc le conducteur pourrait a priori être classé comme hors de la boucle à ce niveau d'automatisation. Pourtant il doit être capable de réagir à tout moment en cas de demande de reprise en main (cf section A.2.3). Dans un cas extrême, si le conducteur ne surveille pas du tout l'environnement de conduite, par exemple en ne regardant pas la route pendant le temps d'un film, cette condition ne peut pas être remplie au cours du temps. Ainsi, si la surveillance continue de l'environnement de conduite n'est pas exigée au niveau 3, le conducteur doit au minimum surveiller l'environnement de conduite de manière partielle. Au niveau 3, le conducteur peut donc être sur la boucle si sa supervision partielle est suffisante, mais hors de la boucle dans le cas contraire.

Suivant cette définition, le contrôle physique du véhicule correspondant au niveau opérationnel de la conduite selon Michon, et la supervision de la scène de conduite appartenant plus au niveau tactique, un conducteur sort de la boucle lorsque les boucles de

contrôle opérationnel et tactique sont interrompues. Pour les véhicules autonomes pour lesquels l'interaction avec le conducteur reste importante (niveau 2 et 3), déterminer si le conducteur est sur ou hors de la boucle revient à analyser la qualité de sa supervision de la situation. Cette analyse peut se faire par l'utilisation du concept de conscience de la situation.

A.3.2. Lien avec la conscience de la situation

Si plusieurs auteurs ont proposé des définitions de la conscience de la situation (Sarter & Woods, 1991 ; Smith & Hancock, 1995), le concept le plus retenu par la littérature est celui développé par Endsley (1995, 1988). La conscience de la situation est définie comme « *la perception des éléments dans l'environnement dans un volume de temps et d'espace, la compréhension de leur signification, et la projection de leur statut dans le futur proche* ». Pour Endsley, la conscience de la situation doit donc être abordée selon trois niveaux : la perception, la compréhension et la projection (voir Figure A-5). Au premier niveau correspond la perception de l'état et de la dynamique des éléments pertinents au regard des buts fixés par l'opérateur. Au second niveau, l'opérateur interprète les différents éléments perçus en fonction de ses connaissances et de ses buts. Enfin, au dernier niveau, l'opérateur anticipe l'évolution dynamique de l'environnement dans les instants suivants, en se basant sur les précédents niveaux.




Figure A-5 : Niveaux de conscience de la situation dans le modèle d'Endsley (1995)
(adapté de Endsley et al., 2004)

Selon Endsley elle-même, ces trois niveaux ne sont pas forcément séquentiels (Endsley, 2015 ; Stanton et al., 2017), dans la mesure où la compréhension et l'anticipation créent des

attentes permettant de guider la recherche d'informations (processus de perception top-down). De même, si le conducteur a déjà construit un modèle mental de la situation (à haut niveau de conscience de la situation), il peut faire des inférences sur les éléments à percevoir. L'aspect spécifique de la perception visuelle est traité dans la partie B.

Au niveau 2, le conducteur est tenu de surveiller la scène de conduite (comme il le ferait en conduite manuelle), ce qui devrait se traduire par une conscience de la situation similaire entre les deux conditions. Au niveau 3, la surveillance de l'environnement par le conducteur s'effectue de manière partielle, donc une baisse de la conscience de la situation est attendue. Compte tenu de la définition de la sortie de boucle et des niveaux de conscience de la situation, le conducteur d'un véhicule automatisé (SAE 2+) peut être défini comme hors de la boucle s'il ne maintient pas suffisamment sa conscience de la situation. En revanche, si sa conscience de la situation est correcte, il est considéré sur la boucle.

Pour mesurer la conscience de la situation, trois types de mesures sont possibles : explicites, implicites ou subjectives. Les mesures explicites consistent à demander au sujet de se rappeler des éléments de la scène de conduite au cours de l'expérience, lorsque la tâche s'arrête brusquement (méthode du rappel impromptu, voir test SAGAT développé par Endsley ; 1988 b). Avec les mesures subjectives, la conscience de la situation est directement reportée par le sujet à la fin de l'expérimentation, le score de conscience de la situation se basant donc sur l'ensemble de l'expérience (voir test SART développé par Taylor ; 1990). Les mesures implicites sont des mesures directes de la performance de la tâche accomplie par l'utilisateur. Elles sont objectives et accomplies par des capteurs du comportement, comme peuvent l'être un oculomètre ou un simulateur de conduite.

Dans la suite de cette partie, on s'intéressera aux mesures implicites de la conscience de la situation, en étudiant les performances de conduite.

A.3.3. Impact du phénomène de sortie de boucle sur les performances de conduite

Le phénomène de sortie de boucle a été souvent évalué au travers de ses conséquences. Dans cette section, ces conséquences seront analysées au travers de la mesure de la performance de conduite suivant un cas critique. Des mesures complémentaires portant sur

la réactivité du conducteur à l'évènement critique (temps de réaction à des obstacles apparus de manière imprévue) ou sur la qualité de la reprise en main du véhicule (nombre de collisions, accélérations et écart latéral par rapport au centre de la voie) ont été développées dans la littérature. Ces mesures de performances peuvent être interprétées comme des mesures objectives de la conscience de la situation (De Winter et al., 2014), obtenues a posteriori. Le phénomène de sortie de boucle étant défini de manière relative, les résultats sont présentés ici en comparant les performances de conduite de conducteurs plus dans la boucle que d'autres. Ainsi, la première sous-section (A.3.3.1) concernera la comparaison entre la conduite manuelle et la conduite sous régulateur de vitesse (niveau 1), la seconde (A.3.3.2) se focalisera sur les différences entre la conduite manuelle (ou avec régulateur de vitesse) et la conduite autonome (niveau 2). Une autre sous-section (A.3.3.3) comparera les temps de réaction en conduite autonome selon l'engagement (ou non) du conducteur dans une tâche secondaire (niveau 3). Enfin, la dernière sous-section (A.3.3.4) s'attachera au développement d'hypothèses sur les processus perceptivo-moteurs engagés lors des reprises en main.

A.3.3.1. Conduite Manuelle vs Régulateur de Vitesse

Dans cette première sous-section, les conducteurs utilisent le régulateur de vitesse adaptatif (SAE niveau 1) et sortent par conséquent partiellement de la boucle de contrôle. Comparés à la conduite manuelle (totalement dans la boucle, SAE niveau 0), les conducteurs sont plus longs (environ d'une à deux secondes) à réagir à des événements critiques. Ces résultats ont été prouvés à la fois sur circuit (Rudin-Brown & Parker, 2004) et sur simulateur de conduite (Kassner et al., 2011 ; Larsson et al., 2014 ; Lee et al., 2007 ; Young & Stanton, 2007), en considérant le temps d'appui sur la pédale de frein. De manière analogue, la conduite assistée par régulateur de vitesse adaptatif mène à un nombre plus important de collisions (Stanton et al., 1997) ou de presque collisions (Stanton et al., 2001), ainsi qu'à un temps de collision plus court (Hoedemaeker, 2000). Cependant, d'autres études concluent à des temps de réaction de conducteurs (Kondo et al., 1999) ou un nombre de collisions (Nilsson, 1995) similaires entre les deux conditions de conduite.

A.3.3.2. Conduite Manuelle (ou Régulateur de Vitesse) vs Conduite Autonome

Dans cette seconde section, on considérera un conducteur plus dans la boucle dès lors qu'il est en conduite manuelle ou utilisant un régulateur de vitesse adaptatif (SAE niveaux 0 ou 1), comparé à des conducteurs surveillant une automatisation du contrôle opérationnel

(SAE niveau 2 ou 3). Dès lors, le comportement observé pour des niveaux d'automatisation plus faibles (cf. section précédente) est également observé pour des niveaux d'automatisation plus élevés. Des temps de réponse (visuels ou d'appui sur la pédale de frein) plus élevés à des évènements critiques (Blommer et al., 2017 ; Bourrelly et al., 2019 ; Bueno et al., 2016 ; Damböck et al., 2013 ; Gold, Damböck, Lorenz, et al., 2013 ; Louw et al., 2015 ; Merat & Jamson, 2009 ; Neubauer et al., 2012 ; Radlmayr et al., 2014 ; Vogelpohl et al., 2019). De même, le nombre de collisions est réduit en conduite manuelle (Flemisch et al., 2008 ; Louw et al., 2015a ; Strand et al., 2014).

A.3.3.3. Conduite Autonome avec vs sans tâche secondaire

Dans les deux sections précédentes, l'état du conducteur dans la boucle était défini relativement au niveau d'automatisation : les conducteurs les plus dans la boucle sont ceux ayant le plus faible niveau d'automatisation. Dans cette section, les conducteurs sont en situation de conduite autonome de niveau 3, mais leur niveau dans la boucle dépend de leur engagement dans une tâche secondaire à la conduite : les conducteurs engagés dans une telle tâche sont plus sortis de boucle. Dans ces conditions, le temps de reprise en main du véhicule a été particulièrement analysé.

Plusieurs études ont synthétisé les travaux de la communauté scientifique dans ce domaine (Eriksson & Stanton, 2017 b ; Radlmayr & Bengler, 2015 ; Vogelpohl et al., 2016 ; Walch et al., 2017 ; Zhang et al., 2019). La plus récente (Zhang et al., 2019) a pris en compte les résultats de 129 études analysant les temps de reprise en main des conducteurs selon différents critères : nature des stimuli de reprise en main (auditif, visuel, haptique, multimodale, etc.), budget temporel plus ou moins long (de 2 à 15 s), complexité du trafic (pas de véhicule à trafic dense), âge des conducteurs (plutôt jeunes ou expérimentés), etc. Dans cette méta-analyse, l'impact de la présence (ou l'absence) d'une tâche secondaire et de ses modalités est discuté en fonction du temps de reprise en main (cf Figure A-6). Si seul le critère de tâche secondaire est pris en compte, l'analyse des travaux se restreint à 32 études.

Les résultats (Figure A-6) montrent qu'un conducteur effectuant une tâche secondaire reprend le contrôle du véhicule plus tard qu'un conducteur sans tâche secondaire. Les différences sont significatives dès lors que la tâche secondaire est en partie visuelle (tâche auditive-visuelle et visuomotrice). De plus, lorsque la tâche secondaire s'effectue avec les

A.3. PHENOMENE DE SORTIE DE BOUCLE

mains (sur smartphone, tablette par exemple), le temps de réponse est plus long de 1,33 s comparé à celui sans tâche secondaire. Aussi, lorsque le conducteur n'a pas d'informations sur la route (Yeux Fermés), il est plus long à reprendre le contrôle (pas d'effet significatif ici). Si les conclusions des études ne sont pas toutes univoques (points à abscisse négatifs sur la Figure A-6), on note globalement un retard dans le temps de reprise en main en conduite autonome avec tâche secondaire.




Figure A-6 : Impact d'une tâche secondaire (TS) et de sa nature (auditive-visuelle ; visuomotrice ; cognitive-auditive) sur le temps de reprise en main. La figure recense en abscisse les différences de temps de reprise en main (D) entre 2 conditions (explicitées à gauche). À droite sont indiquées pour chaque comparaison la moyenne (carré rouge) des différences de temps de reprise en main des différentes études (ronds noirs au nombre N), ainsi que la probabilité que la différence des temps de reprise en main a pour médiane 0 (test de Wilcoxon). La figure est adaptée de Zhang et al. (2019)

En plus du temps de reprise en main du véhicule, la qualité de reprise en main est détériorée par l'utilisation d'une tâche secondaire (Clark & Feng, 2017 ; Dogan et al., 2017 ; Eriksson & Stanton, 2017 b ; Gold et al., 2016 ; Gold, Damböck, Lorenz, et al., 2013 ; Ito et al., 2016 ; Merat et al., 2012 ; Wandtner et al., 2018 ; Zeeb et al., 2016). On retrouve cette détérioration significative à la fois sur l'écart au centre de la voie et l'accélération latérale et longitudinale (Zeeb et al., 2016), sur l'angle au volant (Eriksson & Stanton, 2017) que sur les temps de collisions (Gold, Damböck, Lorenz, et al., 2013).

A.3.3.4. Hypothèses expliquant les performances de conduite dégradées lors des transitions

Dans leur article de synthèse sur les coordinations visuomotrices impliquées lors des transitions, Mole et al. (2019) avancent deux pistes pour expliquer les performances de conduite dégradées lors de la reprise en main d'un véhicule lorsque le conducteur est hors de la boucle.

La première concerne la perte de calibration perceptivo-motrice en conduite autonome. En effet, conduire manuellement un véhicule implique de mettre en relation des variables perceptuelles (optiques ou haptique par exemple) et des commandes motrices pour réaliser des gestes adaptés à la dynamique du véhicule et de l'environnement. La mise à jour de ces calibrations se fait en continu sur la base des feed-back sensoriels. Lorsque le conducteur est en conduite autonome pendant un temps prolongé, une perte de calibration peut se faire. Lors d'une reprise en main, la recalibration ne sera pas nécessairement immédiate. Cela se traduira par un contrôle brusque du volant, menant à des écarts par rapport au centre de la voie plus élevée et à des accélérations latérales importantes. Cette phase de recalibration est particulièrement pertinente au regard des transitions sans demande de reprise en main, lorsque le conducteur supervise l'environnement de conduite (niveau 2 SAE). Pour illustrer le besoin de recalibration dans ce cas, les auteurs citent l'expérience de Navarro et al. (2016). Dans cette expérience, les conducteurs doivent éviter des obstacles avec (conduite manuelle) ou sans (conduite autonome supervisée) contrôle du volant. Alors que les obstacles sont détectés à des temporalités similaires, l'évitement de l'obstacle est de meilleure qualité en conduite manuelle qu'en conduite autonome. De fait, cette différence pourrait s'expliquer par un besoin de recalibration motrice en conduite autonome, les conducteurs ayant « perdu » la calibration initiale (lors du tour d'essai sur simulateur). Au contraire, les conducteurs en conduite manuelle restent calibrés tout au long de l'expérience, ce qui mène à un évitement de meilleure qualité.

Les auteurs proposent un mécanisme complémentaire qui repose sur la coordination visuomanuelle. En effet, comme nous le verrons en détail dans la partie B, la tâche de conduite nécessite des coordinations visuomotrices fortes pour parvenir à maintenir le véhicule sur la voie. En conduite manuelle, le regard guide l'action sur le volant. En

conduite autonome, le conducteur n'effectue plus d'action sur le volant, ce qui va affecter la façon dont il va regarder la scène de conduite. Au moment de la reprise en main, le découplage est toujours présent, ce qui implique un temps de recouplage entre le regard et les mains. Cette hypothèse peut expliquer les différences entre les temps de reprise en main observées chez des conducteurs avec ou sans tâche secondaire, la tâche secondaire pouvant renforcer le découplage déjà présent en conduite autonome. Cette hypothèse est également cohérente au regard des résultats portant sur le temps laissé au conducteur pour reprendre la main : si ce temps est suffisamment long, la reprise en main est meilleure. Ceci peut s'expliquer par le fait que le conducteur a eu le temps de resynchroniser ses processus sensorimoteurs.

A.3.4. Évolution du phénomène de sortie de boucle au cours du temps

L'objectif de cette partie est d'évaluer les conséquences de la sortie de boucle avec le temps d'automatisation. Dans la littérature, seules 5 études (Bourrelly et al., 2019 ; Feldhütter, Gold, et al., 2017 ; Josten et al., 2016 ; Naujoks et al., 2018 ; Othersen, 2016) ont traité cet aspect. Les résultats sont présentés dans la figure A-7.




Figure A-7 : Différences de temps de reprise en main selon la durée d'automatisation. Le carré représente la moyenne des différences pour l'ensemble des études (ronds noirs ; nombre N).

Figure adaptée de Zhang et al. (2019) et complétée par les résultats de Bourrelly et al. (2019).

Au niveau des temps de reprise en main, un temps plus élevé est trouvé lors de longues périodes de conduite autonome, même si la différence n'atteint pas le seuil de significativité ($D = -0,33$ s ; $p = 0,313$). Cette différence non significative peut résulter simplement des écarts entre les temps considérés pour la comparaison. En effet, les différences les plus grandes ont été observées lorsque la période d'automatisation était forte (40 min à 1 h), alors que des temps de reprise en main semblables sont trouvés pour de plus faibles durées

d'automatisation (20 min). Par conséquent, le temps de reprise en main du véhicule semble être fonction du temps d'automatisation : plus le conducteur passe de temps en conduite autonome, plus son temps de reprise en main sera élevé. Ceci peut également s'expliquer par l'induction progressive de la fatigue chez le conducteur en conduite autonome.

Même si le temps de reprise en main est moins impacté pour des durées d'automatisation plus courtes (20 min), Feldhütter, Gold, et al. (2017) ont montré qu'une augmentation du temps de réaction à un obstacle survenant à la 20^e minute, comparé au même obstacle survenant à la 5^e minute de conduite autonome. De même, Körber et al. (2015) ont montré une augmentation du niveau de vagabondage de la pensée (« mindwandering ») entre les premières et dernières 5 minutes d'une course automatisée de 40 min. Ce vagabondage est défini comme des « pensées dissociées de la tâche principale » (Smallwood et al., 2004), et donc, dans le cas de la conduite, des pensées dissociées de la tâche de conduite. Les conducteurs en état de vagabondage ont des performances de conduites dégradées (Baldwin et al., 2017 ; Qu et al., 2015) et sont responsables de plus d'accidents de la route (Galéra et al., 2012).

A.3.5. Induction expérimentale du phénomène de sortie de boucle

Cette section a pour but de présenter les différentes méthodes utilisées dans la littérature pour induire le phénomène de sortie de boucle chez les participants des différentes études. Pour rappel, la définition proposée par Merat et al. (2019) repose d'une part sur l'absence de contrôle physique du véhicule, et d'autre part sur l'absence de surveillance de la situation de conduite. Par conséquent, un conducteur hors de la boucle remplira ces deux conditions.

La première condition est automatiquement remplie dès lors que l'on considère de la conduite automatisée (SAE niveau 2+). En revanche, plusieurs manières de remplir la seconde condition sont présentées dans la littérature : utiliser une tâche secondaire, réduire les informations visuelles disponibles pour le participant ou jouer sur la durée d'automatisation.

Utiliser une tâche secondaire :

Dans la plupart des études de conduite autonome, le conducteur peut/doit effectuer des tâches secondaires (lecture, détection d'objets, e-mails, etc.). De ce fait, l'attention du conducteur sur la scène de conduite est détournée par la tâche secondaire, et il va donc moins surveiller l'environnement de conduite. Il va d'autant plus sortir de la boucle si la tâche secondaire nécessite de traiter des informations visuelles, ce qui est visible quantitativement sur les temps et la qualité des reprises en main (voir section A.3.3.3). Ainsi, le participant sort de la boucle du fait de la consigne qui lui est donnée par l'expérimentateur. En termes de processus d'attention visuels (qui sont développés dans la partie B), on peut faire l'hypothèse que dans ce cas, la sortie de boucle nécessite surtout des processus de type top-down : le participant va diriger volontairement son attention vers la tâche secondaire, altérant ainsi sa capacité à surveiller la tâche de conduite de manière à maintenir une conscience de la situation suffisante.

Toutefois, il convient de nuancer le propos, et de distinguer la sortie de boucle d'un simple épisode d'inattention. Si un conducteur peut momentanément partager son attention entre la tâche de conduite et une tâche secondaire (même en conduite manuelle), il n'en est pas forcément sorti de la boucle. La sortie de boucle est un phénomène directement lié à la délégation du contrôle à l'automate, le conducteur n'alimentant plus les boucles de contrôles tactique et opérationnelle. La tâche secondaire peut être considérée comme un catalyseur de la sortie de boucle en conduite autonome.

Réduire des informations visuelles disponibles

Cette méthodologie a été déployée par Tyron Louw (2016) et utilisée dans plusieurs études du même auteur depuis. Elle consiste à réduire les informations visuelles disponibles pour les participants, les empêchant ainsi de percevoir la scène de conduite. Pour ce faire, la méthode utilise des variations expérimentales jouant sur la visibilité (brouillard faible ou épais), de manière à induire momentanément les participants hors de la boucle. Avec cette méthode, la sortie de boucle repose principalement sur une altération des processus bottom-up : c'est un défaut de perception de l'environnement qui va mener à la sortie de boucle.

Augmenter la durée d'automatisation

Les résultats présentés en section A.3.4 suggèrent que même en l'absence de tâche secondaire ou de manipulations expérimentales, le conducteur sort de la boucle si la durée passée en conduite autonome est suffisante. Même si les résultats sur les temps de reprises en main varient pour de longues durées d'automatisation, des changements cognitifs (vagabondage de la pensée notamment) sont toutefois présents pour des durées d'expérimentation plus courtes, ce qui peut indiquer que le processus de sortie de boucle est déjà initié. En jouant sur la durée d'automatisation, on fait donc l'hypothèse que la sortie de boucle nécessite surtout des processus top-down, dans la mesure où le conducteur se désengage de lui-même de la tâche de conduite.

À noter toutefois qu'expérimentalement, les trois conditions peuvent se combiner.

A.3.6. Synthèse et transition

Le phénomène de sortie de boucle est un phénomène cognitif découlant de l'automatisation partielle ou totale de la tâche de conduite. En plus d'une neutralisation de la boucle de contrôle opérationnelle du véhicule, qui affecte les processus perceptivo-moteurs, l'automatisation peut induire un défaut de surveillance de la scène de conduite, altérant la conscience de la situation. Les conséquences de cette sortie de boucle peuvent être étudiées relativement au comportement des conducteurs lors d'une situation critique. Un conducteur hors de la boucle aura ainsi tendance à prendre plus de temps à reprendre le contrôle du véhicule, et une fois récupéré, à maintenir son véhicule en sécurité de façon appropriée. La sortie de boucle affecte ainsi clairement à la fois le temps et la qualité de la reprise en main. De plus, la sortie de boucle semble être un phénomène qui s'amplifie avec la durée d'automatisation, et qui se met en place même pour des durées d'automatisation relativement faibles (environ 20 minutes).

A.4. Synthèse de la première partie

Cette première partie de l'état de l'art est dédiée à la description de l'activité de conduite et à ses modifications induites par la délégation de la tâche de conduite à un automate. L'automatisation progressive de la tâche de conduite amène les conducteurs de plus en plus hors de la boucle, dans la mesure où ils ne contrôlent plus le véhicule ni ne surveillent la scène de conduite. Ce phénomène de sortie de boucle impacte la sécurité des conducteurs lors d'évènements critiques pouvant survenir sur la route, lorsque les limites du système autonome sont atteintes. Ces conséquences sur leur sécurité sont d'autant plus importantes que la durée d'automatisation est forte.

Par conséquent, afin de garantir la sécurité des conducteurs en conduite autonome, des systèmes permettant de « remettre » le conducteur dans la boucle (système d'autorisation à doubler, module d'interaction homme-machine reproduisant la scène de conduite lors d'une tâche secondaire, etc.) peuvent être envisagés. Pour autant, de tels systèmes dans lesquels le conducteur doit être actif (autorisation à doubler) ou même passif (IHM) tendent à réduire l'intérêt d'une conduite automatisée pour le conducteur. Une autre façon de garantir la sécurité des conducteurs serait d'adapter l'automatisation des véhicules à l'état du conducteur dans la boucle de conduite. Par exemple, en augmentant les distances de sécurité du véhicule autonome lorsque le conducteur est hors de la boucle. Cependant, il faut pour ce faire parvenir à définir un état du conducteur dans la boucle de conduite.

Étant donné la définition de la sortie de boucle, la supervision de la scène de conduite par le conducteur revêt une importance particulière. De ce fait, pour définir l'état du conducteur dans la boucle, il est nécessaire d'analyser la façon dont celui-ci traite la scène visuelle, ce qui peut être réalisé en analysant directement ses stratégies visuelles.

Partie B: État de l'art – Stratégies visuelles

La partie précédente a permis de définir l'activité de conduite selon trois niveaux de conduites : le niveau opérationnel, tactique et stratégique. Les informations sont traitées et échangées entre les niveaux à partir d'entrées environnementales, dont la nature va maintenant être développée. Si ces entrées sensorielles sont basées sur l'ensemble des sens humains, la tâche de conduite est essentiellement visuelle (Michaels, 1963 ; Sivak, 1996).

La seconde partie de cet état de l'art se concentre donc sur les stratégies visuelles déployées par les conducteurs. Dans un premier temps (section B.1), le cadre général permettant l'étude des stratégies visuelles dans des situations naturelles différentes de la conduite sera présenté. Dans un second temps (section B.2), nous montrerons comment les stratégies visuelles des conducteurs en conduite manuelle s'inscrivent dans ce cadre. Ensuite (section B.3), la modification des stratégies visuelles induite par la conduite autonome sera développée. Enfin, le lien entre les stratégies visuelles et la sortie de boucle sera évoqué dans la section B.4).

B.1. Cas général

B.1.1. Attention visuelle et mouvements oculaires

Si les informations visuelles sont disponibles sur un champ de vision d'environ 180°, l'homme n'est attentif qu'à une partie de son environnement. L'attention est le processus cognitif qui lui permet de sélectionner des informations visuelles (Desimone & Duncan, 1995). Cette sélection ne se fait pas au hasard, mais dépend essentiellement de la tâche exécutée et/ou des caractéristiques physiques de l'environnement. Ainsi, différents processus de l'attention ont été développés dans la littérature.

D'une part, les processus bottom-up dépendent directement de l'environnement visuel, et s'appuient uniquement sur les propriétés physiques de l'environnement. Ces propriétés physiques (la couleur, l'intensité et l'orientation selon Itti & Koch ; 2001) sont combinées pour créer une carte de saillance de la scène visuelle. L'attention visuelle est ensuite affectée

de manière dynamique dans l'ordre décroissant de saillance (c'est-à-dire des éléments les plus saillants à ceux les moins saillants).

D'autre part, l'attention implique des processus top-down renvoyant directement à la fonction et à la position des objets dans une scène. De ce fait, les processus top-down sont lié aux buts de l'utilisateur et aux bénéfices qu'il y a à les traiter. Ainsi, ils dépendent de la tâche effectuée par l'utilisateur, mais aussi des connaissances a priori sur les objets présents. Ces processus sont prioritaires lors de tâches dynamiques (Land & Hayhoe, 2001), comme la conduite.

Dans le cadre de ce travail de doctorat, on s'intéressera uniquement à une orientation explicite de l'attention, c'est-à-dire que l'on considérera que l'attention s'exprime par des mouvements oculaires (Posner, 1980). Ces mouvements oculaires seront ici restreints aux saccades et aux fixations.

B.1.2. Stratégies visuelles dépendantes de la tâche

Yarbus (1967) est le premier à avoir mis en évidence les liens entre la tâche demandée à l'utilisateur et ses stratégies visuelles. En effet, en demandant à un sujet de regarder une scène visuelle, les patterns de fixations diffèrent selon la question posée (déterminer la richesse des personnes présentes sur la scène, déterminer l'âge des participants, exploration libre, etc.). Les conclusions de Yarbus ont été corroborées par plusieurs études récentes (par exemple DeAngelus & Pelz ; 2009), même si prédire directement la tâche à partir des stratégies visuelles des participants n'a pas donné satisfaction dans l'étude de Greene et al. (2012).

Avec l'émergence d'oculomètres portables, la position du regard a également pu être étudiée dans des environnements dynamiques. Dans ces environnements, la position et la dynamique du regard dépendent également fortement de la tâche qu'effectue le participant (Hayhoe & Ballard, 2005 ; Rothkopf et al., 2007). En effet, les fixations s'effectuent quasi exclusivement sur les objets pertinents au regard de la tâche. Ceci a été mis évidence pour des participants effectuant des tâches écologiques, comme faire un sandwich (Hayhoe et al., 2003 ; cf Figure B-1), servir un thé (Land et al., 1999), jouer au piano (Land & Furneaux, 1997), se laver les mains (Pelz & Canosa, 2001) ou bien marcher (Patla & Vickers, 1997).

Des conclusions similaires sont trouvées pour des expériences en réalité virtuelle, dans lesquelles les sujets doivent manipuler des blocs (Droll et al., 2005 ; Jovancevic et al., 2006).




Figure B-1 : Prises d'informations visuelles d'un participant faisant un sandwich dans Hayhoe et al. (2003). Les fixations (indiquées en cercles orange) se concentrent sur les objets pertinents pour la tâche.

Plusieurs stratégies sont présentées dans la littérature pour analyser la dynamique des prises d'informations visuelles. Selon la théorie de Ballard et al. (1995), les participants passent la plupart du temps à regarder les objets uniquement au moment où ils en ont besoin («*just-in-time strategy*»). En plus de cette stratégie, les participants ont également recours à l'anticipation visuelle. Des preuves expérimentales d'anticipation visuelle des participants ont également été trouvées dans Pelz & Canosa (2001) : lorsqu'ils se lavent les mains, les participants regardent le distributeur de savon quelques secondes avant de l'utiliser. Des preuves similaires ont été trouvées dans d'autres études (Hayhoe et al., 2003 ; Land et al., 1999), les participants effectuant des fixations sur les objets à attraper largement avant d'effectuer la manipulation.

Dans l'étude de Mennie et al. (2007), une dénomination est proposée pour ces fixations d'anticipation : les fixations *look-ahead*¹. Dans ces travaux, le participant doit assembler des pièces dans un ordre séquentiel : les participants regardent la pièce suivante environ 3 s avant de la prendre en main. Pour autant, le temps entre la fixation *just-in-time* et la prise en main effective de l'objet ne dépend pas de l'émission (ou non) d'une fixation *look-ahead*. De ce fait, les fixations *look-ahead* n'améliorent pas les coordinations visuomotrices dans le cas d'une tâche d'assemblage de pièces.

¹ A défaut de traduction appropriée, le terme anglais de « look-ahead fixations » (traduit par fixations *look-ahead*) sera conservé dans l'ensemble du manuscrit.

B.2. Vision en conduite manuelle

La tâche de conduite étant une tâche essentiellement visuelle (Sivak, 1996), la vision des conducteurs a été particulièrement analysée. L'objectif de cette partie est de synthétiser les résultats présentés dans la littérature, en considérant la conduite comme un cas particulier du cas général pour des scènes dynamiques.

D'après la partie précédente, la tâche de conduite est organisée de manière hiérarchique suivant trois niveaux, dont les niveaux opérationnel et tactique sont alimentés par des informations provenant de l'environnement. Pour rappel, le niveau opérationnel met en œuvre les actions motrices décidées au niveau tactique. Dans un premier cas, on s'intéressera au cas de la conduite sans tâche annexe, puis on s'intéressera aux cas spécifiques de suivi d'un autre véhicule et de l'approche d'une intersection.

B.2.1. Conduite sans tâche annexe

En l'absence de sous-tâche spécifique (suivi d'un autre véhicule, discuter avec un passager, etc.), la tâche de conduite se résume à aller d'un point A à un point B en maintenant son véhicule sur la route. Dans ce cas, les conducteurs doivent assurer le contrôle de la trajectoire du véhicule. D'après les travaux de Donges (1978) et McRuer et al. (1977), ce contrôle de trajectoire est assuré à deux niveaux (pour une revue récente sur le contrôle de trajectoire, voir Lappi & Mole ; 2018).

Le premier niveau est chargé de compenser les erreurs de positionnement du véhicule sur la voie (« compensatory control »). Ainsi, à ce niveau, le conducteur agit sur le volant pour recentrer son véhicule sur la voie : les informations visuelles servent de feed-back pour l'information motrice. Les informations visuelles traitées au premier niveau utilisent des informations visuelles proches du véhicule. Elles n'impliquent pas nécessairement des fixations vers l'information pertinente, mais elle peut s'appuyer sur la vision périphérique, notamment celle des bords de voie (Land & Horwood, 1995 ; Mole et al., 2016 ; Summala et al., 1996).

Au 2^e niveau, les conducteurs anticipent les changements de courbure de la route à venir (« anticipatory control »). Dans ce cas, ils déploient des stratégies visuelles permettant de

guider les futures actions motrices, notamment les actions sur le volant. Land & Lee (1994) apportent la preuve de la nécessité d'une coordination visuomotrice en comparant, dans le temps, les angles au volant et les angles visuels des conducteurs (cf Figure B-2). Dans cette étude, les conducteurs anticipent les changements de courbure (dus aux virages) par leur dynamique oculomotrice, puis agissent sur le volant (modifiant ainsi l'angle au volant) avec un décalage d'environ 0,75 s.




Figure B-2 : Coordination visuomotrice en conduite manuelle dans l'expérience de Land & Lee (1994).

L'angle visuel précède l'action sur le volant d'environ 0,75 s.

Cette étude de Land & Lee (1994) constitue la base de l'étude du contrôle visuel de trajectoire. Les auteurs suggèrent que lors d'un virage, les conducteurs regardent principalement le point tangent, qui est un point particulier situé sur le bord de la voie. L'angle entre la direction de ce point et la direction du véhicule dépend à chaque instant de la géométrie du virage à venir. Au contraire, d'autres études suggèrent que le conducteur regarde plutôt un point de sa trajectoire prévue dans 1 à 2 s (Lappi et al., 2017 ; Wann & Swapp, 2000 ; Wilkie et al., 2010). Salvucci & Gray (2004) proposent un modèle combinant des regards du conducteur sur un point proche (généralement le centre de la voie pour gérer l'aspect compensatoire du contrôle de trajectoire) et d'un point plus lointain sur la trajectoire future (anticipation du contrôle de trajectoire). Toutefois, ils précisent que le point lointain peut s'ajuster selon la situation de conduite (point tangent, autre véhicule dans le cas d'un suivi de véhicule, etc.). Enfin, Mars & Navarro (2012) ont proposé que le conducteur regarde des points sur la voie circulation, souvent à proximité du point tangent, qu'il ne veut pas franchir, définissant ainsi une enveloppe de trajectoires acceptables. Les différentes localisations proposées sont présentées sur la Figure B-3.




Figure B-3 : Localisation des points d'anticipation regardés lors du contrôle de trajectoire

Si la localisation précise des regards diffère selon les auteurs, tous s'accordent à dire que les fixations à ces endroits permettent le guidage du véhicule en assurant la coordination visuomotrice. De ce fait, ces fixations sont nommées fixations de guidage (ou « guiding fixations »), et alimentent les coordinations visuomotrices au niveau opérationnel de la conduite. Ces fixations de guidage sont centrales vis-à-vis du conducteur, et constituent la majeure partie des prises d'informations visuelles en conduite manuelle. Ceci a été prouvé à par exemple en considérant des indicateurs de distractions, comme le « *percentage road centre* » (PRC) proposé par Victor (2005). Dans cette étude, une zone d'intérêt circulaire (rayon de 8° d'angle visuel) et centrée sur l'angle visuel le plus souvent adopté par le conducteur définit le centre de la route. Cette zone capture l'ensemble des fixations de guidage. Les auteurs ont ensuite calculé le pourcentage de fixations dans cette zone (PRC). Sur route ouverte et en conduite manuelle, Victor et al. (2005) ont montré que les conducteurs passaient entre 70 à 80 % du temps dans cette zone (voir également Carsten et al. ; 2012). Sur simulateur de conduite, Rydström (2007) obtient jusqu'à 90 % des regards dans cette zone.

En plus de ces fixations de guidage, des études ont prouvé que les conducteurs anticipaient également à plus long terme. En utilisant les angles visuels du conducteur, Mars & Navarro (2012) montrent ainsi que les conducteurs dirigent des regards au-delà de la route immédiate, réemployant pour la première fois le terme de fixations *look-ahead*. De tels

comportements visuels ont également été trouvés sur route ouverte (Kandil et al., 2010 ; Lappi, 2014, 2016 ; Lehtonen et al., 2013, 2014). Par exemple, Kandil et al. (2010) ont montré que plus d'un tiers des regards étaient dirigés au-delà de la sortie du virage.

Pour autant, la définition des fixations *look-ahead* diffère selon les études. Mars & Navarro (2012) proposent que ces fixations servent essentiellement à anticiper des éléments de contexte, comme des objets ou dangers en amont (alimentant donc principalement le niveau tactique). Lehtonen et al. (2013) considèrent au contraire les fixations *look-ahead* comme servant à un contrôle étendu de trajectoire (alimentant donc principalement le niveau opérationnel). Cette thèse a été reprise par Lappi & Mole (2018) dans leur papier de synthèse sur les coordinations visuomotrices en situation de conduite. Les auteurs considèrent qu'effectuer ces fixations *look-ahead*, par alternance avec des fixations de guidage, étend l'horizon du contrôle de trajectoire jusqu'au point d'atterrissage de la fixation *look-ahead*. Dans ce cas, l'émission de fixations *look-ahead* permet de mettre à jour le modèle interne de la route à venir et de planifier le mouvement à venir. Cette distinction faite concernant le rôle des fixations *look-ahead* sera discutée dans la première expérimentation (partie D).

L'information visuelle alimentant le niveau tactique est de plus haut niveau, car elle permet la prise de décision avant exécution par les conducteurs (Kaber et al., 2012 ; Lemonnier et al., 2020 ; Smiley et al., 2004 ; Underwood, Crundall, et al., 2002 ; Wong & Huang, 2013). Elle permet au conducteur de construire sa conscience de la situation de conduite et sa projection dans les instants futurs (niveau le plus élaboré de la conscience de la situation). Pour ce faire, le conducteur oriente ses regards sur différents objets d'intérêts (rétroviseurs centraux et périphériques, autres véhicules sur la route, panneaux de signalisation, feux tricolores, type de marquage au sol, piétons), dans le but de prendre sa décision. Par exemple, dans l'expérimentation de Smiley et al. (2004), l'analyse de l'attention visuelle lors d'intersections montre que, si les conducteurs passent le plus de temps à regarder la route (76 %), ils prennent également des informations sur les piétons (7 % du temps), les panneaux (7 % du temps), les rétroviseurs (3 % du temps). De même, décider de s'arrêter à une intersection va nécessiter d'avoir pris connaissance, via des informations visuelles, du trafic à venir, des panneaux de signalisation, etc. (Lemonnier et al., 2020).

En résumé, en l'absence de tâche annexe, le niveau opérationnel est alimenté par des prises d'informations proches du conducteur et lié principalement à sa vision périphérique afin de compenser, de manière continue, les écarts de position latérale du véhicule. De plus, il alterne entre des fixations de guidage (en majorité) et des fixations *look-ahead* pour anticiper sur la route à venir. Si la nature opérationnelle des fixations de guidage fait consensus, les fixations *look-ahead* pourraient alimenter à la fois les niveaux opérationnels et tactiques. Au niveau tactique, le conducteur cherche des informations visuelles lui permettant d'accéder à une conscience de la situation de conduite.

B.2.2. Conduite avec tâche annexe : suivi d'un véhicule

Les stratégies visuelles, bien que stéréotypées (Lappi, 2014), s'ajustent à la tâche du conducteur. Ces tâches annexes sont définies au niveau stratégique, et appliquées à la prise d'informations visuelles au niveau tactique.

Dans le cas d'un suivi de véhicule, Crundall et al. (2004) ont comparé les stratégies visuelles de conducteurs sans consigne spécifiques (groupe contrôle) à des conducteurs devant suivre un autre véhicule. Les conclusions révèlent que lors d'une situation de suivi d'un autre véhicule, les conducteurs allouent différemment leur attention visuelle. D'une part, les fixations sur le véhicule de tête sont plus longues, doublant le temps total passé à regarder ce véhicule. D'autre part, les conducteurs réduisent l'exploration horizontale de la scène de conduite dans le cas d'un suivi de véhicule, et ce peu importe le nombre de dangers potentiels présents en périphérie (manipulé dans cette expérience par le nombre de piétons).

