



**UNIVERSIDADE ESTADUAL PAULISTA
FACULDADE DE ARQUITETURA, ARTES,
COMUNICAÇÃO E DESIGN
PROGRAMA DE PÓS-GRADUAÇÃO EM DESIGN**

**EFEITOS DA EXPERIÊNCIA E DAS DEMANDAS COGNITIVAS SOBRE A
CARGA DE TRABALHO MENTAL DURANTE A CONDUÇÃO DE
AUTOMÓVEL: MÉTODOS DE PUPILOMETRIA**

Gustavo de Andrade Silva

BAURU - SP

2023

GUSTAVO DE ANDRADE SILVA

**EFEITOS DA EXPERIÊNCIA E DAS DEMANDAS COGNITIVAS
SOBRE A CARGA DE TRABALHO MENTAL DURANTE A CONDUÇÃO DE
AUTOMÓVEL: MÉTODOS DE PUPILOMETRIA**

Tese apresentada como parte dos requisitos para obtenção do título de doutor em Design, no Programa de Pós - Graduação em Design da Universidade Estadual Paulista “Júlio de Mesquita Filho”, linha de pesquisa Ergonomia, sob a orientação do Prof. Dr. Sérgio Tosi Rodrigues.

BAURU - SP

2023

Silva, Gustavo de Andrade.

Efeitos da experiência e das demandas cognitivas sobre a carga de trabalho mental durante a condução de automóvel: métodos de pupilometria / Gustavo de Andrade Silva, 2023

169 f. : il.

Orientador: Sérgio Tosi Rodrigues

Tese (Doutorado)-Universidade Estadual Paulista (Unesp). Faculdade de Arquitetura, Artes, Comunicação e Design, Bauru, 2023

I. Pupilometria. 2.Carga de Trabalho Mental. 3. Simulador de Automóvel. 4.Smartwatch. 5. Freada. I. Universidade Estadual Paulista. Faculdade de Arquitetura, Artes, Comunicação e Design. II. Título.

GUSTAVO DE ANDRADE SILVA

Efeitos da experiência e das demandas cognitivas sobre a carga de trabalho mental durante a condução de automóvel: métodos de pupilometria

COMISSÃO EXAMINADORA

MEMBROS TITULARES

Prof. Dr. Sergio Tosi Rodrigues (Presidente)

UNESP/FC/Bauru.

Prof^a. Dr^a. Paula Fávaro Polastri Zago

UNESP/FC/Bauru.

Prof. Dr. José Angelo Barela

UNESP/IB/Rio Claro.

Prof. Dr. Fausto Orsi Medola

UNESP/FAAC/Bauru.

Prof. Dr. Fernando Luis Barroso da Silva

USP/FCFRP/Ribeirão Preto.

MEMBROS SUPLENTES

Prof. Dr. Fábio Augusto Barbieri

UNESP/FC/ Bauru

Prof. Dr. Luis Carlos Paschoarelli

UNESP/FAAC/UNESP

Prof. Dr. Carlos Eduardo Lopes Verardi

UNESP/FC/Unesp

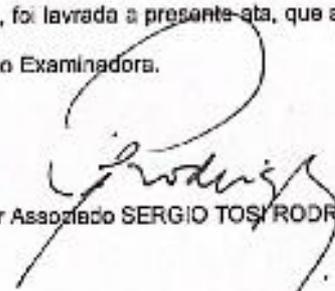
Prof. Dr. Renato de Moraes

USP/EEFERP/Ribeirão Preto

ATA DA DEFESA PÚBLICA DA TESE DE DOUTORADO DE GUSTAVO DE ANDRADE SILVA, DISCENTE DO PROGRAMA DE PÓS-GRADUAÇÃO EM DESIGN, DA FACULDADE DE ARQUITETURA, ARTES, COMUNICAÇÃO E DESIGN - CÂMPUS DE BAURU.

Aos 17 dias do mês de março do ano de 2023, às 14:00 horas, por meio de Videoconferência, realizou-se a defesa de TESE DE DOUTORADO de GUSTAVO DE ANDRADE SILVA, intitulada **EFEITOS DA EXPERIÊNCIA E DAS DEMANDAS COGNITIVAS SOBRE A CARGA DE TRABALHO MENTAL DURANTE A CONDUÇÃO DE AUTOMÓVEL: MÉTODOS DE PUPILOMETRIA**

A Comissão Examinadora foi constituída pelos seguintes membros: Professor Associado SERGIO TOSI RODRIGUES (Orientador(a) - Participação Presencial) do(a) Departamento de Educação Física / Faculdade de Ciências /UNESP/Bauru, Prof. Dr. JOSE ANGELO BARELA (Participação Virtual) do(a) Departamento de Educação Física / UNESP - Instituto de Biociências de Rio Claro - SP, Profa. Dra. PAULA FAVARO POLASTRI ZAGO (Participação Presencial) do(a) Departamento de Educação Física / Faculdade de Ciências - UNESP - Bauru, Professor Associado FAUSTO ORSI MEDOLA (Participação Presencial) do(a) Programa de Pósgraduação em Design / FAAC/Unesp/Bauru, Prof. Dr. FERNANDO LUIS BARROSO DA SILVA (Participação Virtual) do(a) Departamento de Ciências Moleculares / Faculdade de Ciências Farmacêuticas de Ribeirão Preto - USP. Após a exposição pelo doutorando e arguição pelos membros da Comissão Examinadora que participaram do ato, de forma presencial e/ou virtual, o discente recebeu o conceito final: APROVADO. Nada mais havendo, foi lavrada a presente ata, que após lida e aprovada, foi assinada pelo(a) Presidente(s) da Comissão Examinadora.


Professor Associado SERGIO TOSI RODRIGUES

Dedico essa tese de doutorado
ao meu marido Andrew e aos meus pais
Airton e Rosania, que sempre me apoiaram
e incentivaram em diversos desafios.

AGRADECIMENTOS

Foram 4 anos de trabalho para concluir a presente tese de doutorado. Diversas pessoas me apoiaram neste período e, por mais simbólica que tenha sido a sua contribuição, foram extremamente importantes para a finalização deste estudo. Por isso, gostaria de agradecer:

Ao meu querido marido Andrew, parceiro para a vida toda, que acompanhou de perto toda a minha jornada acadêmica na pós-graduação, sendo meu apoio emocional, confidente e maior incentivador, aguentou momentos de estresse e ansiedade com muito zelo e paciência.

À minha família: à minha mãe Rosania, ao meu pai Airton e minha irmã Juliane, que torceram, incentivaram, apoiaram e acreditaram nos meus sonhos, por mais distantes e difíceis que eles fossem.

Ao meu orientador, Sérgio Tosi Rodrigues, por ser a minha inspiração como profissional e pessoa, desde o meu primeiro contato na disciplina da pós-graduação, pela compreensão, confiança, respeito e parceria, me guiando pela carreira acadêmica como pesquisador ético, sendo paciente e atento, sempre.

À Tamara de Souza Brandão Guaraldo, por se tornar uma amiga, por me guiar e orientar nas atividades de docência e ensino e ser tão humana, acolhedora, compreensiva e respeitosa comigo.

Aos meus queridos amigos Larissa Lotufo e Everton Fernandes, por acompanhar esta trajetória desde a graduação e por me incentivar a apoiar em dezenas de momentos.

Aos colegas do Laboratório de Informação, Visão e Ação (LIVIA) da UNESP de Bauru, pela parceria, força e comunidade.

A todos,
muito obrigado!

RESUMO

Com a variedade de dispositivos eletrônicos disponíveis no ambiente interno do carro, aumentou-se a preocupação com a possibilidade desses equipamentos desviarem a atenção do motorista da tarefa de conduzir um veículo no trânsito. Os smartwatches são relógios inteligentes que possibilitam a interação do motorista com as notificações oriundas de um celular smartphone. O uso deste relógio durante a condução de automóvel pode provocar aumento na carga de trabalho mental do motorista, já que ambas as atividades disputam os mesmos recursos cognitivos e visuais. Uma forma promissora para aferir a carga de trabalho mental é através da dilatação do diâmetro pupila. Diferentes métodos foram desenvolvidos para aferir a carga de trabalho mental com base nos dados de diâmetro da pupila. Para investigar os efeitos da experiência do motorista e da demanda cognitiva resultante das tarefas de freada e do uso de smartwatch sobre a carga de trabalho mental, durante a condução de automóvel e avaliar como métodos de pupilometria (Index of Pupillary Activity, Low/High Index of Pupillary Activity e Task-evoked Pupillary Response, respectivamente, IPA, LHIPA e TEPR) são sensíveis às variações da carga de trabalho mental, durante a condução de automóvel, 40 voluntários, sendo 20 motoristas experientes e 20 novatos, foram selecionados para dirigir em quatro condições experimentais – controle (somente dirigir o automóvel), dirigir o automóvel com situação de freada, dirigir o automóvel com leitura do smartwatch e dirigir o automóvel com a situação de freada ocorrendo simultaneamente à leitura do smartwatch. Resultados mostraram que ao aumentar-se a demanda cognitiva nas condições experimentais, notou-se uma piora no desempenho de motoristas: diminuição da velocidade média, aumento da variabilidade da velocidade média, aumento da distância ao carro líder e aumento no número de colisões. Motoristas experientes apresentaram menor velocidade média e maior variabilidade da velocidade média. Os métodos IPA, LHIPA e TEPR foram sensíveis à manipulação da demanda cognitiva nas condições experimentais.

Palavras-chave: pupilometria, carga de trabalho mental, simulador de automóvel, smartwatch, movimento dos olhos, freada.

ABSTRACT

With the variety of electronic devices available in the internal environment of the vehicle, there has been increased concern about the possibility of these devices diverting the driver's attention from the task of driving a vehicle in traffic. Smartwatches are smart devices that allow drivers to interact with notifications from a smartphone. Using a smartwatch while driving can increase the driver's mental workload, as both tasks compete for the same cognitive and visual resources. A promising way to measure mental workload is through pupil dilation. Different methods have been developed to measure mental workload based on pupil diameter data. To investigate the effects of driver's experience and cognitive demands resulting from braking and smartwatch use tasks on mental workload while driving a car and to evaluate how pupillometry methods (Pupillary Activity Index, Low/High Index of Pupillary Activity, and Task-Evoked Pupillary Response, respectively, IPA, LHIPA, and TEPR) are sensitive to variations in mental workload while driving a car, 40 volunteers (20 experienced drivers and 20 novice drivers) were selected to drive in four experimental conditions - control (only driving the vehicle), driving with braking situation, driving with smartwatch reading and driving with the braking situation occurring simultaneously with the smartwatch reading. Results showed that when cognitive demands were increased in the experimental conditions, the driver's performance was compromised (a decrease in the average speed, an increase in the variability of the average speed, an increase in the distance to the leading car, and an increase in the number of collisions). Experienced drivers had lower mean speed and higher mean speed variability. IPA, LHIPA, and TEPR methods were sensitive to the manipulation of cognitive demands in experimental conditions.

Keywords: Pupillometry, mental workload, driving simulator, smartwatch, eye movements, braking.

SUMÁRIO

1.	INTRODUÇÃO	12
1.1.	Questões da tese	18
1.2.	Objetivos da tese	18
1.3.	Hipóteses da tese	19
1.4.	Contribuições da tese ao Design	19
1.4.1.	Smartwatch	21
2.	REVISÃO DE LITERATURA.....	22
2.1.	Carga de trabalho mental.....	22
2.1.1.	Termo e suas variações	23
2.1.2.	Modelos sobre carga de trabalho mental	24
2.1.2.1.	Modelos estruturais de recursos atencionais.....	24
2.1.2.2.	Modelos de recursos energéticos.....	25
2.1.3.	Causas para carga de trabalho mental	26
2.1.4.	Consequências da carga de trabalho mental.....	26
2.1.5.	Carga de trabalho mental e sua influência no desempenho	26
2.1.6.	Principais métodos de mensuração da carga de trabalho mental ..	27
2.1.6.1.	Medidas subjetivas.....	28
2.1.6.2.	Medidas psicofisiológicas	29
2.1.6.3.	Medidas de desempenho: tarefa primária e tarefa dupla.....	30
2.1.7.	Direção de automóvel e a carga de trabalho mental	32
2.2.	Teoria da Carga Cognitiva	34
2.3.	Pupilometria	35
2.3.1.	Estado da arte na mensuração de carga de trabalho mental através da pupila.....	39
2.3.1.1.	Task-evoked pupillary response (TEPR)	39
2.3.1.2.	Index of cognitive activity (ICA)	40
2.3.1.3.	Index of pupillary activity (IPA)	41
2.3.1.4.	Low/High index of pupillary activity (LHIPA)	44
2.3.1.5.	Fixation-aligned pupillary response averaging (FAPRA).....	45
2.4.	Efeitos da dupla tarefa	47
2.5.	Efeitos do aumento da complexidade da tarefa	48
2.6.	Efeito da experiência na percepção de perigo.....	50
3.	MÉTODO	54
3.1.	Características da amostra.....	54
3.1.1.	Participantes	54

3.1.2. Critério de inclusão	55
3.1.3. Critério de exclusão	55
3.2. Materiais	55
3.2.1. Equipamentos	56
3.2.2. Softwares	58
3.2.3. Simulador de veículo automotor	58
3.2.3.1. Configurações do ambiente virtual simulado	59
3.2.3.2. Cenários virtuais 3D	60
3.3. Procedimento experimental	64
3.4. Condições experimentais	68
3.4.1. CAR: Condição controle – tarefa de dirigir	69
3.4.2. NOT: Condição de dupla tarefa – tarefa dupla de dirigir e ler mensagem no smartwatch	69
3.4.3. FRE: Condição com freada abrupta do veículo líder	69
3.4.4. FNOT: Condição com freada abrupta do carro líder e leitura de mensagem no smartwatch	70
3.5. Tratamento e análise dos dados	70
3.5.1. Aleatorização dos dados coletados	71
3.5.2. Pré-processamento dos dados	72
3.5.3. Análise temporal	74
3.5.4. Delineamento e seleção dos eventos a partir da análise temporal	77
3.5.5. Variáveis dependentes	79
3.5.6. Análise estatística	81
4. RESULTADOS	82
4.1. Aumento da carga de trabalho mental e métodos pupilométricos	82
5. DISCUSSÃO	92
5.1. Efeito da demanda cognitiva nas condições experimentais	92
5.2. Efeito da demanda cognitiva e métodos de pupilometria	98
5.3. Diferença entre grupos e métodos de pupilometria	101
5.4. Efeito da experiência na tarefa de dirigir	103
5.5. Efeito da tentativa	104
6. CONCLUSÃO	106
7. REFERÊNCIAS	108
APÊNDICES	120
APÊNDICE I – Configuração de hardware e software	121
APÊNDICE II – Método de randomização	128
APÊNDICE III – Tratamento de dados	131
1. Tratamento de dados: simulador	132

2.	Tratamento de dados: filmagem.....	132
3.	Tratamento de dados: movimento dos olhos	134
APÊNDICE IV – Algoritmos.....		135
1.	Algoritmos para manipular os dados do simulador:.....	136
2.	Algoritmos para manipular os dados da pupila.....	138
3.	Algoritmos para calcular carga mental de trabalho	140
4.	Algoritmos para manipular dados de movimentos dos olhos	145
ANEXOS		149
ANEXO I – Algoritmo para gerar as sequencias de tentativas		150
ANEXO II – Formulário de seleção e classificação de participantes		152
ANEXO III – Temo de Consentimento Livre e Esclarecido		154
ANEXO IV – Formulário de Caracterização de Participante		156

LISTA DE FIGURAS

- Figura 1 - Capacete Eye Tracker ASL H6 da Applied Sciences Laboratories. Equipamento que coleta dados do movimento dos olhos, da cabeça e diâmetro da pupila. 56
- Figura 2 - Estrutura montada do Cockpit com banco reclinável e ajustável, suporte para a televisão Samsung 46" e kit de acessórios Gamer Logitech G27 com pedais, câmbio e volante acoplado ao Cockpit..... 57
- Figura 3 - A: Roteador D-link 524G 54mb. B: Notebook Macbook Pro 13,3" Mid 2012 da fabricante Apple. C: Relógio inteligente Apple Watch Series 1 da fabricante Apple. D: Celular smartphone iPhone 5 16Gb da fabricante Apple. 57
- Figura 4 - A: Câmera DSLR Nikon D5100 da fabricante Nikon. B: Lente AF-S Nikkor DX 18-55mm 1:3.5-5.6G da fabricante Nikon. C: Microfone Direcional P2 Video Mic Go da Fabricante Rode. 58
- Figura 5 - A: Imagem da televisão Samsung de 46" exibindo a imagem do simulador. B: Tela de controle do pesquisador mais a tela de replicação da imagem que o participante observa na televisão. C: Imagem do olho do participante com a identificação da pupila e da córnea, mais a replicação da tela que o participante estava observando. 59
- Figura 6 - Vista aérea da divisão da rodovia. Ao total foram disponibilizadas 6 faixas, sendo 3 delas na mesma direção do motorista e as outras 3 na direção oposta ao sentido da via. Cada grupo de 3 faixas foi separado por uma linha dupla continua. 61
- Figura 7 - Visão do participante mostrando o ambiente interno do carro com velocímetro, contador de giros, conjunto de espelhos e o ambiente virtual urbano 3D. 62
- Figura 8 - Distância temporal relativa de 3 segundos entre o carro do motorista participante e o carro líder no início de cada tentativa..... 63
- Figura 9 - Organização final do participante com os equipamentos posicionados e sincronizados. Observa-se em 1: o volante; 2: os pedais; 3: a caixa de câmbio para troca de marchas; 4: o smartwatch para leitura das mensagens de texto e 5: o *eye tracker* calibrado para captura dos movimentos dos olhos e o diâmetro da pupila..... 66
- Figura 10 - Ilustração dos cenários de familiarização utilizados neste estudo. A: Cenário de familiarização para adaptação dos controles. B: Cenário de familiarização para estimular o controle do volante em velocidades mais alta. 67
- Figura 11 - Exemplo da composição das tentativas após o procedimento de randomização. A: tem-se tentativas (T) para cada um dos participantes (P) da pesquisa. B: Os números de 1 a 12 foram, posteriormente, substituídos por uma sigla de identificação da condição experimental, sendo C1(CAR), C2 (NOT), C3, (FRE) e C4(FNOT)..... 72
- Figura 12 - Esquema ilustrativo para definição dos marcos temporais disponíveis analiticamente para definir o intervalo de dados de cada condição experimental..... 79

Figura 13 - Variáveis dependentes da presente tese, organizadas em categoria: desempenho da tarefa primária, desempenho da tarefa secundária, movimento dos olhos e índices pupilométricos.	80
Figura 14 - Curvas médias (± 1 erro padrão) do diâmetro da pupila: A) Condição controle CAR: diâmetro da pupila após a estabilização da velocidade do carro na tentativa. B) Condição NOT: comportamento da pupila antes do início e fim médios da leitura da mensagem. C) Condição FNOT: diâmetro da pupila variando entre os diferentes eventos (freada e leitura). D) Condição FRE: Diâmetro da pupila após o acender da luz de freio e resposta motora da freada. 82	
Figura 15 - Valor do índice IPA em função das condições experimentais. ...	84
Figura 16 - Valor do índice LHIPA em função das condições experimentais.	84
Figura 17 - Valor da porcentagem de mudança do diâmetro da pupila (PMDP) em função das condições experimentais. PMDP foi calculado em relação ao <i>baseline</i> de cada condição experimental o qual foi definido como o valor médio do diâmetro da pupila em um intervalo de 0,5 s antes do início do evento característico da condição experimental.	84
Figura 18 - Número de colisões entre o motorista e o carro líder em função das condições experimentais. As condições experimentais CAR e NOT não possuíam eventos de colisão.	85
Figura 19 - Comparativo entre as velocidades médias dos motoristas novatos e experientes, independente de condição experimental.	86
Figura 20 - Comparativo entre as variabilidades das velocidades médias dos motoristas experientes e novatos por condição experimental.	86
Figura 21 - Distância relativa ao carro líder em função das tentativas por grupos de experiência (experientes e novatos) na direção de veículo automotor. 87	87
Figura 22 - Pressão sobre o pedal de freio em função da condição experimental para cada uma de suas 3 tentativas. Os dados foram normalizados entre 0 e 100 %, com 100% indicando que o pedal foi completamente pressionado (* $p < 0,05$).	88
Figura 23 - Número de fixações do olhar na tarefa de dirigir em função das condições experimentais para a área de interesse da simulação.	89
Figura 24 - Número de fixações do olhar em função das condições experimentais para a área de interesse fora da simulação.	89
Figura 25 - Duração total das fixações do olhar em função da condição experimental por grupos (experientes e novatos).	91
Figura 26 - Imagem do software ASL Eye Tracker 6000 mostrando o painel de controle (superior esquerdo), o painel de ajustes de brilho e contraste da câmera responsável pela captura do movimento dos olhos (centro acima) o painel (inferior direito) que mostra em tempo real o olho do participante com as marcações das linhas de detecção da pupila e da córnea do olho (esquerda) e a cena que ele está observando na televisão Samsung 46" (direita).	123

- Figura 27 - Esquema mostrado pelo software de Painel de Controle da placa de vídeo Nvidia, mostrando as 5 conexões de saída (3 Display Port, 1 HDM e 1 DVI) e o nome do monitor que está conectada aquela conexão. Observa-se na imagem o Monitor Dell de 19", a televisão Samsung de 46", o monitor Samsung de 15" e o cabo de 10 metros que se conecta no Splitter de vídeo..... 124
- Figura 28 - A: Imagem da televisão Samsung de 46" exibindo a imagem do simulador. B: Tela de controle do pesquisador mais a tela de replicação da imagem que o participante vê na televisão. C: Imagem do olho do participante mais a replicação da tela que o participante está observando. 125
- Figura 29 - Apêndice: Comparativo entre os canais de áudio. A: Canal de áudio de uma tentativa sem filtro. B: Canal de áudio de uma tentativa com o filtro para realçar o instante da chegada da mensagem ao relógio inteligente. C: Canal de áudio de uma tentativa com o filtro para realçar o período em que o participante leu a mensagem de texto..... 133
- Figura 30 - Apêndice: A: Características do filtro de áudio aplicado ao vídeo da filmagem da tentativa para visualizar o instante auditivo em que chegou à mensagem de texto no relógio do participante. B: Características do filtro de áudio aplicado ao vídeo da filmagem da tentativa para visualizar o instante auditivo em que o participante iniciou e finalizou a leitura mensagem de texto no relógio do participante. 133

LISTA DE TABELAS

Tabela 1 -	Caracterização dos voluntários participantes do estudo.....	54
Tabela 2 -	Organização experimental do estudo da presente tese, relacionando o cenário virtual 3D utilizado de acordo com a condição experimental e o número de tentativas realizadas por participante.....	64
Tabela 3 -	Atribuição dos códigos para criação da sequência única de tentativa para cada participante.	71
Tabela 4 -	Conjunto de arquivos gerados para cada procedimento de pré análise por fonte de dados.	74
Tabela 5 -	Condições de definição do período de 10 segundos para realização da análise temporal.....	76
Tabela 6 -	Delineamento experimental do estudo, especificando as condições de pesquisa e um detalhamento das respectivas tarefas.....	81
Tabela 7 -	Nomeação exemplo das condições de direção para cada grupo para gerar conjuntos de sequência de condição de forma aleatória pelo algoritmo. 129	
Tabela 8 -	Exemplo da composição das tentativas após o procedimento de randomização. Na tabela, tem-se tentativas (T) para cada um dos participantes (P) da pesquisa. Os números de 1 a 12 representam os códigos para as possíveis condições e suas repetições.	129

LISTA DE SIGLAS

- ABERGO** – Associação Brasileira de Ergonomia
- ANOVA** – Análise de Variância
- ANOVA-rm** – Análise de Variância com Medidas Repetidas
- ASL** - Applied Sciences Laboratories
- CLT** – Cognitive Load Theory
- CMT** – Carga de trabalho mental
- CNH** – Carteira Nacional de Habilitação
- CNT** – Código Nacional de Trânsito
- fMRI** - Functional Magnetic Resonance Imaging
- HDMI** - High-Definition Multimedia Interface
- ICA** – Index of Cognitive Activity
- IPA** – Index of Pupillary Activity
- IPEA** – Instituto de Pesquisa Econômica Aplicada
- IS** – Intrusão Sacádico
- LC** – Locus Cereleus
- LCD** - Liquid Crystal Display
- LHIPA** – Low High Index of Pupillary Activity
- FAPRA** - Fixation-aligned Pupillary Response Averaging
- NASA-TLX** – NASA Task Invoked Index
- NE** - Norepinefrina
- PMDP** - Porcentagem de Mudança do Diâmetro da Pupila
- TCC** – Teoria de Carga Cognitiva
- TCLE** – Termo de Consentimento Livre e Esclarecido
- TEPR** – Task-evoked Pupillary Response
- VGA** - Video Graphics Array

1. INTRODUÇÃO

A tarefa de dirigir um carro é extremamente complexa, exigindo do condutor do veículo um controle concorrente entre o volante, pedais e câmbio, checagem de espelhos, manutenção da velocidade, manutenção no trajeto em direção ao destino desejado, observação do tráfego de veículos na mesma direção e na direção oposta, manutenção na faixa desejada, observação de potenciais perigos no ambiente, entre outras atividades (LAND, 2006). Controlar um veículo não é somente uma atividade do tipo física para aplicar força, mover e apertar botões ou alavancas, mais também visual e mental (MARQUART; CABRALL; de WINTER, 2015).

Cada vez mais, novas tecnologias são integradas ao ambiente interno de um veículo, criando experiências novas para o condutor com diversos sistemas de tecnologia da informação. Estas tecnologias podem ser para aumentar a segurança, produtividade, conforto e até mesmo para o entretenimento do motorista (SINGH; SINGH; BAJWA, 2014). Ao mesmo tempo em que estas tecnologias agregam recursos ao veículo, tendem a aumentar a carga de trabalho mental do motorista e, conseqüentemente, aumentar o risco de acidentes (REIMER e at., 2009).

Segundo pesquisa do Instituto de Pesquisa Econômica Aplicada (IPEA, 2020), os acidentes de transportes terrestres no Brasil matam mais de 45 mil pessoas por ano, sendo uma das principais causas de mortes no país. Ainda, no Brasil, segundo este estudo, cerca de R\$ 50 bilhões de reais são gastos anualmente com estes acidentes devido a custos relativos à perda de produção das vítimas e custos hospitalares.

Apesar do Código de Trânsito Brasileiro (CTB) prever infração específica para falta de atenção de motoristas ao transitar de forma insegura no trânsito, através do Artigo 169 do CTB, seu enquadramento no ato da autuação de motoristas é custoso aos agentes de segurança do trânsito, já que a “falta de atenção” não é fácil de ser categorizada e atribuída ao motorista infrator pois, neste caso, há necessidade de declaração expressa do mesmo ou de testemunhas, o que não ocorre na realidade. Por isso, há uma subclassificação deste tipo de infração na comparação com a quantidade total de infrações registradas pela Polícia. Há no CTB duas categorias de autuação que podem ser

associadas a falta de atenção do motorista no trânsito. A partir dos dados abertos da Polícia Rodoviária Federal Brasileira (PRF, 2021), as infrações de trânsito para o tipo de enquadramento “Dirigir sem atenção ou sem cuidados indispensáveis a segurança”, foram 1.499 infrações das 370.624 infrações registradas nas rodovias federais brasileiras ao longo do ano de 2021. A autuação por transitar com celular enquanto conduz o veículo representaram 3.843 infrações registradas naquele ano.

A distração de motoristas no trânsito pode ser considerada uma forma de falta de atenção, especialmente, quando esta atenção dividida é atribuída às atividades não relacionadas a tarefa principal de conduzir o veículo automotor (ENGSTRÖM et al., 2013; LEE; YOUNG; REGAN, 2009). Dentre as principais causas de falta de atenção no trânsito, segundo Engström et al. (2017), tanto atividades internas quanto externas ao ambiente do carro são distratoras, como observar outdoors e propagandas em monitores de vídeo, enviar mensagem de texto via smartphone, conversar no celular ou com outros passageiros, engajar em atividades em smartwatches, interagir com sistemas de som multimídia e até mesmo em dispositivos de navegação. Ainda segundo os autores, as distrações podem ser categorizadas em três tipos: visual, manual e cognitiva. As distrações do tipo visual e manual se referem, respectivamente, a interferências que prejudicam a percepção e resposta motora de um indivíduo. A distração cognitiva se refere à mudança de foco da atenção para uma atividade não relacionada à tarefa de condução do veículo.

A Teoria de Carga Cognitiva, desenvolvida inicialmente por Sweller (2011), compreende que a memória de trabalho é um recurso limitado. Logo, ao interagir com várias fontes de informação ao mesmo tempo, pode-se causar uma sobrecarga neste sistema, já que a memória de trabalho é utilizada para todas as atividades conscientes e que pode ser monitorada nos seres humanos (KIRSCHNER; KIRSCHNER; PAAS, 2009). Dessa forma, a falta de recursos para alocar a atenção necessária para processar informação relevante, pode comprometer as necessidades de percepção de uma determinada tarefa. Ao mesmo tempo, interagir com tarefas que são irrelevantes à atividade de direção de um veículo automotor pode afetar diretamente o processo de decisão e produzir respostas demoradas ou incorretas (RECARTE; NUNES, 2003).

A demanda perceptiva externa que exige atenção de um motorista é compreendida como carga de trabalho (SILVA, 2014). Hoedemaeker (2002) define carga de trabalho como a quantidade de recursos requeridos para executar um conjunto concorrente de tarefas, da mesma forma que elas exigem recursos para serem desenvolvidas ao longo do tempo. A carga de trabalho é categorizada da mesma forma que a distração. Neste estudo foca-se na carga de trabalho mental que envolve diversos processos como aqueles neurofisiológicos, perceptuais e cognitivos (BALDWIN; COYNE, 2003). Brookhuis e De Waard (1993) definem a carga de trabalho mental como a capacidade de um indivíduo de processar informação para executar uma tarefa. Ao avaliar a carga de trabalho mental, busca-se compreender a razão entre a capacidade mental aplicada para uma determinada tarefa e o desempenho percebido da própria tarefa (O'DONNELL; EGGEMEIER, 1986).

Ao interagir com atividades concorrentes durante a condução de um veículo, cria-se proporções aumentadas de diversos tipos de erros como perceptivos, de processamento de informação e má tomada de decisão, causando acidentes no trânsito (TREAT et al., 1977). Ao mensurar a carga de trabalho mental de motoristas, pode-se aferir a sua capacidade durante a realização da tarefa principal de conduzir o veículo, além de avaliar as demandas impostas sobre o condutor ao se envolver com novas tarefas concorrentes. Assim, a identificação deste aumento de carga mental, devido ao uso de mais sistemas internos ao carro, pode facilitar a compreensão do comportamento perceptivo-motor humano e gerar alternativas em busca da redução de acidentes.

Além da já mencionada complexidade da tarefa de dirigir um veículo e da realização de múltiplas tarefas concorrentes ao dirigir, a experiência de um motorista ao volante é um outro fator importante e decisor na seleção de informações relevantes do ambiente para uma tomada de decisão efetiva e rápida, especialmente, na detecção e prevenção de acidentes no trânsito. De acordo com Pammer et al. (2018), durante a condução de veículo automotor, são coletadas, mentalmente, dezenas de informações as quais são rapidamente filtradas naquelas que são importantes e naquelas que são irrelevantes. Motoristas experientes são aqueles que possuem maior repertório de habilidades e melhor seleção de informação relevante do ambiente, para

conduzir um veículo automotor e evitar acidentes, devido ao maior tempo de prática nesta tarefa e com maior probabilidade de experimentação de variadas combinações das condições do trânsito. Para Crundall et al. (2012), os motoristas experientes tendem a observar mais estrategicamente o ambiente, focando sua atenção em eventos que podem ser relevantes à ocorrência de uma situação de perigo quando comparado aos motoristas inexperientes. A atenção tem, portanto, uma conceitualização de um filtro que permite a passagem de informação relevante a uma determinada tarefa em desenvolvimento enquanto bloqueia aquelas que são irrelevantes (PAMMER et al., 2018). Assim, para Underwood, Ngai e Underwood (2013), a medida em que o motorista ganha experiência na condução de veículo automotor, em diferentes situações e parâmetros no trânsito, é provável que ele vivencie eventos diferentes entre si, especialmente, quanto ao nível de periculosidade que cada um desses eventos oferece. Conseqüentemente, ao aumentar o seu acervo de eventos e seu conjunto de habilidades, o motorista tende a prever melhor quando e onde um perigo em potencial pode ocorrer (PRADHAN et al., 2009).

Para Engströme et al. (2003), a quantidade de carga de trabalho mental necessária para realizar uma atividade de conduzir um veículo automotor está associada com o processo de aprendizagem e aquisição de experiência nesta tarefa. O grau de experiência de um motorista pode modular a influência das habilidades deste motorista na tarefa de dirigir e no modo como a informação é processada; de acordo com o grau de automação da tarefa, a condução de veículo automotor pode ocorrer de forma controlada ou automática (PAXION; GALY; BERTHELON, 2014). Motoristas inexperientes tem um menor grau de automação na tarefa de dirigir (PATTERN et al., 2006), já que o processo de automação de uma determinada tarefa ocorre progressivamente com a prática. Dessa forma, a tarefa de dirigir um veículo automotor induz uma alta carga de trabalho mental em motoristas inexperientes (SWELLER, 1993; SWELLER e al., 1998; PATTEN et al., 2006; WICKENS; HOLLANDS, 2021), concomitantemente, os motoristas experientes necessitam de um menor grau de carga de trabalho mental (SCHNEIDER; SHIFFRIN, 1977), já que as habilidades cognitivas e motoras foram adquiridas com a prática, requerendo sucessivamente um menor nível de carga de trabalho metal (PATTERN et al., 2006).

Uma das principais técnicas para se mensurar a carga mental é através de variações no diâmetro da pupila sob a ocorrência de uma tarefa (PIGNONI; KOMANDUR, 2019). A pupilometria é uma técnica de medição do diâmetro da pupila e é considerada um indicador válido de carga mental (BEATTY; LUCERO-WAGONER, 2000). As variações na pupila referentes à carga mental estimuladas por uma atividade são pequenas e no máximo de até 0,5 mm (HESS; POLT, 1964). Por isso, utilizar equipamentos como um *eye tracker* – equipamento que utiliza câmeras de vídeo de alta resolução e sensores de infravermelho para capturar, em vídeo, a movimentação ocular e registrar as variações do diâmetro da pupila - tornou a mensuração desta medida viável e possível.