Dans un étude de Shinoda et al. (2001), les participants devaient également suivre un véhicule, mais les consignes les autorisaient (ou non) à respecter le code de la route lors d'intersections. Lorsqu'ils faisaient fi du code de la route, les participants regardaient le véhicule 75 % du temps à l'approche d'intersections. En revanche, lorsque les participants devaient faire attention aux panneaux et feux, ils ne regardaient le véhicule de tête que 45 % du temps.

B.2.3. Conduite avec tâche secondaire

Dans le cas où la tâche demandée est totalement dissociée de la conduite, le conducteur entre alors dans un état de distraction. Selon la modalité de la tâche, la distraction peut être visuelle (tâche secondaire sur une tablette par exemple), auditive (réagir à de certains mots prononcés par l'expérimentateur) ou cognitive (tâche de calcul mental). Généralement, les modalités sont multiples.

Dans ce cas, les conducteurs distraits adaptent leurs stratégies visuelles en fonction de la modalité de la tâche secondaire, comme l'ont montrés Victor et al. (2005). Dans cette étude, les conducteurs expérimentaient deux modalités de tâche secondaire (visuelle et auditive), dont le niveau de difficulté variait selon 3 niveaux. La tâche visuelle consistait en une recherche d'une flèche ascendante parmi un panel de 16 flèches au premier niveau. Le nombre et les différences d'orientation des flèches variaient en fonction de la difficulté de la tâche, avec au dernier niveau 36 flèches différentes. La tâche auditive consistait à retenir le nombre de fois qu'un ensemble de mots appris par les participants a été évoqué dans un texte de 30 s. La difficulté augmente avec le nombre de mots appris (2 au premier niveau, 4 au dernier niveau). Les résultats montrent que les stratégies visuelles des conducteurs dépendent du type de tâche secondaire : une tâche visuelle distrait le conducteur de la route, de manière proportionnelle à la difficulté de la tâche. Pour autant, l'effet est important même pour une tâche visuelle simple (premier niveau). Au contraire, dans le cas d'une tâche auditive, l'attention du conducteur se concentre plus sur le centre de la route. Cependant, l'impact de la difficulté de la tâche auditive n'est pas significatif.

Ces résultats ont été analysés par rapport au pourcentage de temps passé sur la route (PRC). Dans d'autres études (Hammel et al., 2002 ; Harbluk et al., 2002 ; Kaber et al., 2012 ; Nunes & Recarte, 2002 ; Recarte & Nunes, 2000 ; Victor, 2005), des résultats similaires sont trouvés en utilisant le nombre de regards sur la route ou bien des indicateurs angulaires.

Les modifications des stratégies visuelles sont également modifiées lorsque la distraction est interne au conducteur, c'est-à-dire dans les cas de vagabondage de la pensée. En effet, lorsque les conducteurs expérimentent l'expérimentent (c'est-à-dire lorsqu'ils pensent à autre chose que la conduite), l'exploration visuelle diminue, leur attention se focalisant surtout sur la route. (Lemercier et al., 2014 ; Qu et al., 2015).

B.2.4. Contrôle des stratégies visuelles par l'apprentissage

Dans une méta-analyse récente, Robbins & Chapman (2019) dressent un bilan de l'effet de l'expérience de conduite sur les stratégies visuelles sur 9 études (Alberti et al., 2014; Borowsky & Oron-Gilad, 2013; Crundall et al., 2003; Crundall & Underwood, 1998; Hills et al., 2018; Jiang et al., 2012; Kahana-Levy et al., 2019; Konstantopoulos et al., 2010; Underwood, Chapman, et al., 2002). Pour cela, les stratégies visuelles ont été analysées selon la recherche visuelle horizontale et verticale (dispersion angulaire du regard) et la durée et fréquence des fixations selon l'expérience des participants. Aucune différence globale n'a pu être tirée selon la durée et la fréquence des fixations. Pourtant, en s'intéressant directement à des aires d'intérêts, Underwood et al. (2002) ont montré que les conducteurs expérimentés favorisaient les contrôles visuels sur les rétroviseurs.

Un effet significatif a cependant été trouvé pour la dispersion visuelle horizontale (cf. Figure B-4), montrant que les conducteurs expérimentés analysent l'environnement de conduite de manière plus large que les conducteurs novices. Même si certaines études montrent que les conducteurs novices regardent la route plus proche du véhicule que les conducteurs expérimentés (notamment Mourant & Rockwell ; 1972), la dispersion verticale du regard ne ressort pas significativement différente si on considère l'ensemble de la littérature.

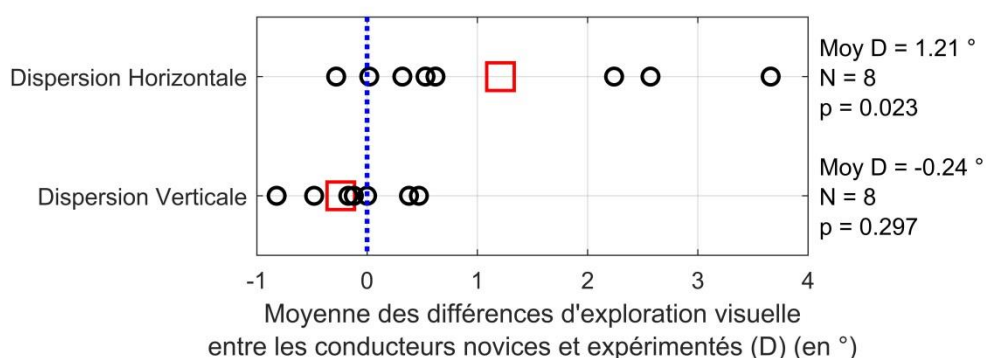


Figure B-4 : Différence d'exploration visuelle en fonction de l'expérience des conducteurs. Les conducteurs expérimentés ont une dispersion horizontale plus forte ($p < 0.05$) que les conducteurs novices. Données issues de Robbins & Chapman (2019).

B.3. Impact de l'automatisation sur les stratégies visuelles des conducteurs.

Dans cette section, on s'intéressera à l'impact de l'automatisation progressive des véhicules sur le comportement visuel des conducteurs. Il s'agit pour cela de comparer les stratégies visuelles de conducteurs selon le niveau d'automatisation des véhicules. La plupart des études ont étudié les stratégies visuelles en considérant que la délégation de la conduite induira de la distraction visuelle. De ce fait, des indicateurs de distraction visuelle (comme le PRC déjà évoqué) ont été utilisés. Aussi, les stratégies visuelles peuvent être étudiées par rapport à l'exploration de la scène de conduite, en étudiant la distribution angulaire des regards. Une manière algorithmique de quantifier cette exploration consiste à considérer directement l'écart type des angles visuels recueillis lors d'expérimentations : c'est la dispersion du regard.

Au niveau 1 (SAE), le conducteur est en charge du contrôle longitudinal ou latéral (conduite semi-autonome). L'étude de Carsten et al. (2012) a permis d'étudier l'impact de la délégation du contrôle latéral, du contrôle longitudinal ou des deux sur les stratégies visuelles des conducteurs. Dans cette étude, les participants parcouraient d'abord le parcours sur simulateur en conduite manuelle, puis en conduite semi-autonome, et enfin en conduite autonome. Les participants pouvaient s'engager dans des tâches secondaires. En utilisant le pourcentage de temps à regarder au centre de la route (PRC), les auteurs ont montré une baisse globale du PRC au niveau 1 comparé à la conduite manuelle (72 %). Pour autant, les stratégies visuelles des conducteurs diffèrent selon la partie du contrôle déléguée à l'automate : lorsque les participants gèrent le contrôle du volant uniquement, leurs stratégies visuelles sont semblables à celles obtenues en conduite manuelle (PRC = 70 %). Au contraire, lorsque les participants gèrent la vitesse du véhicule, le PRC n'atteint que 60 %, de manière similaire à la condition totalement autonome. En effet, en conduite autonome et en l'absence de tâche secondaire, les conducteurs dirigent moins leur attention vers le centre de la route (57 % seulement), mais plutôt vers les aires latérales (gauche et droite du centre de la route).

Des résultats similaires sont trouvés à partir de mesures angulaires du regard dans l'expérience de Mars & Navarro (2012). Dans cette expérimentation, les auteurs analysent

la distribution des angles relative au point tangent lors d'un parcours en virages, en conduite manuelle et autonome (cf Figure B-5).

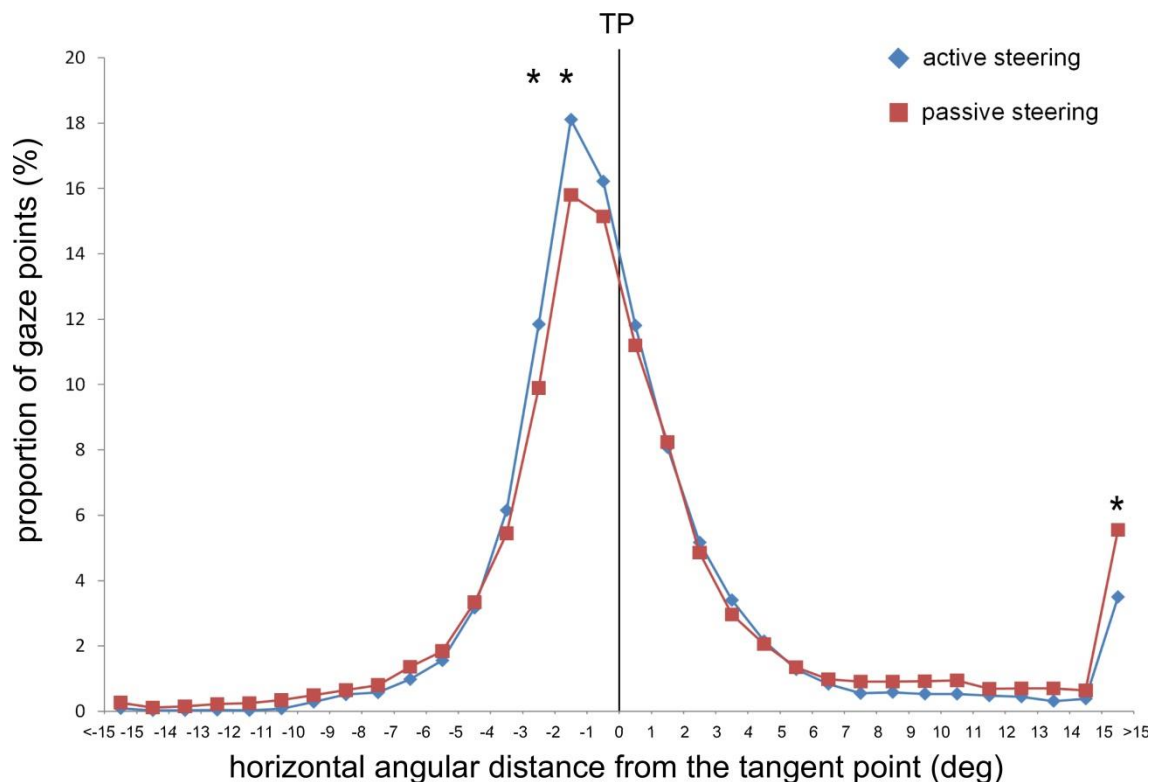


Figure B-5 : Distribution du regard par rapport au point tangent dans l'étude de Mars & Navarro (2012)

En conduite autonome, les conducteurs étaient explicitement avertis de leur nécessité de surveiller la route (SAE niveau 2). Les résultats montrent que, lors de la négociation d'un virage, les prises d'informations visuelles sont davantage dédiées à l'anticipation lointaine ($>15^\circ$, fixations *look-ahead*) en conduite autonome, les fixations de guidage diminuant en contrepartie.

Ce transfert d'information des zones visuelles centrales vers la périphérie en conduite autonome se retrouve dans d'autres études, traitant les données oculaires relatives à la route (PRC, nombre de regards sur la route ou temps à regarder hors de la route dans les études de Barnard & Lai, 2010 ; Jamson et al., 2013 ; Llaneras et al., 2013) ou via des indicateurs angulaires (distribution ou dispersion du regard dans les études de Damböck et al., 2013 ; Louw & Merat, 2017 ; Mackenzie & Harris, 2015). Plus particulièrement, concernant la dispersion angulaire, les auteurs notent une dispersion horizontale plus importante en

B.4. LIEN ENTRE LES STRATEGIES VISUELLES ET LA SORTIE DE BOUCLE

conduite autonome comparée à la conduite manuelle. En revanche, l'effet n'est pas significatif sur la dimension verticale de la scène.

Lorsque le conducteur est engagé dans une tâche secondaire en conduite autonome, par exemple regarder un DVD dans l'étude de Carsten et al. (2012), son attention visuelle est encore plus détournée de la scène de conduite. Carsten et al. (2012) reportent ainsi un PRC de 49 % en conduite autonome avec tâche secondaire, contre 57 % sinon. Dans l'expérimentation de Nakajima & Tanaka (2017), les auteurs évaluent la proportion de regards dirigés vers la route en conduite autonome. En l'absence de tâche secondaire, 51 % des regards sont dirigés vers la route, contre seulement 29 % en moyenne lorsqu'une tâche secondaire est effectuée par les participants. Ce ratio est d'autant plus faible que la tâche secondaire nécessite des informations visuelles : dans le cas de l'utilisation d'un smartphone, seuls 14 % des regards se dirigent vers la route.

En revanche, les conséquences de ce transfert d'informations ne sont pas décrites de manière univoque dans la littérature. En effet, l'expérience de Navarro et al. (2016) a montré que le manque de fixations de guidage altère les coordinations visuomotrices, ce qui contribue à une qualité d'évitement d'obstacle plus faible en conduite autonome. Cet aspect est en contradiction avec les résultats de McKenzie et Harris (2016), qui montrent qu'en conduite autonome, les conducteurs sont plus aptes à distinguer des dangers potentiels du fait d'une plus grande exploration visuelle.

B.4. Lien entre les stratégies visuelles et la sortie de boucle

Du fait de la définition de la sortie de boucle, qui se base sur la supervision de la scène visuelle en conduite autonome, l'analyse des stratégies visuelles apparaît particulièrement intéressante pour étudier et quantifier le phénomène. De fait, quelques études font le lien entre les stratégies visuelles des conducteurs et la sortie de boucle.

Induction de la sortie de boucle par la tâche secondaire

Lorsqu'une tâche secondaire est demandée au conducteur (en encore plus lorsque la modalité de la tâche est visuelle), ses stratégies visuelles vont s'adapter de manière à porter l'attention du conducteur sur autre chose que sur la route. De fait, la sortie de boucle est donc directement liée à la proportion de temps passé sur la tâche secondaire. Par

conséquent, détecter la sortie de boucle et la quantifier peut être fait à partir d'algorithmes de détection de la distraction visuelle, prenant en compte le temps maximum passé à regarder hors de la route, etc. (voir par exemple Ahlstrom et al., 2013)

Dans l'étude de Zeeb et al. (2015), les conducteurs devaient effectuer une tâche secondaire sur une console centrale, puis réagir à un obstacle présent sur la route. Dans l'analyse des résultats, 3 groupes ont été constitués à partir d'indicateurs de la distraction visuelle (temps maximum passé à regarder hors de la route, pourcentage de temps passé à regarder la console centrale). De fait, les groupes ont été catégorisés selon les risques de collisions : élevé, moyen ou faible, le groupe « élevé » ayant les pires valeurs pour les indicateurs de distraction. Les résultats au cas critique montrent que le groupe élevé a de plus longs temps de réaction aux obstacles, ce qui est l'une des conséquences de la sortie de boucle.

Induction de la sortie de boucle en augmentant la durée d'automatisation

Lorsque la durée d'automatisation augmente, les conducteurs deviennent de plus en plus hors de la boucle. Dans une étude, Feldhütter et al. (2017) montrent que les stratégies visuelles des conducteurs changent avec le temps passé en conduite autonome. En effet, les conducteurs passent de moins en moins de temps à regarder la route lors de l'expérimentation. De plus, la durée maximum passée à ne pas regarder la route est également plus élevée à la fin qu'au début du parcours. De même, l'étude de Greenlee et al. (2018) montre que, lorsqu'une tâche de détection des dangers est demandée aux conducteurs, le taux de bonnes détections diminue au cours du temps d'automatisation. Au regard de ces études, on peut faire l'hypothèse qu'une analyse longitudinale des stratégies visuelles permettrait de discerner la sortie de boucle.

Pour autant, le lien entre les stratégies visuelles et la sortie de boucle reste à faire, par exemple en considérant les conséquences de la sortie de boucle. Dans l'étude de Feldhütter et al. (2017), les conséquences de la sortie de boucle ont été évaluées au travers d'évènements de conduite, montrant que le temps de réaction aux évènements était plus court après 5 min de conduite autonome qu'après 20 min de conduite autonome. Les conséquences peuvent être également abordées du point de vue du vagabondage de la pensée. Körber et al. (2015) ont en effet montré que le niveau de vagabondage de la pensée des conducteurs était plus fort à la fin de l'expérimentation, traduisant un désengagement cognitif de la conduite.

B.5. Synthèse et transition

Cette partie a présenté l'état de la littérature sur les stratégies visuelles. Après une introduction sur le cas général, les stratégies visuelles des conducteurs en contrôle manuel ont été présentées. Dès lors, différentes prises d'informations visuelles ont pu être discutées selon leur utilisation au niveau opérationnel ou au niveau tactique.

Au niveau opérationnel, chargé d'exécuter les manœuvres décidées au niveau tactique, les stratégies visuelles employées dépendent d'entrées visuelles relativement proches du véhicule (jusqu'à environ 2 secondes en amont). Ces stratégies visuelles ont pour but d'anticiper la route à venir (fixations de guidage). Cette anticipation à court terme s'effectue en parallèle de la correction des erreurs de positionnement latéral du véhicule.

Les conducteurs utilisent également des fixations *look-ahead*, dont le rôle aux niveaux opérationnel ou tactique est encore discuté : ces fixations pourraient servir à mettre à jour le modèle interne de la route pour la planification de trajectoire sur une distance étendue, alimentant ainsi le niveau opérationnel. Au contraire, elles pourraient servir à la recherche d'informations tactiques.

Ces prises d'informations tactiques permettent au conducteur de construire et de mettre à jour un modèle mental de la situation de conduite, ce qui lui confère une conscience de la situation. Pour ce faire, le regard est porté plus largement sur l'environnement de conduite, en prenant en compte les déplacements des autres usagers notamment.

Lorsque la conduite du volant est déléguée à l'automate, une adaptation visuomotrice a lieu, les conducteurs se désengageant des prises d'informations centrales au profit d'informations périphériques. Les conséquences de ce transfert d'informations ne sont pas univoques, dans la mesure où à la fois il mènerait à une détection accrue des dangers potentiels, mais en même temps perturberait la reprise du contrôle du conducteur lorsqu'un obstacle apparaît soudainement.

Enfin, le dernier point concerne les liens entre les stratégies visuelles et la sortie de boucle. Si la sortie de boucle est causée par le temps passé en conduite autonome, les stratégies visuelles peuvent être analysées en fonction du temps.

Partie C: Axes de travail du doctorat

L'état de l'art (parties A et B) nous a d'abord amenés à considérer trois boucles de contrôles, de nature et de temporalités différentes, permettant d'effectuer la tâche de conduite : la boucle stratégique (définition de l'itinéraire), la boucle tactique (contrôle des manœuvres du véhicule) et opérationnelle (exécution des manœuvres du véhicule). Les deux boucles utilisées en temps réel lors de la conduite effective (opérationnelle et tactique) sont alimentées par différentes entrées sensorielles, notamment par les entrées visuelles.

Au niveau opérationnel, ces entrées visuelles servent principalement à la mise en place et au maintien des coordinations visuomotrices, permettant de guider le véhicule sur sa voie. Au niveau tactique, il s'agit pour le conducteur d'acquérir une conscience de la situation de conduite, c'est-à-dire de son véhicule mais aussi de l'ensemble des autres usagers. Ces informations tactiques lui permettent par exemple d'identifier des dangers potentiels pouvant subvenir (obstacle sur la voie, piétons pouvant traverser par exemple).

L'automatisation d'un véhicule vient directement impacter ces boucles de contrôles, en conférant le contrôle opérationnel et/ou tactique à l'automate. De ce fait, le conducteur ne va plus suffisamment alimenter ces boucles de contrôle d'entrées visuelles, modifiant ainsi sa capacité à surveiller l'environnement de conduite : c'est le phénomène de sortie de boucle, tel que défini par Merat et al (2019). Avec la classification des conducteurs présentés dans cette étude, le conducteur est dans la boucle en conduite manuelle, s'il surveille son environnement de conduite. En conduite autonome, il peut être sur la boucle s'il maintient sa conscience de la situation, ou hors de la boucle dans le cas contraire. Les conséquences de cette sortie de boucle ont été étudiées de manière relative, notamment en comparant les performances de conduite. De manière globale, être « plus » dans la boucle améliore ces performances de conduite au moment de la reprise en main, dans la mesure où les processus sensorimoteurs ont été maintenus actifs.

L'objectif principal de ce travail de doctorat est d'étudier et de modéliser les stratégies visuelles en conduite autonome, de manière à déterminer des patterns visuels indiquant la sortie de boucle. Dans le cadre de cette thèse, la sortie de boucle a été étudiée à différents

niveaux, selon qu'elle affecte la boucle opérationnelle et/ou la boucle tactique. Trois axes de recherches ont été développés, et sont présentés ci-après.

C.1. Équilibre entre les processus sensorimoteurs et tactiques lors de la sortie de boucle opérationnelle

Le premier axe de recherche s'intéresse à l'impact de la sortie de boucle opérationnelle (les conducteurs étant chargés de surveiller la route) sur l'équilibre entre les processus servant au guidage du véhicule et l'anticipation visuelle lors d'une conduite à virage.

Une première étude de Mars & Navarro (2012) a mis en évidence un transfert des informations visuelles entre les regards relevant du guidage du véhicule (alimentant les processus sensorimoteurs) vers ceux relevant de l'anticipation à long terme (fixations *look-ahead*). Dans cette étude, les stratégies visuelles des conducteurs ont été évaluées au travers de la déviation des angles visuels relatifs au point tangent. Les conducteurs expérimentaient à la fois un mode de conduite actif (avec contrôle du volant) et passif (sans contrôle du volant) et contrôlaient la vitesse dans les virages (vitesse d'environ 80 km/h dans les deux conditions).

L'approche expérimentale que nous avons menée permet d'aller plus loin pour observer la dynamique du transfert entre les fixations de guidage et d'anticipation, tout en faisant varier les contraintes temporelles de la tâche au travers d'une manipulation de la vitesse du véhicule dans le virage. Les distributions angulaires relatives à une position de référence seront analysées en fonction de la position du véhicule dans le virage, en distinguant la phase d'approche (ligne droite) et la phase de négociation (1^{re} moitié du virage) du virage. Au-delà de leur temporalité (le véhicule arrivant d'abord dans la phase d'approches), ces phases se distinguent également par le rôle des coordinations visuomotrices, qui est plus important en phase de négociation, puisque le conducteur doit effectivement tourner le volant pour s'adapter aux changements de courbure de la route.

L'objectif est également d'aller au-delà de l'analyse des stratégies visuelles par la distribution du regard. Nous avons ainsi cherché à mieux comprendre la dynamique des stratégies visuelles en considérant des événements particuliers : les événements de *gaze-polling*. Ces événements sont constitués de 2 saccades entre la zone de guidage et d'anticipation,

C.2. DISTINCTION DES CONDUCTEURS EN CONDUITE MANUELLE ET AUTONOME : PRISE EN COMPTE DE LA DYNAMIQUE DU REGARD

intercalées par une fixation de type *look-ahead*. La fréquence de ces événements, ainsi que la durée moyenne et cumulée des fixations *look-ahead* ont été étudiées.

In fine, cette étude permettra d'avancer sur la compréhension de la nature et de la fonction des fixations *look-ahead*, qui ne fait pas consensus dans la littérature. En effet, alors que Mars & Navarro (2012) ont proposé qu'elles servent à la recherche d'éléments tactiques, Lethonen et al. (2013) les considèrent comme servant à la planification anticipée du contrôle de trajectoire, alimentant donc principalement les processus sensorimoteurs.

Les résultats expérimentaux associés à cet axe de recherche sont développés dans la partie D.

C.2. Distinction des conducteurs en conduite manuelle et autonome : prise en compte de la dynamique du regard

Le deuxième axe de recherche porte sur la distinction des conducteurs selon qu'ils sont en conduite manuelle (dans la boucle) et autonome (sur la boucle ou hors de la boucle) à partir de leurs stratégies visuelles.

La majorité des études de la littérature décrivent désengagement des conducteurs de la scène de conduite en situation de conduite autonome, comparé à la même situation expérimentée en conduite manuelle. Ce désengagement est surtout présenté au travers d'indicateurs globaux, comme les distributions angulaires ou le pourcentage de temps passé sur les aires d'intérêts. Avec de tels indicateurs, une plus grande dispersion horizontale du regard (Damböck et al. 2013) et un temps moins important passé à regarder la route (Carsten et al. 2012) sont rapportées en conduite autonome. Pour autant, lorsque la scène visuelle est décomposée en aires d'intérêts, il est possible d'obtenir, en plus d'indicateurs « statiques » (pourcentage de temps passé sur les aires d'intérêts), des indicateurs dynamiques du regard. Nous avons donc opté pour un découpage de la scène de conduite en 13 aires d'intérêts, présentés dans la Figure C-1.

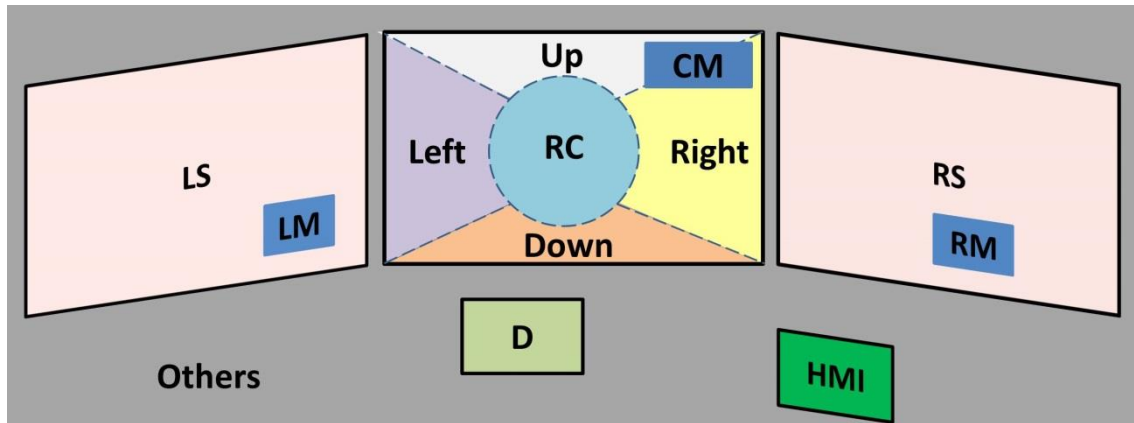


Figure C-1 : Découpage de la scène visuelle en 13 aires d'intérêts.

Dans le cadre de cette thèse, nous avons pris en compte la dynamique du regard, modélisée de manière originale sous forme de matrices de transitions, calculée comme des chaînes de Markov d'ordre 1 (voir Figure C-2). Si la scène visuelle contient N aires d'intérêts, cette matrice est de taille $N \times N$. Chaque élément de cette matrice est constitué de la probabilité que le regard atterrisse dans une zone (zone réceptrice, Recept) sachant qu'il provient d'une autre zone (zone émettrice, Emet).

Si une zone n'a pas été consultée pendant une expérimentation (ce qui est le cas par exemple lorsque de courts temps d'expérimentation sont considérés), il convient tout de même de remplir cette matrice de transition. Nous avons fait le choix d'une répartition de probabilité uniforme, c'est-à-dire que la probabilité d'émettre un regard de cette zone vers une quelconque autre zone est la même. Pour autant, la probabilité d'atterrir dans cette zone reste 0.

C.2. DISTINCTION DES CONDUCTEURS EN CONDUITE MANUELLE ET AUTONOME : PRISE EN COMPTE DE LA DYNAMIQUE DU REGARD

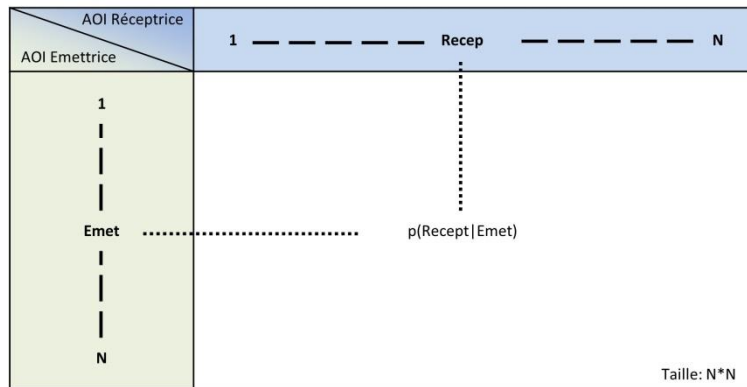


Figure C-2 : Visualisation théorique d'une matrice de transition avec N aires d'intérêts. Les éléments de la matrice sont calculés à partir des observations, sous forme de probabilité p que le regard arrive dans une aire réceptrice (Recep) sachant qu'il provient d'une certaine zone (Emet).

Le modèle de prédiction choisi est la régression PLS, qui permet notamment de réduire drastiquement le nombre d'indicateurs lors du processus de prédiction, en sélectionnant uniquement ceux pertinents à la prédiction. D'autre part, la sortie du modèle est une combinaison linéaire des différents indicateurs retenus, pondérée par des coefficients dont le signe et l'amplitude sont facilement interprétables. Enfin, le modèle s'adapte parfaitement aux contraintes de forme des matrices de stratégies visuelles, notamment au fait que le nombre d'indicateurs dynamiques (169) est bien plus élevé qu'un nombre habituel de sujets (12 dans notre cas). Les détails sur le modèle utilisé sont présents dans la partie expérimentale.

L'objectif de cette partie du travail de thèse est donc de comparer des modèles prédictifs du mode de conduite (manuel ou autonome) à partir des stratégies visuelles observées. Nous considérerons d'abord uniquement le pourcentage de temps passé à regarder le centre de la route, puis l'ensemble des indicateurs statiques. Pour mesurer l'intérêt de prendre en compte la dynamique du regard, nous chercherons à prédire l'état d'automatisation de la conduite à partir des indicateurs de transition entre aires d'intérêt ($13 \times 13 = 169$ indicateurs), puis enfin en considérant la combinaison de tous les indicateurs, statiques et dynamiques.

Les résultats expérimentaux relevant de cet axe de travail sont développés dans la partie E.

C.3. Prédiction de la sortie de boucle en conduite autonome à partir des stratégies visuelles

Ce dernier axe de travail s'attache à évaluer la surveillance de la scène de conduite par le conducteur en conduite autonome au cours du temps, de manière à distinguer les conducteurs sur la boucle des conducteurs hors de la boucle.

Lorsque la sortie de boucle concerne à la fois la boucle opérationnelle et la boucle tactique, le conducteur a tendance à sortir progressivement de la boucle : il va se désengager de la scène routière au fil du temps en conduite autonome. L'étude clé de Feldhütter et al. (2017) montre que sur un laps de temps assez court (15 min), le regard des conducteurs sur la route est plus faible à la fin par rapport au début du parcours, en prenant en compte les temps de regards cumulés. Körber et al. (2015) montre dans le même temps que le niveau de vagabondage de la pensée augmente avec le temps, ce qui est également un marqueur de désengagement. La question reste de déterminer s'il est possible de prédire l'état de désengagement du conducteur à partir des stratégies visuelles qu'il développe.

Dans notre étude, nous avons proposé comme un indicateur de sortie de boucle le niveau de vagabondage de la pensée des participants. Pour ce faire, les participants ont reporté la proportion de temps passé à penser à autre chose que la conduite. Les participants ayant le plus pensé à autre chose sont par la suite considérés plus sortis de la boucle (c'est-à-dire plutôt hors de la boucle), alors que ceux restés plus focalisés sur la conduite sont plutôt sur la boucle.

De la même façon que précédemment, les stratégies visuelles ont été décomposées en indicateurs statiques et dynamiques. Pour autant, afin d'étudier l'effet du temps sur la sortie de boucle, les indicateurs ont été calculés sur des fenêtres d'analyses variables, de 1 à 15 min, en partant de la fin du scénario (c'est-à-dire au moment où les conducteurs sont le plus hors de la boucle).

Dans cet axe de recherche, l'objectif est donc de prédire le niveau de sortie de boucle à partir des stratégies visuelles, ces stratégies visuelles étant définies sur différentes plages temporelles. Cette prédiction a également été effectuée à partir de la régression PLS, pour

des raisons similaires à la partie précédente. D’ailleurs, expérimentalement, ces deux axes de travail ont été traités au travers de la même expérimentation.

C.4. Synthèse de la démarche expérimentale

Le Tableau C-1 est un tableau présentant, pour chaque section expérimentale à suivre, l’axe de travail auquel il se réfère, les états de sorties de boucle comparés lors de l’expérimentation, ainsi que les indicateurs visuels considérés et les méthodes principales utilisées lors du traitement des données.

Sections du manuscrit		Partie D	Partie E	Partie F
Axe de Travail		Équilibre entre processus sensorimoteurs et tactiques lors de la sortie de boucle opérationnelle	Distinction des conducteurs en conduite manuelle et autonome : prise en compte de la dynamique du regard	Prédiction de la sortie de boucle en conduite autonome à partir des stratégies visuelles
États de sortie de boucle	État 1	Dans la boucle	Dans la boucle	Sur la boucle
	État 2	Sur la boucle	Sur ou Hors de la boucle	Hors de la boucle
Indicateurs visuels considérés		- Distributions angulaires du regard - Transitions entre la zone de guidage et d'anticipation	- Pourcentage de temps passé sur la route - Pourcentage de temps passé sur toutes les aires d'intérêts - Transitions entre aires d'intérêts	- Pourcentage de temps passé sur les aires d'intérêts - Transitions entre aires d'intérêts
Méthodes utilisées		- Modèles de mélange gaussien pour la ségrégation des zones de guidage et d'anticipation	- Chaînes de Markov - Régression PLS - Classification des conducteurs	- Questionnaire de vagabondage de la pensée - Chaînes de Markov - Régression PLS

Tableau C-1 : Synthèse de la démarche expérimentale

Pour chacune des parties expérimentales, une synthèse de l’expérimentation en français est d’abord proposée, suivie du détail de l’étude sous format article publié, soumis ou en préparation.

Partie D: Stratégies visuelles des conducteurs lors d'une conduite en virages : influence de l'automatisation et de la vitesse

D.1. Synthèse de l'expérimentation

D.1.1. Contexte scientifique et hypothèses

D'après le modèle de Donges (1978), le contrôle visuel de trajectoire lors d'un virage est assuré à deux niveaux. Au premier niveau, le but est de corriger les écarts de position latérale, au travers d'informations visuelles proches pouvant provenir de la vision périphérique. Au second niveau, le conducteur utilise des informations visuelles plus lointaines afin d'anticiper le changement de courbure de la route en amont. Cette anticipation visuelle s'effectue en alternant des fixations à court-terme (1-2s), servant directement à guider le véhicule dans la voie (fixations de guidage), et des fixations à plus long-terme (fixations *look-ahead*; LAFs).

En considérant les déviations angulaires autour du point tangent en conduite autonome, Mars & Navarro (2012) ont mis en évidence un transfert des prises d'informations centrales (2° autour du point tangent) vers les prises d'informations périphériques lointaines (à plus de 15° d'excentricité dans le sens de la sortie du virage; fixations *look-ahead*). Ces fixations *look-ahead* ont été interprétées comme relevant de la recherche d'informations tactiques, ce qui concorde avec l'analyse de MacKenzie et Harris (2015) montrant une meilleure détection des dangers potentiels en conduite autonome qu'en conduite manuelle. En revanche, le manque d'alimentation de la boucle opérationnelle au profit de la boucle tactique détériore les performances de conduite lorsque le conducteur doit réagir à un obstacle (Navarro, 2016), ce qui est notamment le cas aux niveaux 2 et 3 d'automatisation.

La définition des LAFs telle que proposée par Mars & Navarro (2012) se restreint aux informations lointaines. Pour autant, d'autres chercheurs considèrent des LAFs en conduite

STRATEGIES VISUELLES DES CONDUCTEURS LORS D'UNE CONDUITE EN VIRAGES : INFLUENCE DE L'AUTOMATISATION ET DE LA VITESSE

manuelle comme des fixations moins excentriques, s'écartant de plus de 6° de la trajectoire de référence déterminée par les fixations de guidage (Lehtonen et al, 2013). Ces LAFs serviraient plutôt à la planification de trajectoire, permettant au conducteur de mettre à jour son modèle interne de la route à venir (Lappi & Mole, 2018). De ce fait, les LAFs seraient donc partie intégrante du contrôle opérationnel.

Le but de cette expérience est de caractériser la dynamique des fixations *look-ahead* en fonction du mode de conduite (manuel ou autonome) et de la vitesse du véhicule dans le virage (60, 75 et 90 km/h). Pour ce faire, les phases d'approche (100 m de ligne droite avant le virage) et d'entrée (50 m dans le virage) ont été considérées séparément. De plus, on s'est intéressé à la temporalité des transitions entre la zone de guidage (fixations de guidage) et la zone d'anticipation (LAF).

Des différences de stratégies visuelles sont attendues dans la phase d'approche et de négociation du virage, du fait du manque d'alimentation des coordinations visuomotrices en conduite autonome, comparée à la conduite manuelle. Pour autant, en conduite manuelle, la demande de coordinations visuomotrices est plus forte lors de la négociation du virage, les conducteurs devant ajuster l'angle au volant en fonction des changements de courbure. De ce fait, les conducteurs auront moins tendance à effectuer des LAFs en conduite manuelle dans la phase de négociation du virage, les stratégies visuelles alimentant essentiellement les coordinations visuomotrices. Par conséquent, nous faisons l'hypothèse que les différences entre les distributions angulaires entre la conduite manuelle et autonome devraient être plus marquées dans la phase de négociation du virage.

De plus, la temporalité des transitions pourrait être affectée par les contraintes spatiotemporelles imposées à la tâche de conduite via la vitesse du véhicule. En effet, plus le véhicule est rapide, plus les fixations de guidage doivent être fréquentes pour maintenir le véhicule correctement sur la voie. De plus, avec un véhicule rapide, le temps de collision avec un objet se trouvant potentiellement sur la voie est plus faible. En conséquence, les transitions d'anticipations pourraient être plus fréquentes, mais la durée totale passée sur la zone d'anticipation plus courte à vitesse élevée.

D.1.2. Résultats et conclusion

Les résultats ont d'abord été analysés en termes de déviation angulaire horizontale par rapport à une position de référence déterminée sur la base des fixations de guidage. Dans l'analyse, les fixations d'anticipations lointaines ($> 18^\circ$) et intermédiaires ($< 18^\circ$) ne relevant pas du guidage du véhicule ont été distinguées.