Devido à técnica ser sensível às variações da luz, tanto do ambiente quanto em relação à própria sensibilidade da pupila as fontes de luz, métodos foram desenvolvidos para aferir a carga de trabalho mental e desconsiderar os efeitos do reflexo pupilar da luz. O método de estimulação de resposta pupilar a partir de uma determinada tarefa (ou, em inglês, Task-evoked pupillary response - TEPR) é uma medida que se baseia na resposta pupilar observada a partir da realização de uma determinada tarefa. Esta técnica é vantajosa quando há controle da iluminação do ambiente e demais fontes de luz, reflete instantaneamente e associativamente os efeitos da tarefa sobre a memória de trabalho. O índice de atividade pupilar (ou, em inglês, Index of Pupillary Activity - IPA) foi desenvolvido por Duchowski et al. (2018) e é uma técnica que se utiliza do diâmetro da pupila como entrada de dados, mas não é sensível às variações da luz no ambiente devido ao seu algoritmo separar as frequências do sinal pupilométrico naquele que é gerado por carga de trabalho mental e aquele que é considerada ruído, ou seja, separando as frequências do sinal do diâmetro da pupila em dois; frequência do sinal do diâmetro da pupila atribuída a carga de trabalho mental e à quaisquer outros motivos. Este método utiliza a técnica matemática de *wavelets* para construção de seu algoritmo e é uma nova proposta ao método de índice de atividade cognitiva (ou, em inglês, Index of Cognitive Activity - ICA). O ICA foi desenvolvido por Marshall (2002) e foi o primeiro método de pupilometria a considerar *wavelets* para calcular um índice de carga de trabalho mental e, assim como o IPA, não é influenciado por variações da luz no ambiente; entretanto, é um método patenteado e detalhes

de sua implementação não são públicos. O método de baixo/alto índice de atividade pupilar (ou, em inglês, Low/High Index of Pupillary Activity - LHIPA) foi desenvolvido por Duchowski et al. (2020) e é uma evolução do IPA, sendo sua diferença caracterizada pela forma como a técnica manipula o sinal do diâmetro da pupila; o LHIPA faz a decomposição do sinal, como no método IPA, mas separando o sinal em alta e baixa frequências. Segundo os autores, o LHIPA representa melhor as mudanças nos sistemas simpático e parassimpático do sistema nervoso autônomo. Além dos métodos já citados, há o método que calcula a média das fixações alinhadas durante a resposta pupilar (ou, em inglês, Fixation-aligned Pupillary Response Averaging - FAPRA). O FAPRA foi desenvolvido por Klingner (2010) e seu objetivo é medir a carga de trabalho mental a partir de dados de fixação do olhar, para tarefas que precisam de mudança rápida no foco atencional e de forma imprevisível, portanto, sendo utilizado para tarefas mais complexas.

Apesar da pupilometria ser utilizada há décadas, nenhum estudo comparou extensivamente os seus diferentes métodos. Os estudos que aplicaram as referidas técnicas de pupilometria não o fizeram em situações com demanda cognitiva dinâmica e em uma tarefa mais realista, justificando a necessidade de melhoria da validade ecológica dos experimentos para o cálculo da carga de trabalho mental. Além disso, nenhum estudo analisou o comportamento da pupila com estes métodos, comparando diferentes grupos, como os de motoristas experientes e novatos, submetidos à condição de freada e com aumento gradual da demanda cognitiva de forma multissensorial, ou seja, com canais de aquisição de informação diferentes e que na presente tese ocorre através da visão, tato e audição pois a tarefa de leitura da mensagem de texto exibe, paralelamente, um som de sino característico e um padrão de vibração tátil no punho do participante. Ao investigar métodos diferentes, permite-se que trabalhos futuros possam utilizar destes dados para o desenvolvimento de novas técnicas, algoritmos e modelos para aferição e inferência da carga de trabalho mental via pupilometria, contribuindo, ainda, com sistemas inteligentes de prevenção de acidentes. A partir deste contexto, a presente tese se concentrará no estudo dos métodos IPA, LHIPA e TEPR.

O presente estudo avança na investigação de desempenho da tarefa de condução de automóvel e seus distintos requerimentos cognitivos a partir dos

dados da dissertação de mestrado de Silva (2018). O trabalho de Silva (2018) buscou avaliar o efeito da leitura de mensagem de texto em smartwatch sobre motoristas experientes e inexperientes, durante a condução de automóvel, analisando dados de 40 participantes quanto ao desempenho de uma tarefa dupla, com registro de movimentos dos olhos e da cabeça. Segundo o autor, a leitura de texto em um smartwatch pode afetar o controle longitudinal e lateral de veículos e a leitura de texto no smartwatch compromete a percepção do tempo para contato de motoristas, problemas mais proeminentes em motoristas inexperientes. Assim, a presente tese de doutorado é uma evolução do trabalho de mestrado de Silva (2018).

Em busca de conhecimentos para suprir as referidas lacunas da literatura, esta tese busca melhor compreender como a demanda cognitiva envolvida em distintas tarefas simultâneas à condução de automóvel afeta a dilatação ou constrição do diâmetro da pupila, comparando e avaliando a precisão de métodos inferência da carga de trabalho mental para a supracitada tarefa, a partir de uma condição de pesquisa com validade ecológica.

1.1. Questões da tese

A presente tese se concentra em responder duas questões relacionadas:

Como a carga de trabalho mental, durante a condução de automóvel, é afetada pela experiência do motorista e pela demanda cognitiva das tarefas de freada e uso do smartwatch?

Como os métodos de pupilometria IPA, LHIPA e TEPR são sensíveis às variações da carga de trabalho mental geradas pelo referido contexto?

1.2. Objetivos da tese

Os objetivos da presente tese foram:

- Investigar os efeitos da experiência do motorista e da demanda cognitiva resultante das tarefas de freada e do uso de smartwatch sobre a carga de trabalho mental durante a condução de automóvel.

- Neste contexto, avaliar como métodos de pupilometria IPA, LHIPA e TEPR são precisos às variações da carga de trabalho mental, durante a condução de automóvel envolvendo, simultaneamente, às tarefas de freada e uso do smartwatch.

1.3. Hipóteses da tese

Para a presente tese, foram estabelecidas as seguintes hipóteses:

- Hipótese 1: A demanda cognitiva resultante de cada condição experimental afetará a carga de trabalho mental, registrada através da pupilometria, do seguinte modo: em comparação à condição controle (somente dirigir o automóvel), haverá aumento da carga de trabalho mental nas condições de leitura da mensagem de texto no smartwatch e de freada, atingindo seu máximo na condição simultaneamente combinada de leitura e freada.
- Hipótese 2: A maior experiência na condução de automóvel atenuará a carga de trabalho mental dos motoristas, sendo que o grupo de motoristas experientes apresentará menores valores em comparação com os motoristas novatos.
- Hipótese 3: Os métodos de pupilometria IPA, LHIPA e TEPR produzirão medidas de carga de trabalho mental compatíveis com as demandas cognitivas das diferentes condições experimentais.

1.4. Contribuições da tese ao Design

São diversos os dispositivos eletrônicos que estão presentes no ambiente interno de um veículo automotor. Alguns com objetivos de auxiliar na condução do veículo enquanto outros são voltados ao entretenimento e segurança, por exemplo. A possibilidade de ser interrompido por algum desses sistemas de informação é alta, provocando uma mudança no foco atencional do motorista em detrimento ao controle do veículo e à interação com as atividades da via. A combinação entre conduzir um veículo de forma segura e executar tarefas concorrentes dentro do ambiente de um carro levanta preocupações relacionadas à segurança do motorista no trânsito.

Dessa forma, projetar e desenvolver sistemas para o ambiente interno do carro que poderão ser utilizados por motoristas durante a condução de veículo

automotor, proporcionaram a criação de diversas estratégias para que o motorista interaja com estes sistemas. No entanto, compreender a carga de trabalho mental envolvida no uso destes sistemas e dispositivos de forma individual e combinada com a tarefa de dirigir torna-se necessário para que mecanismos de segurança ou de correção de erros possam ser desenvolvidos e, assim, projetos mais sofisticados de interação do motorista com estes sistemas de informação possam ser analisados, projetados, testados e implementados a partir de um design centrado nas demandas cognitivas de cada tarefa e em relação às capacidades e limitações do seu usuário, seguindo, portanto, princípios ergonômicos.

Ademais, compreender as demandas cognitivas ajuda a melhor organizar a informação para que estas sejam mais adequadas e mais rapidamente percebidas e interpretadas, utilizando-se de estratégias de criação de instrução ótimas, em canais sensoriais que não se interferem, gerando uma condição ideal de aprendizado de forma variada e que proporcione um efeito catalisador na obtenção de habilidades e seleção de informação relevante no momento e no local corretos no ambiente durante a realização da tarefa de dirigir.

A pupilometria se mostra como promissora nos estudos em design, permitindo aferir a carga de trabalho mental em variadas tarefas, incluindo a tarefa de dirigir um veículo. Ao quantificar a carga de trabalho mental, enquanto uma pessoa realiza alguma atividade, ajuda-se a prever e otimizar o desempenho desta pessoa ou do sistema utilizado. O desenvolvimento de interfaces e experiência de usuário tanto para dispositivos eletrônicos quanto para os softwares destes equipamentos, pode ser aprimorada e mais bem avaliado, levando em consideração a carga mental requerida desses usuários em tarefas complexas, especialmente, neste caso, na tarefa de conduzir um veículo automotor. Dessa forma, a carga de trabalho mental se torna um outro parâmetro de análise aos sistemas autônomos de freada de emergência e de correção de posição lateral do veículo na faixa, por exemplo.

Compreender a demanda cognitiva de um website, de um aplicativo, da percepção de um determinado produto, por exemplo, permite, através da pupilometria, de forma constante, para prevenção, análise ou correção de comportamento de usuários, desenvolver projetos que levam em consideração as capacidades do usuário a fim de reduzir erros, estimulando a sua interação e

garantindo a sua saúde, eficiência e eficácia, além de aumentar a satisfação deste usuário com o sistema, equipamento ou produto em questão.

1.4.1. Smartwatch

Smartwatches ou, em português, relógios inteligentes, são dispositivos eletrônicos do tipo vestíveis, isto é, equipamentos que podem ser utilizados junto à alguma parte do corpo humano e, neste caso, utilizado junto ao punho de um indivíduo. Estes equipamentos acessórios trabalham em sincronia com um celular do tipo smartphone através de conexão sem fio de curto alcance, via sinal Bluetooth. Seus principais recursos são relacionados a recepção de notificações de aplicativos diversos, realização de ligações telefônicas, registro e acompanhamento de desempenho de atividades físicas, dentre outras. De forma resumida, o avanço da miniaturização de chips de computador permitiu que esses relógios, ou melhor, esses pequenos computadores de punho, tivessem acesso à internet e realizassem até pagamentos.

Esses dispositivos eletrônicos de punho são desenvolvidos para aumentar a conveniência e versatilidade do uso e consumo de informação ao longo do dia a dia das pessoas, sem que essas tenham que acessar ou retirar o celular do tipo smartphone de algum compartimento, além disso, são atualmente focados no registro e monitoramento de atividades físicas e na saúde de forma geral de seus usuários (ABDULLAH, et al., 2020; AL-QASSAB et al., 2020; XIA et al., 2021; MARQUES et al., 2021; WU et al., 2021).

De acordo com pesquisa da empresa Internacional Data Corporation (IDC), em 2021, foram vendidos mais de 101,9 milhões de unidades de smartwatches no mundo todo, sendo um aumento de 7,2% nas vendas em relação ao ano anterior. A marca líder de vendas é a Apple com 33,9% de fatia de mercado enquanto Samsung vem na vice-liderança, com 9,4%, e a Huawei com 8,3% (IDC, 2022). Desse modo, a partir destes dados e devido a sua representatividade no mercado consumidor, escolheu-se para a presente tese o smartwatch da fabricante Apple como equipamento que desvia a atenção de motoristas no trânsito da atividade principal de conduzir o veículo automotor.

2. REVISÃO DE LITERATURA

A revisão de literatura da presente tese envolveu estudos sobre os temas de carga de trabalho mental, teoria da carga cognitiva e pupilometria.

2.1. Carga de trabalho mental

As atividades contemporâneas exigem um esforço mental cada vez maior dos seres humanos, à medida em que as tarefas a serem realizadas, agora cada vez mais cognitivas e menos físicas, dependem de desempenho e devem ser executadas em um curto espaço de tempo. Adicionalmente a isto, tem-se uma necessidade de tomada de decisão baseada nestes critérios e uma relação entre homem-máquina desequilibrada.

A quantidade de dados e informação gerada e consultadas pelos seres humanos nunca foi tão grande e tão rapidamente criada e modificada. A mudança e atualizações das soluções industriais, comerciais e até mesmo nas atividades do dia a dia requerem de seus usuários altos níveis de desempenho sobre condições adversas e restritas.

A relação entre as demandas de uma determinada tarefa, a capacidade mental e o desempenho de um indivíduo na realização dessa atividade é um construto denominado Carga de Trabalho Mental (CTM). Na psicologia e nos estudos de ergonomia cognitiva, carga de trabalho mental é definida em função da capacidade do operador e da demanda requerida para a realização de uma determinada tarefa (GROPPER; DONCHIN, 1986).

Para Tsang e Vidulich (2006), a noção de carga de trabalho mental é relacionada à demanda e necessidade de recursos atencionais ou de processamento cognitivo. Tokuda (2009) complementa com a ideia de que a carga de trabalho mental é uma medida que busca avaliar quão perto um indivíduo chega do seu limite de processamento cognitivo em um determinado momento. Ruff (2017) define carga de trabalho mental como o resultado da interação entre as demandas de uma determinada tarefa e o limite de recursos disponíveis para o processamento cognitivo desta tarefa. Para Weber et al. (2021), o desempenho a ser realizado em uma determinada tarefa é alcançado quando ocorre um equilíbrio e produtividade ideais entre os níveis de carga

mental, evitando sobrecarga e uma sub carga mental. Cain (1993) resume carga de trabalho mental como um construto mental que reflete a tensão mental resultante de uma tarefa executada, em um determinado ambiente e condições operacionais, juntado com as limitações e capacidades do indivíduo em responder essas demandas.

Apesar de não haver um consenso ou uma definição formal para o conceito de carga de trabalho mental, Young e Stanton (2004) propõem uma definição global na qual a carga de trabalho mental de uma determinada tarefa representa os recursos disponíveis e o nível atencional requerido para atender tanto os critérios de desempenho objetivos quanto subjetivos desta tarefa, podendo estes, serem mediados pelas próprias demandas da tarefa, suporte externo e experiências passadas.

Ao mesmo tempo, quando ocorre uma demanda maior de recursos cognitivos e há uma ultrapassagem deste limite, o indivíduo precisa compensar este excesso ou seu desempenho começará a cair (MULDER, 1986; HOCKEY, 1997; YOUNG et al., 2015). A capacidade humana de aumentar seu esforço para atingir uma certa demanda cognitiva para processar informação pode ser realizada até um certo limite. A partir deste limite, com o aumento da demanda, o desempenho do ser humano, ao realizar uma atividade, começa a decair e começa a ser caracterizado por aumento no número de erros na tarefa, estresse dentre outros efeitos negativos (CHEN et al., 2016).

2.1.1. Termo e suas variações

Na literatura aparecem diferentes termos para definir o conceito de carga de trabalho mental. Os mais comuns são carga cognitiva e carga cognitiva de trabalho. Ademais, termos como carga de trabalho, esforço cognitivo e esforço mental também já foram utilizados.

Apesar de diferentes, estes termos, geralmente, referenciam o mesmo fenômeno. Isto é, o esforço ou esforço percebido para resolver um determinado problema ou tarefa através do aprendizado, pensamento ou raciocínio (BODALA et al., 2014). Entretanto, as definições de carga de trabalho mental podem variar de acordo com o contexto de seu uso (DE ALWIS EDIRISINGHE, 2017).

2.1.2. Modelos sobre carga de trabalho mental

Os modelos teóricos sobre carga de trabalho mental podem ser divididos em dois tipos: modelos estruturais de recursos atencionais e modelos de recursos energéticos. O primeiro refere-se ao entendimento de que os recursos cognitivos são estruturas de recursos atencionais (KAHNEMAN, 1973; WICKENS, 1980, 2002) enquanto o segundo, como recurso energético que influencia a eficiência dos estágios de processamento da informação (PRIBRAM; MCGUINNESS, 1975; MULDER, 1986; HOCKEY; GAILLARD; COLES, 1986).

2.1.2.1. Modelos estruturais de recursos atencionais

A partir da noção de que a atenção é um recurso limitado e que este recurso pode ser de natureza única ou múltipla (RUFF, 2017), a atenção pode ser compreendida como um recurso de uma única natureza e acessado sequencialmente, ou um recurso de natureza múltipla, na qual há diferentes canais que compõem a atenção e estes podem ser acessados de forma concorrente.

As teorias de natureza única desenvolvidas por Moray (1967) e Kahneman (1973), descrevem os recursos atencionais como um sistema processador de capacidade limitada que pode alocar recursos entre diferentes tarefas. Já as teorias de recursos múltiplos como aquelas propostas por Navon e Gopher (1979) e Wickens (1980, 2002, 2008) propõem o conceito de atenção como aquele recurso específico para funções específicas; assim, este modelo visa explicar o bom desempenho enquanto múltiplos recursos são utilizados. A seguir, descreve-se o modelo de múltiplos recursos propostos por Wickens (2002). A teoria dos múltiplos recursos distingue quatro diferentes dimensões que impactam no desempenho de tarefas duplas ou múltiplas. As quatro dimensões são: i) estágio de processamento; ii) código de processamento; iii) modalidades e iv) canais visuais.

O estágio de processamento diferencia os recursos necessários para a percepção, cognição e resposta. A memória de trabalho é envolvida nas etapas de percepção e cognição e compartilham os mesmos recursos enquanto a seleção e execução da resposta é separada destes primeiros estágios. O código de processamento distingue entre os recursos necessários para atividades do tipo espacial ou verbal a partir do estágio de processamento. As modalidades

diferenciam os recursos necessários para a percepção de estímulos visuais ou auditivos e o canal visual distingue entre a percepção focal e do ambiente. Desse modo, as tarefas podem compartilhar recursos entre as quatro dimensões. Entretanto, se duas ou mais tarefas o fazem na mesma dimensão, elas causam mais interferência do que tarefas que utilizam dimensões diferentes.

A ideia desta teoria é que os recursos não são completamente independentes entre si e interferências podem ocorrer. Esta proposição é suportada por pesquisas em estruturas neurais nas quais o sistema atencional é uma rede de múltiplas estruturas cerebrais responsáveis por tarefas específicas, orientando estímulos, mantendo o estado de alerta e o controle executivo (RUFF, 2017). Os modelos de recursos compartilhados são bem aceitos em pesquisas da área de ergonomia (PROCTOR; VAN ZANDT, 1993; WICKENS, 2007). Assim, as atividades cognitivas compartilham recursos mentais, os quais são limitados, mas que podem ser acessados de forma compartilhada e proveem recursos suficientes para que atividades sejam executadas, mesmo de que forma inferior a necessária, em relação aos aspectos de desempenho e comportamento. Portanto, os modelos estruturais de recursos atencionais são orientados quando há necessidade de interpretar e inferir quais tarefas disputam por quais recursos.

2.1.2.2. Modelos de recursos energéticos

Além da teoria de modelos de estruturais, Yerkes e Dodson (1908) sugeriram uma relação no formato de “U” invertido entre ativação fisiológica e desempenho. Pribram e McGuinness (1975) propuseram o conceito de três sistemas neurais separados, mas interativos, responsáveis pelo controle da atenção: um sistema de ativação da intensidade de estímulos, um sistema de ativação para preparação de respostas motoras e um sistema de esforço superior para coordenar os outros dois. É importante distinguir dois tipos de esforços: o primeiro pode ser entendido como energia fundamental para o processamento de informação enquanto o segundo, como uma função compensatória que ajusta a demanda de tarefas (SANDERS, 1983; MULDER, 1986; HOCKEY, 1997).

Por fim, os modelos de recursos energéticos são mais utilizados para mensurar e interpretar os esforços psicológicos associados com diferentes cargas mentais de trabalho.

2.1.3. Causas para carga de trabalho mental

De acordo com Holmqvist (2011), o aumento da carga de trabalho mental pode acontecer devido a diferentes fatores e, dentre eles, a dificuldade da tarefa, pressão de tempo, desempenho, idade, esforço físico, frustração, tensão, fadiga e o tipo da atividade em si. Chen e Epps (2014) afirmam que a restrição da memória de trabalho pode elevar a carga de trabalho mental durante a execução de tarefas exigentes às características e limitações de um indivíduo.

2.1.4. Consequências da carga de trabalho mental

A medida em que há um aumento na carga de trabalho mental, podem ocorrer problemas físicos, psicológicos e sociais. De acordo com Jorna (1992), os problemas físicos podem ocorrer sob a forma de estresse e fadiga. Como resultado, podem ser desenvolvidos problemas de saúde como hipertensão e falhas cardíacas. Os problemas psicológicos podem ocorrer afetando o desempenho de indivíduos. A degradação de desempenho em tarefas pode ser crítica e severa, de acordo com o contexto de trabalho, como direção de automóvel, na aviação e em procedimentos cirúrgicos, por exemplo. Já para o contexto social, ao vivenciar altas cargas de trabalho mentais, jovens estudantes podem ter desempenho ruim em provas e exames em geral que podem resultar em experiências frustrantes enquanto, para médicos, devido à alta carga de trabalho mental, desempenho ruim em cirurgias pode implicar em risco de vida para pacientes.

2.1.5. Carga de trabalho mental e sua influência no desempenho

Para avaliar o desempenho de sistemas na relação entre homem-máquina, a carga de trabalho mental tem papel fundamental para explicar erros e determinar falhas atencionais de operadores. A mensuração de carga de trabalho mental pode permitir uma resposta mais adequada do sistema, diminuindo ou aumentando seu grau de dificuldade, adaptando-se ao estado cognitivo do operador (SHI et al., 2009). Assim, de acordo com diferentes níveis de carga de trabalho mental pode-se avaliar como esta atividade afeta o

desempenho do operador (YOUNG et al., 2015). Ao prever o desempenho do sistema e do operador, através da carga de trabalho mental, pode-se quantificar e prover uma avaliação sobre seu estado cognitivo, identificando se seus recursos, que são limitados, são suficientes para realizar determinada tarefa (WICKENS, 1992; MULDER et al., 2000).

Por fim, a relação entre desempenho e carga de trabalho mental tem o objetivo de otimizar a eficiência do sistema homem-máquina, sendo a carga de trabalho mental um dos fatores a ser considerado neste processo de otimização (MITCHELL, 2000).

2.1.6. Principais métodos de mensuração da carga de trabalho mental

A carga de trabalho mental não é facilmente observada nos seres humanos, isto é, não é expressa a partir de algum movimento muscular proeminente ou através da expressão facial de um indivíduo, por exemplo (MATTHEWS et al., 2014). A carga de trabalho mental é uma propriedade abstrata da interação entre homens e máquinas e inferida a partir de diferentes métodos, dentre os quais os principais tipos são: medidas a partir de questionários com respostas subjetivas, medidas de variáveis psicofisiológicas e medidas de desempenho da tarefa (HANCOCK; CHIGNELL, 1988; O'DONNELL; EGGEMEIER, 1986; VIDULICH; TSANG, 2012).

A escolha da metodologia para aferição e inferência da carga de trabalho mental é extremamente importante e, segundo O'Donnell e Eggemeier (1986), deve-se levar em consideração a sensibilidade da técnica, verificando se o método consegue diferenciar variações na carga de trabalho mental e a diagnosticidade do método, ou seja, se a técnica consegue distinguir diferentes tipos de carga de trabalho mental. Gopher e Dochin (1986) e Boff e Lincoln (1988) desenvolveram seus próprios critérios de avaliação de métodos para inferir carga de trabalho mental. Segundo os autores, para avaliar e esclarecer qual método utilizar, há a necessidade de se verificar a sensibilidade – quão bem o método consegue perceber a CTM do operador; confiabilidade – se a medida for reproduzida, ela deve gerar resultados similares em condições similares; instrumentalidade – se a medição da CTM interfere na atividade principal do operador; requerimento de implementação – se as condições de implementação da investigação oferece um custo-benefício adequado; aceitação do operador –

verifica se a medição da CTM oferece facilidade para o operador em termos psicológicos e físicos. De Waard (1996) completa que a avaliação deve também considerar se a adição de uma tarefa secundária interferirá ou prejudicará o desempenho da atividade principal.

Há na literatura duas categorias de técnicas para inferir carga de trabalho mental: métodos analíticos e métodos empíricos. O primeiro refere-se a métodos que visam quantificar a carga de trabalho mental a partir do cálculo da dificuldade teórica de uma atividade. Já os métodos empíricos utilizam métodos para estimar a CTM a partir da resposta do operador (RUFF, 2017). Para Wickens (2007) os métodos empíricos são mais acurados para prever a deterioração do desempenho cognitivo, já que o critério de sensibilidade nem sempre é satisfeito nas técnicas do tipo analítico.

Como o objetivo deste trabalho é avaliar o comportamento e a deterioração do desempenho cognitivo do operador, utiliza-se neste estudo a vertente de métodos empíricos os quais são detalhados nas subseções a seguir.

2.1.6.1. Medidas subjetivas

As técnicas para aferição de carga de trabalho mental a partir de medidas subjetivas buscam revelar a percepção do operador quanto ao grau de dificuldade na demanda de uma determinada tarefa. Neste tipo de método, os participantes graduam a si mesmos baseados na sua interpretação de dificuldade na realização de uma tarefa. Johnson e Proctor (2004) completam que a ideia desta técnica é baseada na suposição de que as pessoas conseguem reportar de forma acurada a sua carga de trabalho.

A vantagem desta técnica está na proximidade da relação entre operador-tarefa na quantificação da CTM, pois é o próprio operador que mensura o seu esforço mental e dificuldade. Devido a sua característica subjetiva, este método oferece ainda possibilidades de novas descobertas, restritas a outras técnicas, é acessível e de baixo custo de implementação e não há interferência na atividade primária do estudo (SILVA, 2014).

A desvantagem é que para aplicar esta técnica, há a necessidade de pausar o andamento do estudo ou tarefa em questão e aplicar o questionário, inviabilizando uma estimativa em tempo real, já que o próprio questionário leva algum tempo para ser respondido. Ademais, O'Donnell e Eggemeier (1986)

alegam que há dificuldade de separação entre características de carga de trabalho física e mental. Brookhuis e De Waard (2000) apontam como uma outra desvantagem a falta de capacidade de algumas pessoas na detecção de mudanças internas.

Dentre as principais técnicas de medidas subjetivas podemos listar: i) questionário NASA-TLX (HART; STAVELAND, 1988); ii) Escala MCH-Modified Cooper Harper (COOPER; HARPER, 1969); iii) RSME Rating Scale Mental Effort (ZIJLSTRA; VAN DORM, 1985); iv) Subjective Workload SWAT-Assessment Technique (REID; NYGREN, 1988).

O questionário NASA-TLX é o mais utilizado devido a sua característica multidimensional; ele avalia seis fatores diferentes – demanda mental, demanda física, demanda temporal, desempenho e níveis de frustração e esforço - para compor um índice final de carga de trabalho mental. Segundo Hoedemaeker (2002), o NASA-TLX é indicado para aferição de carga de trabalho mental para tarefas com longa demanda de tempo, sendo não tão sensível para atividades de curta duração. Dessa forma, como a tarefa deste estudo terá, em média, 90 segundos de duração para cada tentativa, esta técnica não seria a mais indicada.

2.1.6.2. Medidas psicofisiológicas

As medidas psicofisiológicas visam interpretar processos psicológicos através de algum efeito resultante no corpo humano. Neumann (2002) descreve as medidas psicofisiológicas como aquelas que buscam avaliar propriedades bem estabelecidas do corpo humano que podem ser um indicativo de carga de trabalho mental. Tokuda (2009) define as medidas psicofisiológicas como medidas que utilizam respostas do comportamento humano para medir a carga de trabalho mental. Se uma resposta fisiológica sempre ocorre em um determinado estado mental, pode-se fazer uma associação direta entre estes dois.

De Waard (2002) alega que a maior vantagem deste tipo de medição está no fato de que a resposta é clara e objetiva, sem a interferência do operador. As medidas psicofisiológicas precisam ser avaliadas com cuidado e de acordo com a tarefa a ser realizada pois registram medidas fornecidas pelo sistema nervoso central e periférico durante a realização de uma determinada tarefa.

Dentre as medidas de resposta fisiológica, tem-se: i) medidas de batimentos cardíacos; ii) ondas cerebrais via eletroencefalograma; iii) eletromiografia, iv) movimentos dos olhos; v) dilatação da pupila; vi) pressão sanguínea; vii) avaliação dos níveis de respiração; viii) avaliação dos níveis de atividade elétrica na pele e xi) determinação de níveis hormonais. As respostas fisiológicas podem fornecer uma estimativa acurada da carga de trabalho mental devido ao seu sinal ser de forma contínua, indicando um status referente a CTM instantânea do indivíduo, em um determinado momento, e não sofre interferência da realização da atividade principal do operador (TOKUDA, 2009).

Apesar de ser uma técnica de medição promissora, muitos dos equipamentos utilizados para medição de respostas fisiológicas podem ser invasivos e, em alguns casos, são equipamentos caros e não portáteis, sendo utilizados exclusivamente em laboratórios de pesquisa e gerando dados complexos para posterior análise (WEBER et al., 2021).

2.1.6.3. Medidas de desempenho: tarefa primária e tarefa dupla

As técnicas para aferição de carga de trabalho mental, a partir da medida de desempenho, buscam registrar a habilidade do operador na realização de uma determinada tarefa. Estas medidas podem ser divididas em dois grupos: medição direta (tarefa primária) ou medição indireta (tarefa secundária ou tarefa dupla).

Segundo Cain (2007), as medidas de desempenho, realizadas a partir de tarefas primárias, são de interesse quando se deseja acessar, de forma direta, o desempenho do operador na tarefa. Assim, quando o operador excede um limiar pré-estabelecido, avalia-se se houve piora ou melhoria de desempenho. Já para as medidas de desempenho de tarefa dupla, o autor complementa alegando que a realização de medição de desempenho indireta, fornece um índice referente à capacidade restante de recursos durante a execução da tarefa principal e, em comparação com as medidas diretas, fornece uma visão mais diagnóstica. Desse modo, esta técnica auxilia inferir interações entre as tarefas primária e secundária, além de avaliar quando o operador pode se adaptar as demandas manipuladas na tarefa secundária que não afetam a tarefa principal.

Neste trabalho a tarefa principal é a direção de veículo automotor e, por isso, segue-se com um exemplo de tarefa deste tipo nesta seção. Assim, medir

o desempenho de automóveis como tarefa primária é medir a habilidade do motorista em controlar o carro e realizar manobras de forma segura e aceitável, evitando colisões e ocorrências de acidentes. As medições diretas demonstram medidas explícitas de desempenho do motorista na tarefa em que ele está realizando. A partir deste exemplo, tem-se medidas:

- i) de controle longitudinal – medidas de desempenho que avaliam a permanência do carro na via em relação a outros veículos na mesma direção e na direção contrária. Variáveis como distância e tempo relativo entre os dois veículos são medidas de desempenho interessantes pois a execução deste tipo de manobra exige percepção e atenção do motorista e, além disso, o tempo de reação pode ser um outro fator demonstrativo de desempenho. A velocidade é um indicativo para manter a segurança e evitar colisões, tanto a velocidade do carro quanto a sua variabilidade em relação ao limite permitido na via, exige o controle temporal para ajustes afim de evitar colisões, além de o aumento da velocidade (TÖRNROS; ÖSTLUND, 2002) – sob influência de distratores – ser um indicativo na inabilidade do motorista em controlar o carro e ser, por conseguinte, uma medida de piora de desempenho (CARVALHAIS, 2002).
- ii) de controle lateral – medidas de desempenho que avaliam o deslocamento lateral do veículo na via. Variáveis como posição lateral do veículo na via e desvio padrão da posição lateral na via são bons indicadores de deficiência na direção e podem ser interpretados com a possibilidade de ocorrência de acidentes já que o deslocamento lateral pode resultar em colisões. Para De Waard (1996), desvios no posicionamento lateral do carro em relação ao meridiano da via, é um dos mais importantes indicadores da deficiência do motorista na tarefa de dirigir. Brookhuis et al. (1985) complementa que a variação lateral do carro é uma medida bastante sensível para a mensuração de desempenho.

A medição indireta ocorre quando se adiciona uma tarefa secundária aquela já executada pelo operador. No exemplo da direção de automóvel, ocorre uma situação de tarefa dupla quando o operador está conduzindo um veículo na via e precisa interagir com uma segunda tarefa de forma concorrente. A adição

da interação com um smartphone, por exemplo, está associada com a “perturbação” causada por ele no sistema homem-máquina; a partir da realização da tarefa dupla, avalia-se o ponto de saturação do limite da carga de trabalho mental (CANTIN et al., 2009), refletindo na operação da tarefa principal através do desvio lateral na pista, comparação de desempenho na situação com e sem a tarefa secundária, e na detecção de atividades periféricas na visão, por exemplo (SILVA, 2014).

Dessa forma, a tarefa dupla estima o desempenho de carga de trabalho mental a partir da avaliação do operador com a adição da tarefa extra (TOKUDA, 2009). Assim, para registrar o desempenho da tarefa primária, as medidas precisam ser comparadas entre os desempenhos da tarefa sozinha e após a adição da carga de trabalho mental, expressa através da tarefa secundária (CANTIN et al., 2009).

A técnica de aferição de carga de trabalho mental a partir da comparação de desempenho na adição de uma tarefa secundária busca quantificar a carga de trabalho mental a partir da comparação e avaliação com diferentes níveis de complexidade da tarefa primária que resultam em mudanças na tarefa secundária. Segundo Pereira da Silva (2003), a adição de tarefas secundárias implica, geralmente, no acesso à memória, cálculos mentais, atenção dentre outros, criando um estado de competição entre os recursos.

Por fim, buscando uma melhor validade ecológica, a avaliação de desempenho somente a partir de medidas de desempenho da tarefa primária torna-se impraticável para a aferição da carga de trabalho mental. Isto ocorre devido ao atraso ou atraso no tempo de resposta percebidas, a partir de mudanças na carga de trabalho mental ou por não possuir dados suficientes para estimar a CTM de forma efetiva, sem acurácia e com a estimativa necessária (TOKUDA, 2009).

2.1.7. Direção de automóvel e a carga de trabalho mental

A tarefa principal de conduzir um veículo ao longo de uma via através de controles como volante, pedais e câmbio continua a mesma por décadas, entretanto, o ambiente interno e externo ao veículo muda constantemente. Paralelamente, a interação do motorista com recursos e funcionalidades

tecnológicas dentro do carro são das mais variadas, permitindo, até mesmo, em alguns casos, o uso de todos os sentidos de forma concorrente.

Com esta constante mudança da interação entre motorista-veículo-ambiente, compreender as demandas cognitivas frente a este novo conjunto de atividades torna-se necessário, a fim de evitar distrações que resultariam em acidentes, especialmente, aquelas que demandam maior carga de trabalho mental.

Manter-se em um estado de segurança no trânsito torna-se cada vez mais complexo. De acordo com Michon (1985), a direção de automóvel envolve pelo menos três tipos diferentes de controles: o estratégico – responsável pelo planejamento e tomada de decisão relacionados a viagem, trajeto a ser realizado, ajustes necessários no trajeto e quais os meios de transporte serão utilizados; o tático – responsável pelas manobras, monitoramento de situações no ambiente e a seleção de respostas de acordo com a situação de tráfego, condições de tempo e comportamento de outros motoristas na via; o operacional – responsável pelo controle fundamental do veículo como movimentação do volante, freada, manutenção do carro na faixa e controle de velocidade.

Na literatura, a tarefa de condução de veículo é chamada de tarefa principal (RUFF, 2017). Esta tarefa envolve demandas perceptuais e diversos estágios cognitivos de processamento de informação como memória de trabalho e afeta, principalmente, recursos visuais como o foco visual para reconhecimento de objetivos e perigos e a visão periférica para orientação e deslocamento (LAND, 2016; WICKENS, 2008). No contexto de condução de veículo automotor, as tarefas secundárias podem ser definidas como aquelas que disputam os recursos atencionais necessários para a manutenção da tarefa principal e estas tarefas adicionais podem ocorrer no ambiente interno ou externo ao veículo.