L'analyse de cette distribution du regard confirme qu'il y a un transfert de fixations servant au guidage du véhicule vers des fixations d'anticipations en conduite autonome. Ce transfert démarre dans la phase d'approche : même si les conducteurs en conduite autonomes continuent de regarder la route en majorité, ils la regardent moins qu'en conduite manuelle (une baisse significative étant trouvée dans l'intervalle $[-3^\circ \ 1]$ autour de la position de référence). Dans le même temps, les conducteurs prennent plus d'informations périphériques à long et moyen terme en conduite autonome, comparé la conduite manuelle (8,08 % vs 5,10 % et 9,62 % vs 3,31 % respectivement).

Ce transfert est plus important dans la phase d'entrée du virage, ce qui confirme notre première hypothèse. En effet, les conducteurs en conduite autonome anticipent largement (32,3 %), alors que l'anticipation ne représente qu'une part négligeable en conduite manuelle (4,51 %). En conduite autonome, les conducteurs favorisent également l'anticipation à long terme (23,78 %) par rapport à l'anticipation à moyen terme (8,42 %).

Cette distinction fonctionnelle entre les anticipations à long et à moyen terme en conduite autonome nous permet de discuter plus précisément de la nature des LAFs. En effet, la conduite autonome réduisant le besoin de coordinations visuomotrices dans la phase d'entrée du virage, les conducteurs réduisent le nombre de fixations de guidage. Ils favorisent au contraire l'information à long terme, leur permettant par exemple d'anticiper des dangers potentiels. Pour autant, ils conservent une partie d'anticipation à moyen terme, qui leur permet de maintenir une planification de trajectoire et de se préparer à reprendre la main si nécessaire.

Ces distributions ont également été modélisées de manière originale à partir de modèles de mélange gaussien, qui convergent, dans la phase d'approche comme dans la phase d'entrée du virage, vers 4 gaussiennes, dont deux servent l'anticipation, une à moyen terme, l'autre à long terme. La distinction théorique entre les deux niveaux d'anticipation, l'un alimentant le

STRATEGIES VISUELLES DES CONDUCTEURS LORS D'UNE CONDUITE EN VIRAGES : INFLUENCE DE L'AUTOMATISATION ET DE LA VITESSE

niveau tactique, l'autre alimentant le niveau opérationnel, est donc cohérente avec les résultats du modèle de mélange gaussien que nous avons développé.

L'analyse des transitions entre les zones de guidage et d'anticipation confirme que les transitions sont plus fréquentes en conduite autonome lorsque la vitesse du véhicule augmente, mais l'effet reste limité et ne se traduit pas par un effet de la vitesse sur la distribution globale du regard. Ce résultat ne s'accorde pas avec l'idée que plus la vitesse est élevée, plus le regard a tendance à se porter loin, tout du moins pas pour la gamme de vitesse considérée dans cette expérimentation.

D.2. Article complet

Ce premier article est le fruit d'un travail en collaboration avec plusieurs chercheurs étrangers : Otto Lappi (Université d'Helsinki), Callum Mole (Université de Leeds) ainsi que Jammi Pekkanen (Université d'Helsinki).

Le papier original a été publié dans *Frontiers in Psychology* et est disponible au format éditeur au lien suivant : <https://doi.org/10.3389/fpsyg.2019.01699>

D.2.1. Abstract

When negotiating bends car drivers perform gaze polling: their gaze shifts between guiding fixations (GFs; gaze directed 1–2 s ahead) and look-ahead fixations (LAFs; longer time headway). How might this behavior change in autonomous vehicles where the need for constant active visual guidance is removed? In this driving simulator study, we analyzed this gaze behavior both when the driver was in charge of steering or when steering was delegated to automation, separately for bend approach (straight line) and the entry of the bend (turn), and at various speeds. The analysis of gaze distributions relative to bend sections and driving conditions indicate that visual anticipation (through LAFs) is most prominent before entering the bend. Passive driving increased the proportion of LAFs with a concomitant decrease of GFs, and increased the gaze polling frequency. Gaze polling frequency also increased at higher speeds, in particular during the bend approach when steering was not performed. LAFs encompassed a wide range of eccentricities. To account for this heterogeneity two sub-categories serving distinct information requirements are proposed: mid-eccentricity LAFs could be more useful for anticipatory planning of steering

actions, and far-eccentricity LAFs for monitoring potential hazards. The results support the idea that gaze and steering coordination may be strongly impacted in autonomous vehicles.

D.2.2. Introduction

Manual driving is a complex task that requires continuous processing of visual information to control the vehicle's speed and lateral position, read traffic signs, examine potential hazards, etc. However, with the rapid development of autonomous vehicles research questions concerning the impact of automation on gaze strategies are increasing. In highly automated driving the driver delegates lateral and longitudinal control of the vehicle to the system. He or she becomes the supervisor of decisions made by the system. The driver is by definition outside the operational control loop, even without engagement in a secondary task, which can lead to changes in gaze strategies. The general objective of this study is to examine how gaze behavior differs between active (manual) and passive (automated) driving in curves, with a particular interest in anticipatory visual behavior under different spatiotemporal constraints.

The visual control of steering during active driving has been extensively studied and modeled. Commonly, steering is considered as depending on both feedback and feedforward processes (McRuer et al., 1977 ; for a recent review see Lappi and Mole, 2018). A compensatory feedback process may depend more on near-distance visual information (e.g., peripheral vision of the edge lines), and support corrections of lateral position (Mole et al., 2016; Summala et al., 1996). In parallel, an anticipatory feedforward process uses more distant visual information relating to changes in curvature of the road ahead. Precisely how gaze is functionally employed to supply visual preview information is a topic of ongoing research (Lappi and Mole, 2018). However, empirical observations from both on-road (Lappi et al., 2017; Lehtonen et al., 2013, 2014) and simulator studies (Mars & Navarro, 2012; Wilkie et al., 2008) suggests that the predominant gaze strategy during curve driving interleaves guiding fixations (GFs) with look-ahead fixations (LAFs).²

Guiding fixations are characterized by saccades to a point in the road 1–2 s ahead of the driver. These fixations provide a short-term preview of the road dedicated to the steering

² In the driving context, the concept of “fixations” also includes oculomotor pursuit (as the vehicle is in movement). However, the terms “GFs” and “LAFs” were conserved to refer to the literature.

STRATEGIES VISUELLES DES CONDUCTEURS LORS D'UNE CONDUITE EN VIRAGES : INFLUENCE DE L'AUTOMATISATION ET DE LA VITESSE

of the vehicle. GFs can be accommodated by a number of steering models in the theoretical literature (Lappi, 2014). Still, precisely how GFs provide preview, and the nature of visual information being sampled, has long been debated. Land and Lee (1994) hypothesized that the tangent point, a particular feature of the inner edge line, was functionally important during curve driving. Salvucci and Gray (2004) proposed an alternative model based on near and far points traveling ahead of the vehicle on the future path, although they acknowledged the driver can flexibly choose to look at the tangent point, a lead vehicle or any other relevant visual target depending on the driving situation (cf. also Lehtonen et al., 2018). On the other hand, Wann and Swapp (2000), Wilkie et al., (2010), and Lappi (2014) have argued that drivers look at waypoints on the future trajectory rather than at particular road characteristics. Additionally, Mars & Navarro (2012) proposed a view in which the driver is looking for the limits of an acceptable trajectory envelope (that often falls close to the tangent point). Although the debate on the exact nature of the GFs is still open, the common underlying assumption of these hypotheses is that the GFs promote visuomotor coordination for steering control.

Saccades to points in the road at considerably longer timescales than those commonly reported for GFs have also been observed. Under real driving conditions, Kandil et al. (2010) reported that drivers spent one-third of the time looking at the bend exit as they approached the curve. Such fixations appear to be too far ahead to be useful for directly controlling the immediate steering trajectory. Further observations led Mars & Navarro (2012) and Lehtonen et al. (2013, 2014) to apply to curve driving the concept of LAFs, previously developed for manipulation tasks (Ballard et al., 1995; Hayhoe et al., 2003; Land et al., 1999; Land and Furneaux, 1997; Mennie et al., 2007; Pelz and Canosa, 2001 ; cf. also the gaze polling strategy observed by Wilkie et al. (2008) in a slalom task). LAFs in driving can be defined as intermittent glances directed further ahead on the road than where GFs are directed (i.e., significantly beyond the normal preview distance), with the gaze returning to the guiding preview distance.

Though the functional significance of each type of fixation is currently unknown, the overall gaze strategy has been described as a trade-off between the need to control the immediate steering trajectory (GFs), and the need to make longer-term navigation decisions (LAFs) (see Lappi and Mole, 2018, for a recent review). Such a trade-off would predict that

reducing the need for steering corrections may “free-up” gaze to obtain anticipatory information from further ahead (i.e., make more LAFs).

Indeed, in a simulator study comparing automated and manual driving Mars & Navarro (2012) reported an increase in the proportion of LAFs and a concomitant decrease of GFs when the driver was in a passive driving condition (i.e., they did not need to move the steering wheel). It is possible that a higher proportion of LAFs improves the driver’s ability to anticipate, in line with Mackenzie and Harris (2015) who reported better hazard detection under passive driving conditions. However, an apparent increase in an ability to notice hazards (during automation as compared to manual control) does not seem to translate to an improved ability to safely respond to hazards: in Navarro et al. (2016) drivers that were passively driven showed more LAFs (than manual control) but poorer driving performance when an unexpected obstacle needed to be avoided. It is clear that being out of the operational loop causes disruption to steering and gaze control that cannot be compensated for by simply making more LAFs to get anticipatory information (for a detailed discussion see Mole et al., 2019).

In order to more fully understand the potential role of gaze during both manual and automated driving a better description of LAFs is required. The present study aimed to empirically define LAFs in curve driving. In particular, we set out to map the spatial and temporal characteristics of LAFs: how far, how long for, and how often (gaze eccentricity, fixation duration, and gaze polling frequency). The level of description provided will improve on previous research and allow researchers to investigate the influence of steering activity (or the lack of) on gaze by describing the shifting dynamics of GFs and LAFs. When manually driving, a tighter coordination between gaze and steering is required during corners rather than in the approaching straight line due to the need to compensate for changes in road curvature. Therefore, gaze distributions were analyzed depending on the section of the bends (approach or cornering). When passively driving, steering is performed by the vehicle so we might not observe large changes in gaze behavior between the approach or cornering phases. Therefore, it was hypothesized that differences in gaze behavior between active and passive driving would be larger in the Cornering section compared to the Approach section. Since gaze strategy is sensitive to the specific driving scenario the spatiotemporal constraints of the driving task were manipulated by modifying the speed of the vehicle. Anticipatory strategies (LAFs) were expected to change as a

function of speed: when speed is high, the time available to perform LAFs and the time to reach to a potential hazard ahead is reduced, thus, shorter but maybe more frequent LAFs would be expected.

D.2.3. Materials and methods

D.2.3.1. Experiment

D.2.3.1.1 Participants

Nineteen volunteers participated in this study. A full dataset was collected (i.e., there was no simulator sickness), though data from one participant have not been considered due to poor eye-tracker calibration. Mean age for the remaining participants ($N = 18$) was 26.1 years ($SD = 4.2$). Participants drove on average 9500 km per year ($SD = 6500$ km/year). To facilitate the recording of accurate gaze data participants had only normal or corrected (with contact lenses) vision. They also held a valid driving license and had no known neurological disease.

D.2.3.1.2 Equipment

The experiment was conducted using a fixed-base simulator that included an adjustable seat, a steering wheel with force feedback, a gear lever, clutch, accelerator and brake pedals, and a speedometer (see Figure D-1). The driving simulator software was SCANeR Studio 1.4. The visual rendering of the road environment was displayed on three screens located in front of the driver, which offered drivers a 120° field of view.

Gaze data were recorded by means of a Smart Eye Pro (V5.9) eye-tracker with four cameras (two below the central screen and one below each peripheral screen). Calibration was achieved with 13 points, with the head fixed and oriented to the center of the central screen and the eyes directed to each calibration point in turn. Gaze position accuracy was given by the software: approximately 1.5° in the central screen, and 1.9° for more peripheral fixation points (standard deviation was 0.85° on average). Both eye-tracking data and vehicle position data were acquired at 20 Hz and synchronized by the driving simulator software.



Figure D-1 : Driving simulator setup: the driving scene is displayed on three screens.
The Eye Tracker was composed of four cameras.

D.2.3.1.3 Road

The test route was a 3 km two-lane rural road with no traffic. The width of the lane was 3.5 m for the whole track, with a continuous line in the middle of the road and broken markings for edge lines. LAFs are hypothesized to have a role in medium to long-term trajectory planning (Lappi and Mole, 2018), so it was considered that a track with curves of a variety of radii and lengths would elicit more LAFs than a track with predictable curves. However, since gaze strategy is heavily dependent on the unfolding track, curves with different parameters are effectively an uncontrolled confound when analyzing gaze data. Therefore, only six identical curves were retained for data analysis.

To allow drivers enough time to anticipate as they approached the test bends (at least 4 s), a straight line of 120 m preceded the bends. This constituted the Approach section. For the Cornering section, the radius and length of the bend have been adjusted so that participants could pass through the bend in the three speed conditions (see Procedure). The bend radius was set at 100 m, and the arc length at 100 m. A 100 m straight line followed each bend. To make the road more easily discernible on the screen, this exit section was elevated of 1 m. Only the orientation differed between the bends: half of them were oriented to the left and three to the right (see Figure D-2). The entire Approach section (A) and the first part of the turn section (C1; length = 50 m) were studied in the data analysis.




Figure D-2 : Geometry of the curves used for data analysis. The curves were composed of an Approach section (length = 120 m, straight line), a Cornering section (length = 100 m, radius = 100 m) and an exit section (length = 100 m, straight line). The analysis of gaze was performed in the first half of the Cornering section (C1) and in the Approach section (A).

D.2.3.1.4 Procedure

First, the simulator seat position was adjusted to ensure that the participant was comfortably settled. Participants then drove manually along a training track to familiarize themselves with the driving simulator setup and the simulator environment. Since there is considerable heterogeneity in how familiar participants are with virtual environments the practice phase was open-ended and ended only when the participant felt comfortable with the vehicle and virtual environment. The practice phase lasted approximately 5 min.

After practice the eye-tracker calibration was performed and the participants were instructed that they would experience two driving modes, passive and active driving:

- In the active driving condition, drivers were in charge of the lateral control of the vehicle. Participants were asked to always remain in their own lane.
- In the passive driving condition, the lateral position of the car was managed by the driving simulator software. Drivers were told that the car was fully automated, although they might have to return to manual control. In that case, a red steering wheel symbol would appear on all screens. This event actually never happened. The aim was to ensure that drivers maintained their attention to the road scene.

In both conditions, the speed was fixed using a cruise control system at three different speeds: 60 km/h, 75 km/h or 90 km/h. The speedometer was hidden from the participant to avoid irrelevant glances at the dashboard. The road was designed so that the vehicle reached the given speed before entering in the first Approach section.

Each participant drove the test route six times, taking part in all conditions (3 speeds \times 2 driving modes). The order of presentation of the conditions was counterbalanced using a diagram-balanced Latin Square.

D.2.3.2. Data Analysis

Investigating the balance between GFs and LAFs requires a method to parse a gaze signal into either GFs or LAFs. The data analysis was composed of five different steps:

1. Computation of a GF reference from the horizontal gaze distribution.
2. Identification of two areas in the visual scene: GFs area of interest (GF AOI, computed from the gaze distribution analysis) and look-ahead fixations area of interest (LAF AOI).
3. Segmentation of eye-movements into fixations/pursuits and saccades.
4. Definition of gaze polling events based on eye-movements and gaze landing area.
5. Calculation of dependent variables and statistical inference.

The following subsections fully explain the processes taken in each analysis step.

D.2.3.2.1 Calculation of the Reference for Guiding Fixations

Gaze behavior in curve driving is fairly stereotypical, with the gaze following the road ahead 1–2 s ahead of the driver. This GF behavior describes the bulk of gaze observations, with the occasional LAF interspersed. There are two conceptual alternatives when identifying GFs. One is to define a priori some geometrical GF reference points, such as 2 s time headway on the future path (Lehtonen et al., 2014) or the tangent point (Land and Lee, 1994; see Lappi, 2014, for discussion). However, differences in gaze distribution relative to such points might be elicited by participants' preferences, speed or other unknown variables. To take this into account, we opted for an alternative approach of deriving the GF reference position empirically from the observed gaze distribution (as used in Lehtonen et al., 2013) under the assumption that most gaze is GF. The median gaze

STRATEGIES VISUELLES DES CONDUCTEURS LORS D'UNE CONDUITE EN VIRAGES : INFLUENCE DE L'AUTOMATISATION ET DE LA VITESSE

eccentricity was used to determine the GF reference at each longitudinal position on the road. This analysis is accurate when the number of gaze measurements is high (so the influence of outliers is small), which was the case here (at least 108 measurements for each track position). In practical terms, gaze measurements of all participants in all conditions were collected for each position along the road and the median value was calculated for every 0.5 m interval. A third-order Savitzky–Golay filter with a 31 m window was applied to the median values in order to obtain a smoothed signal that defined the guiding reference, as illustrated by Figure D-3.




Figure D-3 : Visualization of the GF reference on raw data. The value of the GF reference was obtained using the filtered median horizontal angular value for all participants at each location along the track.

The following analyses were performed on horizontal deviations from that GF reference. The vertical deviations were not considered since they held very little information in our conditions (almost flat road). Indeed, the gaze angle varied mainly along the horizontal axis ($SD = 20.3^\circ$ for horizontal eccentricities vs. 3.1° for vertical eccentricities). In addition, although vertical deviations were used to distinguish fixations from saccades, it should be noted that gaze polling saccades are mostly horizontal (see section “Segmentation of Eye Movements”).

Two analyses were carried out separately, one for the bend approach, the other for the Cornering section.

D.2.3.2.2 Computation of a Guiding Area and Identification of an Anticipatory Area

To classify gaze observations as GF (or not), threshold values for the boundary of a GF AOI around the GF reference position is needed, such that it will encompass most or all of the GFs but few or no LAFs (or fixations in the scenery). In Lehtonen et al. (2013), a threshold value (6°) was chosen on the basis of visual inspection of data of a similar nature to Figure D-3. A threshold approach by visual inspection is practical, but will be specific to the data, relies on the researcher's prior assumptions of the functional role of LAFs, and is unlikely to translate well to different steering tasks (i.e., the thresholds may be overfitted to the data). Since the primary aim of the current study was to better describe gaze behavior in a way that is useful for researchers when analyzing gaze behavior on their own steering tasks, we set out to model the gaze distributions in a way that could be used to predict distributions for new steering tasks. Therefore, the GF AOI threshold value was determined on the basis of fitting a mixture of Gaussians to the gaze distribution obtained in the active driving condition. For the analyses, a positive eccentricity corresponded to a glance oriented toward the bend exit. With this sign convention, the gaze distribution is right-skewed due to anticipating glances (LAFs; see Figure D-4). The rationale was to isolate one standard Gaussian distribution (with no skew) that encompasses GF, with the remaining gaze data points corresponding to anticipatory gazes.

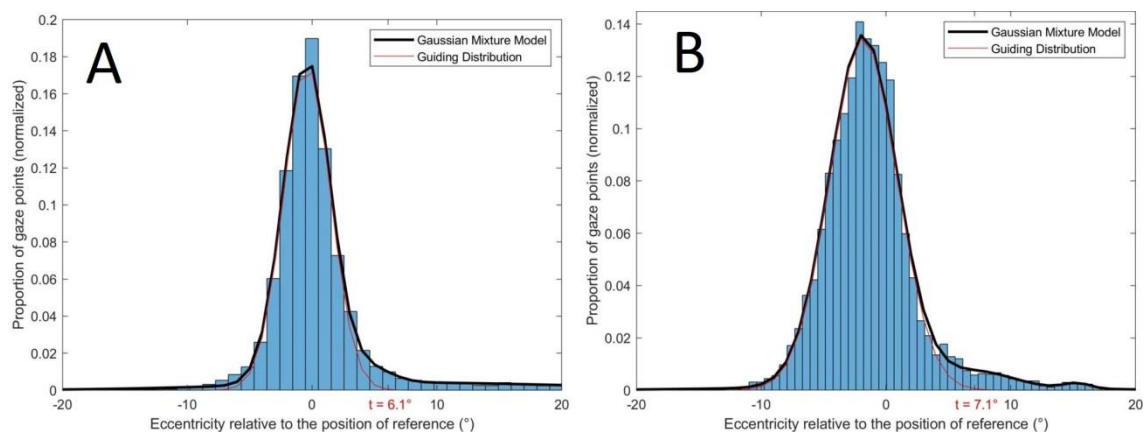


Figure D-4: Threshold calculation. For each section (A: Approach, B: Cornering), the gaze distribution in the active driving condition was modeled with a Gaussian mixture model of 4 Gaussians. The main Gaussian (GF Gaussian) allows operationally defining the guiding fixations. The threshold (t) was set so that 99.95% of guiding fixations were below the threshold value.

STRATEGIES VISUELLES DES CONDUCTEURS LORS D'UNE CONDUITE EN VIRAGES : INFLUENCE DE L'AUTOMATISATION ET DE LA VITESSE

Gaze distribution was modeled as a Gaussian mixture model: a weighted sum of components, each component following a Gaussian distribution. The minimum number of components was calculated to ensure the convergence of the model for gaze distributions in both the Approach and Cornering sections. The final number of components ($n = 4$) was selected using the Bayesian information criterion (BIC). Initial settings (Supplementary Table 1) and detailed results of the Gaussian mixture model can be found in the Appendix section (D.2.7).

Once the Gaussian mixture model was obtained for the Approach and the Cornering sections the central distribution (Gaussian 1 in table Tableau D-2 and Tableau D-3) was considered as the GF component. Then, the threshold for GF AOI was determined as gaze eccentricity values encompassing most (99.95%) of the GF component.

Thresholds of 6.1° for the Approach section and 7.1° for the Cornering section were determined (see Figure D-4). For each vehicle position gaze was classified as belonging to the GF AOI if the eccentricity (horizontal gaze angle) was below the threshold value. As positive eccentricities correspond to gaze oriented toward the bend exit, a LAF area could also be computed: if gaze eccentricity exceeds the threshold then it would belong to the LAF area. Figure D-5 presents the obtained thresholds superimposed on schematic representations of the driving scene at two vehicle positions, one during the Approach and the other during Cornering. It can be observed at a qualitative level that the threshold matches up with the descriptions of GFs and LAFs in the literature: fixations that are directed ahead of the driver on the road, with a short time headway, are classified as GF; to be classified as a LAF the driver needs to look beyond the current trajectory and toward the bend exit.

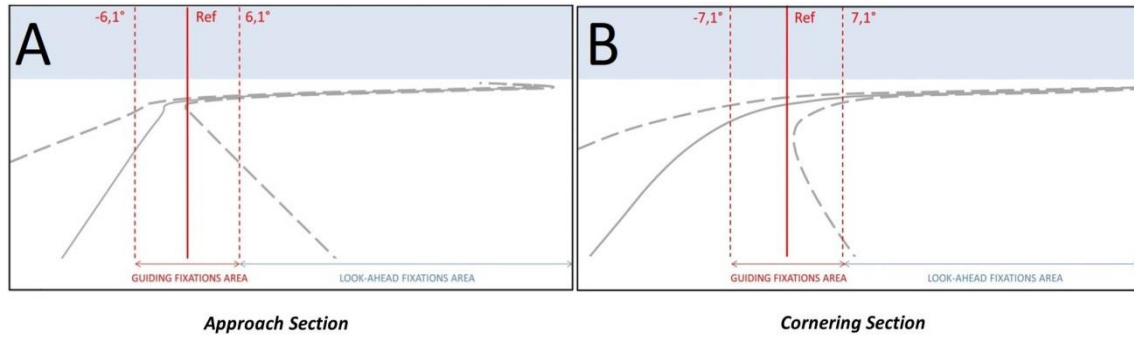


Figure D-5 : Schematic view of the driving scene during the Approach (A) and the Cornering (B) of the bend. The position of reference for guiding fixations as well as the threshold value allows defining two areas of interest: the guiding fixations area and the look-ahead fixations area.

D.2.3.2.3 Segmentation of Eye Movements

In order to quantify when drivers executed a saccade to a far (LAF) or nearer (GF) region it was necessary to parse the eye movement signal into saccades, and otherwise. The Naïve Segmented Linear Regression (NSLR) algorithm proposed by Pekkanen and Lappi, (2017) appears to be an effective method of segmenting eye movement data into saccades, fixations and smooth pursuits. The segmentation treats angular gaze data and assumes that eye movements are reasonably approximated by linear segments. Then, for each new gaze data point, the algorithm calculates the maximum likelihood for this sample to belong to the prior linear segment or create a new one. The segmentation is performed by taking into account the slope of a given linear segment. An example of segmentation for one participant is presented on Figure D-6.

STRATEGIES VISUELLES DES CONDUCTEURS LORS D'UNE CONDUITE EN VIRAGES : INFLUENCE DE L'AUTOMATISATION ET DE LA VITESSE




Figure D-6 : Segmentation of eye-movements using Naïve Segmented Linear Regression algorithm (Pekkanen and Lappi, 2017). Classification is obtained as a function of the shape of a given linear segment using Hidden Markov Models.

D.2.3.2.4 Characterization of Gaze Polling

A gaze polling event (cf. Wilkie et al., 2008) was defined as the following sequence (Figure D-7):

1. A saccade is launched from the GF area and lands in the LAF area.
2. Gaze remains in the LAF area for one or more fixations/pursuit movements.
3. The gaze returns to the GF area with a saccadic movement.




Figure D-7 : Characterization of gaze polling.

The gaze shifts between guiding fixations and look-ahead fixation areas (1 → 2 → 3).

In this study we focused on the dynamics of shifts between GF and LAF areas (i.e., gaze polling events). For that reason, eye-movements occurring within the LAF area during gaze polling were treated as a single LAF, even though it may have included multiple saccades, fixations, or pursuits (see Figure D-7).

In a given bend section (Approach or Cornering), a driver may look either within the GFs area only, either within the LAFs area only, or perform gaze polling. The number of bends with one of those visual behaviors was calculated depending on driving conditions. When drivers performed gaze polling at least one time in a bend section, gaze polling frequency (total number of gaze polling events divided by duration of the given section), the mean LAFs duration, and the cumulative duration in percent (cumulative duration of all LAFs on a section divided by duration of the given section) were computed.

D.2.3.2.5 Dependent Variables and Statistical Analysis

Gaze distribution relative to the GF reference

The gaze distribution relative to the position of reference was computed between -11° and 18° using a 1° interval. Values outside the range ($<-11^\circ$ and $>18^\circ$) were gathered in two extreme classes (total = 31 intervals). The values of -11° and 18° were chosen so that there was at least one data point per interval for each condition and each participant. All gaze data (fixations, saccades, smooth pursuits) were included in this analysis. Gaze distributions were analyzed in six conditions: speeds (60, 75 or 90 km/h) × driving condition (active or passive).

STRATEGIES VISUELLES DES CONDUCTEURS LORS D'UNE CONDUITE EN VIRAGES : INFLUENCE DE L'AUTOMATISATION ET DE LA VITESSE

To allow comparison between left and right curves a sign convention had been used: a positive value of eccentricity correspond to a gaze directed toward the bend exit relatively to the position of reference. Differences between driving conditions at each bin were investigated with paired t-tests. Holm's adjustment procedure (Holm, 1979) was used to control the type I error ($\alpha = 0.05$) for the 31 (=number of bins) comparisons.

Look-ahead fixations during a gaze polling event

A 2×3 Type III ANOVA (2 driving conditions: active or passive, 3 speed conditions: 60, 75 or 90 km/h) with repeated measures was performed on gaze polling frequency, the mean duration of LAFs and the cumulative duration of LAFs during each section (Approach or Cornering). Post hoc analysis was performed using t-tests adjusted with Holm's procedure for a level of significance at 0.05.

D.2.4. Results

D.2.4.1. Gaze Distributions

Figure D-8 shows the distribution of gaze as a function of driving activity in the Approach (a) and Cornering (b) sections. In all cases, the gaze distributions are right-skewed, with a non-zero mass above the LAF threshold and a large amount of data points in the positive extreme bin (any fixation above 18°). We shall henceforth describe fixations in the extreme category as far-eccentric LAFs, and fixations between the extreme category and the LAF threshold as mid-eccentric LAFs.




Figure D-8 : Gaze distributions as a function of the driving condition (blue: active, red: passive) and bend section (A: Approach, B: Cornering). The shaded area corresponds to the standard error of the means. Asterisks indicate a significant difference between active and passive driving at a given eccentricity.

D.2.4.1.1 Approach Section

Descriptively, the peak of the both active and passive gaze distributions is located close to the GF reference (0°), within the interval $[-1^\circ, 0^\circ]$, both in the active and passive driving conditions. The distributions are asymmetric with a higher proportion of gaze points directed toward the bend exit (positive values) than toward the opposite direction (negative values). One can notice that there is a larger proportion of gaze data points around the GF reference in the active driving condition than in the passive driving condition. However, passive driving gave rise to a higher proportion of gaze points that exceeds the LAF threshold (6.1° in the Approach section): 17.7% in the passive driving condition and 8.41% in the active driving condition ($t(17) = 5.28, p < 0.001, r^2 = 0.62$). More precisely, far-eccentric gazes (directed toward the bend exit; extreme eccentricities $>18^\circ$), accounted for 8.08% of all points in passive driving (5.10% in active driving). Mid-eccentric gaze points (from 6.1° to 18°) also represented 9.62% in the passive driving condition (3.31% during active driving).

Statistical analysis revealed a significantly higher proportion of gaze points in the active driving condition for eccentricities for all the intervals between -3° and 1° . Extreme eccentricities ($<-11^\circ$ and $>18^\circ$) also reached statistical significance, with a larger proportion of far-eccentric LAFs made in the passive driving condition.

D.2.4.1.2 Cornering Section

In the Cornering section, the two gaze distributions are strikingly different. In the active driving condition, the peak of the distribution is located at the $[-2^\circ, -1^\circ]$ interval, whereas in the passive driving condition the peak is wider with a large proportion of points between -1° and 4° . The total percent of gaze points that exceeds the LAF threshold (7.1° in the Cornering section) was 4.51% in the active driving condition and 32.3% in the passive driving condition ($t(17) = 6.31, p < 0.001, r^2 = 0.75$). Moreover, gaze was rarely directed toward the far-eccentricities ($>18^\circ$) (1.99%) or mid-eccentricities (2.52%) during active driving, whereas 8.42 and 23.78% of gaze points were directed there during passive driving.

Statistical analysis of the effect of driving condition on eccentricity revealed a significantly higher proportion of gaze points in the active driving condition for all eccentricities between -5° and 0° ($p < 0.05$ in all cases). On the other hand, a higher proportion of gaze

STRATEGIES VISUELLES DES CONDUCTEURS LORS D'UNE CONDUITE EN VIRAGES : INFLUENCE DE L'AUTOMATISATION ET DE LA VITESSE

points were found in the passive condition between 2° and 4° and for the far-eccentric LAFs (>18°).

D.2.4.1.3 Effect of Speed

There was not a significant effect of speed in either the Approach section or in the Cornering section (see the similar distributions across speeds in Figure D-9).




Figure D-9 : Gaze distributions as a function speed (red: 60 km/h, blue: 75 km/h, black: 90 km/h), bend section (A,C: Approach, B,D: Cornering) and driving conditions (A,B : active driving, C,D: passive driving). The shaded area corresponds to the standard error of the means

D.2.4.2. Detected Gaze Polling Events

Figure D-10 summarizes in how many bends and in which driving condition drivers performed gaze polling




Figure D-10 : Gaze strategies adopted per participant in the Approach (A) and Cornering (B) section. Each bend was categorized as one of the four following behaviors: gaze polling during active driving (blue), gaze polling during passive driving (red), no gaze polling with the gaze always in the GF area (gray), no gaze polling with the gaze always in the LAFs areas (yellow). The participants are ordered according to their propensity to perform gaze polling in the Approach section.

Over a total of 648 bends (18 participants \times 6 negotiated bends \times 2 driving conditions \times 3 speeds), drivers performed gaze polling in 343 bends (53% of all bends) in the Approach section. Gaze polling happened slightly more during passive driving (195 bends) than during active driving (148 bends). In the Cornering section, gaze polling was observed in 188 bends, with a larger difference between passive driving (160 bends) and active driving (28 bends) than in the Approach section. In other words, during active driving most drivers performed gaze polling only in the Approach section, whereas during passive driving most drivers performed gaze polling in both Approach and Cornering sections. In bends where gaze polling occurred, it represented 19.46% of all gaze data in the Approach section and 38.27% in the Cornering section.

In both sections, when no gaze polling was detected, the driver's gaze remained in the GF area in all but 5 (Approach) and 20 (Cornering) bends. These exceptions, for which drivers spent all the time looking beyond the LAF threshold, always happened in the passive driving condition.

D.2.4.3. Temporal Characteristics of LAFs during Gaze Polling

Figure D-11 shows the gaze polling frequency, the mean duration of LAFs and the cumulative duration of all LAFs when gaze polling was performed.

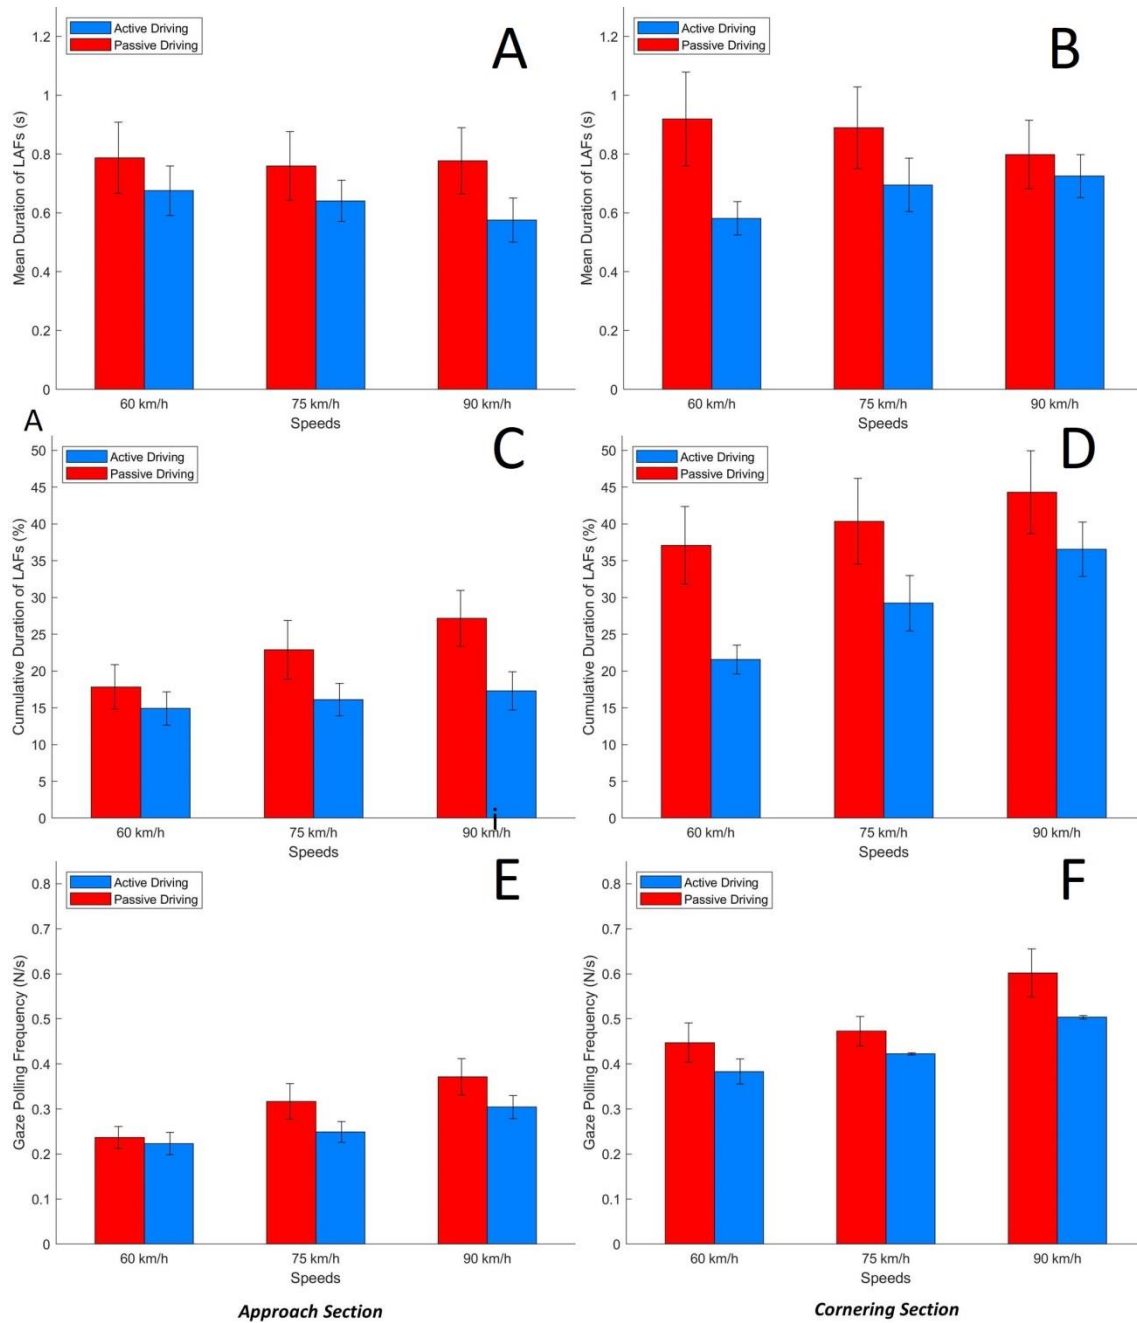


Figure D-11 : LAFs mean duration (A,B), cumulative duration (in percent of total duration; C,D) and gaze polling frequency (E,F) as a function of speed and driving condition for the Approach (A,C,E) and Cornering (B,D,F) sections.

D.2.4.3.1 Approach Section

The ANOVA revealed significantly higher values in the passive driving condition compared to the active driving condition for the mean LAF duration [$F(1, 17) = 8.83$, $p < 0.01$, $\eta_p^2 = 0.023$], the cumulative LAF duration [$F(1,17) = 18.1191$, $p < 0.001$, $\eta_p^2 = 0.051$], and the gaze polling frequency [$F(1,17) = 9.81$, $p < 0.01$, $\eta_p^2 = 0.032$].

The main effect of speed was significant only for the cumulative LAF duration [$F(2,34) = 5.09$, $p < 0.01$, $\eta_p^2 = 0.036$] and the gaze polling frequency [$F(2,34) = 16.86$, $p < 0.001$, $\eta_p^2 = 0.091$]: all values increased as a function of speed.

D.2.4.3.2 Cornering Section

For the Cornering section, higher values were found in the passive driving condition compared to the active driving conditions for all indicators. However, this difference was significant only for the cumulative duration [$F(1,17) = 4.95$, $p < 0.01$, $\eta_p^2 = 0.051$].

The effect of speed was significant only for the frequency [$F(2,34) = 3.47$, $p < 0.05$, $\eta_p^2 = 0.12$].

There was not a significant interaction between speeds and driving condition for both Approach and Cornering sections.