No entanto, ao interagir com uma segunda tarefa, o motorista lida com uma carga de trabalho adicional. O principal desafio do motorista é garantir uma direção segura no trânsito e, para isso, mensurar seu desempenho é crucial. De acordo com Wickens (2002), quando tarefas competem pelos mesmos recursos, há possibilidade de uma alta interferência entre elas, especialmente, se estes recursos forem perceptuais e cognitivos e envolverem o uso da memória de trabalho. Para Stanton et al. (2004) quando há sobrecarga mental, há uma

potencialidade de se comprometer a segurança na direção de automóvel através de erros cometidos pelo motorista.

2.2. Teoria da Carga Cognitiva

A Teoria da Carga Cognitiva (ou, em inglês, Cognitive Load Theory) busca estimar a carga do esforço mental causado a partir de uma determinada tarefa, modelando aspectos do comportamento humano, com o objetivo de auxiliar na aprendizagem desta tarefa com o menor esforço cognitivo. Esta teoria parte do princípio de que a memória de trabalho é um recurso limitado e que interage constantemente com a memória de longa duração. A carga cognitiva é definida como um construto multidimensional que representa o esforço mental necessário para que um determinado indivíduo realize uma determinada tarefa (PAAS; van MERRIE 'NBOER, 1994).

Desse modo, para evitar a sobrecarga cognitiva ao executar uma tarefa complexa, a ideia é projetar instruções informacionais codificadas em um mesmo pedaço de informação e de forma otimizada. O desafio de criar esta instrução encontra-se no fato de garantir que o operador não tenha atingido o seu limite de memória de trabalho para processar a informação.

A carga cognitiva é afetada por fatores causais e de avaliação (PAAS; van MERRIE 'NBOER, 1994). Os fatores causais podem ser de características de habilidades cognitivas, de complexidade da tarefa, de ruído e das relações entre eles. Os fatores de avaliação podem ser de carga mental – carga cognitiva gerada a partir da tarefa e da demanda do ambiente, esforço mental – capacidade cognitiva alocada para a tarefa - e desempenho - causada a partir dos fatores causais, carga cognitiva e esforço mental (KIRSCHNER, 2002). Assim, a carga cognitiva é um construto formado pelos fatores causais que são aqueles que afetam e que produzem a carga cognitiva e pelos fatores de avaliação os quais são aqueles afetados pelos causais em detrimento da demanda cognitiva.

A Teoria da Carga Cognitiva (TCC) foca principalmente nos aspectos da carga cognitiva afetada por uma tarefa (MORENO; PARK, 2010). A TCC compreende que a memória de trabalho é subdividida em três partes: i) carga intrínseca – relacionada ao desempenho direto da tarefa, suas instruções e a quantidade de elementos que serão processados na memória de trabalho. Uma

tarefa complexa exige maior carga intrínseca, por exemplo; ii) carga irrelevante – relacionada as instruções mal projetadas, isto é, ao ruído e iii) carga relevante – relacionada aos processos que realmente contribuem para o processo de aprendizagem, está relacionada a capacidade de um indivíduo de formar esquemas cognitivos a partir das informações apresentadas, ou seja, à modulação dos recursos cognitivos adaptados para realizar a tarefa (MORENO; PARK, 2010).

Estas partes são aditivas; a soma total das cargas impostas sobre um indivíduo, para a realização de uma tarefa, não deve superar a capacidade total da memória de trabalho para que a aprendizagem da tarefa aconteça (KIRSCHNER; KIRCHNER; PAAS, 2009). A TCC busca compreender a relação entre estes três componentes para que ocorra um aprendizado mais efetivo e com melhores resultados.

Para Paas et al. (2003), as medidas psicofisiológicas são as melhores para mensurar a carga cognitiva de um indivíduo pois permitem uma visualização detalhada da tendência e padrão da carga mental; pode-se verificar picos, médias, valores acumulados e instantâneos. Nesta tese, compara-se técnicas diferentes de medidas de carga cognitiva a partir de métodos pupilométricos.

2.3. Pupilometria

Um dos métodos mais promissores para se mensurar a carga de trabalho mental, utilizando medidas do tipo psicofisiológica, e que não é invasiva e permite coleta de dados de forma contínua, é através do diâmetro da pupila. A partir da dilatação e contração da pupila pode-se relacionar a atual demanda de carga mental exigida do operador e, no caso deste estudo, do condutor de veículo automotor.

A pupilometria é uma área de pesquisa na qual estudos buscam correlacionar as mudanças no diâmetro da pupila à função de atividades cognitivas; a pupila dilata quando operadores estão com aumento na demanda atencional, carga cognitiva ou ativação emocional e cognitiva (SIROIS; BRISSON, 2014). Estudos relacionando a pupila e atividade cognitiva estão presentes na literatura há mais de 50 anos (LAENG; SIROIS; GREDEBACK, 2012). A pupila é a abertura nos olhos que permite a regulação da quantidade

de luz que entra no olho, pela íris, e atinge a retina, permitindo, portanto, a captação de luz do ambiente e gerando o sentido da visão.

A captação de luz para a retina é controlada por dois conjuntos de músculos na íris: o músculo esfíncter pupilar e o músculo dilatador pupilar. O esfíncter pupilar é inervado pelas fibras do sistema parassimpático (GOLDWATER, 1972) e faz a contração pupilar. O dilatador pupilar é vinculado ao sistema simpático sobre o controle adrenérgico do gânglio simpático e dilata a pupila, aumentando seu tamanho. Assim, a dilatação pupilar é atribuída à ativação do sistema nervoso simpático (ativação ocorre quando o corpo detecta uma situação de estresse ou ameaça), gerando a estimulação do músculo dilatador, ao mesmo tempo, inibindo a atividade dos mecanismos parassimpáticos – ativação quando o corpo entre em estado de repouso, conservando e restaurando a energia do corpo humano (SIROIS; BRISSON, 2014).

De acordo com Lowenstein (1962), o diâmetro da pupila pode variar entre 1.5 mm e 9 mm e sua reação a estímulos ocorre em torno de 200 ms. Em condições de luz no ambiente, o diâmetro fica em torno de 3 mm (WYATT, 1995). Em condições ambientais de pouca ou nenhuma luz, a pupila dilata para que ocorra a entrada de uma maior quantidade de luz enquanto em condições de ambiente com muita luz, ocorre o contrário, contraindo a pupila para diminuir a incidência de luz na retina. Este efeito é chamado de reflexo pupilar da luz (HAKEREM, 1967). Este efeito de refletir as condições de luminância do ambiente é a principal característica de interesse e maior potencial dos estudos de pupilometria cognitiva.

Com relação à resposta pupilar, a sua indução causada por estímulos de carga cognitiva é vinculada à ativação dos neurônios do Locus Cereleus (KOSS, 1986). O Locus Cereleus é uma estrutura subcortical e é o condutor do sistema noradrenérgico em todo o cérebro; dessa forma, o Locus Cereleus e o sistema de norepinefrina estão envolvidos em diferentes processos como variações de estresse, recuperação de memória e atenção seletiva (FOOTE; MORRISON, 1986). A relação entre ativação dos neurônios do Locus Cereleus e o tamanho da pupila já foi demonstrada na literatura (RAJKOWSKI et al., 2004; RAJKOWSKI, 1993). Entretanto, para melhor visualizar o seu efeito, pesquisadores utilizam uma técnica de ativar o índice de atividade dos sistemas Locus Cereleus e

norepinefrina através da estimulação ou evocação de uma atividade isolada. Alnaes et al. (2014) identificou a relação entre as mudanças na pupila e o sistema Locus Cereleus - norepinefrina através de imagens de ressonância magnética funcional (fMRI) – técnica de neuroimagem que estuda as reações cerebrais durante a realização de alguma tarefa.

O Locus Cereleus possui dois tipos principais de modos de operação: o modo fásico e o modo tônico. O modo fásico dispara neurônios de forma rápida para otimizar o desempenho durante uma determinada tarefa, focando a atenção durante a exploração geral. Assim, esta ativação do Locus Cereleus gera rápidas dilatações pupilares. Ao mesmo tempo, o modo tônico ocorre para sustentar, de forma eficiente, a etapa de processamento. Dessa forma, promove a retirada do engajamento da atividade e dissemina a exploração (LOWENSTEIN, 1962).

Ao realizar estudos com pupilometria deve-se levar em consideração que a pupila pode dobrar o tamanho do seu diâmetro devido a variações de luminosidade do ambiente enquanto mudanças relacionadas a atividades de carga cognitivas ou algum tipo de ativação são pequenas e em torno de 0,5 mm (BEATTY et al., 2000). As respostas pupilares são geralmente involuntárias, todavia, as pessoas podem aprender a induzir uma dilatação pupilar através da manutenção de pensamentos (WHIPPLE, 1992), mesmo assim, não há como as pessoas inibirem a reação pupilar a algum estímulo (LOEWENFELD; LOWENSTEIN, 1993). Se em uma determinada tarefa o operador chega a um estado de fadiga, a média do tamanho do diâmetro da pupila diminui e depois varia constantemente (LOWENSTEIN; FEINBERG; LOEWENFELD, 1963).

Hess e Polt (1964) notaram em seu estudo que o diâmetro da pupila aumentava à medida em que se aumentava a dificuldade da resolução de problemas de multiplicações. Vogels, Demberg e Kray (2018) afirmam, em concordância, que dilatações pupilares maiores podem corresponder a uma demanda maior na carga mental durante a realização de alguma tarefa. Just e Carpenter (1993) identificaram um aumento no diâmetro da pupila de participantes de seu estudo um segundo após uma sentença ser apresentada a eles; os autores identificaram este efeito devido à complexidade das frases. Ahlstrom e Friedman-Berg (2006) examinaram a relação entre o tamanho do diâmetro da pupila com a carga de trabalho mental. Neste estudo, foi manipulado a carga mental cognitiva de seis controladores de tráfego aéreo a partir da

variação do número de aeronaves nos seus sistemas de radares. Os autores identificaram um aumento linear no diâmetro da pupila entre 3.5 mm e 3.6 mm a medida em que se aumentavam o número de aeronaves. Outros estudos identificaram o impacto da carga mental refletido na pupila devido à carga na memória de trabalho (AHERN; BEATTY, 1979), na tomada de decisão (HAHNEMANN; BEATTY, 1967) e na sustentação de um estado de processamento atencional (BRADSHAW, 1968). Atualmente, a forma mais comum para se medir o diâmetro da pupila é através de equipamentos como *eye trackers*.

Os avanços nas áreas de visão computacional e processamento de imagem permitiram o desenvolvimento de softwares e hardwares capazes de extrair medidas sofisticadas e rastrear os diferentes tipos de movimentos dos olhos em tempo real (MAHANAMA et al., 2021). Os *eye trackers* são um desses equipamentos e através de uma câmera e sensores de infravermelho, permitem capturar o direcionamento do olhar através da posição relativa da pupila e do reflexo da luz na superfície da córnea. Como o diâmetro da pupila já é um dado capturado por este tipo de equipamento, simplifica-se e facilita-se o seu acesso (ASL, 2008). Desse modo, com o acesso e expansão do uso de *eye trackers*, os métodos de pupilometria tiveram maior atenção e, conseqüentemente, desenvolvimento (SIRIOUS; BRISSON, 2014).

Portanto, para o sistema homem-máquina, a ocorrência de erros é um fato, especialmente, com a adição de recursos tecnológicos dentro do ambiente do veículo e a possibilidade de interação com dispositivos eletrônicos de fácil acesso ou até mesmo vestíveis – como smartphones, sistemas inteligentes, smartwatches e recursos multimídia - os quais podem aumentar significativamente a demanda operacional do motorista devido a situação de tarefa dupla (SCHWALM; KEINATH; ZIMMER, 2008). A carga de trabalho mental medida através da pupilometria pode auxiliar na prevenção, análise e correção destes erros. Ao quantificar a carga de trabalho mental, pode-se detectar falhas atencionais na condução de veículo automotor para que alertas ou mecanismos de respostas automáticas, como freada ou correção de deslocamento, sejam ativadas reduzindo o risco de acidentes no trânsito (TOKUDA et al., 2009), ou ainda, criando mecanismos de detecção e prevenção de acidentes. Através da

pupilometria tem-se uma correlação direta entre o diâmetro medido da pupila e a atual demanda cognitiva do operador.

2.3.1. Estado da arte na mensuração de carga de trabalho mental através da pupila

Mensurar a pupila humana significa capturar as variações do seu tamanho e de sua orientação para produzir medidas que tenham algum significado. Há alguns métodos para extrair dados da pupila. Quando se utiliza métodos de pupilometria, a primeira restrição que se observa é com relação ao reflexo pupilar à luz. Como a pupila controla involuntariamente a entrada e saída de luz para se adaptar à fonte de luz do ambiente, torna-se necessário separar na análise dos dados do diâmetro da pupila aqueles que são provenientes do reflexo da luz e as reações induzidas por esforços cognitivos.

Há na literatura algumas medidas que buscam quantificar o esforço cognitivo e que objetivam resolver este desafio. Assim, é importante mencionar os métodos que avaliam a posição do movimento dos olhos durante uma fixação do olhar para inferir a dificuldade de uma tarefa. Os movimentos microsacádicos também foram sugeridos como uma forma de indicar a dificuldade de uma tarefa (SIEGENTHALER et al., 2014). Com o aumento da dificuldade da tarefa há uma expectativa de uma redução refletida na taxa de movimentos microssacádicos e um aumento na magnitude da microssacada. Tokuda et al. (2009) investigou um tipo específico de movimento dos olhos chamado intrusão sacádico, utilizando-se do mesmo princípio de análise de movimentos microssacádicos, diferenciando-os pela amplitude do movimento. Entretanto, nesta tese, não se utiliza a técnica de intrusão sacádico devido às limitações da frequência de aquisição de dados do equipamento utilizado.

A seguir tem-se os principais métodos para relacionar o esforço mental de um operador com a resposta observada a partir do diâmetro de sua pupila.

2.3.1.1. Task-evoked pupillary response (TEPR)

A *task-evoked pupillary response* (TEPR) é uma medida que se utiliza diretamente do diâmetro da pupila para identificar o uso da memória de trabalho por um indivíduo. A resposta pupilar é obtida a partir da estimulação da resposta involuntária da pupila a partir de uma tarefa e há um acompanhamento de seu desenvolvimento e resposta pupilar. Foi observado que durante a execução de tarefas, que utilizam a memória de curta-duração, a fase de apresentação foi

associada com uma resposta pupilar de dilatação enquanto a fase de recordação na memória foi associada com a contração da pupila. Kahneman e Beatty (1966) identificaram em seu estudo que o pico do diâmetro da pupila, durante a evocação de uma tarefa, pode ser relacionado com a quantidade de itens apresentados durante a tarefa.

Todavia, outros estudos (JIANG et al., 2014; KRUGER; STEYN, 2014) identificaram que os dados brutos da pupila não são comparáveis entre participantes e, assim, ao invés de se utilizar diretamente o diâmetro da pupila como métrica, propuseram sua substituição pela porcentagem de mudança do diâmetro da pupila (PMDP) – medida calculada através da diferença entre a medida do diâmetro atual da pupila e um valor base do diâmetro da pupila, dividido pelo valor base do diâmetro da pupila -, alegando que seu cálculo é realizado com relação a um valor base, geralmente, o valor médio dentro de um período de análise antes do experimento e, portanto, comparável. Palinko et al. (2017) sugere a utilização da medida média de porcentagem de mudança do diâmetro da pupila (MPMDP) que consiste no cálculo da PMDP durante um período. Assim, a MPMDP é maior para tarefas mais complexas quando comparadas a tarefas simples.

Apesar de ser uma métrica interessante, não se pode atribuir completamente a variação pupilar da TEPR a uma demanda cognitiva durante todo o tempo de execução da tarefa. Há, neste caso, uma necessidade de controle da luminância do ambiente pois, caso contrário, não se pode afirmar que os dados obtidos foram referentes ao esforço cognitivo medido ou as variações de luz do ambiente, lembrando que até mesmo a movimentação do olhar no ambiente pode produzir variações no seu diâmetro. Ao mesmo tempo, as variações do diâmetro da pupila devido ao reflexo da luz são grandes enquanto as medidas de diâmetro atribuídas à uma demanda cognitiva é relativamente pequena e rápida, geralmente, entre 0.1 mm e 05 mm (BEATY, 1982).

2.3.1.2. Index of cognitive activity (ICA)

Com o objetivo de distinguir os reflexos da luz da resposta pupilar referentes à uma demanda cognitiva, Marshall (2002) propôs um índice de atividade cognitiva a partir do sinal registrado do diâmetro da pupila, analisando-

o a partir da técnica matemática de *wavelets* e as taxas de ocorrência de descontinuidades abruptas no sinal biológico da pupila. Desse modo, índices baixos de ICA refletem pouco esforço cognitivo na tarefa enquanto valores mais altos refletem grande esforço cognitivo na tarefa, respectivamente menores ou maiores descontinuidades do sinal por período.

De acordo com Marshall et al. (2003), o ICA é uma medida sensível às estratégias de mudanças no comportamento de operadores durante a execução de demandas da tarefa. Atividades aritméticas se mostraram sensíveis ao índice de atividade cognitiva definido pelo ICA (MARSHALL; DAVIS; KNUST, 2004), assim como a tomada de decisões táticas por militares (MARSHALL, 2007). Demberg e Sayeed (2016) mediram o ICA em diversos experimentos, explorando atividades de leitura e compreensão da linguagem para investigar a sensibilidade do índice frente à diferentes manipulações linguísticas complexas. Os resultados de seu estudo mostraram que o ICA refletia a quantidade de carga cognitiva necessária para o processamento de uma sentença.

Apesar de ser uma técnica promissora, devido ao algoritmo ser protegido por direitos autorais e seus detalhes de implementação permanecerem em segredo, não há validações independentes desta métrica. A forma de uso deste índice é através de softwares licenciados; geralmente, são módulos adicionados aos softwares de coleta e análise de dados de fornecedores de hardware do tipo *eye tracker* como aqueles da marca Tobii, por exemplo. Infelizmente, devido a esta restrição, este método não será utilizado nesta tese.

2.3.1.3. Index of pupillary activity (IPA)

O índice de atividade pupilar (IPA, da sigla em inglês) é um método inspirado na métrica ICA, mas que não possui restrições de direitos autorais devido a uma proteção de patente. Desse modo, permite-se o acesso aos detalhes inerentes ao processo de análise e cálculo do índice IPA.

De forma resumida, Duchowski et al. (2018) iniciam a análise do sinal de diâmetro da pupila descartando todas as piscadas identificadas no sinal, extraíndo de cada uma delas um intervalo de 200 ms antes e depois da ocorrência da piscada. Similar ao ICA, o IPA também utiliza a técnica matemática de *wavelets* para calcular o índice, mas, a diferença ocorre na escolha da função

mãe da *wavelet*, do limiar de seleção da descontinuidade do sinal e no uso do conceito de módulo máximo (MAHANAMA et al., 2022).

O processo de cálculo do índice pupilométrico começa com a decomposição do sinal do diâmetro da pupila através de uma *Symlet-16 wavelet* mãe em dois níveis. O objetivo é separar os componentes do sinal de baixa frequência (nível 1) – a qual corresponde aos reflexos da luz na pupila – e os componentes do sinal de alta frequência (nível 2) – o qual são ativados a partir de uma demanda cognitiva. O princípio de módulo máximo é utilizado para encontrar o extremo local dos coeficientes do nível 2, que é a detecção do valor máximo local do sinal através do módulo da função *wavelet*. Esse módulo máximo é comparado com um limiar arbitrário definido a partir da função $\sigma\sqrt{2\log n}$, em que σ é um coeficiente universal. Todos os módulos máximos com valores acima desse limiar são considerados descontinuidades abruptas e compõem a formação do índice IPA (WEBER et al., 2021).

O método IPA utiliza a técnica de transformada *wavelet* discreta para decompor o sinal do diâmetro da pupila em diferentes ondas de frequências menores, chamadas *wavelets*. O objetivo desta técnica matemática é representar o sinal da pupila no domínio da frequência e do tempo simultaneamente. O sinal é, portanto, decomposto em bandas de frequência diferentes que compõem o sinal original, criando uma representação dele. Esta análise permite uma representação eficiente dos sinais, especialmente, aqueles que são não-estacionários ou que variam no tempo, como o caso do diâmetro da pupila. Ou seja, sinais em que as propriedades estatísticas como a média e variância variam ao longo do tempo (ADDISON; WALKER; GUIDO, 2009).

O processo de transformada *wavelet* começa decompondo o sinal original em um conjunto de sinais de diferentes frequências. A transformada é realizada em uma sequência de passos na qual cada passo é chamado de decomposição e, a cada nível de decomposição, o sinal é decomposto em frequências baixas e altas, chamados, respectivamente, de coeficiente de aproximação e coeficiente de detalhe. O coeficiente de aproximação representa a variação suave e lenta do sinal enquanto o coeficiente de detalhe representa a variação rápida e fina do sinal. Desse modo, uma transformada *wavelet* discreta de múltiplos níveis aplica o processo da transformada repetidamente, a partir do sinal original, aplicando

as aproximações dos coeficientes obtidos na etapa anterior na função mãe *wavelet* até se obter o número de níveis de decomposição desejado. O resultado desta operação se dá por um conjunto de coeficientes que representam as diferentes bandas de frequência do sinal original (POLIKAR, 1996).

A escolha da função *wavelet* é importante devido a sua relação com a frequência de captura de dados do sinal. Para um sinal com frequência de 60 Hz, a função Daubechies-4 é mais indicada enquanto a Daubechies-16 é indicada para sinais de 250 Hz (DUCHOWSKI et al., 2018), por exemplo. No cálculo do IPA, a função mãe *wavelet* utilizada, originalmente, é a Symlet-16. A interpretação do índice IPA se dá pela avaliação do valor resultante no intervalo de valores entre 0 e 1: quanto maior o índice e mais próximo de 1, maior a demanda cognitiva da tarefa.

A transformada *wavelet* discreta é utilizada para remover o ruído do sinal do diâmetro na pupila que, diante disso, é a influência do reflexo pupilar através da identificação de componentes de alta frequência da decomposição. Duchowski et al. (2018) utiliza em seu algoritmo a família de funções Symlet – família de *wavelets* que são indicadas para remover ruído de sinais -, e, neste caso, a Symlet 16, utilizada no trabalho do referido autor, é mais indicada para analisar sinais com alto grau de suavidade, permitindo a captura de um nível alto de detalhamento do sinal original da pupila, identificando ainda uma ampla variedade de frequências deste sinal. Ou seja, devido ao *eye tracker* utilizado no seu trabalho ser de um tipo que captura dados do diâmetro da pupila em uma frequência mais alta.

Em contrapartida, equipamentos *eye tracker* com frequência de captura de dados menores devem considerar *wavelets* do tipo Symlet de índices menores como Symlet 4 ou Symlet 2. Resumidamente, a Symlet 2 é indicada para analisar sinais com frequências de detalhes mais altos e variações acentuadas, a Symlet 4 é indicada para analisar sinais com suavidade e variedade de frequências moderada e a Symlet 16 é indicada para analisar sinais com ampla variedade de frequências e alto grau de suavidade.

O desafio desta técnica é justamente escolher a função *wavelet* ótima para representar o sinal e o número de níveis de decomposição. Duchowski et al. (2018) verificaram em seu estudo, com 17 participantes, em uma tarefa de acurácia de resposta de cálculos aritméticos, que o índice IPA é bastante

sensível para detectar o grau de dificuldade de uma tarefa. À medida em que os cálculos se tornaram mais complexos, maiores foram os valores de IPA.

2.3.1.4. Low/High index of pupillary activity (LHIPA)

Assim como o índice IPA, o LHIPA é um algoritmo baseado no ICA desenvolvido por Marshall (2002). A ideia é avaliar as variações do diâmetro da pupila durante a execução de uma determinada tarefa e aferir a carga cognitiva demandada por ela, no entanto, descartando as interferências do reflexo da luz na pupila. O LHIPA é uma evolução do IPA e, de forma análoga, utiliza-se da técnica de transformada de *wavelet* discreta para identificar, a partir de um sinal do diâmetro da pupila em um determinado período, o sinal referente a carga mental de trabalho e o seu ruído.

A implementação do índice LHIPA ocorre da mesma forma que aquela descrita na seção 2.3.1.3, diferenciando-se pelo fato de que o IPA conta o valor remanescente do limiar definido pelo módulo máximo de qualquer banda de frequência de uma *wavelet*. Já o índice LHIPA conta o módulo máximo da razão entre as bandas de baixa e alta frequência contidas na decomposição da função *wavelet* do sinal do diâmetro da pupila (DUCHOWSKI et al., 2020), ou seja, conta-se o número de valores acima do limiar definido pelo módulo máximo de cada banda de frequência, dividindo-os pelo tempo total de duração do sinal do diâmetro da pupila, após as frequências baixa e alta serem normalizadas pelo fator $1/\sqrt{2^j}$, onde j é o nível de decomposição desejado.

De acordo com Duchowski et al. (2020), a razão entre a alta e baixa frequência representa melhor as mudanças nos sistemas simpático e parassimpáticos do sistema nervoso autônomo. Peysakhovich et al. (2017) ainda sugere que as bandas de baixa e alta frequência refletem melhor a relação do sistema Locus Cereleus - norepinefrina com o diâmetro da pupila.

É importante salientar que como o índice LHIPA é uma razão entre a baixa e alta frequência do sinal do diâmetro da pupila, com o aumento da banda de alta frequência há a expectativa de aumento na carga cognitiva, ou seja, na dificuldade da tarefa. Ao mesmo tempo, o valor do índice LHIPA esperado deve ser menor com o aumento da demanda na carga mental, assim, sendo um valor reverso aquele encontrado no índice IPA. Portanto, quanto menor for o valor do índice LHIPA, maior a demanda cognitiva exigida na tarefa.

2.3.1.5. Fixation-aligned pupillary response averaging (FAPRA)

Ao realizar uma tarefa que demanda um aumento na carga de trabalho mental, aumento do estado de vigiância ou da carga sobre a memória de trabalho de curta duração, há, conseqüentemente, uma maior atividade cerebral que resulta em uma ativação do sistema simpático, causando uma dilatação pupilar (ANDREASSI, 2006).

Ao se medir este efeito da dilatação da pupila, tem-se uma forma de mensurar a carga cognitiva de trabalho imposta a partir de diversas tarefas (KLINGNER, 2010). As variações no diâmetro da pupila podem ocorrer por diversas razões e, dentre elas, devido ao reflexo da luz na pupila, resposta emocional e em resposta a outras atividades cerebrais. Médicos utilizam uma caneta de luz e passam sobre a pupila para avaliar se há algum sintoma de problemas cognitivos ou intoxicação por alguma substância (SIROIS; BRISSON, 2014), por exemplo.

Conforme visto na seção 2.2, a variação do diâmetro da pupila para inferir carga de trabalho mental é menor que 0,5 mm. Diferenciar esta variação de outras em um espaço de tempo pode ser uma tarefa difícil. Uma alternativa é fazer a medição do sinal do diâmetro da pupila em pequenas frações de segundos e, a partir de diversas repetições da tarefa, alinhar os intervalos de tempo respectivos ao momento em que ocorre a dilatação pupilar em resposta a uma tarefa. Assim, com estes sinais alinhados, calcular a sua média (BEATY; LUCERO-WAGONER, 2000).

Esta operação de calcular a média dos sinais preserva os componentes que produzem o tamanho do sinal que está correlacionado à tarefa que ativa a resposta fisiológica da pupila. Ao mesmo tempo, a técnica mensura o ruído do sinal e de outras variações da pupila, mas estes tenderam a zero pois o efeito principal que ativa a pupila neste intervalo de tempo pequeno é em resposta a realização de uma tarefa. Quanto mais repetições da mesma tarefa forem realizadas e incluídas no cálculo do sinal médio do diâmetro da pupila, a razão entre as respostas causadas em resposta à tarefa e o ruído causado por outros tipos de resposta pupilar, se tornarão maiores e, desse modo, a resolução do intervalo de tempo da média do sinal melhora.

Apesar deste método prover uma boa resolução de tempo, é indicado para mensurar respostas em tarefas simples e de curta duração e que possuem respostas rápidas logo após a apresentação do estímulo.

Klingner (2010) propôs um novo método para inferir a carga de trabalho mental de tarefas que precisam de mudança rápida no foco atencional e de forma imprevisível, permitindo o uso do método descrito anteriormente em tarefas mais complexas. Este método, utiliza como base o cálculo das médias apresentado acima; no entanto, o pesquisador alinha as fixações do olhar, em um mesmo período, antes de fazer o cálculo das médias. Inicia-se o método com a identificação dos períodos nos quais as subtarefas ocorrerão. A seguir, alinha-se os períodos de todas estas subtarefas para, por fim, fazer o cálculo de sua média. O importante é que o período em que ocorre a subtarefa seja consistente e em um espaço de tempo no qual ocorre a resposta pupilar. Este período deve ser entre 2 e 10 segundos e reflete o tempo de acomodação da pupila. Dentro deste período, há diversos tipos de movimentos dos olhos acontecendo e entre eles fixações e movimentos sacádicos.

Quando os olhos se direcionam para uma posição e ficam parados na mesma posição por alguns instantes, ocorre uma fixação. O número de fixações dentro de um período já foi utilizado para determinar importância semântica, eficiência e dificuldade de busca visual e o impacto causado pela experiência na tarefa (MAHANAMA et al., 2022). As durações das fixações são outra medida interessante na qual indicam a quantidade de tempo em que os olhos permaneceram parados na mesma posição. Assim, quanto maior a duração das fixações, maior o processamento cognitivo necessário para absorver informação do ambiente (RAYNER, 1978; SALTHOUSE; ELLIS, 1980).

Os movimentos sacádicos ocorreram entre duas fixações, ou seja, quando o olho se direciona a uma nova posição, de forma rápida, após realizar uma fixação. De acordo com Philips e Edelman (2008), as amplitudes – distância percorrida pelo olho, em ângulo visual, durante a movimentação do olho - do movimento sacádico tendem a diminuir a medida em que ocorre um aumento na dificuldade da tarefa. May et al. (1990) adiciona que o mesmo comportamento acontece quando há aumento na carga cognitiva.

Estes movimentos dos olhos são registrados a partir de um *eye tracker*, um equipamento bastante utilizado em estudos de pupilometria e que oferece

inferências sobre os processos mentais internos de uma pessoa a partir do movimento de seus olhos (POMPLUN; SUNKARA, 2003).

Por fim, este método é utilizado para calcular a média das fixações alinhadas e permite a detecção rápida de mudanças cognitivas de tarefas com duração mais longa, especialmente, aquelas que registram atividades visuais em que as fixações ou sequência de fixações são indicadores de tempo direcionados à tarefa. Apesar de ser um método interessante, devido ao seu princípio utilizar fixações do olhar, mostrasse-o nesta tese como revisão de literatura e estado da arte das principais técnicas de aferição de carga de trabalho mental, entretanto, como o objetivo da presente tese é avaliar a sensibilidade de métodos baseados nos dados brutos da pupila, esta técnica não será utilizada neste trabalho.

2.4. Efeitos da dupla tarefa

A popularidade de dispositivos eletrônicos para serem utilizados no ambiente interno do carro levanta preocupações com relação a segurança do motorista devido ao seu potencial risco de distração (KABER et al., 2011). Tarefas realizadas de forma concorrente à tarefa primária de condução de veículo automotor competem pelos mesmos recursos atencionais. Estas tarefas podem ser divididas em internas e externas ao veículo.

As tarefas secundárias que são realizadas dentro do espaço interno do veículo podem ser ainda organizadas em relevantes ou irrelevantes a atividade de direção de automóvel (RUFF, 2017). Segundo Lee, Regan e Young (2007), a distração na condução de veículo automotor é uma dispersão da atenção das tarefas principais, importantes e críticas para manter a segurança no trânsito, com o objetivo de garantir um desempenho na tarefa secundária concorrente.

Dirigir requer essencialmente, atenção visual para perceber as diversas atividades ocorrendo na via e recursos cognitivos para compreender aquilo que foi percebido e realizar uma tomada de decisão. Distrações cognitivas podem causar falhas na aquisição de informação do ambiente, críticas para programar uma resposta apropriada (MALATERRE, 1990).

A partir da Teoria de Carga Cognitiva (SWELLER, 2011), define-se que a memória de trabalho é um recurso limitado e ao realizar tarefas concorrentes por este mesmo tipo de recurso, pode-se causar impactos negativos, afetando o

desempenho de uma ou mais tarefas (KIRCHNER, 2002). Para avaliar o desempenho do motorista, ao se criar uma sobrecarga cognitiva, o paradigma da tarefa dupla é o mais tradicional. Dessa forma, o desempenho do motorista é comparado nas condições com e sem a tarefa secundária.

Os dispositivos eletrônicos internos ao carro podem ser portáteis e acoplados a alguma parte do corpo de um indivíduo, chamados de dispositivos vestíveis, não sendo acoplados diretamente ao painel do carro, como smartwatches. Silva et al. (2017) define os smartwatches como uma segunda tela para filtrar e exibir notificações provenientes de mídias sociais, e-mails, notícias e mensagens de texto. Ao utilizar um smartwatch no trânsito, o qual fica acoplado ao punho do usuário e possui diversas formas multissensoriais (iluminação da tela, padrão de vibração no punho e som característico de sino) de exibir uma notificação, o motorista pode facilmente engajar com este dispositivo eletrônico e divergir sua atenção visual e cognitiva para realizar alguma atividade no smartwatch.

A pesquisa de Summala et al. (1998) mostrou que motoristas que interagiram com atividades de dupla tarefa dentro do ambiente do veículo demonstraram pior desempenho na condução do mesmo, além de falha na alocação de atenção (LIU, 1996) e carga de trabalho mental (HANCOCK; VERWEY, 1997). Gropher (1990) adiciona que ao executar uma tarefa secundária a uma tarefa que já é complexa, como a direção de automóvel, tem-se uma sobrecarga do processamento da capacidade cognitiva do operador e, assim, piora no desempenho da tarefa primária.

Para aferir a quantidade de recursos cognitivos direcionados a tarefa secundária distratora de uso de smartwatch, a dilatação da pupila mostra-se como um indicador de demanda cognitiva.

Diversos estudos já foram realizados com tarefa dupla e até mesmo com relógios do tipo smartwatch, mas nenhum deles utilizou métricas de movimentos dos olhos, técnicas variadas de pupilometria e desempenho ao mesmo tempo para aferir e caracterizar os efeitos da tarefa dupla no diâmetro da pupila e no desempenho de condução veicular, especialmente, em uma tarefa com validade ecológica.

2.5. Efeitos do aumento da complexidade da tarefa

Uma das principais causas do aumento da carga de trabalho mental é devido à complexidade da tarefa (DE ALWIS EDIRISINGHE, 2017). Jorna (1992) explica que ao executar uma tarefa com demanda mental por um período extenso, há possibilidades de causar estresse e fadiga no usuário. Ademais, ao experimentar um estado de alta demanda de carga de trabalho mental, o desempenho da pessoa é comprometido na tarefa (Engström et al., 2017).

Dessa forma, em situações de condução de veículo automotor, identificar o momento no qual as demandas cognitivas acontecem, pode ser uma forma de mensurar a carga de trabalho mental, verificando o seu aumento para criar sistemas de alertas ou de correção da direção, com o objetivo de evitar acidentes.

Recarte e Nunes (2003) afirmam que é extremamente importante avaliar as cargas mentais como um possível efeito distrator na condução de veículos, ao mesmo tempo, reforçam a necessidade de se investigar os efeitos causados por diferentes tarefas durante a tarefa de dirigir. Ewing, Grace e Liao (2016) identificaram no seu estudo que quanto maior a carga cognitiva do motorista, menor é a sua capacidade de lidar com distrações no trânsito.