D.2.5. Discussion

The current study examined gaze behavior for the Approach and Cornering sections of a bend, across active and passive driving conditions. During active driving a high concentration of gaze points was directed to the GF area with only few intermittent LAFs, mostly directed to the far distance toward the bend exit or beyond (cf. Lehtonen et al., 2014). This observation is in line with a number of on-road studies (e.g., Land and Lee, 1994; Lappi et al., 2017, 2013a, 2013b; Lehtonen et al., 2014, 2013). The proportion of LAFs increased in passive driving, as was the case in Mars & Navarro (2012). However, in Mars & Navarro (2012), the bend was considered as a whole, whereas in the present study the LAFs made during the Approach and Cornering phase were considered separately. The distinction revealed that the increase in the proportion of LAF (or equivalently the decrease in the proportion of GFs) starts early, before entering the bend, but is much more

STRATEGIES VISUELLES DES CONDUCTEURS LORS D'UNE CONDUITE EN VIRAGES : INFLUENCE DE L'AUTOMATISATION ET DE LA VITESSE

pronounced when actually steering along the curve. When passively driving, LAFs represented more than 30% of all gaze data. By contrast, actively driving around corners gave rise to more than 95% of gaze points in the GF region below the LAF threshold (see Figure D-8). The small amount of LAFs observed when actively steering around corners, and the proportionally larger amount of LAFs observed both before the bend and during passive driving, are consistent with the notion that GFs are involved in visuomotor coordination. When fewer steering corrections are required (so the need for visuomotor coordination is reduced), drivers preview the road further ahead, which gives rise to dramatically more LAFs.

If GFs are considered to be used for immediate lateral and longitudinal control of the vehicle, it follows that looking further ahead could provide anticipatory information over and above immediate trajectory control, for example upcoming maneuvers such as obstacle avoidance, gap acceptance, turning, and overtaking. While GFs guide ongoing action “just in time” (direct visuomotor coupling), LAFs could anticipate later actions (Mars and Navarro, 2012; Lehtonen et al., 2013, 2014; Navarro et al., 2016; Lappi and Mole, 2018). However, precise descriptions of GF function benefit from relatively tight time headway bounds and a long history of modeling the visual control of steering (Lappi, 2014). LAFs, on the other hand, encompass a much wider range of time headways so are a considerably more heterogeneous classification. For example, in the current study a glance is categorized as a LAF if it is more eccentric than the GF threshold but there is no upper limit to how eccentric a LAF can be, therefore LAFs could be just beyond the GF region or they could be very distant indeed (Figure D-8). It would be unreasonable to assume that LAFs of such different eccentricities have identical functions.

Thus, we have made a distinction between LAFs of different eccentricities: mid-eccentricity and far-eccentricity LAFs. This distinction is particularly obvious when considering the results obtained in the passive driving condition during cornering (Figure D-8). Here the gaze distribution was characterized by a number of far-eccentric LAFs that was twice as large as in the approach phase, but also by a large number of mid-eccentric glances directed between the GF area and the far-eccentricity LAF area. This suggests that for advanced information drivers did not always look “as far as they could see,” but also sampled the road at an intermediate distance.

This distinction between mid-eccentricity and far-eccentricity LAFs has never been really discussed before. In Mars & Navarro (2012), the driving activity only influenced the balance between GFs and far-eccentric fixations. As a consequence, the definition of LAFs was restricted to far-eccentric fixations. LAFs were considered as anticipatory glances to assess future road features (e.g., is the upcoming bend followed by a straight section or by another bend which may be hard to negotiate?) or traffic hazards (e.g., is there oncoming traffic or an obstacle on the road?). In other words, LAFs were thought as serving decision making, such as choosing to decelerate to anticipate a detected hazard or to accelerate when the road was assessed as safe to drive.

On the other hand, Lehtonen et al. (2013, 2014) used a single eccentricity threshold to separate GF and LAF, considering all fixations beyond GF as a single category. The authors reported mid-eccentricity LAF, similarly to what was observed in the present experiment. Those mid-eccentricity LAFs, mostly directed to the road, may not provide anticipatory information that is advanced enough to support decision making. Still, they are positioned too far to have a direct “online” contribution to steering responses. Lappi and Mole (2018) proposed that LAFs may rather be used for motor planning, allowing the selection and parameter setting of internal models of the vehicle-environment dynamics.

The results reported here illustrate this distinction: passive driving, by removing the need for direct visuomotor coupling leads to a much larger dispersion of gaze. Part of the gaze was dedicated to far eccentric features. We hypothesize that these LAFs mostly serve anticipation of future hazards (Mackenzie and Harris, 2015), although it cannot be excluded that a minor part of them was directed to parts of the visual field irrelevant to driving, such as looking at the scenery (the 2% increase of glances directed in the direction opposite to the bend may also reflect that). The rest of gaze behavior shows that drivers did not completely disengage from steering control. Indeed, mid-eccentricity LAFs suggest that drivers continued to gather information for trajectory planning in case a return to manual control was necessary, and there remained a substantial number of glances into the GF area.

Analyzing horizontal gaze distributions captures broad trends across conditions. However, one of the key reported characteristics of gaze behavior is the interleaving of GFs and LAFs. Therefore, individual bends were examined for the presence of specific gaze polling

STRATEGIES VISUELLES DES CONDUCTEURS LORS D'UNE CONDUITE EN VIRAGES : INFLUENCE DE L'AUTOMATISATION ET DE LA VITESSE

events (Figure D-10). The results showed that gaze polling occurred more often during the Approach section than during cornering. Gaze polling was also more frequent in the passive driving condition (compared to active driving), this difference was especially pronounced when cornering. Interestingly, gaze polling did not happen in all bends. Moreover, drivers' tendency to perform gaze polling showed large individual variations (similar to the results of Wilkie et al., 2008), suggesting that gaze polling may depend on participant's preferences and driving experience.

During passive driving drivers performed gaze polling more often and also increased the time spent looking to the LAF area. Increased exploration of the visual scene during passive driving may lead to an improved situation awareness (Mackenzie and Harris, 2015), but it could equally mean partial disengagement from the driving task. In some rare cases (yellow data in Figure D-10) the driver spent all the time looking at the LAF area. Looking far ahead may improve the ability to detect hazards well in advance. However, the absence of GFs may lead to poor visuomotor coordination and inadequate maneuver performance if these drivers were unexpectedly needed to take-over manual control (Navarro et al., 2016; Mole et al., 2019).

Finally, it is worth noting that while no effect of speed was found on gaze distributions Gaze polling frequency did increase with speed, principally in the passive driving condition. This suggests that even if speed did not cause substantial alterations to the spatial distribution, it influenced the dynamics of gaze sampling. However, it should be noted that the range of speeds used in the study (60–90 km/h) was not very large, and as such would not substantially change the eccentricity of GF glances (cf. Tuhkanen et al., 2019). Larger differences in GF gaze distribution might be observed at very high speeds, which might in turn have an effect on gaze polling.

The current study shows differences in gaze strategy between active and passive driving over relatively short timescales. In future studies it will be interesting to examine how passive driving may affect gaze distributions and gaze polling dynamics over longer periods of time. A more prolonged period of automated driving may result in the driver being (further) out-of-the-loop (Merat et al., 2019), which can imply a degradation of perceptual-motor coordination (Mole et al., 2019) and a loss of situation awareness (Endsley, 1995). For instance, Körber et al. (2015) and Feldhütter et al. (2017) showed that drivers' reaction

time to events progressively increased with the duration of automated driving. It is possible that continuous assessment of gaze during automated driving could indicate when gaze has been redistributed and/or gaze polling dynamics have shifted, thereby providing clues as to whether a driver is safe to take-over control.

D.2.6. Conclusion

The study analyzed gaze behavior when negotiating bends at various speeds when the driver was in charge of steering or when it was delegated to automation. When not driving, drivers looked further ahead, and polled more often between near and far regions. The distribution of gaze appears to support a distinction between two types of anticipatory LAFs: glances extremely far ahead (far-eccentric LAFs) that may be useful for hazard perception, and glances to an intermediary region (mid-eccentric LAFs) that may serve advanced movement planning. Speed did not change the global distribution of gaze but influenced gaze polling dynamics, in particular during the bend approach during automated driving. In the context of the current development of autonomous vehicles, in which the driver becomes a supervisor of the driving activity, this suggests that the monitoring of gaze behavior may serve the assessment of the driver state.

D.2.7. Appendix

D.2.7.1. Initialization of the Gaussian Mixture Model

D.2.7.1.1 Definition of a Gaussian Mixture Model

The model was set up using the function *fitgmdist* from Matlab. With this function, the Gaussian Mixture Model likelihood is optimized using an iterative Expectation-Maximization (EM) algorithm. This model fits a distribution as a sum of N components (each one following a Gaussian distribution) weighted by the proportion of each component. After convergence of the algorithm, gaze distribution (GD) is then modeled by the formula:

$$GD = \sum_{i=1}^N C_{p_i} * N(\mu_i ; \sigma_i)$$

STRATEGIES VISUELLES DES CONDUCTEURS LORS D'UNE CONDUITE EN VIRAGES : INFLUENCE DE L'AUTOMATISATION ET DE LA VITESSE

where C_{p_i} is the proportion of component i , following a Gaussian distribution with mean μ_i and standard deviation σ_i .

D.2.7.1.2 Initial parameters and choice of the number of components

Gaussian Mixture models were estimated with several different initializations and the best fitting model was selected using the Bayesian Information Criterion (BIC). The 1st Gaussian Mixture Model comprised only a central component ($C_p = 1$; mean = 0; std = 5) to ostensibly capture the guiding fixations. For the two component model a component to capture the noise of the distribution ($C_p = 0.1$; $\mu = 0.0$; std = 20) was added. For further models the initial parameters of the central (mean = 0.0; std = 5.0; and $C_p = 0.5$) and noise (mean = 0.0; std = 20 and $C_p = 0.1$) components remained the same and additional components were added with initial mean of 15, standard deviation of 2.0 and component proportion $0.4/(N-2)$ to capture glances directed toward the bend exit (positive eccentricities).

The final number of components was decided by minimizing the BIC value for the two bend sections. The final number of components for both models was 4 (see Figure D-12), with initial parameters given in table Tableau D-1.

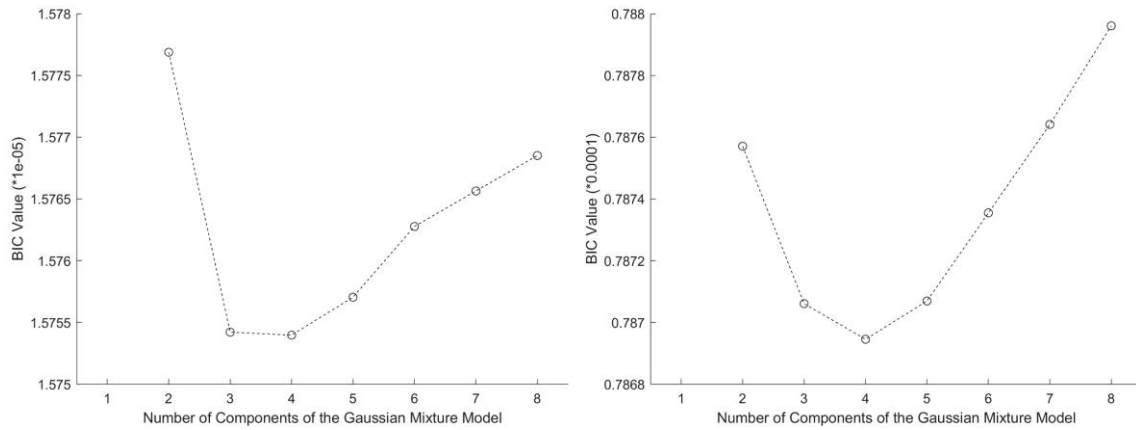


Figure D-12 : BIC values as a function of the number of components of the model for the Approach (a) and Cornering (b) sections. A blank remained for one component because the model did not converge in that condition.

Properties	<i>Gaussian 1</i>	<i>Gaussian 2</i>	<i>Gaussian 3</i>	<i>Gaussian 4</i>
Data contained	Guiding Fixations	Noise	Anticipating Glances	Anticipating Glances
Mean (μ)	0	0	15	15
Standard Deviation (σ)	5	20	2	2
Component Proportion (C_p)	0.5	0.1	0.2	0.2

Tableau D-1 : Initial parameters of the Gaussian Mixture Model with 4 components

D.2.7.2. Gaussian Mixture Model of gaze distribution in the Approach section

After convergence, the parameters in table Tableau D-2 were obtained in the Approach section.

Properties	<i>Gaussian 1</i>	<i>Gaussian 2</i>	<i>Gaussian 3</i>	<i>Gaussian 4</i>
<i>Data contained</i>	Guiding Fixations	Noise	Mid-term anticipation	Long-term anticipation
<i>Mean (μ)</i>	-0.4227	8.8337	5.2454	24.3850
<i>Standard Deviation (σ)</i>	1,9554	13.5282	1.4778	4.0340
<i>Component Proportion (C_p)</i>	0.8397	0.1326	0.0241	0.0035

Tableau D-2 : Final parameters of the model with 4 components in the Approach section

A visualization of each component of the model is presented in Figure D-13.

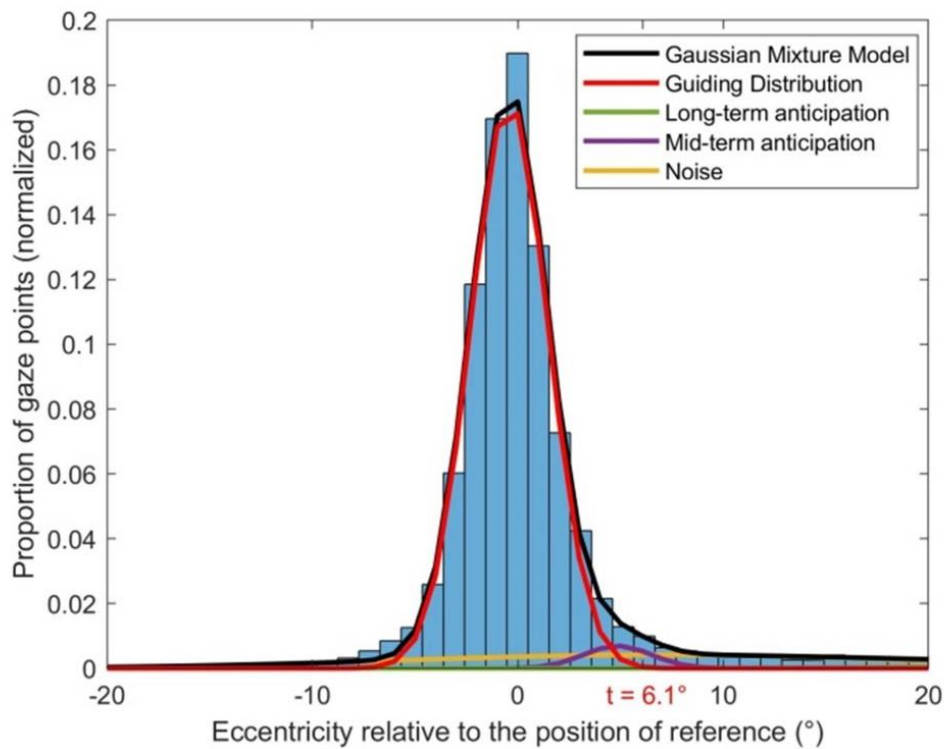


Figure D-13 : View of the Gaussian Mixture Model on the gaze distribution for the approach section.
Each Gaussian represents one component of the Gaussian Mixture model

D.2.7.3. Gaussian Mixture Model of gaze distribution in the cornering section

After convergence, the parameters in table Tableau D-3 were obtained in the cornering section.

Properties	<i>Gaussian 1</i>	<i>Gaussian 2</i>	<i>Gaussian 3</i>	<i>Gaussian 4</i>
<i>Data contained</i>	Guiding Fixations	Noise	Mid-term anticipation	Long-term anticipation
<i>Mean (μ)</i>	-1,8217	0.4857	7,2616	15,2994
<i>Standard Deviation (σ)</i>	2,6990	11,4790	2,9133	1,0237
<i>Component Proportion (C_p)</i>	0,9108	0.0401	0.0438	0.0055

Tableau D-3 : Final parameters of the model with 4 components in the cornering section

A visualization of each component of the model is presented on Figure D-14.

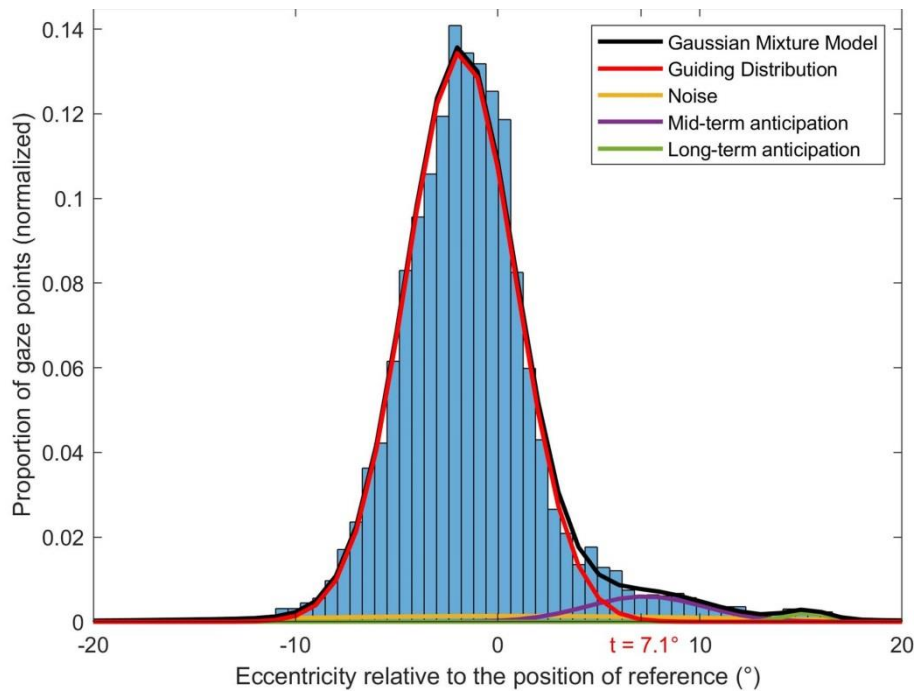


Figure D-14 : View of the Gaussian Mixture Model on the gaze distribution for the cornering section.

Each Gaussian represents one component of the Gaussian Mixture Model.

STRATEGIES VISUELLES DES CONDUCTEURS LORS D'UNE CONDUITE EN VIRAGES :
INFLUENCE DE L'AUTOMATISATION ET DE LA VITESSE

Partie E: Prédiction du mode de conduite à partir des stratégies visuelles des conducteurs en contexte autoroutier

E.1. Synthèse de l'expérimentation

E.1.1. Contexte scientifique et hypothèses

La majorité des études de la littérature ont étudié les conséquences de la délégation de la tâche de conduite sur les stratégies visuelles. L'ensemble de ces études considèrent l'attention visuelle globale portée sur la scène visuelle par les conducteurs, à partir d'informations angulaires (dispersion horizontale chez Damböck et al., 2013; Mackenzie & Harris, 2015; Mars & Navarro, 2012) ou des pourcentages de temps passés sur des aires d'intérêts (Carsten et al., 2012 ; Jamson et al., 2013).

Les conclusions de ces études sont univoques : les conducteurs favorisent la recherche d'informations périphériques, au détriment des informations centrales (sur la route). Lorsque la scène de conduite est décomposée en aires d'intérêts, les résultats montrent une baisse globale du pourcentage de temps passé à regarder le centre de la route (PRC ; Carsten et al., 2012 ; Jamson et al., 2013). Pour autant, la dynamique d'exploration de la scène visuelle n'est pas prise en compte.

Les résultats tirés de notre première étude vont aussi dans ce sens, avec une première prise en compte de la dynamique de ce transfert de prise d'informations du centre vers les aires périphériques. Cette étude s'est effectuée sur route à virage, où les coordinations visuomotrices sont fortes, avec le conducteur surveillant la route en conduite autonome.

Dans cette seconde expérimentation, nous prenons le contre-pied de la méthodologie employée dans la littérature. En effet, au lieu de décrire la modification des stratégies visuelles en conduite autonome, nous avons cherché à prédire le mode de conduite (manuel ou autonome) directement à partir des stratégies visuelles spontanées du conducteur.

PREDICTION DU MODE DE CONDUITE A PARTIR DES STRATEGIES VISUELLES DES CONDUCTEURS EN CONTEXTE AUTOROUTIER

Durant l'étude, le conducteur était en conduite autonome de niveau 3, donc il n'était pas obligé de surveiller la route. Cependant, aucune tâche secondaire n'était disponible pour le conducteur, afin que les stratégies visuelles ne soient pas essentiellement déterminées par elles.

Dans les faits, nous nous sommes tout d'abord intéressés à savoir dans quelle mesure une analyse restreinte au PRC permettait de bien de distinguer les conducteurs en conduite manuelle ou autonome. Nous avons ensuite étendu cette analyse en considérant les stratégies visuelles de manière de plus en plus complète, en considérant d'abord l'ensemble des indicateurs statiques (pourcentage de temps sur l'ensemble des aires d'intérêts), puis les indicateurs de la dynamique d'exploration visuelle (transitions entre les aires d'intérêts), et enfin la combinaison des informations statiques et dynamiques. Nous faisons ainsi l'hypothèse que la prise en compte de la dynamique du regard améliore la prédiction du mode de conduite.

Dans cette étude, le modèle de prédiction choisi est la régression PLS, qui permet d'estimer l'état d'automatisation du conducteur (mode de conduite) en fonction des stratégies visuelles. D'après notre recherche bibliographique, c'est la première fois que cette méthode est appliquée aux stratégies visuelles afin de caractériser un état psychologique ou le contexte dans lequel se trouve un individu. En plus de répondre aux contraintes provenant de la structure des données visuelles, cette méthode permet d'explicitier les indicateurs visuels retenus pour effectuer la prédiction. Ce modèle permet, pour chaque individu statistique (c'est-à-dire chaque ensemble de données obtenu dans un essai expérimental), de prédire l'état d'automatisation du véhicule de manière numérique. Une catégorisation est ensuite effectuée à partir de la valeur numérique, chaque individu statistique étant attribué à une classe (conduite manuelle ou autonome).

E.1.2. Principaux résultats et conclusions

4 modèles de prédictions ont été ainsi été construit. Ils diffèrent par la nature des informations visuelles prises en compte pour la prédiction (PRC, indicateurs statiques, indicateurs dynamiques, ou la combinaison d'indicateurs statiques + dynamique).

Les résultats montrent que le PRC seul donne une assez bonne estimation du mode de conduite, mais des erreurs de classification apparaissent chez 3 sujets. Les résultats de la prédiction s'améliorent avec la prise en compte de tous les indicateurs statiques : il n'y a plus d'erreurs de classifications, mais certaines prédictions restent approximatives, proches du seuil de décision. La prise en compte de la dynamique d'exploration de la scène donne lieu à une séparation largement plus marquée des deux groupes, sans erreurs de classification. Un pattern de résultats similaire est trouvé pour les combinaisons statiques et dynamiques, avec une erreur de prédiction légèrement plus faible.

Ces résultats confirment notre hypothèse, et vont même plus loin. En effet, la prise en compte de la dynamique ne permet pas seulement de mieux prédire le mode de conduite, elle constitue l'essence même des différences entre les modes de conduite.

Le meilleur modèle pour prédire l'appartenance des sujets à un groupe est donc le modèle comportant les indicateurs statiques et dynamiques. Ces indicateurs sont au nombre de 39. Sur ces 39, la plupart sont dynamiques ($N = 32$; 14 relevant de la conduite manuelle, 18 relevant de la conduite autonome). La prise en compte de la dynamique permet d'affiner les patterns visuels caractéristiques des conducteurs en conduite manuelle et autonome. En effet, en conduite manuelle, si la plupart des entrées visuelles sont focalisées sur la route, les conducteurs continuent de regarder de manière dynamique les rétroviseurs importants (rétroviseurs central et gauche). En conduite autonome, le transfert des informations centrales vers des aires périphériques est bien noté par des indicateurs statiques. En revanche, ils regardent de manière dynamique les interfaces homme-machine instrumentées sur le véhicule (IHM de conduite autonome, tableau de bord) et en dehors de l'habitacle du véhicule.

E.2. Article complet

Cet article est a été soumis à *Journal of Eye Movement Research* en mai 2020, sous le titre : "Model-based estimation of the state of vehicle automation as derived from the driver's spontaneous visual strategies". L'expérience a été pensée et les résultats développés en étroite collaboration avec Camilo Charron.

E.2.1. Abstract

When manually steering a car, the driver's visual perception of the driving scene and his or her motor actions to control the vehicle are closely linked. Since motor behaviour is no longer required in an automated vehicle, the sampling of the visual scene is affected. Passive driving typically results in less gaze being directed towards the road centre and a broader exploration of the driving scene, compared to manual driving. To examine the corollary of this situation, this study estimated the state of automation (manual or automated) on the basis of gaze behaviour. To do so, models based on partial least square regressions were computed by considering the gaze behaviour in multiple ways, using static indicators (percentage of time spent gazing at 13 areas of interests), dynamic indicators (transition matrices between areas) or both together. Analysis of the quality of predictions for the different models showed that the best result was obtained by considering both static and dynamic indicators. However, gaze dynamics played the most important role in distinguishing between manual and automated driving. This study may be relevant to the issue of driver monitoring in autonomous vehicles.

Keywords: automated driving, manual driving, gaze behaviour, gaze dynamics, eye movement, area of interest.

E.2.2. Introduction

Driving is a complex dynamic task in which the driver must continuously process information from the environment. This is necessary to control the speed and direction of the vehicle; to gather information about other vehicles, road signs or potential hazards; and to make decisions about the route to be taken. Theoretical models of driving activity have been developed to account for this complexity. Michon (1985), for example, proposed dividing driving activity into three hierarchically organised levels: the strategic level, the tactical level and the operational level. The strategic level corresponds to the definition of general driving goals, such as itinerary selection. At the tactical level, objects are recognised, danger is assessed and acquired rules are used to make short-term decisions. These decisions are implemented at the operational level, which is underpinned by online perceptual-motor loops.

During manual driving, drivers perform all the subtasks associated with the three control levels. However, during automated driving, some tasks are transferred to the automation. Then, the driver's role depends on the level of automation, as defined by the Society of Automotive Engineers (SAE International, 2016). When lateral and longitudinal control are delegated to automation (SAE level 2), drivers become system supervisors rather than actors. This transformation of the driver's role changes their visual processing of the environment and their interaction with the vehicle (Mole et al., 2019).

At SAE Level 2, drivers are required to maintain their attention on the road so that they can regain manual control of the vehicle without delay at all times. However, the visuo-motor coordination necessary for the online control of steering and braking is no longer required, which constitutes a neutralization of the operational control loop. Land & Lee (1994) showed that eye movements typically preceded steering-wheel movements by 800 ms in manual driving. Once control of the steering wheel is delegated to the automaton, this perceptual-motor coupling is no longer necessary. This explains why even in the absence of a secondary task, and with the instruction to monitor the driving scene, changes in gaze behaviour were observed under such conditions. Drivers who no longer have active control of the steering wheel tend to neglect short-term anticipation of the road ahead; they produce more distant fixations, known as “look-ahead fixations” (Mars & Navarro, 2012; Schnebelen et al., 2019).

At SAE Level 3, drivers might no longer actively monitor the driving scene. When the system perceives that it can no longer provide autonomous driving, it issues a takeover request, allowing the driver a time budget to restore situational awareness and regain control of the vehicle. Failure to monitor the driving scene for an extended period is tantamount to neutralizing both the tactical control loop and the operational loop. During this time, drivers can engage in secondary tasks. The distraction generated by the secondary task results in less attention being directed towards the road than in the case of manual driving (Barnard & Lai, 2010; Carsten et al., 2012; Merat et al., 2012). One possible way to measure this shift of attention is to compute and compare the percentage of time spent in road centre (PRC; Victor et al., 2005). Low PRC is associated with drivers being out of the operational control loop (Carsten et al., 2012; Jamson et al., 2013). However, even without a secondary task, sampling of the driving environment is affected, with higher horizontal

PREDICTION DU MODE DE CONDUITE A PARTIR DES STRATEGIES VISUELLES DES CONDUCTEURS EN CONTEXTE AUTOROUTIER

dispersion of gaze during automated driving compared to manual driving (Damböck et al., 2013; Louw & Merat, 2017; Mackenzie & Harris, 2015).

All previous studies point to the same idea: the gaze is directed more towards the peripheral areas than the road during automated driving. However, observations based on the angular distribution of gaze only capture an overall effect and do not consider the gaze dynamics. For this purpose, a decomposition of the driving scene into areas of interest (AOIs) may be more appropriate, with an analysis of transitions between areas. Such a method was implemented by Underwood et al., (2003) to determine AOI fixation sequences as a function of driver experience and road type in manual driving. Gonçalves et al. (2019) similarly proposed analysing the fixation sequences during lane-change manoeuvres. The present study uses this approach to assess the driver's gaze behaviour during an entire drive of either manual or automated driving.

Previous documented studies have examined the consequences of automated driving for drivers' visual strategies. For example, PRC has been shown to be low during automated rides. The present study uses the opposite methodological approach, aiming to determine the state of automation (i.e., manual or automated) based on the driver's spontaneous visual strategies. These visual strategies were considered in several ways. The analysis was performed by first considering only the PRC, and then a set of static indicators (percentage of time spent in the different AOIs) and/or dynamic indicators (transitions between AOIs). Partial Least Square (PLS) regressions were used to estimate a score between -1 (automated driving) and 1 (manual driving). This estimate of the state of automation from the visual indicators considered was used to classify the trials, with a calculation of the quality of the estimate in each case.

The objective was to determine whether considering the PRC was sufficient to discriminate between automated and manual driving. The extent to which the inclusion of other static and dynamic indicators would improve the driver-state estimation was also assessed. We hypothesised that considering the gaze dynamics would improve the ability to distinguish between manual and automated driving.

E.2.3. Materials and methods

E.2.3.1. Participants

The study sample included 12 participants (9 male; 3 female) who had a mean age of 21.4 years (SD = 5.34). They all had normal or corrected vision (with contact lenses only). All participants held a French driver's licence, with mean driving experience of 9950 km/year (SD = 5500). A signed written informed consent form, sent by e-mail one week before the experiment and printed for the day of experimentation, was required to participate in the study.

E.2.3.2. Experimental Setup

The study used a fixed-base simulator consisting of an adjustable seat, a digital dashboard, a steering wheel with force feedback, a gear lever, a clutch, an accelerator and brake pedals (see figure E-1). The driving scene was generated with SCANeR Studio (v1.6) and displayed on three large screens in front of the driver (field of view $\approx 120^\circ$). An additional screen, simulating a central console, provided information about the vehicle automation mode.



Figure E-1 : Driving simulator environment

Gaze data were recorded using a Smart Eye Pro (V5.9) eye-tracker with four cameras (two below the central screen and one below each peripheral screen). The calibration of the eye-tracker occurred at the start of the experiment and required two steps. In the first step, a 3D model of the driver's head was computed. In the second step, the gaze was computed

PREDICTION DU MODE DE CONDUITE A PARTIR DES STRATEGIES VISUELLES DES CONDUCTEURS EN CONTEXTE AUTOROUTIER

using a 12-point procedure. The overall accuracy of calibration was 1.2° for the central screen and 2.1° for peripheral areas. Gaze data and vehicle data were directly synchronised at 20 Hz by the driving simulator software.

E.2.3.3. Procedure

After adjusting the seat and performing the eye-tracker calibration, participants were familiarised with the simulator by driving manually along a training track. Once this task was completed, instructions for automated driving were given orally. These were as follows: when the autonomous mode was activated, vehicle speed and position on the road would be automatically controlled, taking into account traffic, speed limits and overtaking other cars if necessary. To fit with SAE level 3 requirements, drivers were told that the automated function would only be available for a portion of the road, with the distance and time remaining in the autonomous mode displayed on the left side of the human-machine interface (HMI). When automation conditions were not met, the system would request the driver to regain control of the vehicle.

Two use cases were presented to the participants. In the first case, the vehicle was approaching the end of the automated road section. The drivers received mild auditory and visual warning signals and had 45 s to regain control. The second use case was an unexpected event, such as the loss of sensors. In this case, a more intense auditory alarm and a different pictogram were displayed, and drivers had only 8 s to resume control. All the pictograms (figure E-2) and sounds used by the HMI were presented to participants at the end, before they started a second training session.



Figure E-2 : Pictograms displayed on the HMI. A: autonomous driving available; B: autonomous driving activated; C: take-over request (8 s); D: take-over request (45 s)

During the second training session, participants first experienced manual driving (with cruise control, corresponding to SAE level 1) and then automated driving (SAE level 3: conditional automation). At level 3, drivers experienced four transitions from automated to

manual driving, two in each use case presented in the instructions. All takeovers were properly carried out during the training session.

Then, after a short break, the experimental phase started. All participants experienced the manual and automated conditions and the order of presentation was counter-balanced. The scenario was similar in the two driving conditions and comprised an 18-min drive in a highway context. Most of the road was a 40-km two-lane dual carriageway, with a speed limit of 130 km/h, in accordance with French regulations. Occasional changes in road geometry (temporary three-lane traffic flow, highway exits and slope variation) and speed limits (130 km/h to 110 km/h) were included to make the driving less monotonous. In both directions on the highway, traffic was fluid, with eight overtaking situations.

A critical incident occurred at the 18th minute of automated driving. Thereafter, a questionnaire was administered. However, these results are not reported as they are beyond the scope of this paper, which merely aims to characterise differences in gaze behaviour for manual versus automated conditions. Therefore, only the data common to both conditions is considered here; that is, 17 min of driving time, during which no major events occurred.

E.2.3.4. Data Structure and Annotations

The driving environment was divided into 13 AOIs as shown in figure E-3. These were as follows:

- The central screen contained six areas: the central mirror (area CM); the road centre (RC), defined as a circular area of 8° radius in front of the driver; and four additional areas defined relative to the road centre (Up, Left, Down and Right).
- Each peripheral screen contained two areas: the lateral mirror (LM, RM) and the remaining peripheral scene (LS, RS).
- The dashboard (D).
- The HMI (HMI).
- All gaze data directed outside of the stipulated areas were grouped as an area called "Others".

PREDICTION DU MODE DE CONDUITE A PARTIR DES STRATEGIES VISUELLES DES CONDUCTEURS EN CONTEXTE AUTOROUTIER

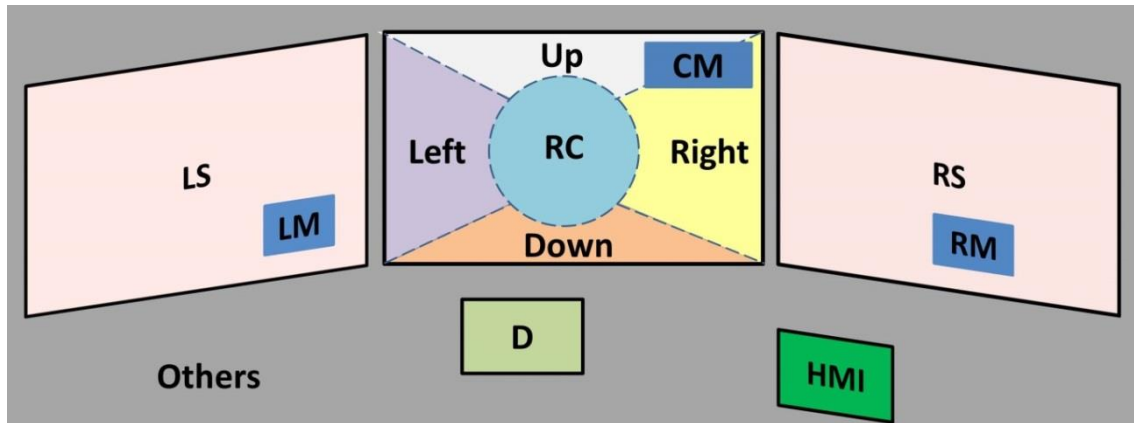


Figure E-3 : Division of the driving environment in 13 areas of interest

The percentage of time spent in each AOI was computed, as was a matrix of transitions between AOIs. The transition matrix indicated the probability to shift from one AOI to another or to remain in the same AOI. Probabilities were estimated by the observations made on the participants. As there were 13 AOIs that defined the entire world, the transition matrix was a 13*13 matrix.

The gaze behaviour of each participant can be consequently characterised by 182 visual indicators (= 13*13 transitions + 13 percentage of time on each AOI), considering both static and dynamic indicators. As 24 statistical individuals were considered (= 12 (individuals) * 2 (driving conditions)), the complete matrix of gaze behaviour for all subjects was then 24*182 and was denoted as \mathbf{X}_{DS} . When only the transitions were considered, the matrix was denoted as \mathbf{X}_D and its size was 24*169. When only the percentages of time spent on each AOI were considered, the matrix was 24*13 and was denoted as \mathbf{X}_S . Another vector, constituted of only the PRC, was also computed (size: 24*1) and was labelled \mathbf{X}_{PRC} . All the matrices were centred and reduced for the next step of the analysis. As described below, this entailed PLS regressions.

The data were structured according to the aim of predicting an automation state (\mathbf{Y}) from either \mathbf{X}_{PRC} , \mathbf{X}_S , \mathbf{X}_D or \mathbf{X}_{DS} . The automation state was defined as follows: it was valued 1 for manual driving and -1 for automated driving.

The appropriate model of prediction was chosen with respect to certain constraints. First, the number of visual indicators (max 182 for \mathbf{X}_{DS}) available to explain \mathbf{Y} was notably higher than the number of observations ($n=24$). Second, the visual indicators were correlated.

Indeed, with the driving environment divided into 13 AOIs, the percentage of time spent on 12 AOIs enabled calculating the percentage of time spent on the 13th AOI. In mathematical terms, \mathbf{X} might not be full rank. Given this correlation between variables, a simple linear model was not appropriate.

Considering these constraints, the PLS regression model was selected. PLS regression yields the best estimation of \mathbf{Y} available with a linear model given the matrix \mathbf{X} (Abdi, 2010). All PLS regressions performed in this study used the PLS regression package on R (R Team, 2013).

PLS regression is based on a simultaneous decomposition of both \mathbf{X} and \mathbf{Y} on orthogonal components. Once the optimal decomposition is found, the number of visual indicators is systematically reduced to consider only relevant visual indicators for the prediction. Ultimately, the most accurate model – involving optimal decomposition and only the most relevant visual indicators – is set up to provide the estimation of \mathbf{Y} , based on a linear combination of the relevant visual indicators. For more details, see the Appendix section.

E.2.3.5. Data analysis

Three sequential stages composed the analysis:

- The first step only considered the percentage of time spent on each AOI individually. The difference between manual and automated driving was evaluated using paired t-tests to determine whether it was significant.
- In the second step, prediction models of the automation state were developed using PLS regression. Several models were developed, depending on the nature of visual indicators that served as input: PRC only (\mathbf{X}_{PRC}), static indicators only (\mathbf{X}_{S}), dynamic indicators (\mathbf{X}_{D}) or a combination of static and dynamic indicators (\mathbf{X}_{DS}).
- In the final step, a binary classification of the prediction was performed. A given statistical individual was classified as “automated” if its prediction was negative and as “manual” in the opposite case. The number of errors was then considered.

E.2.4. Results

E.2.4.1. Distribution of visual attention as a function of the automation state

The percentage of time spent in each of the 13 AOIs during the entire drive is presented in tableau E-1.

Visual Indicator	Manual Driving	Automated Driving	Auto - Manu Difference
Percentage of time spent in the <i>Road Center</i>	67.45	40.76	26.69***
Percentage of time spent in the Right Mirror	0.01	0.07	0.06
Percentage of time spent in the Left Mirror	0.137	0.31	0.173
Percentage of time spent in the HMI	0.01	0.31	0.3*
Percentage of time spent in the Down Area	0.32	0.67	0.35**
Percentage of time spent in the Left Area	1.561	2.09	0.529
Percentage of time spent in the Right Area	2.91	4.46	1.55
Percentage of time spent in the Dashboard	2.08	4.45	2.37*
Percentage of time spent in the Central Mirror	4.084	6.9	2.816**
Percentage of time spent in the Up Area	14.74	17.99	3.25
Percentage of time spent in the Right Screen	2.679	6.78	4.101**
Percentage of time spent in the Left Screen	2.6	7.14	4.54**
Percentage of time spent in the Others Area	1.48	8.03	6.55*

Tableau E-1 : Distribution of visual attention for manual and automated drives.

Stars indicate the results from the paired t-tests. (* $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$).

During manual driving, participants spent about 27% more time in the Road Centre area than during automated driving. Conversely, automated driving was associated with significantly more gazing directed to the left and right peripheral screens, the down area, the central mirror, the dashboard, the HMI and Others. The remaining AOIs did not show significant differences.

E.2.4.2. Predictions of the automation state with PLS regression

Several predictions were performed with PLS predictions, depending on the input matrix. These were as follows: \mathbf{X}_{PRC} (PRC only), \mathbf{X}_{s} (static indicators only), \mathbf{X}_{D} (dynamic indicators) or the combination of dynamic and static indicators (\mathbf{X}_{DS}). Estimations obtained with the PLS regression method are presented in figure E-4.




Figure E-4 : Estimations (markers) of the automation state from: A, PRC only; B, static indicators only; C, dynamic indicators only; D, static and dynamic indicators. The marker type indicates the real automation state: circle for automated driving, star for manual driving. The MSEP and number of visual indicators retained during the PLS process (N) are annotated in text. Errors of classifications (relative to the classification threshold in black) are indicated in red.

Results showed that considering PRC alone provided a rough estimation of the automation state, with a mean square error of prediction (MSEP) of 0.42. It gave rise to three classification errors (figure E-4-A). When all static indicators were considered as input, seven were selected for PLS regression (tableau E-2, column 1). This analysis yielded a more accurate estimation of the automation state than prediction based on PRC alone; the MSEP was halved and there was no classification error. However, four statistical individuals (1, 3, 8 and 17) remained close to the classification threshold (figure E-4-B).

When dynamic indicators alone were considered, 32 (out of 169) indicators were selected by the PLS regression. The prediction results were greatly improved, with an MSEP of 0.04. Moreover, the manual and automated driving conditions could be more clearly discriminated (figure E-4-C). Considering static and dynamic indicators together yielded the

PREDICTION DU MODE DE CONDUITE A PARTIR DES STRATEGIES VISUELLES DES CONDUCTEURS EN CONTEXTE AUTOROUTIER

lowest prediction error (MSEP = 0.02), although the pattern of results was quite similar to those obtained for dynamic PLS (figure E-4-D). It should be noted that the indicators selected by the combined static and dynamic PLS were the same as those selected for static PLS and for dynamic PLS.

The PLS regression coefficients for each visual indicator retained in the different predictions are presented in tableau E-2. The sign of the coefficients indicates the direction of their contribution to the estimate. A positive coefficient tends to increase the estimated score and is therefore a feature of manual driving. A negative coefficient decreases the estimated score, which corresponds to automated driving. A coefficient's absolute value indicates its importance for the prediction, with large coefficients contributing strongly to the estimation.

Visual Indicator	Static	Dynamic	Static & Dynamic
Percentage of time spent in the Road Center	0.257		0.058
Percentage of time spent in the Dashboard Area	-0.149		-0.034
Percentage of time spent in the Others Area	-0.171		-0.039
Percentage of time spent in the Left Screen	-0.191		-0.043
Percentage of time spent in the Right Screen	-0.194		-0.044
Percentage of time spent on the Central Mirror	-0.203		-0.046
Percentage of time spent in the Down Area	-0.202		-0.046
Transition from the Left Area to the Road Center		0.064	0.051
Transition from the Up Area to the Road Center		0.058	0.047
Transition from the Right Screen to the Road Center		0.057	0.045
Transition from the Down Area to the Road Center		0.055	0.044
Transition from the Right Area to the Road Center		0.052	0.042
Transition from the Left Screen to the Road Center		0.052	0.041
Transition from the Dashboard Area to the Left Screen		0.048	0.039
Transition from the Right Mirror to the Left Mirror		0.046	0.037
Transition from the Right Screen to the Down Area		0.046	0.037
Transition from the Others Area to the Road Center		0.046	0.037
Transition from the Road Center to the Down Area		0.045	0.036
Transition from the HMI to the Central Mirror		0.044	0.035
Transition from the Dashboard to the Road Center		0.041	0.033
Transition from the Others Area to the Dashboard		0.042	0.033
Transition from the HMI to the Others Area		-0.033	-0.025
Transition from the Right Area to the Dashboard		-0.040	-0.032

Transition from the Central Mirror to the Dashboard		-0.040	-0.032
Transition from the Down Area to the HMI		-0.044	-0.035
Transition from the Left Area to the Central Mirror		-0.046	-0.036
Transition from the Road Center to the HMI		-0.046	-0.037
Transition from the Central Mirror to the Left Mirror		-0.047	-0.037
Transition from the Others Area to the Others Area		-0.046	-0.037
Transition from the Up Area to the Up Area		-0.048	-0.039
Transition from the Road Center to the Others Area		-0.049	-0.039
Transition from the Down Area to the Down Area		-0.052	-0.042
Transition from the Central Mirror to the Right Screen		-0.056	-0.044
Transition from the Others Area to the Left Screen		-0.057	-0.044
Transition from the Left Area to the Right Area		-0.059	-0.047
Transition from the Left Area to the Left Area		-0.057	-0.05
Transition from the Down Area to the Central Mirror		-0.067	-0.052
Transition from the Road Center to the Central Mirror		-0.069	-0.055
Transition from the HMI to the HMI		-0.081	-0.065

Tableau E-2 : PLS regression coefficients per visual indicator. A positive coefficient corresponds to a visual indicator characteristic of manual driving. A negative coefficient is associated with automated driving.

In accordance with the analysis presented in table 1, the only static indicator selected by the PLS analyses as a feature of manual driving was the percentage of time spent looking at road centre. By contrast, automated driving was characterised by a combination of looking at the peripheral areas (left and right screen), the dashboard, Others, central mirror and the down area.

Both dynamic PLS and the combined static and dynamic PLS selected 32 AOI transitions, 14 related to manual driving and 18 related to automated driving. To facilitate the identification of dynamic visual patterns characteristic of manual or automated driving, we performed a final analysis of the AOI transitions. We examined whether the gaze mostly entered or exited each AOI. The difference between the number of transitions entering the AOI and the number of transitions exiting the AOI was calculated. If the resulting value was positive, the AOI was classed as an entering AOI; if the value was negative, the AOI was classed as an exiting AOI. The results are presented in figure E-5.

PREDICTION DU MODE DE CONDUITE A PARTIR DES STRATEGIES VISUELLES DES CONDUCTEURS EN CONTEXTE AUTOROUTIER




Figure E-5 : Visualisation of exiting AOIs (blue) and AOIs (orange) for manual and automated driving.

The analysis of gaze dynamics during manual driving showed that many more glances were coming in than going out the road centre area. To a lesser extent, the area just below (down area) and the left and central mirror also received more glances in than out. All other AOIs had more exiting glances, apart from the left screen, which was at equilibrium.

Automated driving was characterised by many glances moving away from the road (road centre, left area and down area), and a favouring of areas that provided information about the vehicle’s status (dashboard, HMI) and the adjacent lane (left mirror, left screen). More glances entered the areas not related to the driving task (Others, right screen) than exited.

E.2.5. Discussion

The aim of this work was to try to predict, on the basis of drivers' visual strategies, whether they were driving manually or in autonomous mode. To do this, we analysed how drivers distributed their attention over a set of AOIs that composed the driving environment. We considered both static indicators (percentage of time spent on AOIs) and indicators of gaze dynamics (matrices of transitions between AOIs). The indicators that best predicted the driving mode were selected using PLS regression. The quality of the prediction was then evaluated by examining the ability of the models to distinguish between the two driving modes without error.

The results confirm a recurrent observation in studies of visual strategies in autonomous driving situations. That is, drivers spend less time looking at the road and more time looking at the periphery (Barnard & Lai, 2010; Damböck et al., 2013; Louw & Merat, 2017;

Mackenzie & Harris, 2015; Mars & Navarro, 2012; Schnebelen et al., 2019). Under the experimental conditions in this study, the diversion of the gaze from the road centre area was partly in favour of the lateral visual scene, the central rear-view mirror, the dashboard and the down area. This dispersion of the gaze could have contributed to maintaining good situational awareness, as this may have provided information on the external environment. However, a substantial increase in the number of glances directed at places not relevant to the driving task (Other area) was also reported. Hence, even in the absence of a major source of distraction or secondary task, some disengagement was observed.

In comparison, manual driving appeared stereotypical, with more than two thirds of the driving time spent looking at the road ahead. There were also many transitions back to this area once the gaze had been turned away from it. This phenomenon is explained by the need to maintain good visuomotor coordination to keep the vehicle in its lane.

Previous work has shown that automation of driving is associated with reduced PRC (Carsten et al., 2012; Jamson et al., 2013). Here, we examined the corollary by attempting to predict the state of driving automation based on the observed PRC. The results showed that PRC was indeed a relevant indicator. Categorising drivers on this criterion showed fairly accurate results, although with some error. By considering all areas of potential interest in driving, the quality of prediction increased significantly. The improvement in prediction notably depended on the nature of the indicators. Although it was possible to categorise – without error – the mode of driving according to the percentage of time spent on all AOIs, the quality of prediction was far higher when we also considered the dynamics of transitions between AOIs. The MSEF was reduced 6-fold using the dynamic approach compared to the static approach. Moreover, adding static indicators to dynamic indicators yielded the same pattern of results as that obtained from dynamic indicators alone, with slightly less prediction error.

These results confirm the hypothesis that gaze dynamics are strongly impacted by automation of the vehicle. Specifically, gaze dynamics appear to explain the essence of the distinction between manual and autonomous driving.

As mentioned, considering the transitions between AOIs improved the prediction of the driving mode. It also enabled refining the visual patterns characteristic of manual or

automated driving. For example, during manual driving, static indicators highlighted the predominance of information obtained from the road centre area. Accounting for the gaze dynamics confirmed this observation but also revealed a subtle imbalance in terms of reception versus emission for the left and central rear-view mirrors. Even if glances at the mirrors do not account for substantial visual processing time, they might be essential for the driver to create a mental model of the driving environment.

E.2.6. Conclusion

This study predicted a person's driving mode from visual strategies, using PLS regression. The quality of this prediction depended essentially on gaze dynamics, although the optimal prediction was achieved by examining a combination of static and dynamic characteristics. This study helps to pave the way for developing algorithms to estimate the driver's state in an autonomous vehicle based on oculometric data. Driver monitoring is a challenge in the development of new generations of these vehicles as it may be essential to assess whether the driver is in the loop or out of it, in terms of vehicle control and environmental supervision.

E.2.7. Appendix : step-by-step procedure of PLS regression

This appendix develops step-by-step the procedure to predict the automation state (\mathbf{Y}) from a matrix of gaze behaviour (\mathbf{X}) using PLS regressions. In the experiment, four matrixes of gaze behaviour were considered, so this procedure was applied four times.

Step A: Calculating the optimal number of components

Principle:

PLS models are based on several orthogonal components, which constitute the underlying structure of the prediction model. With many components, the model is complex and highly accurate but also highly specific to the data. By contrast, few components mean a simpler model structure; the model may lose accuracy but can be more generalizable to other datasets. Thus, an optimal compromise in the number of components can prevent data overfitting while maintaining high accuracy.

Application:

This compromise was sought by testing several numbers of components – from one to 10 components. The optimal number would minimise the mean square error of prediction (MSEP) with a leave-one-out procedure.

Step B: Reducing the number of visual indicators

In the previous step, an optimal structure of the prediction model was found, considering certain visual indicators (depending on the matrix of gaze behaviour) to predict the automation state. The aim of this next step was to increase the predictive power – that is, the percentage of variance in **Y** that was explained – by selecting fewer indicators that were relevant for the prediction.

Principle:

The PLS regression is a linear statistical model. Therefore, the relationship between the input matrix (**X**) and the dependent variable to estimate $\hat{\mathbf{Y}}$ was linear:

$$\hat{\mathbf{Y}} = \mathbf{X} * \mathbf{C}$$

where **C** is the matrix of the regression coefficients.

Coefficients can be interpreted as follows:

- Coefficient signs indicate the direction in which a visual indicator (from **X**) influenced the estimation of the automation state ($\hat{\mathbf{Y}}$). If positive, the score increased, meaning that this indicator featured mainly in manual driving. By contrast, a negative coefficient meant that this indicator featured mainly in automated driving.
- A coefficient's magnitude (absolute value) indicates the relative importance of each indicator. If the magnitude of a coefficient was close to zero, the contribution of the visual indicator to the prediction was negligible. By contrast, a large magnitude indicated a crucial indicator in the prediction.

Application:

To reduce the number of visual indicators of **X**, coefficient magnitudes were compared with an increasing threshold value, which ranged from 0.01 to 0.2. A new PLS regression was computed for each partial matrix – that is, a matrix comprising only the indicators

PREDICTION DU MODE DE CONDUITE A PARTIR DES STRATEGIES VISUELLES DES CONDUCTEURS EN CONTEXTE AUTOROUTIER

whose coefficient magnitude exceeded the threshold value. The threshold was increased by steps of 0.005 until the percentage of variance in \mathbf{Y} that was explained by the partial model no longer increased.

At the end of this step, a partial matrix of gaze behaviour that included only the selected visual indicators was computed. This partial matrix was denoted \mathbf{X}^p .

Step C: Computing the mean square error of prediction

The previous steps found the most appropriate parameters for PLS regression models. A new model that considered those parameters was set up, with its coefficients denoted \mathbf{C}^p . Then, the estimations ($\widehat{\mathbf{Y}}^p$) and the MSEP were calculated as follows:

$$\begin{cases} \widehat{\mathbf{Y}}^p = \mathbf{X}^p * \mathbf{C}^p \\ \text{MSEP} = (\mathbf{Y} - \widehat{\mathbf{Y}}^p)^2 \end{cases}$$

PREDICTION DU MODE DE CONDUITE A PARTIR DES STRATEGIES VISUELLES DES
CONDUCTEURS EN CONTEXTE AUTOROUTIER

Partie F: Estimation du phénomène de sortie de boucle à partir des stratégies visuelles des conducteurs en conduite autonome

F.1. Synthèse de l'expérimentation

Dans l'étude précédente, nous avons cherché à distinguer la conduite autonome de la conduite manuelle en fonction des stratégies visuelles des conducteurs. Les résultats ont montré que cette distinction était possible, et que la meilleure prédiction était basée sur les indicateurs statiques et dynamiques. Dans cette partie, nous avons analysé uniquement les données oculaires des conducteurs en conduite autonome, en cherchant à prédire leur niveau de sortie de boucle.

F.1.1. Contexte scientifique et questions de recherches

Dans la littérature, le phénomène de sortie de boucle a toujours été regardé de manière relative, et rapporté aux conséquences qu'il entraîne. Au niveau 3 SAE, plusieurs études ont par exemple étudié les performances de conduite lors de reprises en main (suivant une phase de conduite autonome, donc avec un conducteur présumé moins dans la boucle), à celles de conducteurs en conduite manuelle tenus de réagir au même obstacle (plus dans la boucle). De manière analogue, lorsque le conducteur effectue une tâche secondaire en conduite autonome de niveau 3, ses réactions sont à la fois plus longues et plus brusques au moment de la reprise en main, comparé à des conducteurs n'effectuant pas de tâches secondaires (surtout si la tâche secondaire a une composante motrice).

Dans de telles études, les conducteurs étaient mis dans des situations de conduite totalement différentes, dont l'une était considérée comme une situation de référence avec un conducteur dans la boucle. Cependant, la sortie de boucle peut également arriver spontanément, du fait du temps passé en conduite autonome : du fait d'un manque d'activité, les conducteurs vont avoir tendance à sortir progressivement de la boucle, en

vagabondant par la pensée. En effet, Körber et al. (2015) ont montré une plus forte tendance à vagabonder par la pensée à la fin qu'au début d'un parcours en conduite autonome. Cette sortie de boucle en fonction du temps a également des conséquences visibles au niveau des processus cognitifs. Ainsi, Bourrelly et al. (2019) montre que les conducteurs ont des temps de reprise en main suivant un cas critique plus élevé après une heure de conduite autonome, comparé à une situation analogue présentée après seulement 10 min d'automatisation. De même, le temps de réaction suivant la demande de reprise en main est plus long après 20 min d'automatisation qu'après 5 min d'automatisation (Feldhütter et al., 2017).

Dans cette étude, on considérera la sortie de boucle liée au temps passé en conduite autonome. De ce fait, on analysera les différents indicateurs des stratégies visuelles statiques et dynamiques sur différentes plages temporelles, en considérant entre 1 et 15 min de données avant la fin du parcours, moment où les conducteurs sont le plus susceptibles d'être hors de la boucle. Les différents indicateurs visuels seront mis en relation avec le niveau de sortie de boucle. Ce niveau a été rapporté par les participants, et reflète le pourcentage de temps passé en vagabondage de la pensée. Ce niveau a également été mis en relation avec les résultats à un cas critique présenté à la fin de l'expérimentation.

L'objectif de la présente étude est de répondre à ces deux questions de recherche :

- Est-il possible d'identifier des patterns visuels caractéristiques des conducteurs hors de la boucle en situation de conduite autonome ?
- Est-il possible d'estimer l'état du conducteur dans la boucle de conduite à partir de l'observation de ses stratégies visuelles ?

F.1.2. Résultats principaux et discussion

Pour parvenir à répondre à ces deux questions, nous avons d'abord calculé des matrices recensant les différents indicateurs visuels, sur les 15 premières minutes (apprentissage) et sur les 2 dernières minutes (validation) du parcours en conduite autonome. Les matrices servant pour l'apprentissage différaient par la plage temporelle sur laquelle les indicateurs étaient calculés, de 1 à 15 min.

Un modèle PLS a permis de prédire le score de sortie de boucle, reflétant le temps passé en vagabondage de la pensée reporté par les participants, à partir de chaque matrice d'apprentissage (15 matrices). Une fois ces 15 modèles construits, la précision de chacun de ces modèles a été évaluée à partir de la matrice d'apprentissage (calculant ainsi une erreur d'apprentissage), mais aussi à partir de la matrice de validation (erreur de validation).

Les résultats ont permis de montrer que le meilleur modèle (du point de vue de l'erreur de validation) expliquant le score de sortie de boucle était obtenu pour des indicateurs visuels initiaux calculés sur une plage de 10 min. Même si la prédiction n'est pas parfaite (erreur de prédiction de 0,21 sur l'échantillon d'apprentissage), une forte corrélation est observée entre les données prédites et les données réelles à la fois sur l'échantillon d'apprentissage et de test. Ce résultat supporte l'idée qu'une fois que le modèle de prédiction de sortie de boucle est construit (à partir des stratégies visuelles analysées sur 10 minutes en conduite autonome ; échantillon d'apprentissage), il est possible de l'appliquer sur une fenêtre temporelle plus courte (de 2 minutes dans notre cas ; échantillon de test) et d'obtenir des résultats corrects.

Ce modèle de régression PLS utilise uniquement 12 indicateurs visuels pour aboutir à la prédiction finale. Sur ces 12 indicateurs, 5 sont caractéristiques de conducteurs plutôt sur la boucle et se réfèrent à des prises d'informations tactiques (sur l'écran de gauche où se trouvent majoritairement les autres véhicules ou le rétroviseur gauche. Au contraire, 7 sont plutôt caractéristiques de conducteurs hors de la boucle (plus de temps passé hors de la scène de conduite, y compris sur le tableau de bord et l'IHM embarqué, voire sur la route très peu en amont du véhicule). Ces résultats suggèrent que les conducteurs les plus hors de la boucle prennent plus d'informations visuelles sur des aires non pertinentes pour la tâche de conduite. Même s'ils regardent aussi l'état de leur véhicule et la route immédiate, ils semblent négliger des informations importantes pour construire une bonne conscience de la situation, notamment celles permettant d'anticiper sur la situation future.

F.2. Article Complet

Ce dernier article est en cours de révision pour publication dans *Accident Analysis and Prevention*. L'expérience a été pensée et les résultats développés en étroite collaboration avec Camilo Charron.

F.2.1. Abstract

During highly automated driving, drivers no longer physically control the vehicle but they might need to monitor the driving scene. This is true for SAE level 2, where monitoring the external environment is required; it is also true for level 3, where drivers must react quickly and safely to a take-over request. Without such monitoring, even if only partial, drivers are considered out-of-the-loop (OOTL) and safety may be compromised. The OOTL phenomenon may be particularly important for long automated driving periods during which mind wandering can occur. This study scrutinized drivers' visual behaviour for 18 min of highly automated driving. Intersections between gaze and 13 areas of interest (AOIs) were analysed, considering both static and dynamic indicators. An estimation of self-reported mind wandering based on gaze behaviour was performed using partial least squares (PLS) regression models. The outputs of the PLS regressions allowed defining visual strategies associated with good monitoring of the driving scene. This information may enable online estimation of the OOTL phenomenon based on a driver's spontaneous visual behaviour.

Keywords: mind wandering; gaze behaviour; autonomous vehicles; PLS regression; driver monitoring

F.2.2. Introduction

The deployment of highly automated vehicles on the roads is imminent; it could occur anywhere between 2020 and 2030 (Chan, 2017). Among the expected benefits of autonomous vehicles (environmental, societal, etc), road safety is expected to improve (Fitch et al., 2014). The number of crashes caused by human error could be reduced by 90%, according to Stanton and Salmon (2009). However, to meet that target, drivers must be clearly aware of their role in the vehicle. That role partly depends on the level of automation.

There are five levels of automation (SAE International, 2016), corresponding to a different balance of tasks between the automation and the driver. At levels 0 and 1, the driver is in full or partial control of the vehicle commands. Automated driving starts at level 2, when longitudinal and lateral control of the vehicle is performed by the automation, but the driver must continuously monitor the driving scene and intervene when needed, even

without a request from the system. At level 3 (conditional automation), the driver may engage in secondary tasks, but must be able to regain vehicle control when required by the system. This implies that monitoring the driving scene is only required starting with the take-over request. At level 4 (high automation), under certain conditions, the automation is able to perform all driving functions and can handle critical situations without requesting a take-over, although driver override may be possible. In level 5 (full automation), the vehicle is autonomous in all conditions and the driver's action is no longer required.

In all cases, as soon as the operational part of the driving task is automated, drivers become supervisors of the automation system and of the driving scene. The level of expected supervision decreases as the level of automation increases. In manual driving, drivers must gather information from the driving scene and the vehicle (perceptual process), and must interpret that information (cognitive process) and act appropriately (motor process). Their actions in turn generate information. By contrast, starting with level 2 automation, the perceptual-motor loop is neutralized, which has consequences for perception and cognition (Mole et al., 2019). At level 3, driver engagement in secondary tasks may intensify those consequences, with long periods of distraction from the driving scene. These consequences are referred to in the literature as the out-of-the-loop (OOTL) phenomenon.

The OOTL phenomenon was first observed in the aviation field (Endsley & Kiris, 1995), where automated piloting has long existed. Parasuraman and Riley (1997) showed that human pilots may be poor supervisors of the system. They may enter into a passive state when interacting with highly automated systems, causing a lack of situation awareness (Endsley, 1995). Recently, Merat et al. (2019) proposed an operational definition of OOTL in the context of automated driving. To be OOTL, drivers must lack physical control of the vehicle (motor process) and must not be monitoring the driving scene (perceptual or cognitive process). By contrast, when the driver is in manual control, they are considered to be in-the-loop. An intermediate state, namely on-the-loop (OTL), was introduced to designate cases where the driver correctly monitors the situation during autonomous driving.

In cars, the OOTL phenomenon has mainly been investigated through comparisons of driver behaviour between automated and manual driving. As most of the information processed during driving is visual (Sivak, 1996), the analysis of gaze behaviour has received

much interest. Compared to manual driving, simulated automated driving involves more horizontal dispersion of gaze (Louw & Merat, 2017a; Mackenzie & Harris, 2015) and a lower percentage of glances towards the road centre (Louw, Kountouriotis, et al., 2015; Mackenzie & Harris, 2015). Similarly, in curve driving, automated driving was shown to enhance long-term anticipation through look-ahead fixations, to the detriment of short-term anticipation used to guide the vehicle (Mars & Navarro, 2012; Schnebelen et al., 2019). When a secondary task was performed by drivers, automated driving was associated with relatively frequent fixations on those tasks (Merat et al., 2012).

When drivers are required to regain control of the vehicle, their behaviour after the take-over request is also considered to be an indicator of the OOTL phenomenon. Differences between automated and manual driving, as observed in critical scenarios, indicate that automated driving leads to impaired visuomotor coordination during take-over (Mole et al., 2019). Navarro et al. (2016) showed that gaze distribution was widely dispersed, resulting in difficulties in steering around unexpected obstacles. Furthermore, drivers had longer reaction times to critical events, and vehicular control was impaired (Eriksson & Stanton, 2017a; Gold, Damböck, Bengler, et al., 2013; Louw, Merat, et al., 2015; Neubauer et al., 2012; Saxby et al., 2013; Zeeb et al., 2015, 2017). Such changes in driver behaviour during take-over were attributed to drivers being OOTL during automated driving.

In addition, the OOTL phenomenon seems to increase with a prolonged period of automation. In the aviation field, Molloy and Parasuraman (1996) showed that monitoring performance decreased with time. In the automated driving context, some studies have indicated that prolonged periods of automated driving rendered drivers further OOTL (Bourelly et al., 2019; Feldhütter et al., 2017; Körber et al., 2015). For example, Bourelly et al. (2019) observed longer reaction times (+0.5 s) to a critical event after 1 h of automated driving, compared to reactions to the same event after 10 min.

According to the definition of OOTL in automated driving (Merat et al. 2019), OOTL drivers do not correctly monitor the driving situation. The OOTL state may be experimentally induced by modifying perceptions of the driving environment or through instructions given to the drivers (i.e. using a secondary task). Louw et al. (2015b, 2016, 2017) reduced the visual information available for drivers using simulated fog to examine whether the driver was further OOTL when the fog was dense. In that sense, the OOTL

state mostly occurred through impairment of perception. In other studies (Carsten et al., 2012; Merat et al., 2012), monitoring of the driving environment was altered by a secondary task. In these cases, the degradation of both perceptual (eyes off-road) and cognitive processes (mind off-road) yielded the OOTL phenomenon.

However, OOTL may also spontaneously and progressively occur without any modification of the driving environment or the presence of a secondary task. Due to lack of activity, drivers can experience mind wandering (MW), progressively disengaging from the supervision task even in the absence of an external source of distraction (Körber et al., 2015; Feldhütter et al., 2017; see also Gouraud et al., 2017 for a detailed review of the links between the OOTL phenomenon and MW). MW may occur at level 2, when the driver is supposed to monitor the driving scene. It may also happen at level 3 if the driver chooses not to engage in secondary tasks. In both cases, MW can be more difficult to assess than visual distraction, since gaze is not diverted from the driving scene.

The OOTL state was defined in previous studies in a relative way: either drivers are more OOTL when automation is on, compared to manual driving; or they are more OOTL during prolonged automation, compared to a shorter duration. In all cases, the OOTL phenomenon impacts driver safety during take-over, especially during long automated drives. Hence, determining whether a driver is OOTL or OTL must be performed before any situation requiring a take-over.

This study estimated the driver's state based on the observation of spontaneous gaze behaviour. The participants experienced an 18-min drive of automated driving (similar to Feldhütter et al. 2017), with the OOTL phenomenon occurring spontaneously due to MW. Quantitative assessment of the OOTL state was based on the self-reported time of MW. The drivers' gaze behaviour was analysed by considering 13 areas of interest, using static and dynamic indicators. Static indicators refer to the percentage of time the gaze is directed to one AOI and dynamic indicators refer to transitions from one AOI to another. An original method was used that involved multiple partial least squares (PLS) regression analyses. The goals were 1) to identify and select the most important gaze indicators, and 2) to generate models for the relationship between gaze behaviour and MW score. The principle of this methodological choice was to identify the essential indicators from the overall spontaneous gaze behaviour, without relying on theoretical preconceptions.

The research was guided by two research questions:

1. Is it possible to identify gaze behaviour that is characteristic of OOTL drivers? (i.e. what constitutes inadequate monitoring of a driving situation?)
2. Is it possible to estimate the driver's OOTL state from the observation of spontaneous gaze strategies?

F.2.3. Materials and methods

F.2.3.1. Participants

The study involved 12 participants (N = 12; 3 female, 9 male), with a mean age of 21.4 years (SD = 5.34 y). To facilitate the recording of accurate gaze data, volunteers were required to have either normal vision or vision corrected with contact lenses. They all held a valid driver's license, with average driving experience of 9950 km/year (SD = 5500). They signed written informed consent to participate.

F.2.3.2. Experimental Setup

Figure F-1 presents the driving simulator setup. This fixed-base simulator consisted of an adjustable seat, a steering wheel with force feedback, a gear lever, clutch, accelerator and brake pedals. The driving scene was generated with SCANeR Studio (v1.6) and displayed on three large screens in front of the driver (field of view $\approx 120^\circ$). A dashboard screen indicated the speed of the vehicle. An HMI screen was added to the right-hand side of the driver, approximately where a vehicle's centre console is located. The description of the HMI can be found in the Procedure section.

Gaze data were recorded using a Smart Eye Pro (V5.9) eye-tracker with four cameras; two were below the central screen and one below each peripheral screen. The calibration was performed in two steps. First, a 3D model of the driver's head was computed using an 11-point head calibration procedure with the head and gaze oriented toward the points. Then, the gaze was calibrated using 15 points: nine on the central screen, two on each peripheral screen, one on the dashboard and one on the HMI screen; with the head oriented to the central screen and gaze directed to the points. Gaze data were synchronized and recorded with vehicle data at 20Hz by the driving simulator software.



Figure F-1 : Driving simulator setup

Most of the road was a 40-km two-lane dual carriageway, with a speed limit of 130 km/h in accordance with French regulations. Occasional changes in road geometry and speed limits were included to make the driving less monotonous. This included temporary 3-lane traffic flow, highway exits, slope variation and variation of the speed limit (130 km/h to 110 km/h). In both directions on the highway, traffic was fluid, with eight overtaking situations.

F.2.3.3. Procedure

The participants first adjusted the seat position, and the gaze calibration procedure was performed. Then, they drove manually along a training track to become accustomed to the driving environment and the vehicle's reactions. Once this training session was completed, instructions for automated driving were given orally.

Drivers were told that the automated function would only be available for a portion of the road. The distance and time remaining in the autonomous mode were displayed on the left of the HMI. When activated by pressing a button, the automation controlled the lateral position and speed of the vehicle appropriately, accounting for traffic, speed limits and other conditions, and overtaking other cars if necessary. Participants were instructed to take control of the vehicle when requested by the system.

Two possible use cases were presented to the participants. In the first case, the vehicle was approaching the end of the automated road section. The drivers would receive mild

ESTIMATION DU PHENOMENE DE SORTIE DE BOUCLE A PARTIR DES STRATEGIES VISUELLES DES CONDUCTEURS EN CONDUITE AUTONOME

auditory and visual warning signals and would have 45 s to regain control. The second use case was an unexpected event, such as the loss of sensors. In this case, an intense auditory alarm would sound and a new pictogram would be displayed, and drivers would have only 8 s to resume control. All the pictograms and sounds used by the HMI were presented to participants before they began a second training session. The pictograms are shown in figure F-2.




Figure F-2 : Pictograms displayed on the HMI. A, autonomous driving available; B, autonomous driving activated; C, critical take-over request (8s); D, planned take-over request (45s)

The second training session allowed participants to experience semi-automated driving (SAE level 1): cruise control with the driver in charge of the steering wheel; and level 3: conditional automation. At level 3, there were four transitions to manual control, two in each use case presented in the instructions. All take-overs were properly performed during the training session.

The experiment itself then commenced. The study followed a within-participant design, with all participants driving under both automated and semi-automated conditions. These conditions were similar, but no critical case happened in the semi-automated condition. However, because this paper concerns the analysis and modelling of gaze behaviour during automated driving, only the results obtained during the automated condition are presented here.

In the automated driving condition, participants activated the automated driving mode just before entering a highway. Gaze data were recorded as soon as the vehicle was correctly inserted in the lane and had reached 130 km/h. No major driving events or take-over request occurred in the first 15 min on the road, to allow enough time for the driver to become OOTL. The driver did not perform any secondary task during that time.

Between minutes 16 and 17, the two vehicles that would be involved in the critical case appeared in the driving scene. One overtook the participant's vehicle on the left and positioned itself in the right lane, 300 m ahead. The other vehicle remained in the left lane, slowly approaching the participant's vehicle. During minute 18 of automated driving, participants experienced a critical take-over request occurring in response to unexpected braking from the lead vehicle. The warning signals were delivered as soon as the lead vehicle started to brake, with a time-to-collision of 8 s. At that moment, the lead vehicle was in the adjacent lane, in the blind spot of the participant. Changing lane would lead to a collision. To successfully handle the critical situation, drivers had to brake, remain in the right lane until the overtaking vehicle had passed, and then change lanes to avoid the lead vehicle. The scenario ended 30 s after the critical case.

Participants were then asked to report on a continuous Likert scale the proportion of time they had spent thinking about something other than the driving task, throughout the trial. This simple method of MW self-assessment has been shown to be sensitive to driver disengagement during prolonged driving sessions (Mars et al., 2014).

F.2.3.4. Data Structure and Annotations

F.2.3.4.1 Definition of the MW Score Y

In the absence of a secondary task, the evaluation of the percentage of time spent thinking about something other than the driving task was regarded as a self-assessment of the MW. The higher the percentage, the more the driver had estimated being OOTL. Percentages for all participants were stored in a vector with 12 elements. After standardization of the data (conversion to a z score), the vector was denoted as Y and named MW score.

F.2.3.4.2 Definition of the matrix of gaze behaviour X

The driving scene was divided into 13 areas of interest (AOI), as shown in figure F-3. These are described below.

a) The central screen contained six AOIs:

- central mirror (CM)
- road centre (RC), defined as a circular area of 8° radius in front of the driver
- four additional areas, defined relative to the road centre (Up, Left, Down, Right).

ESTIMATION DU PHENOMENE DE SORTIE DE BOUCLE A PARTIR DES STRATEGIES VISUELLES DES CONDUCTEURS EN CONDUITE AUTONOME

The percentage road centre (PRC) is defined as the proportion of time spent in RC, as introduced by Victor (2005). A decrease in PRC was found to be a reliable indicator of distraction during driving; drivers reduced their PRC when visually or auditorily distracted (Victor et al., 2005).

b) Each peripheral screen contained two areas, with two items in each:

- lateral mirror (LM, RM)
- the remaining peripheral scene (LS, RS)

c) The dashboard (D)

d) The HMI (HMI)

e) All data for gazes directed outside all the above areas were grouped as “other areas” (Others).

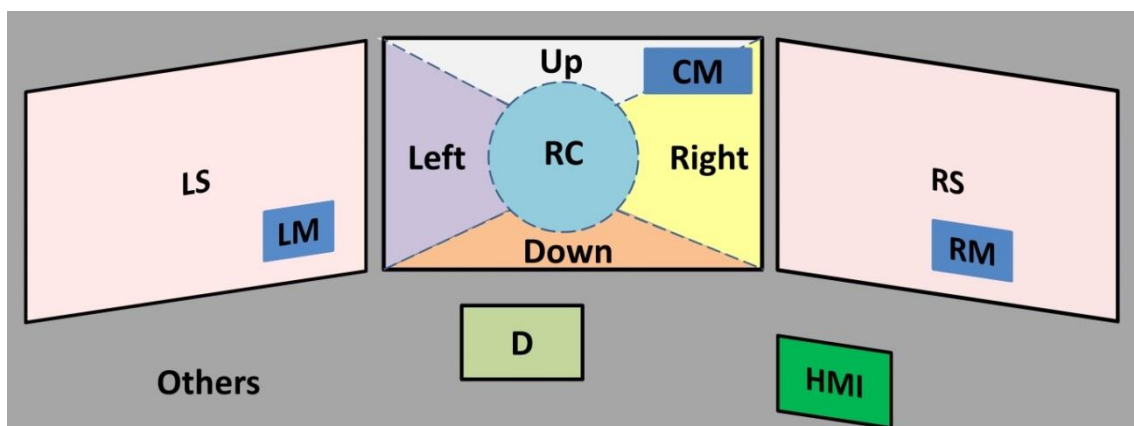


Figure F-3 : Division of the driving environment into 13 areas of interest

The percentage of time spent gazing at each AOI was computed, as was a matrix of transitions between AOIs. Using Markov logic, the matrix of transitions between AOIs corresponded to the probability of shifting from one AOI to another. The probability that gaze remained in the same AOI was also computed. This constituted the diagonal of the transition matrix. Probabilities were estimated by the observations of the participants (see Gonçalves et al., 2019, for an application of Markov chains in case of a lane change manoeuvre). Before a given AOI was intersected for the first time, a prior probability was associated with it. A uniform law was used for prior probabilities.

The 13 AOIs defined the entire world. Thus, the transition matrix was a 13*13 matrix. If rows contained the current AOI and columns the probabilities, the sum of each row was equal to 1. In all cases, next gaze intersection appears in one of the 13 areas of interest.

In this study, the driver's gaze behaviour for each participant was considered to be the combination of static and dynamic indicators of gaze behaviour. Static refers to percentage of time in one AOI; dynamic refers to the transition matrix. Thus, the gaze strategy of a participant was represented by a vector of 182 numerical indicators (= 13*13 transitions + 13 percentage of time on each AOI). When considering all participants, the matrix of gaze strategies was named \mathbf{X} , and its size was 12 (participants) * 182 (visual indicators).

Supplementary indicators that were sensitive to drivers' drowsiness were also computed. These included percentage of eye closure (PERCLOS; see Wierwille et al., 1994) and the blink-rate (Stern et al., 1994).

F.2.3.4.3 Computation of training and validation datasets

The objective was to predict the MW score as a function of gaze behaviour. Therefore, a training dataset (i.e., a gaze-behaviour matrix to create the model) and a validation dataset (a gaze-behaviour matrix to evaluate the model) were required.

The gaze-behaviour matrix obtained during the last two minutes (16 and 17) of automated driving was chosen as the validation dataset. The rationale was that because OOTL increases with automation duration, the final two minutes might reflect the visual consequences of the OOTL phenomenon most accurately. The validation dataset did not include the gaze data recorded once the take-over request was initiated.