Para Haapalainen et al. (2010), estimar a carga de trabalho mental de motoristas pode ser importante para diversas situações nas quais interagem com tarefas concorrentes dentro do ambiente interno do carro. Bailey e Iqbal (2008) mostraram a importância de se mensurar a carga de trabalho mental para ajudar na redução dos custos de notificação de interrupção da realização de uma determinada tarefa quando o motorista está dirigindo. De acordo com Iqbal et al. (2004), quanto maior forem as dificuldades para realizar uma tarefa e mais longo for o tempo necessário para sua execução, mais salientes serão as respostas da pupila em relação às subtarefas. Há na literatura diversas evidências da relação entre a dificuldade da tarefa e o diâmetro na pupila (AHERN; BEATTY, 1979; BEATTY, 1982; BEATTY; KAHNEMAN, 1966; HESS; POLT, 1964), entretanto, nenhum estudo fez uma comparação extensa e diversa entre medidas de desempenho, de movimentos dos olhos e de métodos diferentes de pupilometria em uma tarefa com validade ecológica.

Distrações visuais causam respostas atrasadas em relação ao veículo a ser seguido (ZHANG; SMITH; WITT, 2006), além de comprometer a percepção de dicas no ambiente para tomada de decisão (MALATERRE, 1990). Distrações

cognitivas forçam o motorista a concentrar seu olhar no centro de sua visão (RECARTE; NUNES, 2000). Ademais, Strayer, Drews e Johnston (2003) encontraram que a distração cognitiva compromete a compreensão de informações disponíveis no ambiente relacionadas à direção na qual, geralmente, motoristas usam para garantir sua segurança no trânsito. Horrey e Wickens (2006) concluíram em seu estudo que a distração cognitiva atrasa a resposta de motoristas à percepção de perigo e causa movimentos irregulares no volante. De acordo com Dewing et al. (1995), o desempenho da tarefa primária de dirigir automóvel é bastante afetado pela tentativa de engajamento com múltiplas tarefas secundárias. Dessa forma, ao interagir com tarefas de alta demanda de carga de trabalho mental, o motorista acaba dispersando de sua atividade primária de conduzir o carro na via, causando uma distração (WIERVILLE, 1993).

Compreender os efeitos do aumento da carga cognitiva através da pupila pode ser uma forma não invasiva, viável e de baixo custo, já que as câmeras de alta qualidade de imagem estão disponíveis até mesmo com sensores de infravermelho por um baixo custo de aquisição. Dessa forma, este método pode se tornar um mecanismo acessível de segurança no ambiente de carros, além fornecer dados para recursos mais sofisticados como correção da movimentação lateral e longitudinal de um veículo e impedir acesso à recursos multimídia durante a condução de veículo automotor, mediante aumento da carga de trabalho mental, por exemplo.

2.6. Efeito da experiência na percepção de perigo

De acordo com Lee (2007), motoristas inexperientes são mais vulneráveis a desempenharem mal as atividades de condução de veículo automotor em relação às situações de reação às condições adversas na via, reação a perigos, freando ou mudando a direção do sentido do carro em relação a um veículo a frente; o mesmo acontece no controle táctico, já que novatos apresentam maior dificuldade para realizar manobras com o veículo como responder às condições da via, reação às variações de tráfego de veículos e obter informação visual relevante para realizar interseções, como: reduzindo a velocidade, realizando uma ultrapassagem e aumentando a distância em relação a um veículo a frente.

Isso ocorre devido a este perfil de motorista ser mais inexperiente no controle das habilidades necessárias para conduzir um veículo, não conseguir identificar e antecipar corretamente perigos na via e realizar um julgamento exagerado de suas habilidades na direção, acreditando que são melhores motoristas do que suas habilidades indicam (LEE, 2007).

Underwood et al. (2002) argumenta que as diferenças na condução de automóvel entre motoristas experientes e novatos não são apenas relacionadas à demanda cognitiva para controlar o carro, mas também refletem a falta de modelos mentais apropriados para realizar uma busca por dicas importantes no ambiente durante a direção de automóvel.

Analisar os efeitos da experiência entre motoristas novatos e experientes é uma estratégia que permite compreender o comportamento e os mecanismos utilizados pelos experientes, a fim de permitir que os novatos consigam, através de instruções e prática, ter controle sobre o carro ao mesmo tempo que buscam informação certa, e no momento correto, para antecipar e responder de forma adequada aos perigos de uma via de trânsito.

Os motoristas experientes possuem um conjunto maior de habilidades e melhor estratégia na seleção de informação relevante do ambiente, assim, controlando melhor o veículo automotor e evitando acidentes. Isto ocorre devido aos experientes possuírem mais tempo de prática na tarefa de conduzir um veículo automotor e, além disso, ter tido maior probabilidade de experimentação de condições de trânsito variadas. Ao observar estrategicamente o ambiente, os motoristas experientes focam sua atenção em informações relevantes, provavelmente já vivenciadas, e que, possivelmente, permitem a antecipação de eventos com maior potencial de risco de acidentes (CRUNDALL et al., 2012). Para Pradhan et al. (2009), a medida em que um motorista aumenta o seu repertório de habilidades a partir da prática, com diferentes parâmetros diferenciando as condições de trânsito, este motorista tende a prever melhor quando e onde um perigo em potencial pode ocorrer.

A carga de trabalho mental está relacionada com o processo de aprendizagem e de aquisição de experiência na tarefa de conduzir um veículo automotor (ENGSTRÖME et al., 2003). O grau de experiência de um motorista pode modular a influência das habilidades dele na tarefa de dirigir e no modo como a informação é processada, isto posto, tem-se uma relação entre a

experiência e o grau de automação da tarefa à qual pode ocorrer de forma controlada ou automática (PAXION; GALY; BERTHELON, 2014).

De acordo com Pattern et al. (2006), os motoristas novatos possuem menor grau de automação na tarefa de dirigir e, segundo os autores, isto ocorre pois o processo de automação da tarefa acontece de forma progressiva com a prática. Por conseguinte, a tarefa de dirigir um veículo automotor induz uma alta carga de trabalho mental em motoristas novatos (SWELLER, 1993; SWELLER e al., 1998; PATTEN et al., 2006; WICKENS; HOLLANDS, 2021). Ao mesmo tempo, devido ao maior tempo de prática, motoristas experientes necessitam de menor grau de carga de trabalho mental (SCHNEIDER; SHIFFRIN, 1977).

Pradhan et al. (2005), identificaram em seu estudo que motoristas experientes conseguem antecipar ameaças na via em até seis vezes mais situações do que motoristas novatos. Mourant e Rockwell (1972) observaram que motoristas novatos fazem uma busca visual mais abrangente no ambiente e com menor alcance longitudinal e fazem menos checagem de escolhas em comparação com motoristas experientes. Crundall e Underwood (1998) identificaram que motoristas experientes escaneiam o ambiente mais variavelmente, em rodovias de alta velocidade, em comparação com motoristas novatos. Ainda segundo os pesquisadores, motoristas experientes possuem um comportamento do olhar diferente ao se encontrar em uma situação de perigo. Para Fisher et al. (2011), os motoristas novatos já estão com sobrecarga cognitiva para realizar as atividades da tarefa primária de dirigir um automóvel, não possuindo capacidade suficiente para fazer previsões os quais orientariam o seu movimento do olhar em busca de informações necessárias.

Motoristas novatos são mais propensos à adotar um estilo de direção de automóveis mais arriscado do que motoristas experientes, ao mesmo tempo, são mais ineficientes em lidar com situações de risco no trânsito devido a sua menor habilidade de conduzir um veículo, falhar em moderar a sua velocidade frente a percepção de perigos ou como manobrar o veículo na via para evitar uma colisão, não escanear mais amplamente o ambiente em busca de informação e apresentar menos fixações do olhar horizontais através da visão periférica (IMTIAZ; MUELLER; STANLEY, 2014). Desse modo, o desempenho de motoristas novatos deve ser divergente daquele apresentado por motoristas experientes, especialmente, em situações em que perigos podem aparecer na

via, já que essa e diversas outras habilidades se desenvolvem ao longo dos anos com variadas experiências na tarefa de dirigir (DEERY, 1999).

A partir deste contexto, nenhum estudo comparou e avaliou o comportamento da pupila entre motoristas novatos e experientes, em uma situação de perigo e não há, até a presente tese, estudos comparativos da sensibilidade de métodos pupilométricos diferenciando grupos de motoristas com experiências distintas. Ao se estudar os efeitos de grupo de usuários com experiências diferentes na tarefa de dirigir, busca-se, portanto, compreender as estratégias, mecanismos, comportamento e recursos utilizados pelos experientes que os permitem identificar e antecipar perigos em potencial, assim, identificando-os para que possam ser utilizados para aumentar o conjunto de habilidades dos novatos, encurtando o tempo de aprendizagem através de instrução e prática.

3. MÉTODO

3.1. Características da amostra

3.1.1. Participantes

Pessoas voluntárias e com habilitação ou permissão para dirigir automóveis com idades entre 18 e 35 anos foram selecionados para responder um questionário de classificação online. Este questionário categorizou os participantes voluntários de acordo com uma estimativa pessoal e auto reportada da quantidade de quilômetros percorridos pelo participante desde a obtenção de sua Carteira Nacional de Habilitação (CNH) até a data da coleta de dados do estudo. O questionário foi realizado de forma online através da plataforma gratuita Google Forms e adaptado do trabalho de Gotardi, Navarro e Rodrigues (2016) e foi utilizado para pré-selecionar e classificar os voluntários em 2 grupos: motoristas novatos (NOV) e motoristas experientes (EXP).

A partir deste contexto, 40 voluntários, sendo 20 de cada grupo, foram classificados entre motoristas novatos - aqueles que autodeclararam uma estimativa total de até 5.000 quilômetros percorridos -, e experientes - aqueles que declaram ter conduzido um veículo automotor por mais de 30.000 quilômetros (LEHTONEN et al., 2014). A Tabela 1 caracteriza os voluntários participantes deste estudo.

Tabela 1 - Caracterização dos voluntários participantes do estudo.

Medidas	Novatos	Experientes
Idade (anos)	21,9 ± 2,4	29,0 ± 4,2
Peso corporal (Kg)	78,4 ± 17,2	87,3 ± 17,0
Estatuta (m)	1,7 ± 6,9	1,8 ± 9,4
Experiência em dirigir (km)	1430 ± 1685	187538 ± 307923

Os voluntários foram contatados via telefone e houve agendamento de dia e horário para cada um se direcionar até o Laboratório de Informação Visão e Ação (LIVIA), da Faculdade de Ciências da Unesp – Campus de Bauru, para a realização dos procedimentos experimentais.

A participação de todos os voluntários foi condicionada à autorização por escrito, através do Termo de Consentimento Livre e Esclarecido (TCLE) sob o registro CAAE número 70879917.2.0000.5663, devidamente aprovado pelo Comitê de Ética da Faculdade de Arquitetura, Artes, Comunicação e Design da UNESP – Campus de Bauru.

3.1.2. Critério de inclusão

Os critérios de inclusão de voluntários para a tese foram: (i) não possuir histórico de problemas musculares, neurológicos, posturais e locomotores; (ii) possuir acuidade visual normal ou corrigida para normal através do uso de óculos ou lentes de contato; (iii) não possuir experiência declarada de uso de relógios inteligentes; (iv) para o grupo dos inexperientes: possuir CNH e ter conduzido veículo por até 5 mil quilômetros; (v) para o grupo de experientes: possuir CNH e ter conduzido veículo por pelo menos 30 mil quilômetros; (vi) ter idade entre 18 a 35 anos.

3.1.3. Critério de exclusão

Os critérios de exclusão de voluntários para a tese foram: (i) ter conduzido veículo automotor por mais de 5 mil quilômetros e, ao mesmo tempo, menos do que 30 mil quilômetros; (ii) possuir um smartwatch da mesma marca e modelo daquele utilizado na presente tese; (iii) possuir experiência de uso com o smartwatch por mais de 30 dias a partir da data de aquisição; (iv) não ser aprovado no teste de acuidade visual (possuindo acuidade visual inferior a normal 6/6), realizado antes da coleta de dados; (v) sentir enjoo de movimento durante alguma das condições experimentais após o início do protocolo de coleta de dados.

3.2. Materiais

Os equipamentos necessários para configuração experimental da presente tese utilizaram softwares e hardwares de duas plataformas distintas: para sistemas operacionais Windows da fabricante Microsoft e para sistemas operacionais Macintosh da fabricante Apple.

Nas subseções a seguir, listam-se os softwares e hardwares necessários para criar o ambiente experimental. No Apêndice I encontram-se detalhes sobre

a forma como os equipamentos foram sincronizados, configurados e integrados para a coleta de dados.

3.2.1. Equipamentos

O design experimental para a coleta de dados da condição simulada de veículo necessitou dos seguintes materiais: Computador servidor Dell Precision Tower modelo 5811; Monitor Dell 19" (conexão via cabo Display Port); Placa de Vídeo Nvidia GTX 960 com 5 saídas independentes de vídeo (1 HDMI, 1 DVI e 3 Display port); Adaptador de cabo VGA para cabo DVI; Adaptador de cabo VGA para cabo Display Port; Monitor Samsung 15 " (conexão via cabo VGA); Televisor LCD Samsung de 46" (Conexão via cabo HDMI); Cockpit (Suporte para televisão integrado a um assento com encosto ajustável e ajuste da distância entre o assento e o volante, possuindo ainda suporte para acoplar o volante, os pedais do acelerador, freio e embreagem e o câmbio de 6 marchas, sendo uma dessas a marcha ré) – Figura 2; Acessório Gamer Logitech G27 (volante, pedais e câmbio – conexão via cabo USB 2.0); Cabo VGA de 10 metros; Roteador D-link 524G 54mb – Figura 3A; Eye Tracker modelo H6 da marca ASL (Applied Sciences Laboratories) – Figura 1; Splitter de Vídeo para cabo VGA (Aparelho eletrônico que permite que um sinal de vídeo seja duplicado, com um cabo de entrada replicando seu sinal em outros 2 cabos de saída); Computador Asus; Monitor Asus de 17" (Conexão via cabo VGA).

Figura 1 - Capacete Eye Tracker ASL H6 da Applied Sciences Laboratories. Equipamento que coleta dados do movimento dos olhos, da cabeça e diâmetro da pupila.



Figura 2 - Estrutura montada do Cockpit com banco reclinável e ajustável, suporte para a televisão Samsung 46" e kit de acessórios Gamer Logitech G27 com pedais, câmbio e volante acoplado ao Cockpit.



Para simular uma situação de tarefa dupla, foi utilizado um relógio inteligente da marca Apple modelo Series 1. Os equipamentos necessários para a sua configuração, uso e análise foram: Notebook Macintosh Apple Macbook Pro 13" modelo mid 2012 – Figura 3B; Smartphone Apple iPhone 5 16 Gb – Figura 3D; Smartwatch Apple Watch Series 1 – Figura 3C; Câmera DSLR Nikon D5100 – Figura 4A; Lente Nikkor FX 18-55mm – Figura 4B; Microfone Rode VideoMic Go – Figura 4C; Tripé com regulagem ajustável do suporte para câmera.

Figura 3 - A: Roteador D-link 524G 54mb. B: Notebook Macbook Pro 13,3" Mid 2012 da fabricante Apple. C: Relógio inteligente Apple Watch Series 1 da fabricante Apple. D: Celular smartphone iPhone 5 16Gb da fabricante Apple.



Figura 4 - A: Câmera DSLR Nikon D5100 da fabricante Nikon. B: Lente AF-S Nikkor DX 18-55mm 1:3.5-5.6G da fabricante Nikon. C: Microfone Direcional P2 Video Mic Go da Fabricante Rode.



3.2.2. Softwares

Os softwares utilizados para coletar, processar e analisar os dados foram: Simulador de condução de veículo - STISIM Drive versão 3.14.01; Software de configuração de placa de vídeo NVidia: Painel de Controle da Nvidia; Software de análise de dados: Matlab (The Mathworks Inc, 2021 – Versão); Software de análise de dados: Microsoft Excel 365; Software para edição de textos: Microsoft Word 365; Software de análise estatística SPSS (SPSS Inc., 2008 – Versão 17.0.1); Software para análise do movimento dos olhos: ASL Eye Tracker 6000; Software para manipulação dos dados do Eye Tracker: ASL Result Plus. Ademais, foi utilizado o ambiente de desenvolvimento JupyterLab 3.2.1 vinculado ao software anaconda-navigator para o desenvolvimento de scripts na linguagem de programa Python os quais foram necessários para processar os dados, reduzi-los, organizá-los e realizar cálculos diversos, incluindo os métodos de pupilometria.

Para evitar atrasos de integração, os softwares utilizados para a tarefa secundária foram aqueles utilizados na plataforma do sistema operacional Macintosh. Os softwares necessários foram: Notas; Aplicativo para Macintosh: Mensagens; Aplicativo para iOS: iMessage; Software para análise de áudio e vídeo: Final Cut pro X (Apple, Versão 10.3.4).

3.2.3. Simulador de veículo automotor

O software responsável por gerar o ambiente simulado de condução de veículos utilizado no estudo foi o STISIM Drive. Este software permite a criação de cenários customizados de acordo com a necessidade do pesquisador. Além disso, as variáveis de desempenho do motorista e do seu comportamento ao

longo de um trajeto de direção são facialmente acessadas através de um arquivo de texto contendo esses dados. Foi utilizado a versão M100 do software simulador de automóvel STISIM Drive o qual permite a utilização do software em duas telas (Figura 5): uma para o ambiente simulado e a outra para o painel de controle e acompanhamento do percurso do ambiente virtual, sendo, portanto, uma versão de baixo custo.

Figura 5 - A: Imagem da televisão Samsung de 46” exibindo a imagem do simulador. B: Tela de controle do pesquisador mais a tela de replicação da imagem que o participante observa na televisão. C: Imagem do olho do participante com a identificação da pupila e da córnea, mais a replicação da tela que o participante estava observando.



3.2.3.1. Configurações do ambiente virtual simulado

Para criar condições ambientais próximas ao contexto do dia a dia do participante, parâmetros de configuração do ambiente virtual 3D do software STISIM Drive foram modificados.