Nevertheless, the question of the speed of appearance of OOTL and the observation time required to model it was of interest. To answer this question, 15 training datasets (i.e. 15 gaze-behaviour matrixes), labelled \mathbf{X}_p , were calculated. The difference between the sets was the integration time – that is, the duration of automated driving while the matrix of gaze behaviour was computed. The integration time varied from 1 min to 15 min. The reference for the time window was the 15th minute of simulation (i.e. immediately before the validation dataset). Thus, \mathbf{X}_1 considered gaze behaviour during one minute (the 15th minute), whereas \mathbf{X}_7 was computed from seven minutes of automated driving (between the

9th and 15th minutes). The rationale was to evaluate whether using a short time window was enough to capture the consequences of OOTL to create a satisfactory model, or whether aggregating more data by enlarging the time window would make the model more robust.

In summary, 15 matrixes of gaze behaviours (labelled \mathbf{X}_t for t between 1 and 15 min) were calculated, and these constituted the training datasets for the model. Once the best model had been selected, we validated it by comparing the MW score to the model's prediction based on the two final minutes of driving (16th and 17th minutes).

F.2.3.4.4 Choice of model for prediction: PLS regression

Regarding the data structuring described above, the aim was to predict \mathbf{Y} (MW score) from \mathbf{X}_t (gaze-behaviour matrix), given the following conditions:

- Visual indicators (\mathbf{X}_t) are correlated. The driving environment was divided into 13 AOIs, hence, the percentage of time spent on 12 AOIs enabled calculating the percentage of time spent on the 13th AOI. In mathematical terms, \mathbf{X}_t might not be full rank.
- The number of visual indicators (182) that could explain \mathbf{Y} is higher than the number of observations made on the participants (12).

Considering these constraints, the PLS regression model was selected. PLS regression yields the best estimation of \mathbf{Y} available with a linear model given the matrix \mathbf{X}_t (Abdi, 2010). All PLS regressions performed in this study used the PLS regression package (Wehrens & Mevik, 2007) from R (Core Team et al., 2013).

F.2.3.5. Data analysis

Four sequential stages composed the analysis of the training datasets (\mathbf{X}_t) (see figure F-4):

1. Step A entailed finding the optimal structure (i.e. the optimal number of components) of the PLS regression model for predicting the MW score.
2. Step B entailed selecting the visual indicators that significantly contributed to MW score prediction.
3. In Step C, we considered the optimal parameters (components and visual indicators) of the prediction model, and evaluated the model's accuracy using the

mean square error of prediction (MSEP) for both the training and validation datasets.

4. In Step D, we selected the model with the least validation error.

The step-by-step procedure of the data analysis is presented in the appendix. Only the final results, which lead to model selection, are presented in the next section (Results).




Figure F-4 : Data analysis was performed in four sequential steps. First, the best parameters of the PLS regression models were identified. This entailed finding the optimal number of components and reducing the number of visual indicators (Steps A and B). Then, in this optimal configuration, the accuracy of the models was considered by computing the mean square error of prediction, for both training and validation datasets (Step C). In the last step (Step D), the model with the lowest validation error was selected and interpreted.

F.2.4. Results

F.2.4.1. MW Score and Drowsiness Indicators

Figure F-5 shows that the self-reported MW scores varied widely among participants. The median score was 43%, but four participants (participants 9 to 12) estimated that they had spent more than 70% of the time thinking about something other than the driving task. Those four participants failed in the critical case. Two other participants (3 and 4) also

failed, with moderate MW scores of around 30%. All other participants managed to avoid a collision.




Figure F-5 : MW scores reported by the participants according to the outcome in the critical case. The colour of the marker indicates whether participants passed (green) or failed (red) the critical case. The dashed lines represent the the average of the successful or failed groups. Participants are sorted according to their MW score, not their order of passing the experiment

Mean PERCLOS and blink-rate per participant showed no significant correlation with MW score ($r = 0.25$ and $r = -0.49$ respectively). The highest PERCLOS score was 4.73%, obtained by participant 2. Furthermore, a paired t-test revealed no significant differences for either PERCLOS or blink-rate between the first and last five minutes of automated driving ($p = 0.28$ and $p = 0.11$ respectively).

F.2.4.2. Selection of best model for MW Score prediction

Results obtained for all different training datasets at the end of the PLS regression procedure (see appendixes for details) are presented in tableau F-1.

Tableau F-1 shows that the training error was small (<0.25) in all cases and it depended on the structure of the model (i.e. number of components). The models having the most components (time windows of 1, 5, 7 and 8 minutes) predicted the learning dataset almost perfectly (MSEP <0.001). However, MSEP for the validation dataset was comparatively high. As the time window increased, the validation error decreased, attaining the minimal value (0.419) for 10 min of data. Thereafter, adding more data by expanding the time

window increased the MSEP. Thus, ultimately the best model for predicting MW score from the last two minutes of driving was obtained by aggregating the gaze data for the 10 min that preceded those final minutes.

Time Window (min)	Optimal number of components (step A)	Number of selected visual indicators (step B)	Mean square error of prediction with training dataset (step C)	Mean square error of prediction with validation dataset (step C)
1	3	56	<0.001	0.478
2	1	26	0.200	0.625
3	1	26	0.122	0.697
4	1	16	0.054	0.915
5	3	52	0.002	0.721
6	1	19	0.233	0.542
7	4	88	<0.001	0.563
8	5	80	< 0.001	0.522
9	1	11	0.224	0.443
10	1	12	0.211	0.419
11	1	8	0.130	0.446
12	1	7	0.131	0.496
13	1	57	0.248	0.533
14	1	3	0.141	0.598
15	1	3	0.147	0.595

Tableau F-1 : Optimal number of components, number of selected visual indicators and mean square error of prediction (for both training and validation datasets) as a function of the time window. A minimum of validation error was found for gaze data computed over 10 minutes of automated driving (0.419).

F.2.4.3. Final Prediction of MW Score

After identifying the best model, it remains to be determined what visual indicators were most important for predicting the MW score and how well the predicted scores were correlated to the actual scores.

F.2.4.3.1 Visual indicators

The best PLS model retained only 12 visual indicators to predict the MW score. The PLS regression coefficients and the correlation coefficients between MW score and the 12 selected visual indicators are presented in Tableau F-2. Figure F-6 illustrates the visual indicators retained by the model.




Figure F-6 : Visual indicators relevant for MW score prediction.

The influence of a visual indicator on MW score is displayed in colour: red shows an increase in MW score, and green shows reduced MW score. Arrows represent transitions between AOIs. Filled areas, or name written in red (in the case of Others) means that percentage of time spent gazing in the AOI was selected by PLS regression.

Of the 12 indicators, eight were dynamic (transitions between AOI) and four were static (percentage of time spent in the area). The signs of the coefficients (see tableau F-2) indicate that seven of them contributed to an increase of the MW score estimation. These are shown in red in figure F-6, and can be summarized as follows: 1) taking the gaze off the central mirror to look away from the driving scene, 2) taking the gaze off the road centre area, to look down or away from the driving scene, and 3) spending too much time in the down area or on the dashboard.

By contrast, five indicators contributed to a reduction in MW score estimation, shown in green in figure F-6. These consisted of 1) redirecting the gaze to the road from any area outside the driving scene (Others), 2) regularly checking the surroundings by looking at the left view mirror or the left side screen.

Impact on the prediction	Visual indicators	PLS regression coefficients	Correlation coefficients
Decreases the MW score	Transition from the Central Mirror to the Left Screen	-0.098	-0.65*
	Transition from Others to the Left Screen	-0.096	-0.63*
	Transition from the Others to the Road Centre	-0.093	-0.61*
	Transition from the Road Centre to the Left Mirror	-0.091	-0.63*
	Percentage of time spent in the Left Mirror	-0.089	-0.58*
Increases the MW score	Percentage of time spent in the Others Area	0.087	0.58*
	Percentage of time spent in the Dashboard	0.094	0.62*
	Transition from the Central Mirror to the Others Area	0.099	0.66*
	Transition from the Road Centre to the Others Area	0.101	0.67*
	Transition from the Road Centre to the Down area	0.102	0.66*
	Multiple gazes in the Down area	0.108	0.71**
	Percentage of time spent in the Down area	0.115	0.76**
Non-selected static indicators	Percentage of time spent in the Road Centre (PRC)		-0.16
	Percentage of time spent in the Central Mirror		-0.14
	Percentage of time spent in the Right Mirror		-0.09
	Percentage of time spent in the HMI		0.47

Tableau F-2 : Coefficients of the PLS regression and correlation coefficients between the MW score and the visual indicators (* $p < 0.05$; ** $p < 0.01$). The 12 first indicators correspond to those shown in Figure F-6, which were used for the final prediction of MW score. The last four static indicators were not selected by the PLS regression, but are reported for discussion.

F.2.4.3.2 .Prediction of MW score

Figure F-7 presents the results of estimating the MW scores using the best model (time window = 10 min; 12 visual indicators; 1 component) for the training dataset (A) and the validation dataset (B).




Figure F-7 : Correlation plots between the (real) MW score and the predictions of the MW score by PLS regressions on the training dataset (A) and the validation dataset (B). All the values presented here are standardized.

As discussed in the previous section, the PLS model with the training data provided an accurate estimation of the MW score. The mean square error of prediction was low (MSEP=0.21) and a significant positive correlation was noted between the predicted and real values ($r=0.88$, $p<0.01$). The prediction was not as accurate with the validation dataset (MSEP=0.42), but a significant positive correlation was still obtained ($r=0.82$, $p<0.05$). The goodness-of-fit of this model was computed using R-squared values for training and validation, which were 0.76 and 0.67, respectively. The assessment of goodness-of-fit can also be performed using the model residuals. These results are provided in the Appendix.

F.2.5. Discussion

The OOTL phenomenon results from the combination of a driver not having physical control of their vehicle and incorrectly monitoring the driving situation (Merat et al, 2019). The alternative state, OTL, indicates a driver who satisfactorily monitors the driving environment during automated driving. Monitoring of the driving situation may be impaired when actively engaged in a secondary task. It can also take the form of mindwandering, i.e cognitive disengagement from the driving task due to lack of activity.

This study specifically investigated the second form of the OOTL phenomenon. Whatever the reason of being OOTL, the question of how to model and quantify what constitutes proper monitoring of the driving scene remains debatable. The study addressed this question by distinguishing OTL and OOTL drivers in a highway driving context.

The method consisted of using multiple PLS regressions to identify characteristic elements of the gaze behaviour of OTL and OOTL drivers. The multi-step approach began with 182 indicators as an input matrix, accounting for both static elements (cumulative time spent in 13 AOIs) and dynamic elements (transitions between AOIs). These visual indicators were computed for different time windows to assess the evolution of the OOTL phenomenon over time. Once the optimal parameters of each model were calculated, the MW scores were predicted. Finally, a linear combination of the most important indicators enabled estimating the driver's MW score accurately.

F.2.5.1. What constitutes good monitoring of a driving situation?

The results revealed that drivers with relatively low MW scores made many transitions from the road centre to the left rearview mirror. In total, they spent more time looking at the mirror. They also looked at the left screen, where they could monitor traffic, immediately after gathering information from the central mirror. After spending time looking at areas unrelated to driving (“Others”), they frequently returned their gaze to the road (road centre area) or to the left screen. By contrast, drivers with relatively high MW scores made many transitions from the road centre to areas irrelevant to driving, where they gazed for a considerable time. They also gazed often at the lower part of the front screen and the dashboard.

These findings can be interpreted in terms of the adequacy of the driver's gaze strategy to maintain sufficient situation awareness (Endsley, 1995) in autonomous mode. According to Merat (2019), situation awareness during automated driving involves three dimensions: perception, comprehension and projection. In the current study, OTL drivers remained dynamically aware of their surroundings by regularly checking the road ahead, the left lane and the left rearview mirror. Doing so helped them to anticipate future hazards and avoid difficulties when reacting in the final critical case. These gaze strategies allowed them to

ESTIMATION DU PHENOMENE DE SORTIE DE BOUCLE A PARTIR DES STRATEGIES VISUELLES DES CONDUCTEURS EN CONDUITE AUTONOME

perceive, comprehend and project the future state of the driving situation appropriately. In other words, they had adequate situation awareness.

By contrast, the OOTL drivers' gaze was more strongly attracted by irrelevant information outside the simulator. Even when looking at the driving environment, the driver favoured gazing at the road immediately in front (Down Area) and monitored their vehicle speed on the dashboard. Although OOTL drivers continued to correctly perceive the state of their vehicle and its position in the lane, they showed relatively few signs of visual anticipation by looking far ahead and they paid relatively little attention to other vehicles on the road.

Previous studies (Carsten et al., 2012; Louw et al., 2016) showed that manual drivers displayed a higher percentage of looking at the road centre (PRC) than drivers with automation. In these studies, secondary tasks were allowed or required by the experimental procedure. By contrast, in the current study, PRC did not emerge as a critical indicator (see Table 2). This was the case for most static indicators. This finding indicates that a good monitoring of the situation is not so much a matter of spending considerable time looking at the road. It looks more important to regularly check relevant objects in the scene. Thus, considering the transitions between areas is more important than the amount of time spent on a particular area. For instance, moving the gaze away from the road centre might indicate a relatively high level of disengagement if the driver repeatedly looks at irrelevant areas. However, it could also contribute to situation awareness if the gaze moves to the left rearview mirror.

The multiple PLS regression method allowed us to identify markers of the OOTL phenomenon from a rich set of data on drivers' gazes. This identification might have been achieved with simpler approaches, for example by examining the mean difference in visual indicators between two groups of participants, namely those having high or low MW scores. It might also have been possible to examine only the correlations between MW score and individual indicators. In this case, however, an a-priori selection should have been made, given the number of possibilities (182 indicators, with 13 AOI). Furthermore, individual correlations would not account for relationships between indicators. The advantage of PLS regression analysis is that all visual indicators are considered together to optimize the prediction of MW scores.

F.2.5.2. Is it possible to estimate drivers' OOTL state from the observation of spontaneous gaze strategies?

The results of the modelling work show that the best estimation of the MW score was obtained by considering 10 minutes of gaze data. The least prediction error occurred when the training dataset was used; however, performance was also good for the validation dataset (i.e. only two minutes of driving data, which were not used for the model determination).

It can be concluded that the influence of the driver's state on their gaze strategy was qualitatively similar during the last two minutes of automated driving as it had been during the previous 10 minutes. This point suggests that detecting the OOTL state could perhaps be performed using a shorter time window than 10 minutes. This is interesting from the perspective of defining an algorithm for real automated vehicles to monitor the driver's state. However, further tests are necessary, notably with other participants and in other driving contexts.

The results also suggest that the OOTL phenomenon took some time to appear and that it increased with the duration of automated driving (Bourrelly et al., 2019; Feldhütter et al., 2017; Körber et al., 2015). The prediction error decreased when more gaze data were considered, but the minimal value occurred for 10 minutes. Beyond this point, the error gradually increased. This finding can probably be explained by the fact that considering more than 10 minutes of gaze data meant aggregating data from the beginning of the scenario. During the initial minutes, drivers had not had enough time to become OOTL.

The influence of the OOTL phenomenon has often been assessed in terms of its consequences in a take-over situation. Drivers who are OOTL usually react relatively late and inefficiently when a critical event occurs, especially after a long time spent in automation (Neubauer et al., 2012; Gold et al., 2013; Saxby et al., 2013; Louw et al., 2015b; Zeeb et al., 2015, 2017; Eriksson and Stanton, 2017, Bourrelly et al., 2019). More direct assessment of the OOTL phenomenon may also be performed using post-trial questionnaires (see for instance Lu et al., 2017, for an interesting approach in evaluating situation awareness). In the present study, the drivers' state was assessed by asking the participants to report their level of MW. The results showed that drivers with the highest

level of MW all failed to take over adequately, which implies that they were indeed OOTL. Nevertheless, failure to correctly manage the critical situation also occurred for two participants, who reported only a moderate level of MW. This finding suggests that the quality of a take-over is not entirely determined by the degree of OOTL before the take-over request. The skills of the driver to quickly recover situation awareness and to handle the vehicle in the time allocated may also be essential aspects.

A last point worth mentioning is that the MW scores were not correlated to drowsiness indicators (PERCLOS and blink-rate). The two indicators remained lower than values typically associated with drowsy states during driving. (PERCLOS of $>12.5\%$ was used to categorize drowsy drivers in Hanowski et al. 2008). Thus, we concluded that the MW score did not reflect driver fatigue in our experiments. This result might be different for an extended period of automated driving, during which participants might fall asleep. This was observed by Bourrelly et al. (2018) in a 1-h test run of automated driving. It remains to be determined whether the multiple PLS approach we propose can discriminate between the two phenomena. The value of the PLS approach to realize an integrated diagnostic must also be determined.

F.2.6. Conclusion

We investigated whether drivers' gaze behaviour could be used to detect the OOTL phenomenon during automated driving. The results indicate that the gaze dynamics appear to be a crucial point: being OTL required frequent gaze shifts to the road while also obtaining tactical information about the oncoming situation.

The OOTL phenomenon was induced in this study by a relatively monotonous driving task in the absence of external distraction. However, being out of the loop may also be due to the engagement of attention in a secondary task, an expected consequence of Level 3 automation. In this case, changes in driver behaviour will most likely be characterised by a massive redirection of attention to external displays. It would be interesting to assess whether dynamic indicators will be essential to improve the estimation of the driver's state or whether static indicators, such as the time spent without looking at the road, are sufficient. The method used in this study could help to answer this question.

To more accurately detect the OOTL phenomenon during automated driving, the analysis of gaze behaviour could perhaps be coupled with other approaches. For example, physiological measurements or the analysis of the driver's posture could be incorporated in the diagnosis.

F.2.7. Appendices

F.2.7.1. Step-by-step procedure of PLS regression

This appendix develops step-by-step the procedure to predict the MW score (\mathbf{Y}) using PLS regressions. We used a training dataset (matrix of gaze behaviour computed over a given time window t , \mathbf{X}_t) and a validation dataset (matrix of gaze behaviour computed over the two final minutes of automated driving, \mathbf{X}_{val}).

Steps A and B were performed with the training datasets and enabled computing the optimal parameters (number of components and relevant visual indicators) of the prediction models. With that configuration, the accuracy of the model was tested for both the training and validation datasets (Step C).

Step A: Calculating the optimal number of components

Principle

PLS models are based on several orthogonal components, which constitute the underlying structure of the prediction model. With many components, the model will be complex and highly accurate but also very specific of the data. By contrast, few components will mean a simpler model structure. The model may lose accuracy but may be more generalizable to other datasets. Thus, an optimal compromise in the number of components can prevent data overfitting while maintaining high accuracy.

Application

This compromise was sought by testing several numbers of components (from one to 10 components). The optimal number of components would minimize the mean square error of prediction (MSEP), with a leave-one-out procedure.

Step B: Reducing the number of visual indicators

In the previous step, an optimal structure of the prediction model was found, considering all possible visual indicators (182) to predict the MW score. The aim of this next step was

to increase the predictive power (i.e. the percentage of variance in \mathbf{Y} that was explained) by selecting fewer indicators.

Principle

Because PLS regression is a linear statistical model, the relationship between the training dataset (\mathbf{X}_t) and the dependent variable to estimate $\hat{\mathbf{Y}}_{t,\text{train}}$ was linear:

$$\widehat{\mathbf{Y}}_{t,\text{train}} = \mathbf{X}_t * \mathbf{C}_t$$

where \mathbf{C}_t is the matrix of the regression coefficients.

Coefficients can be interpreted as follows:

- Coefficient signs indicate the direction in which a visual indicator (from \mathbf{X}_t) influenced the estimation of the MW score ($\hat{\mathbf{Y}}_{t,\text{train}}$). If positive, the MW score increased. By contrast, a negative coefficient meant that the MW score decreased.
- A coefficient's magnitude (absolute value) indicates the importance of each indicator relative. If the magnitude of a coefficient was close to zero, the contribution of this visual indicator to the prediction would be negligible. By contrast, a large magnitude indicated a crucial indicator in the prediction.

Application

To reduce the number of visual indicators of \mathbf{X}_t , coefficient magnitudes were compared with an increasing threshold value, which ranged from 0.01 to 0.2. A new PLS regression was computed for each partial matrix (i.e. a matrix comprising only the indicators whose coefficient magnitude exceeded the threshold value). The threshold was increased by steps of 0.005 until the percentage of variance in \mathbf{Y} that was explained by the partial model no longer increased.

At the end of this step, a partial matrix of gaze behaviour, which included only the selected visual indicators, was computed for the training and validation datasets. These partial matrixes are denoted \mathbf{X}_t^p and $\mathbf{X}_{\text{val}}^p$ for the training and validation datasets, respectively.

Step C: Computing the mean square error of prediction

The previous steps found the most appropriate parameters for PLS regression models (number of components in Step A and relevant visual indicators in Step B) for predicting

the MW score. A new model that considered those parameters was set up, with its coefficients denoted \mathbf{C}_t^p . Then, the estimations from the training and validation datasets for a given time window t were calculated as follows:

$$\begin{cases} \widehat{\mathbf{Y}}_{t,\text{train}}^p = \mathbf{X}_t^p * \mathbf{C}_t^p \\ \widehat{\mathbf{Y}}_{t,\text{val}}^p = \mathbf{X}_{\text{val}}^p * \mathbf{C}_t^p \end{cases}$$

From those estimations, the mean square error of prediction was:

$$\begin{cases} \text{MSEP}_t^{\text{train}} = \overline{(\mathbf{Y} - \widehat{\mathbf{Y}}_{t,\text{train}}^p)^2} \\ \text{MSEP}_t^{\text{val}} = \overline{(\mathbf{Y} - \widehat{\mathbf{Y}}_{t,\text{val}}^p)^2} \end{cases}$$

where \mathbf{C}_t^p are the coefficients of the PLS regression, computed from the partial matrixes with the optimal number of components for time window t ; and the terms \mathbf{X}_t^p and $\mathbf{X}_{\text{val}}^p$ refer to the partial matrixes of gaze behaviour for the training and validation datasets, respectively.

F.2.7.2. Goodness-of-fit based on model residuals

Due to the standardization of the data, MW score may be interpreted as Z-scores. Consequently, the residuals are significantly different from 0 with a 95% confidence level if their value is outside the range $[-1.96, 1.96]$. Figure F-8 shows that residuals for each different participant are within this range for both the validation and training datasets. This demonstrates that the model is well-fitted for all participants in all cases.




Figure F-8 : Residuals from the PLS regression models for the training (left) or validation (right) datasets. All residuals are within the confidence interval $[-1.96, 1.96]$ (red dotted lines).

ESTIMATION DU PHENOMENE DE SORTIE DE BOUCLE A PARTIR DES STRATEGIES
VISUELLES DES CONDUCTEURS EN CONDUITE AUTONOME

Partie G: Discussion générale et perspectives

Ce travail de thèse a porté sur l'étude des stratégies visuelles des conducteurs en situation de conduite autonome. Pour les niveaux de conduite autonome considérés dans cette thèse, le conducteur conservait un rôle important, celui de superviseur. Ainsi, le niveau 2, dans lequel le conducteur doit superviser le véhicule de manière similaire à la conduite manuelle, et le niveau 3, pour lequel le conducteur doit être apte à réagir à tout moment, nécessitant de sa part un monitoring partiel (mais pas continu) de la scène de conduite ont été étudiés. Les stratégies visuelles ont été traitées de différentes manières dans les différentes études, en considérant la distribution angulaire du regard ou une décomposition de la scène de conduite en aires d'intérêts. Une attention particulière a été apportée à la modélisation de la dynamique des stratégies visuelles.

Ce doctorat s'est construit expérimentalement autour de deux objectifs principaux :

- Étudier l'adaptation des stratégies visuelles à la délégation de conduite dans deux contextes différents : dans une série de virages avec une automatisation de niveau 2 (partie D) et sur autoroute avec une automatisation de niveau 3 (partie E)
- Mettre en évidence des stratégies visuelles permettant d'estimer la sortie de boucle du conducteur en conduite autonome (parties F).

Cette partie du manuscrit développe chacun de ces deux objectifs, puis une discussion globale des apports et des limites du doctorat.

G.1. Adaptation des stratégies visuelles à l'automatisation de la conduite

Les résultats issus de la littérature (Barnard & Lai, 2010 ; Carsten et al., 2012 ; Damböck et al., 2013 ; Jamson et al., 2013 ; Llaneras et al., 2013 ; Louw & Merat, 2017 ; Mackenzie & Harris, 2015 ; Mars & Navarro, 2012 ; Navarro et al., 2016) montrent un transfert clair des fixations centrales (servant au contrôle opérationnel du véhicule, notamment au maintien du véhicule sur la voie) vers les fixations plus périphériques en conduite autonome. Ces informations périphériques peuvent servir parfois, mais pas toujours, à anticiper la route à

venir. Dans le même temps, les conducteurs en conduite autonome ont une plus forte propension à regarder des aires d'intérêts non pertinentes vis-à-vis de la situation de conduite. Cette adaptation du regard en conduite autonome semble modulée par le niveau d'automatisation du véhicule. En effet, au niveau 2 SAE, le conducteur doit surveiller la route, ce qui va majoritairement conduire à une anticipation visuelle accrue de la route à venir (Mars & Navarro, 2012). Au contraire, au niveau 3 SAE, le conducteur peut s'engager dans des tâches secondaires, ce qui induit plutôt un désengagement visuel de la scène de conduite vers des aires inappropriées (par exemple vers une tablette pour regarder un film, Carsten et al., 2012).

Ces conclusions tirées de la littérature ont été obtenues en étudiant des indicateurs visuels « statiques » : distribution du regard dans l'espace, dispersion visuelle ou pourcentage de temps passé sur la route.

Dans le cadre de ce travail de doctorat, l'adaptation des stratégies visuelles à l'automatisation des véhicules a été étudiée dans des contextes routiers et des niveaux d'automatisation différents, sur route à virage au niveau 2 (partie D), et sur autoroute au niveau 3 (partie E). La méthodologie choisie nous a permis de considérer à la fois des indicateurs statiques (similaires à ceux présentés dans la littérature), mais également des indicateurs dynamiques. Les conclusions expérimentales relevant de ces indicateurs de différentes natures sont développées dans les sections G1.1. et G.1.2. respectivement.

G.1.1. Point de vue statique

Dans notre première expérimentation (partie D), le conducteur devait surveiller la route (SAE niveau 2) et les données visuelles étaient analysées sur six différents virages. Le transfert des fixations a été analysé par le biais de distributions angulaires par rapport à une position de référence, comme dans l'étude de Mars & Navarro (2012). Cependant, nous avons utilisé une méthodologie différente pour traiter les données. En effet, la distribution a été calculée à partir d'une trajectoire de référence reconstruite à partir des données oculaires pour différentes sections du virage (approche, négociation). Par suite, une modélisation par des modèles de mélange gaussien a été effectuée et a permis de distinguer une zone de guidage centrée sur la position de référence, regroupant les fixations de guidage. Du fait de la convention de signe des distributions, une zone d'anticipation a

G.1. ADAPTATION DES STRATEGIES VISUELLES A L'AUTOMATISATION DE LA CONDUITE

également été déduite, avec des regards dirigés dans le sens de la route, mais trop loin pour le guidage « direct » du véhicule. Cette zone d'anticipation regroupe les fixations *look-ahead*. Les résultats des distributions ont montré que les conducteurs en conduite autonome passaient plus de temps dans la zone d'anticipation qu'en conduite manuelle, au détriment des informations de guidage pour lesquels le pattern est inversé. Ce transfert de la zone de guidage vers la zone d'anticipation est initié dans la phase d'approche du virage, et s'intensifie lors de la négociation. Dans ce contexte, très peu de regards semblent dirigés vers des zones non pertinentes pour la conduite (regards éloignés de la route future).

Dans la seconde expérimentation (partie E), les participants expérimentaient un véhicule autonome de niveau 3 sur autoroute. Dans ce cas, les indicateurs visuels statiques ont été définis par le pourcentage de temps passé sur chacune des 13 aires d'intérêts. On retrouve, comme dans la première expérimentation, une plus faible propension à regarder le centre de la route en conduite autonome. Dans le même temps, plus de regards ont été dirigés d'abord vers la zone « autre » et les zones périphériques (écrans gauche et droit). Dans une moindre mesure, plus de regards ont été trouvés sur le rétroviseur central, le tableau de bord et l'IHM, et la route immédiate.

Du fait du contexte autoroutier, constitué surtout de lignes droites et de longs virages, la future route se trouve majoritairement sur l'écran central, et rarement sur les zones périphériques. Ainsi, dans ces conditions, le transfert visuel du centre de la route vers ces aires périphériques ne traduit pas une anticipation accrue de la route à venir. Au contraire, il souligne plutôt un désengagement du conducteur de la tâche de conduite, même en l'absence de tâche secondaire. Ce désengagement se traduit expérimentalement par plus de regards dirigés vers des aires d'intérêts non pertinentes pour la tâche de conduite, comme la zone « autre » (environnement externe au simulateur de conduite) ou bien les écrans périphériques (sur lesquels se trouvent surtout des paysages, notamment sur l'écran droit). Cependant, les résultats montrent que ce désengagement n'est pas total : les conducteurs prennent plus d'informations sur la dynamique et le statut du véhicule (IHM, tableau de bord et rétroviseur central) en conduite autonome qu'en conduite manuelle.

Les différences entre les résultats des deux expérimentations semblent surtout s'expliquer par les différents rôles conférés aux conducteurs. Au niveau 2, le conducteur est tenu de surveiller la route, ce qui se traduit par une majorité des regards sur la route à venir, y compris la route lointaine. Au contraire, au niveau 3, le conducteur se désengage de la

DISCUSSION GENERALE ET PERSPECTIVES

route, même sans tâche secondaire. Pour autant, il continue de superviser la scène de conduite de façon partielle. Dans une moindre mesure, des facteurs contextuels peuvent avoir également influencé les résultats. Par exemple, les conditions de trafic et de contexte routiers n'étaient pas similaires entre les deux expérimentations : dans la partie D, le véhicule était seul sur la route à virage, alors que dans la partie E, d'autres véhicules étaient présents sur autoroute.

Au-delà de l'adaptation des stratégies visuelles à l'automatisation, les résultats confirment qu'en conduite manuelle, les prises d'informations visuelles relèvent principalement du guidage du véhicule. L'analyse des distributions angulaires dans la première expérimentation a également permis de discuter plus en profondeur de la nature de fixations *look-ahead*. En effet, plusieurs propositions ont été formulées dans la littérature : les fixations *look-ahead* (LAFs) peuvent être interprétées comme des fixations alimentant le contrôle tactique (recherche de dangers potentiels ; Mars & Navarro, 2012) ou servant au contrôle accru de trajectoire (Lehtonen et al. 2013), alimentant ainsi le niveau opérationnel. Pour autant, la variation dans la définition des LAFs compliquait l'interprétation fonctionnelle de ces fixations d'anticipation. Cette nuance a été prise en compte au travers de la définition de LAFs de moyen et de long terme. Les résultats suggèrent que la fonction des LAFs n'est pas unique. Les LAFs de moyen terme alimenteraient la boucle opérationnelle en permettant la mise à jour d'un modèle interne de la route à venir (ou de la dynamique véhicule-route), facilitant ainsi la préparation motrice du contrôle de trajectoire futur (Lappi & Mole, 2018). De manière complémentaire, les LAFs de long terme, situés au plus loin de la zone de guidage, alimenteraient plus la boucle tactique. Pour aller plus loin sur cette distinction entre LAFs de long terme et court terme, il serait possible de vérifier si la présence de LAFs de moyen terme (ou de long terme) améliore les performances de conduite dans le virage (via par exemple la mesure de l'écart latéral par rapport au centre de la voie).

Ces résultats expérimentaux obtenus à partir des indicateurs statiques sont cohérents avec les résultats de la littérature : en conduite autonome, les informations visuelles sont moins tournées sur le centre de la route, du fait d'une plus grande exploration visuelle de la scène de conduite. Au niveau 2, cette exploration visuelle se fait quasi exclusivement dans le sens de l'anticipation de la future route. Au contraire, au niveau 3, elle se tourne d'abord vers des aires non pertinentes pour la tâche de conduite.

G.1.2. Point de vue dynamique

Une des originalités de ce travail de doctorat a été de prendre en compte la dynamique des stratégies visuelles en situation de conduite autonome. Pour ce faire, deux méthodologies différentes ont été mises en place dans les expérimentations. Elles reposent cependant sur le même type d'indicateur : les transitions entre les aires d'intérêt.

Dans la première expérimentation (partie D), les distributions angulaires ont permis de mettre en place une zone de guidage (autour de la position de référence) et une zone d'anticipation (vers la route à venir). Dans cette étude, la dynamique du regard dans les virages (approche ou négociation) a été analysée en considérant les événements de *gaze-polling*, constitués de transitions (via des saccades) entre la zone de guidage et la zone d'anticipation.

Les résultats ont d'abord montré qu'en conduite autonome, les conducteurs anticipent la future route de manière beaucoup plus dynamique qu'en conduite manuelle. Ceci est visible à la fois sur le nombre plus élevé d'événements de *gaze-polling* détectés, et un temps plus long passé dans la zone d'anticipation lors d'un tel événement visuel en conduite autonome. Ce pattern de résultats est semblable dans la phase d'approche et de négociation du virage. Lorsque les conducteurs n'alternent pas entre la zone de guidage et d'anticipation en conduite autonome, ils regardent principalement dans la zone de guidage. Cependant, pour quelques cas notables, les conducteurs en conduite autonome passent tout leur temps dans la zone d'anticipation.

Dans la seconde expérimentation (partie E), la dynamique du regard a été traitée en considérant les transitions entre les 13 aires d'intérêts qui décomposent l'environnement de conduite. Pour cela, une modélisation sous forme de chaînes de Markov d'ordre 1 a été menée, prenant en compte à la fois l'aire dans laquelle le regard atterrit, mais aussi l'aire d'où provient le regard. Les résultats de l'analyse de la dynamique du regard ont montré que le désengagement du centre de la route s'effectue de manière dynamique vers les aires périphériques et la zone autre, mais aussi vers les IHM des véhicules (tablette, tableau de bord).

Les conclusions générales tirées des indicateurs dynamiques sont donc similaires à celles obtenues à partir des indicateurs statiques : dans la première expérimentation, au niveau 2,

DISCUSSION GENERALE ET PERSPECTIVES

les conducteurs anticipent plus en conduite autonome. Au contraire, au niveau 3 (seconde expérimentation), ils ont plus tendance à se désengager de la tâche de conduite, mais pas complètement. Cependant, ils permettent de compléter l'analyse dans les deux cas.

Dans le cadre de la première expérimentation (partie D), les indicateurs dynamiques ont notamment montré que certains conducteurs regardent uniquement la zone d'anticipation, à l'approche ou au moment de négocier un virage. Ce type de comportement visuel pourrait être dangereux si le conducteur doit subitement éviter un obstacle, comme l'ont déjà noté Navarro et al. (2016).

Dans la seconde expérimentation (partie E), les stratégies visuelles ont servi de prédicteurs pour déterminer le mode de conduite des participants. Lorsque les stratégies visuelles retiennent uniquement le pourcentage de temps passé à regarder le centre de la route, la prédiction est approximative, avec certaines erreurs de classification. Lorsque les stratégies visuelles prennent en compte les indicateurs statiques seuls, tous les individus sont associés au bon mode de conduite, mais certains participants sont proches d'être mal classés. En revanche, avec l'utilisation des indicateurs dynamiques, la séparation entre les participants en conduite manuelle et en conduite autonome (niveau 3) est de bien meilleure qualité. Lorsque les indicateurs statiques et dynamiques sont combinés, la classification est un peu plus précise que lorsque les indicateurs dynamiques sont utilisés seuls, mais guère plus. Les indicateurs dynamiques, souvent peu considérés dans la littérature, s'avèrent donc cruciaux pour une modélisation fine des stratégies visuelles.

En plus de permettre d'étudier l'adaptation des stratégies visuelles en conduite autonome, l'analyse des indicateurs dynamiques dans ces expérimentations nous permet également de préciser les patterns visuels caractéristiques de la conduite manuelle. Dans la première expérimentation, les événements de *gaze-polling* sont détectés quasi-exclusivement dans la phase d'approche du virage, mais très peu dans la phase de négociation. Ceci peut s'expliquer vis à vis des coordinations visuomotrices plus importantes lorsque le participant tourne effectivement le volant (phase de négociation), ce qui laisse peu de place pour l'anticipation via des fixations *look-ahead*. De telles contraintes de coordinations visuomotrices sont moins strictes dans la phase d'approche du virage (ligne droite). Dans la seconde expérimentation, le seul indicateur statique caractéristique de la conduite manuelle est le pourcentage de temps à regarder le centre de la route. La prise en compte de la

G.1. ADAPTATION DES STRATEGIES VISUELLES A L'AUTOMATISATION DE LA CONDUITE

dynamique souligne également l'importance du centre de la route, mais aussi de regarder de manière occasionnelle les rétroviseurs importants (central et gauche) en conduite manuelle.

L'ensemble de ces résultats confirment l'intérêt de recueillir et d'analyser les indicateurs dynamiques des stratégies visuelles chez les conducteurs en conduite autonome, mais aussi en conduite manuelle.

G.1.3. Synthèse et transition

Les résultats expérimentaux confirment ceux de la littérature : au niveau 2 dans une route à virage, les conducteurs effectuent un transfert du guidage vers l'anticipation sur la route à venir, via des fixations *look-ahead*. Au niveau 3, ils se désengagent partiellement de la tâche de conduite, même en l'absence de tâche secondaire. Cependant, la méthodologie expérimentale employée permet de compléter ces patterns d'adaptation visuelle en conduite autonome, notamment avec l'utilisation d'indicateurs visuels dynamiques.

Au niveau 2 SAE, le comportement visuel des conducteurs diffère dans la phase d'approche (ligne droite) ou de négociation du virage, du fait de plus fortes contraintes visuomotrices lors de la négociation en conduite manuelle. De plus, les travaux font apparaître des conducteurs en conduite autonome restant dans la zone d'anticipation pendant toute une section de virage, ce qui peut être dangereux dans le cas d'une reprise en main. L'étude du comportement visuel en conduite autonome a également permis de préciser la nature des fixations *look-ahead*, qui peuvent servir soit au contrôle de trajectoire (moyen-terme), soit à la recherche d'éléments tactiques permettant de rechercher des aléas potentiels (long-terme).

Au niveau 3 SAE, l'adaptation des conducteurs se traduit par un désengagement visuel des conducteurs de la route. Ce désengagement est détectable avec des modèles de régression PLS, qui permettent de classer les conducteurs selon leur mode de conduite (autonome ou manuelle) à partir de leurs stratégies visuelles. Cette classification est très bonne dès lors que les indicateurs dynamiques sont pris en compte.

Les résultats présentés dans cette section peuvent également être interprétés vis-à-vis des niveaux de sortie de boucle présentés par Merat et al. (2019). Ainsi, ce premier travail consiste à évaluer les différences de comportement visuel entre des conducteurs dans la boucle (conduite manuelle) et sur/hors de la boucle (conduite autonome avec/sans surveillance de la scène de conduite). La prochaine section a pour but de distinguer les

stratégies visuelles de conducteurs en conduite autonome, à partir de leur score de sortie de boucle. Autrement dit, le but est de distinguer les conducteurs sur la boucle de ceux hors de la boucle, à partir de leurs stratégies visuelles.

G.2. Estimation de la sortie de boucle à partir des stratégies visuelles en conduite autonome

Les résultats précédents ont permis de montrer que la distinction entre les conduites autonome et manuelle était meilleure lorsque les indicateurs dynamiques et statiques étaient utilisés conjointement. Ce sont donc ces indicateurs que nous avons privilégiés pour détecter la sortie de boucle.

Dans cette dernière partie expérimentale (partie F), l'accent a été porté sur la distinction entre les conducteurs sur la boucle et ceux hors de la boucle. Pour rappel, Merat et al. (2019) ont proposé que ces deux niveaux diffèrent selon le niveau de supervision de la scène de conduite par le conducteur, un conducteur ne surveillant pas correctement la scène de conduite étant hors de la boucle. Ce phénomène de sortie de boucle a souvent été évalué au travers de ces conséquences, notamment lors de reprises en main (SAE niveau 3). En comparant des conducteurs plus dans la boucle que d'autres (avec/sans tâche secondaire par exemple), la littérature (cf. la méta-analyse de Zhang et al., 2019) montre que les temps de reprise en main des conducteurs sont accrus lorsque les conducteurs sont sortis de la boucle. Des conséquences similaires sont trouvées en comparant les temps de reprise en main des conducteurs en fonction du temps d'automatisation : plus le temps passé en conduite autonome est important, plus la reprise en main est longue (Bourrelly et al., 2019). Ces résultats issus de la littérature suggèrent que le temps d'automatisation permet de faire sortir les participants dans la boucle. C'est ce que nous avons fait dans cette partie expérimentale (partie F).

Pour obtenir une « mesure » du niveau de sortie de boucle des participants, les participants ont rapporté à la fin de l'expérimentation leur niveau de vagabondage de la pensée pendant le parcours en conduite autonome de niveau 3. Körber et al. (2015) avaient déjà montré que les participants vagabondaient plus en fin de parcours qu'au début lorsqu'ils étaient en situation de conduite autonome. De ce fait, nous avons proposé dans l'expérimentation que le niveau de sortie de boucle des conducteurs puisse être obtenu à partir de leur niveau de

G.2. ESTIMATION DE LA SORTIE DE BOUCLE A PARTIR DES STRATEGIES VISUELLES EN CONDUITE AUTONOME

vagabondage de la pensée. Le design expérimental s'est également construit dans cette idée, car aucune tâche secondaire n'était proposée aux participants. Les résultats montrent que, dans le cas d'une conduite autonome sans tâche secondaire, il peut effectivement être un bon indicateur de la sortie de boucle. D'une part, car les participants ayant reporté les plus hauts niveaux de vagabondage ont plus échoué au cas critique, conséquence « classique » de la sortie de boucle. D'autre part, car le niveau de vagabondage de la pensée s'est avéré décorrélé de l'état de fatigue du conducteur, tout du moins dans nos conditions expérimentales. Il reste à déterminer cela se vérifierait avec des temps de conduite plus longs.

Les résultats ont montré qu'il était possible d'estimer ce niveau de sortie de boucle à partir des stratégies visuelles (contenant les indicateurs statiques et dynamiques) des conducteurs en conduite autonome. La meilleure estimation est obtenue en considérant les stratégies visuelles analysées sur une plage de 10 min. De plus, lorsque le modèle obtenu est appliqué sur une période plus courte (2 min) avec des conducteurs le plus hors de la boucle possible (deux dernières minutes du scénario), l'estimation est moins bonne mais une corrélation positive est toujours trouvée entre l'estimation du niveau de sortie de boucle et sa valeur réelle : le modèle permet d'avoir une idée du niveau de sortie de boucle du conducteur. Ceci est d'autant plus important que le modèle est simple et se limite à seulement 12 indicateurs visuels.

L'analyse de ces indicateurs visuels a permis de mettre en évidence des patterns d'exploration visuelle qui sont liés (ou non) au niveau dans la boucle des conducteurs.

D'une part, certains patterns visuels sont dépendants du niveau du conducteur dans la boucle. Ainsi, un conducteur « sur la boucle » (défini via un faible vagabondage de la pensée) effectue des transitions plus fréquentes et reste plus longtemps sur les aires propices à la détection des autres véhicules du trafic, comme le rétroviseur gauche ou la scène latérale gauche dans notre situation expérimentale. Au contraire, les conducteurs les plus hors de la boucle s'attachent plus à des informations ne relevant pas de l'environnement de conduite (aire « Autres »). Même lorsqu'ils surveillent la scène de conduite, ils s'attardent plus sur les aires d'intérêts relatives à la situation de leur véhicule (route immédiate, tableau de bord). Ces patterns visuels peuvent être mis en relation avec le concept de conscience de la situation. Pour Endsley (1995), la conscience de la situation

s'effectue à trois niveaux : la perception et la compréhension de la scène de conduite en cours, et sa projection dans les secondes à venir. Ainsi, les conducteurs sur la boucle prennent des informations visuelles sur les autres usagers de la route et anticipent leurs déplacements par des contrôles visuels fréquents sur les rétroviseurs, ce qui leur confère une conscience de la situation de conduite adéquate à tous les niveaux. Au contraire, les conducteurs hors de la boucle surveillent uniquement leur véhicule, ce qui ne leur permet pas de se projeter dans la scène de conduite à venir.

Les résultats de la partie E ont montré que le pourcentage de temps sur le centre de la route (PRC) est un indicateur assez sensible pour distinguer les conducteurs en conduite manuelle et autonome. Par conséquent, il peut être utilisé pour déterminer la sortie de boucle « physique » des conducteurs. Dans la partie F, en revanche, le PRC ne permet pas de distinguer les conducteurs sur la boucle et hors de la boucle. En revanche, la dynamique des informations visuelles vers et depuis le centre de la route reste essentielle. Même au-delà du centre de la route, une majorité (8 sur 12) des indicateurs sélectionnés sont dynamiques. Par conséquent, une bonne surveillance de l'environnement de conduite repose essentiellement sur des regards fréquents à la recherche d'informations tactiques (sur les rétroviseurs notamment) et sur la route.

G.3. Choix méthodologiques : apports et limites

Cette partie développe d'abord une discussion sur les apports du doctorat en termes de modélisation des stratégies visuelles (modèles de mélanges gaussiens, chaînes de Markov, modèle de régression PLS ; section G.3.1). Ensuite (section G.3.2), les limites liées aux choix méthodologiques lors des expérimentations sont exposées et discutées.

G.3.1. Apports

Mise en place de Modèles de Mélanges Gaussien pour les distributions angulaires

Lorsque les stratégies visuelles ont été étudiées sous forme de distributions angulaires, nous avons mis en place des modèles de mélange gaussien de ces distributions angulaires, afin de déterminer les seuils servant à distinguer les fixations de guidage des fixations *look-ahead*. Cette modélisation s'est faite uniquement en conduite manuelle, dans la mesure où la localisation des fixations de guidage est « connue » (cf. différents modèles de la partie B). La

G.3. CHOIX METHODOLOGIQUES : APPORTS ET LIMITES

mise en place de modèles de mélange gaussien a permis d'établir que la distribution du regard se décompose de façon optimale sous la forme de 4 distributions gaussiennes : une distribution centrale (regroupant l'essentiel des fixations de guidage), une distribution de bruit, et deux distributions d'anticipations, correspondant aux fixations *look-ahead*, situées à moyen et long terme. Cette modélisation a plusieurs avantages. Elle permet d'effectuer une ségrégation des types de fixations de façon objective la plus objective possible. Au-delà de ce bénéfice purement méthodologique, elle a également contribué à une meilleure définition fonctionnelle des fixations *look-ahead*. En effet, on peut faire l'hypothèse que la distribution d'anticipation à moyen terme correspondrait à la planification de trajectoire, relevant ainsi du contrôle opérationnel, alors que la distribution d'anticipation à long terme correspondrait aux fixations servant à la recherche d'éléments tactiques. Cette modélisation gaussienne s'est avérée particulièrement pertinente dans la phase de négociation du virage, où la coordination visuomotrice a un rôle plus déterminant que dans la phase d'approche du virage.

Analyse de la dynamique des stratégies visuelles sous forme de chaînes de Markov

L'analyse des stratégies visuelles en aires d'intérêts a souvent été considérée lors d'études sur le comportement visuel, notamment sur le comportement visuel des conducteurs en conduite manuelle. Pour étudier ce comportement, des mesures de temps passés et de durée moyenne/maximum/nombre de fixations par minute sur les aires d'intérêts sont courantes. De telles mesures restent focalisées sur une aire d'intérêt en particulier et ne mettent pas en évidence les séquences d'aires consultées lors de l'exploration de la scène visuelle.

Une des manières de prendre en compte ces stratégies d'exploration est de constituer, à partir des aires d'intérêts, les matrices de transition d'une aire d'intérêt à une autre, sous la forme de chaînes de Markov d'ordre 1. Avec cette modélisation, on retrouve à la fois une estimation du temps moyen passé sur chaque zone (définissant la probabilité de rester sur une aire d'intérêt), ainsi que la probabilité de migrer vers une autre zone d'intérêt. Ces matrices de transitions ont été par exemple utilisées pour comprendre la manière d'interagir visuellement avec un dispositif multimédia (Krejtz et al., 2016).

Cette modélisation a été appliquée dans le domaine de la conduite dans une tâche de dépassement (Gonçalves et al., 2019). Nous avons utilisé cette approche pour caractériser les stratégies visuelles selon l'état d'automatisation du véhicule (partie E) ou l'état de sortie

de boucle du conducteur (partie F). Les résultats ont montré que cette modélisation était efficace comme prédicteur des états considérés.

Régression PLS

Dans ce travail de thèse, les stratégies visuelles ont servi de prédicteurs pour le phénomène de sortie de boucle ou du mode de conduite, avec un modèle de prédiction commun : la régression PLS. Les résultats de ces modèles étaient cohérents dans chacune des études, notamment au regard des indicateurs retenus par les modèles. En effet, ces indicateurs correspondent à ceux dont on pouvait vérifier manuellement les différences de groupes (t-test manuelle vs autonome ; test de corrélation entre les indicateurs et le score de sortie de boucle). À notre connaissance, c'est la première fois qu'une telle méthode est appliquée à la conduite. L'apport de cette méthode est qu'il permet de prendre en compte directement les « défauts » structurels des matrices de stratégies visuelles (notamment le fait qu'elle ne soit pas de plein rang), et permet d'apprendre sur un échantillon réduit de sujets malgré les multiples variables possibles. Enfin, de manière intéressante pour l'intégration en temps réel, il est assez peu sensible à des données manquantes. Pour ces raisons, cette méthode pourrait être davantage utilisée lors de l'analyse des stratégies visuelles, même dans des contextes autres que la conduite automobile.

G.3.2. Limites

Lien entre l'exploration visuelle et la nature des informations recueillies

Tout d'abord, l'analyse des stratégies visuelles telle qu'effectuée traite surtout de la distribution du regard dans la scène visuelle, mais pas sur la sémantique de ce qu'il regarde : autres véhicules, panneaux, paysage, etc. Pourtant, la dynamique d'exploration d'une scène et la nature des objets présents dans la scène visuelle sont dépendants : Hayhoe & Ballard (2005) montrent qu'une fixation sur un objet s'arrête lorsque l'information recherchée (par exemple, la couleur de l'objet) est acquise par le participant.

Cependant, lorsque la division de la scène visuelle en aire d'intérêt a été considérée, l'analyse des résultats s'est faite en partie en fonction des éléments pouvant majoritairement se trouver sur chacune des aires. Par exemple, les autres véhicules présents sur la voie du conducteur n'apparaissent que sur la zone centrale alors que véhicules se trouvant sur les voies de gauches ne peuvent se trouver que sur les aires périphériques gauches.

Cette limite est plus particulièrement pertinente dans l'analyse expérimentale de la première expérience, dans laquelle les angles visuels ont été considérés. En effet, le lien entre les

G.3. CHOIX METHODOLOGIQUES : APPORTS ET LIMITES

éléments présents sur la scène et l'angle visuel est plus difficile à mettre en place. De plus, si en conduite manuelle, le regard relève directement du contrôle de trajectoire, le regard est « libre » en conduite autonome, les conducteurs pouvant par exemple regarder le paysage ou les éléments du décor. La conception de l'expérience a été conçue en minimisant ce risque : d'une part, les conducteurs ont reçu, en conduite autonome, la consigne de surveiller l'environnement. D'autre part, l'environnement de conduite a été choisi de manière à minimiser le risque de distraction du conducteur : pas d'autres véhicules sur la route, pas d'objets en mouvement dans le champ visuel (seulement des arbres et des maisons). Les résultats semblent confirmer que les participants ne regardent que très peu l'environnement visuel n'ayant aucun rapport avec la future route (cf. Figure D-8 p72 en considérant la partie négative au-delà de la limite sur la distribution angulaire). En cela, les résultats obtenus dans la première expérience concernent davantage l'effet de l'automatisation du véhicule sur les stratégies visuelles utiles au contrôle opérationnel que la seconde expérimentation, où les informations tactiques à extraire du contexte routier étaient plus riches.

Sortie de boucle par questionnaire sur le vagabondage de la pensée

Dans notre étude, l'évaluation de la sortie de boucle se fait au travers d'un questionnaire sur le vagabondage de la pensée. De ce fait, l'évaluation du niveau de sortie de boucle se fait de manière subjective, et propre à chaque participant. Une évaluation objective de la sortie de boucle, basée sur d'autres indicateurs (physiologiques, posturaux ?) aurait été intéressante. Cependant, pour ce faire, une phase de construction et de validation expérimentale de ces indicateurs est à développer, car elle n'existe pas aujourd'hui.

D'autre part, les participants répondaient au questionnaire de vagabondage de la pensée à la fin de l'expérimentation. Ainsi, les réponses de ce questionnaire représentent l'évaluation globale du temps de vagabondage de la pensée, sur l'ensemble de l'expérience. Il aurait été particulièrement intéressant de disposer de cette mesure de sortie de boucle au cours du temps, de manière à pouvoir suivre directement son évolution. Cependant, indiquer aux participants de répondre au questionnaire à différents moments de l'expérience va justement à l'encontre de l'idée de la sortie de boucle, présentée dans cette étude comme le désengagement progressif des participants de la supervision de la scène de conduite. Dans ce sens, seules des mesures objectives permettront de suivre l'évolution de la sortie de boucle au cours du temps, par exemple les mesures des stratégies visuelles des conducteurs.

Conduite autonome de niveau 3 ?

Dans nos résultats expérimentaux, la conduite autonome de niveau 2 a été d'une part considérée, dans le cadre de la conduite à virage. Dans ce cas, le conducteur devait surveiller la route. Dans une autre partie expérimentale, les conducteurs expérimentent le niveau 3, dans lequel les conducteurs sont en théorie libre de s'engager dans des tâches secondaires. En pratique, laisser la liberté aux conducteurs de s'engager dans une tâche secondaire de nature visuelle, comme la lecture ou la consultation d'un smartphone aurait totalement biaisé l'étude. En effet, l'engagement dans une tâche secondaire monopolise l'attention visuelle des conducteurs. De ce fait, les stratégies visuelles observées seraient le reflet de leur tâche visuelle, plutôt que de l'effet d'une sortie de boucle progressive sur l'exploration visuelle de la scène de conduite. De plus, les stratégies visuelles analysées auraient différencié selon que les participants se soient engagés dans des tâches secondaires ou ne l'aient pas fait, rendant difficile toute comparaison entre les sujets. Ainsi, expérimentalement, les conducteurs n'ont pas eu accès à des tâches secondaires, mais ont tout de même porté leur attention sur des aires ne relevant pas de l'environnement de conduite (zone « autre »). Les résultats ont d'ailleurs montré que les conducteurs passaient sensiblement plus de temps dans la zone « autre » en conduite autonome qu'en conduite manuelle.

Reproductibilité des résultats : Simulateur de conduite vs Situation Réelle

Les résultats présentés dans ce manuscrit ont été observés sur simulateur de conduite. De fait, le simulateur de conduite permet de créer des environnements virtuels reproductibles, avec un fort contrôle expérimental, et de mettre les conducteurs dans des situations qui auraient été dangereuses en situation réelle (ex : évitement soudain d'obstacle). Une étude comparative sur route ouverte serait nécessaire pour étudier la validité des conclusions tirées des expérimentations.

G.4. Perspectives


Ce travail de thèse montre l'intérêt de l'étude des stratégies visuelles lors d'une phase de conduite, même autonome. Après avoir investigué les adaptations visuomotrices induites par la conduite autonome, le travail s'est axé sur la problématique de la détection de la sortie de boucle des conducteurs en conduite autonome. Il s'inscrit parfaitement dans le

cadre de sciences cognitives, permettant de modéliser la cognition en utilisant des outils mathématiques.

Au niveau psychologique, « voir » l'évolution du phénomène de sortie de boucle au cours du temps reste à étudier. Ceci pourrait se faire à partir de réseaux bayésiens hybrides, en étant capable de calculer, à chaque instant, la probabilité de sortie de boucle du conducteur à partir de ses stratégies visuelles et de son mode de conduite (manuel ou autonome).

Dans ces travaux, la sortie de boucle est estimée à partir des stratégies visuelles seules. Pour autant, une approche plus complète pourrait être menée, en intégrant d'autres indicateurs sur l'état du conducteur (indicateurs physiologiques, posturaux). La combinaison de l'ensemble de ces indicateurs devrait permettre de caractériser plus finement le phénomène de sortie de boucle. C'est le but du projet ANR AutoConduct, dont s'inscrit ce travail de thèse. Dans ce projet, la caractérisation en temps réel de l'état du conducteur ne constitue pas une fin en soi, le projet a pour ambition d'adapter la coopération homme-véhicule autonome à l'état du conducteur. Dans le cadre de ce projet, nous avons développé un premier algorithme de détection de la sortie de boucle (dont le principe est présenté en annexe). Ses fondations se basent sur nos résultats expérimentaux, permettant la détection de la sortie de boucle à partir des stratégies visuelles. Ainsi, le travail mené lors du doctorat a aussi un intérêt appliqué, dans la mesure où ce type d'algorithme pourrait être implémenté dans de futurs véhicules autonomes.

Rétrospective de la diffusion des travaux



Annexe : Principe de l'algorithme de sortie de boucle

Nous avons suggéré dans l'introduction que la sortie de boucle, lorsqu'elle est induite par une tâche secondaire, serait détectable par des algorithmes de distractions visuelles, le conducteur se désengageant clairement visuellement de la supervision de l'environnement de conduite. Un des algorithmes simples de distraction visuelle se base sur le PRC (pourcentage de temps passé à regarder le centre de la route), considérant un conducteur distrait si son PRC descend sous 58 % en conduite manuelle. (Kircher et al., 2009)

Dans le cadre de nos expérimentations, la sortie de boucle arrivait spontanément, du fait du temps passé en conduite autonome. Dans ce cas, les résultats ont permis de montrer que le temps passé sur la route était similaire chez des conducteurs plus ou moins sortis de la boucle (environ 40 %). En revanche, les conducteurs le plus dans la boucle maintiennent leur anticipation visuelle de la situation à venir, avec notamment des transitions vers le rétroviseur et vers la scène visuelle sur l'écran de gauche. Ces résultats ont été confirmés sur des périodes de deux minutes d'automatisation.

Dans le cadre du projet AutoConduct, un algorithme permettant l'évaluation de la sortie de boucle en combinant ces deux approches a été mis en place sur le simulateur de conduite. L'algorithme est décomposé sur deux niveaux de prise de décision (voir Figure Annexe page suivante).

ANNEXE : PRINCIPE DE L'ALGORITHME DE SORTIE DE BOUCLE

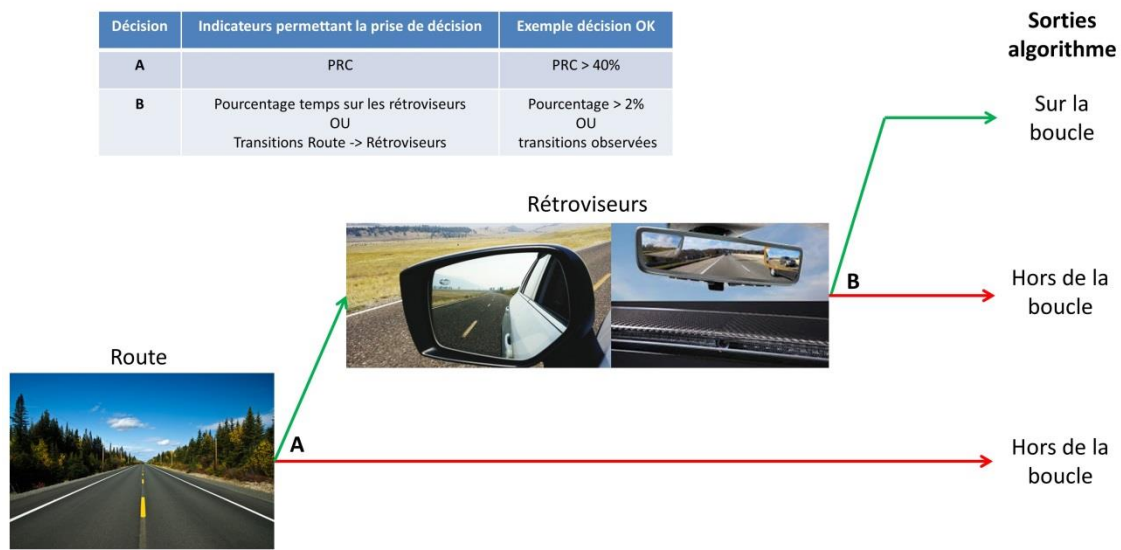


Figure Annexe : Principe de l'algorithme de sortie de boucle

Au premier niveau (décision A), on s'intéresse à la distraction visuelle, en considérant le PRC. Le niveau de la prise de décision (40 % ici) est adapté aux prérequis de la conduite autonome de niveau 3, à savoir que le conducteur ne doit pas surveiller l'environnement de conduite en continu. Pour autant, si la supervision de la route est insuffisante, le conducteur est déclaré hors de la boucle. Lorsque le conducteur a suffisamment regardé la route, l'algorithme quantifie le pourcentage de temps passé sur les rétroviseurs ou la fréquence des regards entre la route et les rétroviseurs (décision B). Si l'une des conditions au moins est respectée, on considère que le conducteur a effectué suffisamment de contrôles pour maintenir sa conscience de la situation : il est sur la boucle. En l'absence de contrôles visuels sur les rétros, le conducteur est classé hors de la boucle.

Les notions « suffisamment » dépendent du seuil fixé pour les différentes conditions. La valeur de ces seuils est modulable.

Cet algorithme utilise les indicateurs visuels calculés sur une plage temporelle modulable. Du fait des résultats obtenus sur l'échantillon de validation, cette plage a été évaluée à 2 min. De ce fait, la sortie de l'algorithme à l'instant t dépend directement de la stratégie de supervision de la scène visuelle entre $t-2$ min et t . Ainsi, dès lors que le conducteur est placé en situation de conduite autonome pendant plus de 2 min, l'algorithme permet de fournir une estimation de l'état du conducteur dans la boucle en temps réel.

Le paramétrage des seuils et de la plage temporelle, ainsi que la validité pratique de l'algorithme (montrant par exemple une plus forte propension à sortir de la boucle après une longue durée d'automatisation) peuvent être testés dans une nouvelle expérimentation.

Cependant, l'algorithme doit également être modifié pour être en adéquation avec une demande de reprise en main. En effet, le calcul d'indicateurs visuels sur une plage temporelle longue rend l'algorithme peu réactif aux changements soudains pouvant subvenir sur la scène visuelle. Par exemple, si le conducteur ne regardait pas du tout la route (PRC 0 %) pendant longtemps, mais qu'il reçoit une demande de reprise en main et concentre alors son attention visuelle sur la route pendant 30 s, son PRC vaudrait alors 25 %, et il serait alors considéré comme hors de la boucle. Une amélioration possible et simple consiste à calculer les données oculométriques à partir du moment de la demande de reprise en main dans ce cas-là.

Bibliographie

- Abdi, H. (2010). Partial least squares regression and projection on latent structure regression (PLS Regression) : PLS REGRESSION. *Wiley Interdisciplinary Reviews: Computational Statistics*, 2(1), 97-106. <https://doi.org/10.1002/wics.51>
- Ahlstrom, Kircher, K., & Kircher, A. (2013). A gaze-based driver distraction warning system and its effect on visual behavior. *IEEE Transactions on Intelligent Transportation Systems*, 14(2), 965–973. <https://doi.org/10.1109/TITS.2013.2247759>
- Alberti, C. F., Shahar, A., & Crundall, D. (2014). Are experienced drivers more likely than novice drivers to benefit from driving simulations with a wide field of view? *Transportation Research Part F: Traffic Psychology and Behaviour*, 27, 124–132. <https://doi.org/10.1016/j.trf.2014.09.011>
- Allen, T., Lunenfeld, H., & Alexander, G. (1971). Driver information needs. *Highway Res Rec*, 366, 102-115.
- Anderson, J. M., Nidhi, K., Stanley, K. D., Sorensen, P., Samaras, C., & Oluwatola, O. A. (2014). *Autonomous vehicle technology : A guide for policymakers*. <https://doi.org/10.7249/RR443-2>
- Awad, E., Dsouza, S., Kim, R., Schulz, J., Henrich, J., Shariff, A., Bonnefon, J.-F., & Rahwan, I. (2018). The moral machine experiment. *Nature*, 563(7729), 59–64. <https://doi.org/10.1038/s41586-018-0637-6>
- Baldwin, C. L., Roberts, D. M., Barragan, D., Lee, J. D., Lerner, N., & Higgins, J. S. (2017). Detecting and quantifying mind wandering during simulated driving. *Frontiers in Human Neuroscience*, 11, 406. <https://doi.org/10.3389/fnhum.2017.00406>

- Ballard, D. H., Hayhoe, M. M., & Pelz, J. B. (1995a). Memory representations in natural tasks. *Journal of Cognitive Neuroscience*, 7(1), 66–80.
<https://doi.org/10.1162/jocn.1995.7.1.66>
- Ballard, D. H., Hayhoe, M. M., & Pelz, J. B. (1995b). Memory representations in natural tasks. *Journal of Cognitive Neuroscience*, 7(1), 66–80.
- Barnard, Y., & Lai, F. (2010). Spotting sheep in Yorkshire : Using eye-tracking for studying situation awareness in a driving simulator. *Proceedings of the Annual Conference of the Europe Chapter of Human Factors and Ergonomics Society*.
- Beiker, S. A. (2012). Legal aspects of autonomous driving. *Santa Clara L. Rev.*, 52, 1145.
<http://dx.doi.org/10.2139/ssrn.2767899>
- Blommer, M., Curry, R., Swaminathan, R., Tijerina, L., Talamonti, W., & Kochhar, D. (2017). Driver brake vs. Steer response to sudden forward collision scenario in manual and automated driving modes. *Transportation Research Part F: Traffic Psychology and Behaviour*, 45, 93–101. <https://doi.org/10.1016/j.trf.2016.11.006>
- Borowsky, A., & Oron-Gilad, T. (2013). Exploring the effects of driving experience on hazard awareness and risk perception via real-time hazard identification, hazard classification, and rating tasks. *Accident Analysis & Prevention*, 59, 548–565.
<https://doi.org/10.1016/j.aap.2013.07.008>
- Bourrelly, A., Jacobé de Naurois, C., Zran, A., & others. (2018). Gaze behavior during take-over after a long period of autonomous driving: A pilot study?. *Proc. Int. Conf. Driving Simulation Conference Europe VR, Antibes, France*.
- Bourrelly, de Naurois, C. J., Zran, A., Rampillon, F., Vercher, J.-L., & Bourdin, C. (2019). Long automated driving phase affects take-over performance. *IET Intelligent Transport Systems*. <https://doi.org/10.1049/iet-its.2019.0018>

BIBLIOGRAPHIE

- Brookhuis, K. A., De Waard, D., & Janssen, W. H. (2001). Behavioural impacts of advanced driver assistance systems—an overview. *European Journal of Transport and Infrastructure Research*, 1(3). <https://doi.org/10.18757/ejtir.2001.1.3.3667>
- Bueno, M., Dogan, E., Selem, F. H., Monacelli, E., Boverie, S., & Guillaume, A. (2016). How different mental workload levels affect the take-over control after automated driving. *2016 IEEE 19th International Conference on Intelligent Transportation Systems (ITSC)*, 2040–2045. <https://doi.org/10.1109/ITSC.2016.7795886>
- Carsten, O., Lai, F. C., Barnard, Y., Jamson, A. H., & Merat, N. (2012). Control task substitution in semiautomated driving : Does it matter what aspects are automated? *Human Factors*, 54(5), 747–761. <https://doi.org/10.1177/0018720812460246>
- Chan, C.-Y. (2017). Advancements, prospects, and impacts of automated driving systems. *International Journal of Transportation Science and Technology*, 6(3), 208-216. <https://doi.org/10.1016/j.ijst.2017.07.008>
- Clark, H., & Feng, J. (2017). Age differences in the takeover of vehicle control and engagement in non-driving-related activities in simulated driving with conditional automation. *Accident Analysis & Prevention*, 106, 468–479. <https://doi.org/10.1016/j.aap.2016.08.027>
- Crundall, Chapman, P., Phelps, N., & Underwood, G. (2003). Eye movements and hazard perception in police pursuit and emergency response driving. *Journal of Experimental Psychology: Applied*, 9(3), 163. <https://doi.org/10.1037/1076-898X.9.3.163>
- Crundall, Shenton, C., & Underwood, G. (2004). Eye movements during intentional car following. *Perception*, 33(8), 975–986. <https://doi.org/10.1068/p5105>
- Crundall, & Underwood, G. (1998). Effects of experience and processing demands on visual information acquisition in drivers. *Ergonomics*, 41(4), 448–458. <https://doi.org/10.1080/001401398186937>

- Cyganski, R., Fraedrich, E., & Lenz, B. (2015). Travel-time valuation for automated driving: A use-case-driven study. *Proceedings of the 94th Annual Meeting of the TRB*.
- Damböck, D., Weißgerber, T., Kienle, M., & Bengler, K. (2013). Requirements for cooperative vehicle guidance. *16th International IEEE Conference on Intelligent Transportation Systems (ITSC 2013)*, 1656–1661. <https://doi.org/10.1109/ITSC.2013.6728467>
- De Winter, J. C., Happee, R., Martens, M. H., & Stanton, N. A. (2014). Effects of adaptive cruise control and highly automated driving on workload and situation awareness: A review of the empirical evidence. *Transportation Research Part F: Traffic Psychology and Behaviour*, 27, 196–217. <https://doi.org/10.1016/j.trf.2014.06.016>
- DeAngelus, M., & Pelz, J. B. (2009). Top-down control of eye movements: Yarbus revisited. *Visual Cognition*, 17(6-7), 790–811. <https://doi.org/10.1080/13506280902793843>
- Desimone, R., & Duncan, J. (1995). Neural mechanisms of selective visual attention. *Annual Review of Neuroscience*, 18(1), 193–222. <https://doi.org/10.1146/annurev.ne.18.030195.001205>
- Dikmen, M., & Burns, C. M. (2016). Autonomous driving in the real world: Experiences with tesla autopilot and summon. *Proceedings of the 8th International Conference on Automotive User Interfaces and Interactive Vehicular Applications*, 225–228. <https://doi.org/10.1145/3003715.3005465>
- Dingus, T. A., Guo, F., Lee, S., Antin, J. F., Perez, M., Buchanan-King, M., & Hankey, J. (2016). Driver crash risk factors and prevalence evaluation using naturalistic driving data. *Proceedings of the National Academy of Sciences*, 113(10), 2636–2641. <https://doi.org/10.1073/pnas.1513271113>

BIBLIOGRAPHIE

- Dogan, E., Rahal, M.-C., Deborne, R., Delhomme, P., Kemeny, A., & Perrin, J. (2017). Transition of control in a partially automated vehicle : Effects of anticipation and non-driving-related task involvement. *Transportation Research Part F: Traffic Psychology and Behaviour*, *46*, 205–215. <https://doi.org/10.1016/j.trf.2017.01.012>
- Donges, E. (1978). A two-level model of driver steering behavior. *Human Factors*, *20*(6), 691–707. <https://doi.org/10.1177/001872087802000607>
- Donges, E. (1999). A conceptual framework for active safety in road traffic. *Vehicle System Dynamics*, *32*(2-3), 113–128. <https://doi.org/10.1076/vesd.32.2.113.2089>
- Droll, J. A., Hayhoe, M. M., Triesch, J., & Sullivan, B. T. (2005). Task demands control acquisition and storage of visual information. *Journal of Experimental Psychology: Human Perception and Performance*, *31*(6), 1416. <https://doi.org/10.1037/0096-1523.31.6.1416>
- economie.gouv.fr. (2018, octobre 3). *Loi PACTE : les 6 mesures qui vont dynamiser l'innovation en France*.
- Endsley, M. R. (1995). Toward a theory of situation awareness in dynamic systems. *Human Factors*, *37*(1), 32–64. <https://doi.org/10.1518/001872095779049543>
- Endsley, M. R. (2015). Situation awareness misconceptions and misunderstandings. *Journal of Cognitive Engineering and Decision Making*, *9*(1), 4–32. <https://doi.org/10.1177/1555343415572631>
- Endsley, M. R. (2017). Autonomous driving systems : A preliminary naturalistic study of the Tesla Model S. *Journal of Cognitive Engineering and Decision Making*, *11*(3), 225–238. <https://doi.org/10.1177/1555343417695197>
- Endsley, M. R. (1988a). Design and evaluation for situation awareness enhancement. *Proceedings of the Human Factors Society annual meeting*, *32*, 97–101. <https://doi.org/10.1177/154193128803200221>

- Endsley, M. R. (1988b). Situation awareness global assessment technique (SAGAT). *Proceedings of the IEEE 1988 National Aerospace and Electronics Conference*, 789–795.
<https://doi.org/10.1109/NAECON.1988.195097>
- Endsley, M. R., Bolté, B., & Jones, D. G. (2004). *Designing for Situation Awareness : An Approach to User-Centered Design*. New York Taylor & Francis.
<https://doi.org/10.1177/106480460401200310>
- Endsley, M. R., & Kiris, E. O. (1995). The Out-of-the-Loop Performance Problem and Level of Control in Automation. *Human Factors*, 37(2), 381-394.
<https://doi.org/10.1518/001872095779064555>
- Eriksson, A., & Stanton, N. A. (2017a). Driving performance after self-regulated control transitions in highly automated vehicles. *Human Factors*, 59(8), 1233–1248.
<https://doi.org/10.1177/0018720817728774>
- Eriksson, A., & Stanton, N. A. (2017b). Takeover time in highly automated vehicles : Noncritical transitions to and from manual control. *Human Factors*, 59(4), 689–705.
<https://doi.org/10.1177/0018720816685832>
- ERTRAC Task Force. (2015). *Automated driving roadmap*.
- European Transport Safety Council. (2016, avril). *Prioritising the Safety Potential of Automated Driving in Europe*.
- Fagnant, D. J., & Kockelman, K. (2015). Preparing a nation for autonomous vehicles : Opportunities, barriers and policy recommendations. *Transportation Research Part A: Policy and Practice*, 77, 167–181. <https://doi.org/10.1016/j.tra.2015.04.003>
- Feldhütter, A., Gold, C., Schneider, S., & Bengler, K. (2017). How the duration of automated driving influences take-over performance and gaze behavior. *Advances in Ergonomic Design of Systems, Products and Processes*, 309–318.
https://doi.org/10.1007/978-3-662-53305-5_22

BIBLIOGRAPHIE

- Fitch, G. M., Bowman, D. S., & Llaneras, R. E. (2014). Distracted driver performance to multiple alerts in a multiple-conflict scenario. *Human Factors*, 56(8), 1497–1505. <https://doi.org/10.1177/0018720814531785>
- Flemisch, F., Kelsch, J., Löper, C., Schieben, A., Schindler, J., & Heesen, M. (2008). Cooperative control and active interfaces for vehicle assistance and automation. *Proceedings of FISITA World Automotive Congress*.
- Galéra, C., Orriols, L., M'Bailara, K., Laborey, M., Contrand, B., Ribéreau-Gayon, R., Masson, F., Bakiri, S., Gabaude, C., Fort, A., & others. (2012). Mind wandering and driving: Responsibility case-control study. *Bmj*, 345, e8105. <https://doi.org/10.1136/bmj.e8105>
- Gasser, T. M., Arzt, C., Ayoubi, M., Bartels, A., Bürkle, L., Eier, J., Flemisch, F., Häcker, D., Hesse, T., Huber, W., & others. (2012). Rechtsfolgen zunehmender fahrzeugautomatisierung. *Berichte der Bundesanstalt für Straßenwesen. Unterreihe Fahrzeugtechnik*, 83.
- Gold, C., Damböck, D., Bengler, K., & Lorenz, L. (2013). Partially automated driving as a fallback level of high automation. *6. Tagung Fahrerassistenzsysteme. Der Weg zum automatischen Fahren*.
- Gold, C., Damböck, D., Lorenz, L., & Bengler, K. (2013). “Take over!” How long does it take to get the driver back into the loop? *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, 57(1), 1938–1942. <https://doi.org/10.1177/1541931213571433>
- Gold, C., Körber, M., Lechner, D., & Bengler, K. (2016). Taking over control from highly automated vehicles in complex traffic situations: The role of traffic density. *Human Factors*, 58(4), 642–652. <https://doi.org/10.1177/0018720816634226>

- Gonçalves, R., Louw, T., Madigan, R., & Merat, N. (2019). Using markov chains to understand the sequence of drivers' gaze transitions during lane-changes in automated driving. *Proceedings of the International Driving Symposium on Human Factors in Driver Assessment, Training, and Vehicle Design*.
<https://doi.org/10.17077/drivingassessment.1698>
- Gouraud, J., Delorme, A., & Berberian, B. (2017). Autopilot, mind wandering, and the out of the loop performance problem. *Frontiers in Neuroscience*, *11*, 541.
<https://doi.org/10.3389/fnins.2017.00541>
- gouvernement.fr. (2017, mai). *La nouvelle France industrielle*.
- Greene, M. R., Liu, T., & Wolfe, J. M. (2012). Reconsidering Yarbus : A failure to predict observers' task from eye movement patterns. *Vision Research*, *62*, 1–8.
<https://doi.org/10.1016/j.visres.2012.03.019>
- Greenlee, E. T., DeLucia, P. R., & Newton, D. C. (2018). Driver vigilance in automated vehicles : Hazard detection failures are a matter of time. *Human Factors*, *60*(4), 465–476. <https://doi.org/10.1177/0018720818761711>
- Groupe PSA. (2019). *En route vers la voiture autonome*.
- Hale, A., Stoop, J., & Hommels, J. (1990). Human error models as predictors of accident scenarios for designers in road transport systems. *Ergonomics*, *33*(10-11), 1377–1387.
<https://doi.org/10.1080/00140139008925339>
- Hammel, K. R., Fisher, D. L., & Pradhan, A. K. (2002). Verbal and spatial loading effects on eye movements in driving simulators : A comparison to real world driving. *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, *46*(26), 2174–2178. <https://doi.org/10.1177/154193120204602615>
- Hanowski, R. J., Bowman, D., Alden, A., Wierwille, W. W., & Carroll, R. (2008). PERCLOS+ : Development of a robust field measure of driver drowsiness. *15th*

BIBLIOGRAPHIE

- World Congress on Intelligent Transport Systems and ITS America's 2008 Annual Meeting, New York, NY.*
- Harbluk, J. L., Noy, Y. I., & Eizenman, M. (2002). *The impact of cognitive distraction on driver visual behaviour and vehicle control.*
- Harper, C. D., Hendrickson, C. T., Mangones, S., & Samaras, C. (2016). Estimating potential increases in travel with autonomous vehicles for the non-driving, elderly and people with travel-restrictive medical conditions. *Transportation Research Part C: Emerging Technologies*, 72, 1–9. <https://doi.org/10.1016/j.trc.2016.09.003>
- Hayes, B. (2011). Leave the driving to it. *American Scientist*, 99(5), 362. <https://doi.org/10.1511/2011.92.362>
- Hayhoe, & Ballard, D. (2005). Eye movements in natural behavior. *Trends in Cognitive Sciences*, 9(4), 188–194. <https://doi.org/10.1016/j.tics.2005.02.009>
- Hayhoe, M. M., Shrivastava, A., Mruczek, R., & Pelz, J. B. (2003). Visual memory and motor planning in a natural task. *Journal of vision*, 3(1), 6–6.
- Hills, P. J., Thompson, C., & Pake, J. M. (2018). Detrimental effects of carryover of eye movement behaviour on hazard perception accuracy: Effects of driver experience, difficulty of task, and hazardousness of road. *Transportation Research Part F: Traffic Psychology and Behaviour*, 58, 906–916. <https://doi.org/10.1016/j.trf.2018.07.014>
- Hoedemaeker, M. (2000). Driving behaviour with ACC and the acceptance by individual drivers. *IEEE Intelligent Transportation Systems Conference Proceedings*. <https://doi.org/10.1109/ITSC.2000.881121>
- Hollnagel, E., N\aaabo, A., & Lau, I. V. (2003). *A systemic model for driver-in-control*. <https://doi.org/10.17077/drivingassessment.1101>
- Hollnagel, E., & Woods, D. D. (1995). *Joint cognitive systems: Foundations of cognitive systems engineering*. CRC press.

- Holm, S. (1979). A simple sequentially rejective multiple test procedure. *Scandinavian journal of statistics*, 65–70.
- Insee Focus N° 143. (2019, février). *Septes salariés sur dix vont travailler en voiture*.
- Ito, T., Takata, A., & Oosawa, K. (2016). *Time required for take-over from automated to manual driving*. SAE 2016 World Congress and Exhibition. <https://doi.org/10.4271/2016-01-0158>
- Itti, L., & Koch, C. (2001). Computational modeling of visual attention. *Nature Reviews Neuroscience*, 2, 194-203. <https://doi.org/10.1038/35058500>
- Jamson, A. H., Merat, N., Carsten, O. M., & Lai, F. C. (2013). Behavioural changes in drivers experiencing highly-automated vehicle control in varying traffic conditions. *Transportation Research Part C: Emerging Technologies*, 30, 116–125. <https://doi.org/10.1016/j.trc.2013.02.008>
- Jiang, J., Lu, J., & Li, X. (2012). *Eye movement of Chinese experienced drivers and novice drivers*.
- Josten, J., Zlocki, A., & Eckstein, L. (2016). Investigation of drivers' handling performance in sudden take-over situations after semi-automated, hands-off driving. *FAT Schriftenreihe*, 289.
- Jovancevic, J., Sullivan, B., & Hayhoe, M. (2006). Control of attention and gaze in complex environments. *Journal of Vision*, 6(12), 9–9. <https://doi.org/10.1167/6.12.9>
- Kaber, D. B., & Endsley, M. R. (1997). Out-of-the-loop performance problems and the use of intermediate levels of automation for improved control system functioning and safety. *Process Safety Progress*, 16(3), 126–131. <https://doi.org/10.1002/prs.680160304>
- Kaber, D. B., Liang, Y., Zhang, Y., Rogers, M. L., & Gangakhedkar, S. (2012). Driver performance effects of simultaneous visual and cognitive distraction and adaptation

BIBLIOGRAPHIE

- behavior. *Transportation Research Part F: Traffic Psychology and Behaviour*, 15(5), 491–501. <https://doi.org/10.1016/j.trf.2012.05.004>
- Kahana-Levy, N., Shavitzky-Golkin, S., Borowsky, A., & Vakil, E. (2019). The effects of repetitive presentation of specific hazards on eye movements in hazard perception training, of experienced and young-inexperienced drivers. *Accident Analysis & Prevention*, 122, 255–267. <https://doi.org/10.1016/j.aap.2018.09.033>
- Kandil, F. I., Rotter, A., & Lappe, M. (2010). Car drivers attend to different gaze targets when negotiating closed vs. Open bends. *Journal of Vision*, 10(4), 24–24. <https://doi.org/10.1167/10.4.24>
- Kassner, A., Muhrer, E., Baumann, M., Vollrath, M., Minin, L., Megard, C., & Heers, R. (2011). *Integrated human modelling and simulation to support human error risk analysis of partially autonomous driver assistance systems. Knowledge-base of driving without and with PADAS.*
- Kidd, D., & McCartt, A. (2015). The relevance of crash type and severity when estimating crash risk using the SHRP2 naturalistic driving data. *International Conference on Driver Distraction and Inattention, 4th, 2015, Sydney, New South Wales, Australia.*
- Kienle, M., Damböck, D., Kelsch, J., Flemisch, F., & Bengler, K. (2009). Towards an H-Mode for highly automated vehicles : Driving with side sticks. *Proceedings of the 1st International Conference on Automotive User Interfaces and Interactive Vehicular Applications*, 19–23.
- Kircher, K., Ahlstrom, C., & Kircher, A. (2009). Comparison of two eye-gaze based real-time driver distraction detection algorithms in a small-scale field operational test. *Proceedings of the Fifth International Driving Symposium on Human Factors in Driver Assessment*. <https://doi.org/10.17077/drivingassessment.1297>

- Kondo, S., Asanuma, N., Ishida, S., Ikegaya, M., & Tanaka, J. (1999). Evaluation of driver assistance system. *Proceedings of 6th World Congress on Intelligent Transport Systems*.
- Konstantopoulos, P., Chapman, P., & Crundall, D. (2010). Driver's visual attention as a function of driving experience and visibility. Using a driving simulator to explore drivers' eye movements in day, night and rain driving. *Accident Analysis & Prevention*, 42(3), 827–834. <https://doi.org/10.1016/j.aap.2009.09.022>
- Körber, M., Cingel, A., Zimmermann, M., & Bengler, K. (2015). Vigilance decrement and passive fatigue caused by monotony in automated driving. *6th International Conference on Applied Human Factors and Ergonomics*, 3, 2403–2409. <https://doi.org/10.1016/j.promfg.2015.07.499>
- Krejtz, Duchowski, A. T., Krejtz, I., Kopacz, A., & Chrzastowski-Wachtel, P. (2016). *Gaze transitions when learning with multimedia*. <https://doi.org/10.16910/jemr.9.1.5>
- Kyriakidis, M., Happee, R., & de Winter, J. C. (2015). Public opinion on automated driving: Results of an international questionnaire among 5000 respondents. *Transportation Research Part F: Traffic Psychology and Behaviour*, 32, 127–140. <https://doi.org/10.1016/j.trf.2015.04.014>
- Land, & Furneaux, S. (1997). The knowledge base of the oculomotor system. *Philosophical Transactions of the Royal Society of London B: Biological Sciences*, 352(1358), 1231–1239. <https://doi.org/10.1098/rstb.1997.0105>
- Land, & Hayhoe, M. (2001). In what ways do eye movements contribute to everyday activities? *Vision Research*, 41(25-26), 3559–3565. [https://doi.org/10.1016/S0042-6989\(01\)00102-X](https://doi.org/10.1016/S0042-6989(01)00102-X)
- Land, & Horwood, J. (1995). Which parts of the road guide steering? *Nature*, 377(6547), 339–340. <https://doi.org/10.1038/377339a0>
- Land, & Lee, D. N. (1994a). Where we look when we steer. *Nature*, 369(6483), 742.

BIBLIOGRAPHIE

- Land, M. F., & Furneaux, S. (1997). The knowledge base of the oculomotor system. *Philosophical Transactions of the Royal Society of London B: Biological Sciences*, *352*(1358), 1231–1239.
- Land, M. F., & Lee, D. N. (1994b). Where we look when we steer. *Nature*, *369*(6483), 742.
- Land, M., Mennie, N., & Rusted, J. (1999). The roles of vision and eye movements in the control of activities of daily living. *Perception*, *28*(11), 1311–1328.
- Land, Mennie, N., & Rusted, J. (1999). The roles of vision and eye movements in the control of activities of daily living. *Perception*, *28*(11), 1311–1328. <https://doi.org/10.1068/p2935>
- Lappi, O. (2014). Future path and tangent point models in the visual control of locomotion in curve driving. *Journal of Vision*, *14*(12), 21–21. <https://doi.org/10.1167/14.12.21>
- Lappi, O. (2016). Eye movements in the wild: Oculomotor control, gaze behavior & frames of reference. *Neuroscience & Biobehavioral Reviews*, *69*, 49–68. <https://doi.org/10.1016/j.neubiorev.2016.06.006>
- Lappi, O., Lehtonen, E., Pekkanen, J., & Itkonen, T. (2013). Beyond the tangent point: Gaze targets in naturalistic driving. *Journal of Vision*, *13*(13), 11–11. <https://doi.org/10.1167/13.13.11>
- Lappi, O., & Mole, C. (2018). Visuomotor control, eye movements, and steering: A unified approach for incorporating feedback, feedforward, and internal models. *Psychological bulletin*, *144*(10), 981. <https://doi.org/10.1037/bul0000150>
- Lappi, O., Pekkanen, J., & Itkonen, T. H. (2013). Pursuit eye-movements in curve driving differentiate between future path and tangent point models. *PLoS one*, *8*(7), e68326. <https://doi.org/10.1371/journal.pone.0068326>

- Lappi, O., Rinkkala, P., & Pekkanen, J. (2017). Systematic observation of an expert driver's gaze strategy—An on-road case study. *Frontiers in Psychology, 8*, 620. <https://doi.org/10.3389/fpsyg.2017.00620>
- Larsson, A. F., Kircher, K., & Hultgren, J. A. (2014). Learning from experience : Familiarity with ACC and responding to a cut-in situation in automated driving. *Transportation Research Part F: traffic psychology and behaviour, 27*, 229–237. <https://doi.org/10.1016/j.trf.2014.05.008>
- Lee, W., Sung, D., Lee, J., Kim, Y., & Cho, J. (2007). Driving simulation for evaluation of driver assistance systems and driving management systems. *Korea Transportation Institute, Development of National Traffic Core Technology*.
- Lehtonen, E., Lappi, O., Koirikivi, I., & Summala, H. (2014). Effect of driving experience on anticipatory look-ahead fixations in real curve driving. *Accident Analysis & Prevention, 70*, 195–208. <https://doi.org/10.1016/j.aap.2014.04.002>
- Lehtonen, E., Lappi, O., Koskiahde, N., Mansikka, T., Hietamäki, J., & Summala, H. (2018). Gaze doesn't always lead steering. *Accident Analysis & Prevention, 121*, 268–278. <https://doi.org/10.1016/j.aap.2018.09.026>
- Lehtonen, E., Lappi, O., Kotkanen, H., & Summala, H. (2013). Look-ahead fixations in curve driving. *Ergonomics, 56*(1), 34–44. <https://doi.org/10.1080/00140139.2012.739205>
- Lemercier, C., Pecher, C., Berthié, G., Valery, B., Vidal, V., Paubel, P.-V., Cour, M., Fort, A., Galéra, C., Gabaude, C., & others. (2014). Inattention behind the wheel : How factual internal thoughts impact attentional control while driving. *Safety science, 62*, 279–285. <https://doi.org/10.1016/j.ssci.2013.08.011>

BIBLIOGRAPHIE

- Lemonnier, S., Désiré, L., Brémond, R., & Baccino, T. (2020). Drivers' visual attention : A field study at intersections. *Transportation Research Part F: Traffic Psychology and Behaviour*, *69*, 206–221. <https://doi.org/10.1016/j.trf.2020.01.012>
- Llaneras, R. E., Salinger, J., & Green, C. A. (2013). *Human factors issues associated with limited ability autonomous driving systems : Drivers' allocation of visual attention to the forward roadway*. <https://doi.org/10.17077/drivingassessment.1472>
- Louw, Kountouriotis, G., Carsten, O., & Merat, N. (2015). Driver Inattention During Vehicle Automation : How Does Driver Engagement Affect Resumption Of Control? *4th International Conference on Driver Distraction and Inattention*, 1-16.
- Louw, Madigan, R., Carsten, O., & Merat, N. (2016). Were they in the loop during automated driving? Links between visual attention and crash potential. *Injury Prevention*, *23*(4), 281–286. <https://doi.org/10.1136/injuryprev-2016-042155>
- Louw, & Merat, N. (2017a). Are you in the loop ? Using gaze dispersion to understand driver visual attention during vehicle automation. *Transportation Research Part C: Emerging Technologies*, *76*, 35–50. <https://doi.org/10.1016/j.trc.2017.01.001>
- Louw, & Merat, N. (2017b). Are you in the loop ? Using gaze dispersion to understand driver visual attention during vehicle automation. *Transportation Research Part C: Emerging Technologies*, *76*, 35–50. <https://doi.org/10.1016/j.trc.2017.01.001>
- Louw, & Merat, N. (2016). A Methodology for Inducing the Out of the Loop Phenomenon in Highly Automated Driving. *International Conference on Traffic and Transport Psychology, Brisbane, Australia*, 10.
- Louw, Merat, N., & Jamson, H. (2015). Engaging with Highly Automated Driving : To be or Not to be in the Loop? *Proceedings of the Eighth International Driving Symposium on Human Factors in Driver Assessment, Training and Vehicle Design*, 190-196. <https://doi.org/10.17077/drivingassessment.1570>

- Lu, Z., Coster, X., & de Winter, J. (2017). How much time do drivers need to obtain situation awareness? A laboratory-based study of automated driving. *Applied Ergonomics*, *60*, 293–304. <https://doi.org/10.1016/j.apergo.2016.12.003>
- Mackenzie, A. K., & Harris, J. M. (2015). Eye movements and hazard perception in active and passive driving. *Visual cognition*, *23*(6), 736–757. <https://doi.org/10.1080/13506285.2015.1079583>
- Mars, F. (2016, novembre 29). Hiérarchie des niveaux de contrôle de l'activité en conduite automobile : Application au contrôle de trajectoire et à la coopération homme-machine. *Habilitation à Diriger les Recherches*.
- Mars, F., Deroo, M., & Charron, C. (2014). Driver adaptation to haptic shared control of the steering wheel. *2014 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, 1505–1509. <https://doi.org/10.1109/SMC.2014.6974129>
- Mars, F., & Navarro, J. (2012). Where we look when we drive with or without active steering wheel control. *PLoS One*, *7*(8), e43858. <https://doi.org/10.1371/journal.pone.0043858>
- McEvoy, S. P., Stevenson, M. R., McCartt, A. T., Woodward, M., Haworth, C., Palamara, P., & Cercarelli, R. (2005). Role of mobile phones in motor vehicle crashes resulting in hospital attendance: A case-crossover study. *bmj*, *331*(7514), 428. <https://doi.org/10.1136/bmj.38537.397512.55>
- McRuer, D. T., Allen, R. W., Weir, D. H., & Klein, R. H. (1977). New results in driver steering control models. *Human Factors*, *19*(4), 381–397. <https://doi.org/10.1177/001872087701900406>
- Meilander, W. (1972). *U.S. patent no. 3,668,403* (3,668,403). U.S Patent and Trademark Office.

BIBLIOGRAPHIE

- Mennie, N., Hayhoe, M., & Sullivan, B. (2007a). Look-ahead fixations : Anticipatory eye movements in natural tasks. *Experimental Brain Research*, 179(3), 427–442. <https://doi.org/10.1007/s00221-006-0804-0>
- Mennie, N., Hayhoe, M., & Sullivan, B. (2007b). Look-ahead fixations : Anticipatory eye movements in natural tasks. *Experimental Brain Research*, 179(3), 427–442.
- Merat, N., & Jamson, A. H. (2009). How do drivers behave in a highly automated car? *Proceedings of the Fifth International Driving Symposium on Human Factors in Driver Assessment, Training and Vehicle Design*. <https://doi.org/10.17077/drivingassessment.1365>
- Merat, N., Jamson, A. H., Lai, F. C., Daly, M., & Carsten, O. M. (2014). Transition to manual : Driver behaviour when resuming control from a highly automated vehicle. *Transportation Research Part F: Traffic Psychology and Behaviour*, 27, 274–282. <https://doi.org/10.1016/j.trf.2014.09.005>
- Merat, N., Jamson, A. H., Lai, F. C. H., & Carsten, O. (2012). Highly Automated Driving, Secondary Task Performance, and Driver State. *Human Factors*, 54(5), 762-771. <https://doi.org/10.1177/0018720812442087>
- Merat, N., Seppelt, B., Louw, T., Engström, J., Lee, J. D., Johansson, E., Green, C. A., Katasaki, S., Monk, C., Itoh, M., & others. (2019). The “out-of-the-loop” concept in automated driving : Proposed definition, measures and implications. *Cognition, Technology & Work*, 21(1), 87–98. <https://doi.org/10.1007/s10111-018-0525-8>
- Michaels, R. (1963). Perceptual factors in car following. *Proceedings of the Second International Symposium on the Theory of Road Traffic Flow*.
- Michon, J. A. (1985). A critical view of driver behavior models : What do we know, what should we do? *Human behavior and traffic safety*, 485–524. https://doi.org/10.1007/978-1-4613-2173-6_19

- Mole, C. D., Lappi, O., Giles, O., Markkula, G., Mars, F., & Wilkie, R. M. (2019). Getting Back Into the Loop: The Perceptual-Motor Determinants of Successful Transitions out of Automated Driving. *Human Factors*, *61*(7), 1037-1065. <https://doi.org/10.1177/0018720819829594>
- Mole, Kountouriotis, G., Billington, J., & Wilkie, R. M. (2016). Optic flow speed modulates guidance level control: New insights into two-level steering. *Journal of Experimental Psychology: Human Perception and Performance*, *42*(11), 1818. <https://doi.org/10.1037/xhp0000256>
- Molloy, R., & Parasuraman, R. (1996). Monitoring an automated system for a single failure: Vigilance and task complexity effects. *Human Factors*, *38*(2), 311–322. <https://doi.org/10.1177/001872089606380211>
- Mourant, & Rockwell, T. H. (1972). Strategies of visual search by novice and experienced drivers. *Human Factors*, *14*(4), 325–335. <https://doi.org/10.1177/001872087201400405>
- Nakajima, Y., & Tanaka, K. (2017). Effects of active and passive secondary tasks in a take-over situation during automated driving. *2017 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, 1161–1166. <https://doi.org/10.1109/SMC.2017.8122769>
- Naujoks, F., Wiedemann, K., Schömig, N., Jarosch, O., & Gold, C. (2018). Expert-based controllability assessment of control transitions from automated to manual driving. *MethodsX*, *5*, 579-592. <https://doi.org/10.1016/j.mex.2018.05.007>
- Navarro, J., François, M., & Mars, F. (2016). Obstacle avoidance under automated steering: Impact on driving and gaze behaviours. *Transportation Research Part F: Traffic Psychology and Behaviour*, *43*, 315–324. <https://doi.org/10.1016/j.trf.2016.09.007>

BIBLIOGRAPHIE

- Neubauer, C., Matthews, G., Langheim, L., & Saxby, D. (2012). Fatigue and voluntary utilization of automation in simulated driving. *Human Factors*, 54(5), 734–746. <https://doi.org/10.1177/0018720811423261>
- NHTSA. (2008). National motor vehicle crash causation survey: Report to congress. *National Highway Traffic Safety Administration Technical Report DOT HS, 811*, 059.
- NHTSA. (2013). Preliminary statement of policy concerning automated vehicles. *Washington, DC*, 1–14.
- Nilsson, L. (1995). Safety effects of adaptive cruise controls in critical traffic situations. *Proceedings of Steps Forward. Intelligent Transport Systems World Congress, III*, 1254-1259.
- Nunes, L., & Recarte, M. A. (2002). Cognitive demands of hands-free-phone conversation while driving. *Transportation Research Part F: Traffic Psychology and Behaviour*, 5(2), 133–144. [https://doi.org/10.1016/S1369-8478\(02\)00012-8](https://doi.org/10.1016/S1369-8478(02)00012-8)
- ONISR. (2020). *Bilan 2019 de la sécurité routière*.
- Othersen, I. (2016). *Investigation of drivers' handling performance in sudden take-over situations after semi-automated, hands-off driving*. Technische Universität Braunschweig.
- Otte, D., Pund, B., & Jänsch, M. (2009). A new approach of accident causation analysis by seven steps ACASS. *Proceedings: International Technical Conference on the Enhanced Safety of Vehicles, 2009*.
- Parasuraman, R., & Riley, V. (1997). Humans and Automation: Use, Misuse, Disuse, Abuse. *Human Factors*, 39(2), 230-253. <https://doi.org/10.1518/001872097778543886>
- Patla, A. E., & Vickers, J. N. (1997). Where and when do we look as we approach and step over an obstacle in the travel path? *Neuroreport*, 8(17), 3661–3665. <https://doi.org/10.1097/00001756-199712010-00002>

- Pekkanen, J., & Lappi, O. (2017). A new and general approach to signal denoising and eye movement classification based on segmented linear regression. *Scientific reports*, 7(1), 17726. <https://doi.org/10.1038/s41598-017-17983-x>
- Pelz, & Canosa, R. (2001). Oculomotor behavior and perceptual strategies in complex tasks. *Vision Research*, 41(25-26), 3587–3596. [https://doi.org/10.1016/S0042-6989\(01\)00245-0](https://doi.org/10.1016/S0042-6989(01)00245-0)
- Posner, M. I. (1980). Orienting of attention. *Quarterly Journal of Experimental Psychology*, 32(1), 3–25. <https://doi.org/10.1080/00335558008248231>
- Qu, W., Ge, Y., Xiong, Y., Carciofo, R., Zhao, W., & Zhang, K. (2015). The relationship between mind wandering and dangerous driving behavior among Chinese drivers. *Safety Science*, 78, 41–48. <https://doi.org/10.1016/j.ssci.2015.04.016>
- Radlmayr, J., & Bengler, K. (2015). Literature analysis and method selection for designing systems for highly automated driving. *FAT-Schriftenreihe*, 276, 1–57. <https://doi.org/10.13140/RG.2.1.2222.4401>
- Radlmayr, J., Gold, C., Lorenz, L., Farid, M., & Bengler, K. (2014). How traffic situations and non-driving related tasks affect the take-over quality in highly automated driving. *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, 58, 2063–2067. <https://doi.org/10.1177/1541931214581434>
- Ranney, T. A. (1994). Models of driving behavior: A review of their evolution. *Accident Analysis & Prevention*, 26(6), 733–750. [https://doi.org/10.1016/0001-4575\(94\)90051-5](https://doi.org/10.1016/0001-4575(94)90051-5)
- Rasmussen, J. (1983). Skills, rules, and knowledge; signals, signs, and symbols, and other distinctions in human performance models. *IEEE transactions on systems, man, and cybernetics*, 3, 257–266. <https://doi.org/10.1109/TSMC.1983.6313160>

BIBLIOGRAPHIE

- Recarte, M. A., & Nunes, L. M. (2000). Effects of verbal and spatial-imagery tasks on eye fixations while driving. *Journal of Experimental Psychology: Applied*, 6(1), 31. <https://doi.org/10.1037//1076-898x.6.1.31>
- Redelmeier, D. A., & Tibshirani, R. J. (1997). Association between cellular-telephone calls and motor vehicle collisions. *New England Journal of Medicine*, 336(7), 453–458. <https://doi.org/10.1056/NEJM199702133360701>
- Robbins, & Chapman, P. (2019). How does drivers' visual search change as a function of experience? A systematic review and meta-analysis. *Accident Analysis & Prevention*, 132, 105266. <https://doi.org/10.1016/j.aap.2019.105266>
- Rothkopf, C. A., Ballard, D. H., & Hayhoe, M. M. (2007). Task and context determine where you look. *Journal of Vision*, 7(14), 16–16. <https://doi.org/10.1167/7.14.16>
- Rudin-Brown, C. M., & Parker, H. A. (2004). Behavioural adaptation to adaptive cruise control (ACC) : Implications for preventive strategies. *Transportation Research Part F: Traffic Psychology and Behaviour*, 7(2), 59–76. <https://doi.org/10.1016/j.trf.2004.02.001>
- Rydström. (2007). *The effect of haptic feedback in visual-manual human-machine interaction* [PhD Thesis]. Luleå tekniska universitet.
- SAE International. (2014). *Taxonomy and Definitions for Terms Related to On-Road Motor Vehicle Automated Driving Systems* (Technical Report J3016_201401).
- SAE International. (2016). *Taxonomy and Definitions for Terms Related to On-Road Motor Vehicle Automated Driving Systems* (Technical Report J3016_201609). SAE International.
- Salvucci, D. D., & Gray, R. (2004). A two-point visual control model of steering. *Perception*, 33(10), 1233–1248. <https://doi.org/10.1068/p5343>

- Sarter, N. B., & Woods, D. D. (1991). Situation awareness : A critical but ill-defined phenomenon. *The International Journal of Aviation Psychology*, 1(1), 45–57. https://doi.org/10.1207/s15327108ijap0101_4
- Saxby, D. J., Matthews, G., Warm, J. S., Hitchcock, E. M., & Neubauer, C. (2013). Active and Passive Fatigue in Simulated Driving: Discriminating Styles of Workload Regulation and Their Safety Impacts. *Journal of experimental psychology. Applied*, 19(4), 287-300. <https://doi.org/10.1037/a0034386>
- Schnebelen, D., Lappi, O., Mole, C., Pekkanen, J., & Mars, F. (2019). Looking at the Road When Driving Around Bends : Influence of Vehicle Automation and Speed. *Frontiers in Psychology*, 10. <https://doi.org/10.3389/fpsyg.2019.01699>
- Sheridan, T. B., & Verplank, W. L. (1978). *Human and computer control of undersea teleoperators*. Massachusetts Inst of Tech Cambridge Man-Machine Systems Lab.
- Shinoda, Hayhoe, M. M., & Shrivastava, A. (2001). What controls attention in natural environments? *Vision Research*, 41(25-26), 3535–3545. [https://doi.org/10.1016/S0042-6989\(01\)00199-7](https://doi.org/10.1016/S0042-6989(01)00199-7)
- Singh, A. M., Bera, S., & Bera, R. (2019). Review on vehicular radar for road safety. *Advances in Communication, Cloud, and Big Data*, 41–47. https://doi.org/10.1007/978-981-10-8911-4_5
- Sivak. (1996). The information that drivers use : Is it indeed 90% visual? *Perception*, 25(9), 1081–1089. <https://doi.org/10.1068/p251081>
- Smallwood, J., O'Connor, R. C., Sudberry, M. V., Haskell, C., & Ballantyne, C. (2004). The consequences of encoding information on the maintenance of internally generated images and thoughts : The role of meaning complexes. *Consciousness and Cognition*, 13(4), 789–820. <https://doi.org/10.1016/j.concog.2004.07.004>

BIBLIOGRAPHIE

- Smiley, A., Smahel, T., & Eizenman, M. (2004). Impact of video advertising on driver fixation patterns. *Transportation Research Record*, 1899(1), 76–83. <https://doi.org/10.3141/1899-10>
- Smith, K., & Hancock, P. A. (1995). Situation awareness is adaptive, externally directed consciousness. *Human Factors*, 37(1), 137–148. <https://doi.org/10.1518/001872095779049444>
- Stanton, N. A., & Salmon, P. M. (2009). Human error taxonomies applied to driving: A generic driver error taxonomy and its implications for intelligent transport systems. *Safety Science*, 47(2), 227–237. <https://doi.org/10.1016/j.ssci.2008.03.006>
- Stanton, N. A., Salmon, P. M., Walker, G. H., Salas, E., & Hancock, P. A. (2017). State-of-science: Situation awareness in individuals, teams and systems. *Ergonomics*, 60(4), 449–466. <https://doi.org/10.1080/00140139.2017.1278796>
- Stanton, N. A., Young, M., & McCaulder, B. (1997). Drive-by-wire: The case of driver workload and reclaiming control with adaptive cruise control. *Safety Science*, 27(2-3), 149–159. [https://doi.org/10.1016/S0925-7535\(97\)00054-4](https://doi.org/10.1016/S0925-7535(97)00054-4)
- Stanton, N. A., Young, M. S., Walker, G. H., Turner, H., & Randle, S. (2001). Automating the driver's control tasks. *International Journal of Cognitive Ergonomics*, 5(3), 221–236. https://doi.org/10.1207/S15327566IJCE0503_5
- Stern, J. A., Boyer, D., & Schroeder, D. (1994). Blink rate: A possible measure of fatigue. *Human Factors*, 36(2), 285–297. <https://doi.org/10.1177/001872089403600209>
- Strand, N., Nilsson, J., Karlsson, I. M., & Nilsson, L. (2014). Semi-automated versus highly automated driving in critical situations caused by automation failures. *Transportation Research Part F: Traffic Psychology and Behaviour*, 27, 218–228. <https://doi.org/10.1016/j.trf.2014.04.005>

- Summala, H., Nieminen, T., & Punto, M. (1996). Maintaining lane position with peripheral vision during in-vehicle tasks. *Human Factors*, 38(3), 442–451. <https://doi.org/10.1518/001872096778701944>
- Taylor, R. M. (1990). Situational awareness rating technique (SART) : The development of a tool for aircrew systems design. *Situational Awareness*, 111–128.
- Team, R. C., & others. (2013). R: *A language and environment for statistical computing*.
- Treat, J. R., Tumbas, N., McDonald, S., Shinar, D., Hume, R. D., Mayer, R., Stansifer, R., & Castellan, N. (1979). *Tri-level study of the causes of traffic accidents: Final report. Executive summary*. Indiana University, Bloomington, Institute for Research in Public Safety.
- Tuhkanen, S., Pekkanen, J., Rinkkala, P., Mole, C., Wilkie, R. M., & Lappi, O. (2019). Humans Use predictive Gaze strategies to target Waypoints for steering. *Scientific reports*, 9(1), 8344.
- Underwood, Chapman, P., Bowden, K., & Crundall, D. (2002). Visual search while driving: Skill and awareness during inspection of the scene. *Transportation Research Part F: Traffic Psychology and Behaviour*, 5(2), 87–97. [https://doi.org/10.1016/S1369-8478\(02\)00008-6](https://doi.org/10.1016/S1369-8478(02)00008-6)
- Underwood, Crundall, D., & Chapman, P. (2002). Selective searching while driving: The role of experience in hazard detection and general surveillance. *Ergonomics*, 45(1), 1–12. <https://doi.org/10.1080/00140130110110610>
- Underwood, S., & Firmin, D. (2014). *Automated vehicles forecast: Vehicle symposium opinion survey*.
- UNECE. (2016, mars). *UNECE paves the way for automated driving by updating UN international convention*.

BIBLIOGRAPHIE

- Victor. (2005). Keeping eye and mind on the road. *Digital Comprehensive Summaries of Uppsala Dissertations from the Faculty of Social Sciences*, 83.
- Victor, Harbluk, J. L., & Engström, J. A. (2005). Sensitivity of eye-movement measures to in-vehicle task difficulty. *Transportation Research Part F: Traffic Psychology and Behaviour*, 8(2), 167-190. <https://doi.org/10.1016/j.trf.2005.04.014>
- Vogelpohl, T., Kühn, M., Hummel, T., & Vollrath, M. (2019). Asleep at the automated wheel—Sleepiness and fatigue during highly automated driving. *Accident Analysis & Prevention*, 126, 70–84. <https://doi.org/10.1016/j.aap.2018.03.013>
- Vogelpohl, T., Vollrath, M., Kühn, M., Hummel, T., & Gehlert, T. (2016). Übergabe von hochautomatisiertem Fahren zu manueller Steuerung. *Berlin: GDV*.
- Walch, M., Mühl, K., Kraus, J., Stoll, T., Baumann, M., & Weber, M. (2017). From car-driver-handovers to cooperative interfaces : Visions for driver-vehicle interaction in automated driving. *Automotive user interfaces*, 273–294. https://doi.org/10.1007/978-3-319-49448-7_10
- Walker, G. H., Stanton, N. A., & Young, M. S. (2001). Where is computing driving cars? *International Journal of Human-Computer Interaction*, 13(2), 203–229. https://doi.org/10.1207/S15327590IJHC1302_7
- Wandtner, B., Schömig, N., & Schmidt, G. (2018). Secondary task engagement and disengagement in the context of highly automated driving. *Transportation Research Part F: Traffic Psychology and Behaviour*, 58, 253–263. <https://doi.org/10.1016/j.trf.2018.06.001>
- Wann, J. P., & Swapp, D. K. (2000). Why you should look where you are going. *Nature Neuroscience*, 3(7), 647. <https://doi.org/10.1038/76602>

- Wehrens, R., & Mevik, B.-H. (2007). The pls Package : Principal Component and Partial Least Squares Regression in R. *Journal of Statistical Software*, 18(2), 1-24. <https://doi.org/10.18637/jss.v018.i02>
- Wickens, C. D. (2002). Multiple resources and performance prediction. *Theoretical issues in ergonomics science*, 3(2), 159–177. <https://doi.org/10.1080/14639220210123806>
- Wickens, C. D., & Kessel, C. (1979). The effects of participatory mode and task workload on the detection of dynamic system failures. *IEEE Transactions on Systems, Man, and Cybernetics*, 9(1), 24–34. <https://doi.org/10.1109/TSMC.1979.4310070>
- Wickens, C. D., & Kessel, C. (1981). Failure detection in dynamic systems. *Human detection and diagnosis of system failures*, 155–169. https://doi.org/10.1007/978-1-4615-9230-3_11
- Wierwille, W. W., Wreggit, S., Kirn, C., Ellsworth, L., & Fairbanks, R. (1994). Research on vehicle-based driver status/performance monitoring; development, validation, and refinement of algorithms for detection of driver drowsiness. *National Highway Traffic Safety Administration Final Report, DOT HS 808 247*.
- Wilkie, R. M., Kountouriotis, G., Merat, N., & Wann, J. P. (2010). Using vision to control locomotion : Looking where you want to go. *Experimental Brain Research*, 204(4), 539–547. <https://doi.org/10.1007/s00221-010-2321-4>
- Wilkie, R. M., Wann, J. P., & Allison, R. S. (2008). Active gaze, visual look-ahead, and locomotor control. *Journal of Experimental Psychology: Human Perception and Performance*, 34(5), 1150. <https://doi.org/10.1037/0096-1523.34.5.1150>
- Wong, J.-T., & Huang, S.-H. (2013). Attention allocation patterns in naturalistic driving. *Accident Analysis & Prevention*, 58, 140-147. <https://doi.org/10.1016/j.aap.2013.04.033>

BIBLIOGRAPHIE

- Yarbus, A. L. (1967). Eye movements during perception of complex objects. *Eye Movements and Vision*, 171–211. https://doi.org/10.1007/978-1-4899-5379-7_8
- Young, M. S., & Stanton, N. A. (2007). Back to the future : Brake reaction times for manual and automated vehicles. *Ergonomics*, 50(1), 46–58. <https://doi.org/10.1080/00140130600980789>
- Zeeb, K., Buchner, A., & Schrauf, M. (2015). What determines the take-over time? An integrated model approach of driver take-over after automated driving. *Accident Analysis & Prevention*, 78, 212-221. <https://doi.org/10.1016/j.aap.2015.02.023>
- Zeeb, K., Buchner, A., & Schrauf, M. (2016). Is take-over time all that matters ? The impact of visual-cognitive load on driver take-over quality after conditionally automated driving. *Accident Analysis & Prevention*, 92, 230–239. <https://doi.org/10.1016/j.aap.2016.04.002>
- Zeeb, K., Härtel, M., Buchner, A., & Schrauf, M. (2017). Why is steering not the same as braking? The impact of non-driving related tasks on lateral and longitudinal driver interventions during conditionally automated driving. *Transportation Research Part F: Traffic Psychology and Behaviour*, 50, 65-79. <https://doi.org/10.1016/j.trf.2017.07.008>
- Zhang, B., de Winter, J., Varotto, S., Happee, R., & Martens, M. (2019). Determinants of take-over time from automated driving: A meta-analysis of 129 studies. *Transportation Research Part F: Traffic Psychology and Behaviour*, 64, 285–307. <https://doi.org/10.1016/j.trf.2019.04.020>

Titre : Étude et modélisation des stratégies visuelles en situation de conduite automobile autonome

Mots clés : stratégies visuelles, conduite autonome, modélisation, sortie de boucle

Résumé : Le comportement du conducteur, notamment ses stratégies visuelles, peut être modifié en situation de conduite automobile autonome, comparé à la conduite manuelle. Le premier axe de ce travail de doctorat porte sur l'adaptation des stratégies visuelles en conduite autonome. Pour ce faire, deux expérimentations ont été menées dans deux contextes routiers (route à virage et autoroute), avec des conducteurs devant superviser de manière continue ou partielle la scène de conduite. Les résultats montrent que les stratégies évoluent dans tous les cas vers un désengagement du regard de la route immédiate pour se diriger soit en amont pour plus d'anticipation (supervision continue en virage), soit vers des zones non pertinentes (supervision partielle sur autoroute).

Le second axe de travail porte sur le lien entre les stratégies visuelles et la sortie de boucle des conducteurs, c'est-à-dire le désengagement progressif de la supervision au fil de la conduite autonome. Les résultats montrent qu'il est possible de prédire l'état du conducteur dans la boucle à partir de ses stratégies visuelles spontanées. Ces conclusions s'appuient sur un travail de modélisation statistique. Les modèles obtenus mettent en avant l'importance de considérer des indicateurs de la dynamique du regard pour prédire l'état du conducteur. Ces résultats s'inscrivent dans la perspective de la mise au point d'algorithmes de détection du désengagement du conducteur dans les futurs véhicules autonomes.

Title : Study and modelling of drivers' visual strategies during automated driving

Keywords : visual strategies, autonomous driving, modelling, out-of-the-loop

Abstract : Driver behaviour, including visual strategies, can be modified in autonomous driving situations compared to manual driving. The first axis of this PhD work focuses on the adaptation of visual strategies in autonomous driving. To this end, two experiments were conducted in different road contexts (rural roads with bends and motorway), with drivers having to continuously or partially supervise the driving scene. The results show that the strategies evolve in all cases towards a disengagement of the gaze from the immediate road to move either upstream for more anticipation (continuous supervision on rural roads) or towards irrelevant areas (partial supervision on motorways).

The second line of work deals with the link between visual strategies and the out-of-the-loop phenomenon, i.e. the gradual disengagement of the driver from supervision as he drives in autonomous mode. The results show that it is possible to predict the state of the driver in the loop from his spontaneous visual strategies. These conclusions are based on statistical modelling work. The resulting models highlight the importance of considering indicators of gaze dynamics to predict the driver's state. These conclusions are based on statistical modelling work. The resulting models highlight the importance of considering indicators of gaze dynamics to predict the driver's state. These results can be used to develop algorithms for detecting driver disengagement in future autonomous vehicles.