As modificações aplicadas ao ambiente virtual para realização da tarefa foram: configuração de câmbio manual, definição de 5 marchas para o veículo mais a marcha Ré, ajuste de volume da movimentação do carro e do motor do veículo, direção e volante do lado direito do carro, velocidade máxima do carro até 210 km/h, exterior do carro exibindo um ambiente à luz do dia com céu claro, sem avisos sonoro quando motorista cometesse infrações de trânsito, calibração automática do volante a cada início de tarefa e, caso ocorresse um acidente, resposta visual, sonora e motora no volante. A taxa de atualização de vídeo da simulação foi mantida em 30Hz independente do cenário. A luz do ambiente de coleta de dados foi mantida a mesma para todos os participantes – luz do tipo tubular fluorescente acima do participante, evitando sombras e reflexos desta fonte de luz na tela da simulação. As configurações de brilho e de contraste

também foram mantidas constantes na televisão Samsung 46” para todos os participantes.

3.2.3.2. Cenários virtuais 3D

Foram desenvolvidos 4 cenários para coletar dados referentes às condições de pesquisa da tese:

i) cenário controle – desenvolvido para a realização da tarefa de dirigir. Neste cenário o participante deveria seguir um carro a sua frente – carro do tipo sedan na cor vermelha - por toda a extensão da rodovia no cenário;

ii) cenário de dupla tarefa – além de conduzir um veículo por toda a extensão da tentativa, haveria a introdução de uma atividade secundária de leitura de uma mensagem na tela do smartwatch;

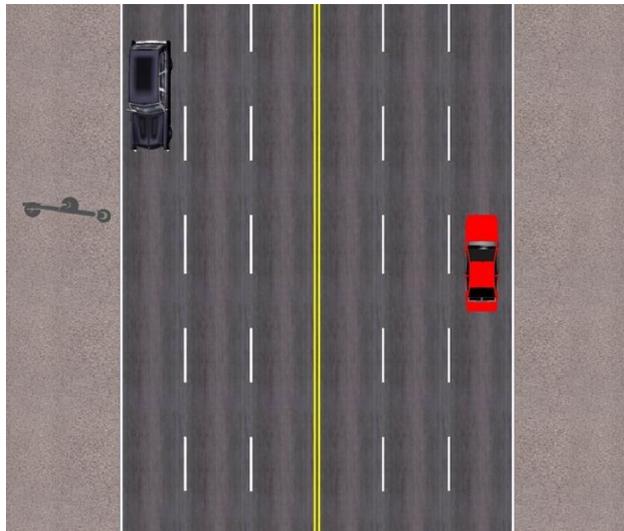
iii) cenário de direção e percepção e resposta à uma freada abrupta do veículo líder;

iv) cenário que combinava as características de ii) e iii), sendo o motorista participante da pesquisa exposto a situação de freada abrupta do carro líder ao mesmo tempo em que deveria realizar a leitura de uma mensagem de texto no smartwatch.

Todos os cenários foram elaborados para exibir um ambiente urbano, na qual o participante deveria dirigir por uma via de alta velocidade (com limite de velocidade da via declarado, através de placa de sinalização no trânsito, em 110 km/h).

O valor mais alto de velocidade máxima foi empregado para favorecer a percepção de movimentação do carro pelo participante. A pista de todos os cenários apresentava 6 faixas, sendo 3 na direção do participante e outras 3 na direção oposta. As 6 vias foram divididas 3 a 3, separadas por uma linha contínua, que impediria a ultrapassagem para a direção oposta, conforme diretrizes do Código Nacional de Trânsito brasileiro (Figura 6).

Figura 6 - Vista aérea da divisão da rodovia. Ao total foram disponibilizadas 6 faixas, sendo 3 delas na mesma direção do motorista e as outras 3 na direção oposta ao sentido da via. Cada grupo de 3 faixas foi separado por uma linha dupla contínua.



A rodovia foi programada para ter comprimento total de 2.000 metros (informação não revelada aos participantes) e apresentava prédios altos, árvores e postes dentre outros tipos de edificações urbanas (Figura 7); isto foi desenvolvido para variar a cena visual e fornecer motivação ao participante e impedir que ele criasse um ponto de apoio visual para inferir o momento exato em que a mensagem do smartwatch seria enviada ou o momento em que fosse ocorrer a freada abrupta, sendo, assim, uma limitação do estudo.

As construções foram organizadas de forma variada e com diferentes fachadas ao longo de 1.000 metros e depois fez-se a replicação desses mesmos prédios, mas em posições diferentes do cenário ao longo dos próximos 1.000 metros de comprimento da rodovia.

Foram colocadas calçadas em ambos os lados da extremidade da rodovia na qual pedestres apareciam, esporadicamente, caminhando em ambos os sentidos em relação ao motorista. Na última faixa de cada sentido de direção foram colocados carros estacionados, ao longo do trajeto, para impedir que o motorista se movimentasse para as laterais, criando um complicador a mais e garantindo um padrão na tomada de decisão.

Figura 7 - Visão do participante mostrando o ambiente interno do carro com velocímetro, contador de giros, conjunto de espelhos e o ambiente virtual urbano 3D.



Veículos em movimentação espontânea foram posicionados em ambos os sentidos da rodovia. Entretanto, a quantidade de carros no sentido oposto foi maior, criando uma situação de perigo e, assim, evitando que o participante se movimentasse livremente e lateralmente em direção ao sentido oposto, assim, limitando suas possibilidades de resposta à freada.

Para criar a situação de seguir um carro, um veículo do tipo sedan na cor vermelha foi criado (Figura 8). Este carro líder foi programado como um evento dinâmico do cenário e foi desenvolvido para alterar sua posição na via, automaticamente, e modificar a sua velocidade de acordo com alguns comportamentos previamente identificados que o motorista participante poderia realizar, criando, assim, uma situação dinâmica para o participante.

Após dar início a uma tentativa de coleta de dados, o participante visualizaria este carro líder estacionado e aguardaria a sua movimentação. A distância temporal do carro líder foi configurada para estar três segundos de distância em relação ao veículo do participante da pesquisa (Figura 8).

Figura 8 - Distância temporal relativa de 3 segundos entre o carro do motorista participante e o carro líder no início de cada tentativa.



O carro líder foi configurado para espelhar a movimentação do carro do participante; isto foi necessário para sempre manter o carro vermelho à frente do participante, ativando o cálculo de algumas variáveis do simulador. Ademais, este espelhamento foi utilizado para simular um dinamismo na movimentação do carro líder, o qual parecia, realmente, estar se movimentando sozinho e, portanto, simulando uma situação real de trânsito em que se tinha um carro a ser seguido. Este movimento foi gerado por uma inteligência artificial – fornecida pelo próprio fabricante - ativada no desenvolvimento do cenário.

Em relação a quantidade de veículos se movimentando no mesmo sentido de direção do participante, foi programado um fluxo menor de carros e com velocidade constante de 25m/s. Este fluxo de carros reduzido foi implementado para impedir que o carro líder tivesse uma velocidade variável. Ou seja, foi um mecanismo para bloquear o disparo da velocidade do carro vermelho à frente e, desse modo, manter a velocidade tanto do carro a frente quanto do participante constantes. Esta é uma limitação do estudo pois para simular uma movimentação autônoma e natural do carro líder, houve a necessidade de conter a variabilidade de sua velocidade, do contrário, ele aumentaria a distância temporal e poderia ficar fora do alcance visual do participante já no início do procedimento experimental.

Tem-se na Tabela 2 um resumo dos cenários e seus objetivos.

Tabela 2 - Organização experimental do estudo da presente tese, relacionando o cenário virtual 3D utilizado de acordo com a condição experimental e o número de tentativas realizadas por participante.

Condição Experimental	Tarefa	Cenário Virtual	Número de Tentativas
CAR	Seguir o carro líder até o final da simulação.	Cenário Controle	3
NOT	Seguir o carro líder até o final da simulação e, quando receber notificação no smartwatch, fazer a leitura da mensagem enviada.	Cenário Dupla Tarefa – Leitura de mensagem no smartwatch	3
FRE	Seguir o carro líder até o final da simulação. Responder a uma situação de perigo – freada brusca do carro líder.	Cenário Freada	3
FNOT	Seguir o carro líder até o final da simulação e quando receber notificação no smartwatch, fazer a leitura da mensagem enviada ao mesmo tempo em que há uma situação de freada do carro líder.	Cenário Freada + Leitura da Mensagem no Smartwatch	3

3.3. Procedimento experimental

Após a sua chegada, o participante recebeu uma cópia do Termo de Consentimento Livre e Esclarecido, o qual atende à Norma ERG BR 1002, do Código de Deontologia do Ergonomista Certificado (ABERGO, 2003) que foi devidamente aprovado pelo Comitê de ética da Faculdade de Arquitetura, Artes, Comunicação e Design da Unesp – Campus de Bauru.

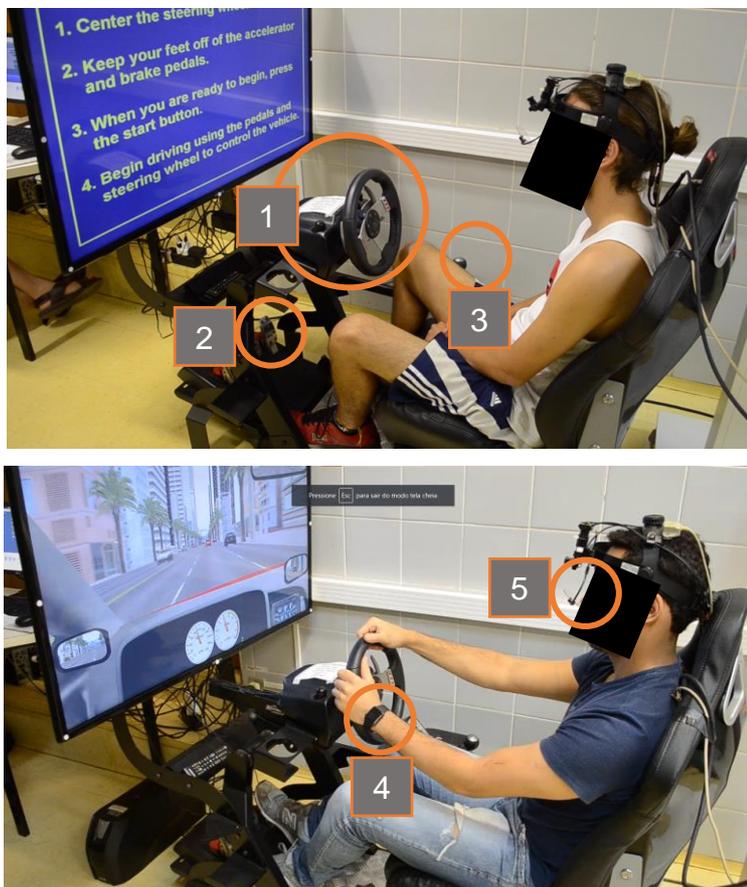
O voluntário foi, então, orientado a ler os termos descritos, assinar e datar o documento se concordasse com eles. A seguir, foi entregue um questionário para caracterização comportamental e física do participante na qual foram feitas perguntas a respeito de alguns dados demográficos, de seu estado atual de saúde, se já foi usuário de smartwatch e dados referentes ao seu histórico de comportamento e infrações já cometidas no trânsito. Posteriormente, medidas de peso, altura e acuidade visual foram anotadas (RIGGS, 1965).

Antes de iniciar a tarefa, o participante recebeu o relógio smartwatch Apple Watch series 1 – que foi previamente higienizado antes da chegada de cada participante - para colocar no seu punho esquerdo. Independentemente da preferência pessoal do participante, o smartwatch foi colocado, necessariamente, no punho esquerdo para que o mapeamento visual da direção e sentido do campo visual – capturado pelo *eye tracker* - não causasse ruído na interpretação dos dados. Desse modo, evitou-se que durante o evento de leitura da mensagem de texto, a movimentação do olhar no ambiente fosse interpretada erroneamente. Esta é uma limitação do estudo pois identificou-se em coleta de dados piloto que alguns participantes com smartwatch no punho direito, direcionavam o olhar tanto para a caixa de câmbio quanto para o relógio, confundindo a análise posterior de dados do olhar, não permitindo a sua caracterização e separação.

Uma breve apresentação sobre as funcionalidades do smartwatch e como fazer a leitura das mensagens de texto foi realizada em até 3 minutos. Depois, o participante foi convidado a ser acomodado no cockpit para ajustar a posição do encosto do assento e sua distância com relação ao volante. Explicações breves sobre o funcionamento dos controles do simulador foram realizadas (Figura 9).

O capacete do Eye Tracker foi posicionado na cabeça do participante e deu-se início ao processo de calibração do equipamento. Com a calibração finalizada, foi explicado ao participante que, antes da tarefa de coleta de dados, haveria 2 situações de direção de veículo simulado para que ele se familiarizasse com o equipamento.

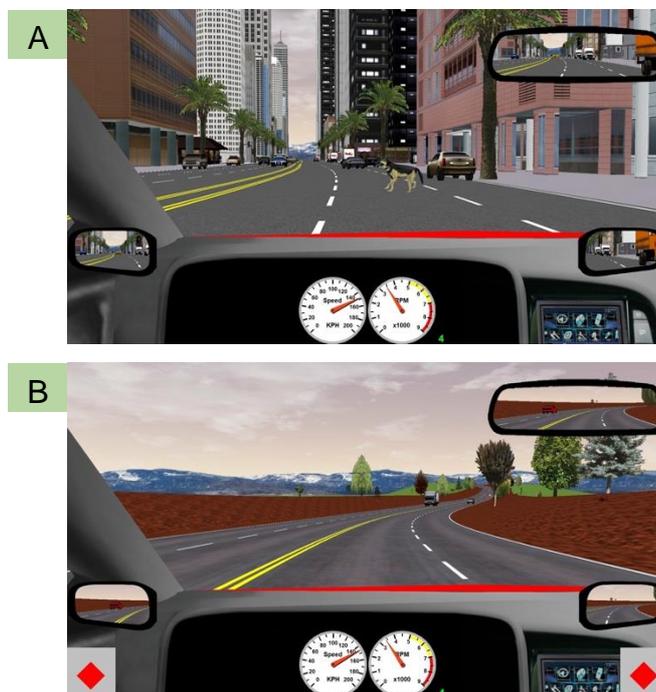
Figura 9 - Organização final do participante com os equipamentos posicionados e sincronizados. Observa-se em 1: o volante; 2: os pedais; 3: a caixa de câmbio para troca de marchas; 4: o smartwatch para leitura das mensagens de texto e 5: o *eye tracker* calibrado para captura dos movimentos dos olhos e o diâmetro da pupila.



O primeiro percurso de familiarização tinha duração máxima média de 5 minutos e foi desenvolvido para que o participante se adaptasse aos controles do carro e pedais (Figura 10-A).

Já o segundo trecho de familiarização foi mais extenso, com duração média de 7 minutos, e visava estimular o controle do volante (em linha reta e em curvas) e a troca de marchas para atingir velocidades mais altas (Figura 10-B). Ao final das duas familiarizações o participante foi avisado de que seguiria com o procedimento experimental do estudo.

Figura 10 - Ilustração dos cenários de familiarização utilizados neste estudo. A: Cenário de familiarização para adaptação dos controles. B: Cenário de familiarização para estimular o controle do volante em velocidades mais alta.



As instruções fornecidas aos participantes foram:

a) O participante deveria ouvir atentamente as instruções fornecidas pelo pesquisador e a tarefa seria composta por 12 repetições de direção de veículo no ambiente simulado, em que cada uma das tentativas teria a duração média de 90 segundos.

b) O participante deveria seguir um carro sedan vermelho a sua frente até que a simulação se encerrasse. Ele não poderia perder o carro de vista, nem deixar que ele ficasse muito longe, ou ainda, permitir que um terceiro carro do cenário ficasse entre o carro líder e o carro do participante; o carro sedan vermelho deveria ser sempre aquele à frente do motorista.

c) Após o início da simulação, o participante se depararia com ambos os carros estacionados na lateral direita de uma das três faixas do sentido de direção do carro do participante. O participante deveria esperar um primeiro fluxo de carros passar pelo carro vermelho a sua frente, para que ele pudesse sair com seu carro e, seguir o carro vermelho, que iria sair automaticamente e junto com ele, permanecendo à sua frente.

d) O motorista deveria manter-se sempre na faixa central em sua via, ou seja, das três disponíveis no seu sentido de direção, ele deveria ficar naquela que estivesse no meio. O carro vermelho estaria com sua inteligência artificial ativada e, seguiria até o final do percurso, liderando o grupo dos dois carros.

e) Toda vez que ocorresse uma notificação de mensagem no smartwatch – representada por uma vibração e som característico ao mesmo tempo - o participante deveria ler esta mensagem em voz alta, de uma só vez, enquanto estivesse dirigindo, fazendo isso através do movimento padrão definido pelo fabricante para consumir a notificação recebida no relógio inteligente. Desta forma, o participante deveria girar em um movimento único e contínuo o seu punho para que o relógio se iluminasse e mostrasse automaticamente a mensagem de texto recebida.

f) Se o participante se envolvesse em um acidente de trânsito enquanto estivesse dirigindo e fazendo a leitura da mensagem de texto no relógio, ele deveria continuar a leitura da mensagem em voz alta. Caso, quando ele fosse fazer a leitura em voz alta da mensagem de texto no relógio, houvesse mais de uma mensagem na tela do relógio, ele deveria ler apenas a última que foi enviada e ignorar as anteriores.

Cada uma das 4 condições experimentais fora repetida três vezes, totalizando 12 tentativas para cada participante.

Antes do início de cada tentativa no simulador, os pesquisadores verificavam o estado e funcionamento dos equipamentos; primeiramente, ligava-se a câmera Nikon no modo de vídeo e iniciava-se a gravação da coleta de dados. O participante deveria aguardar um sinal de “OK” dos pesquisadores para que ele mesmo iniciasse a sua tentativa, apertando um botão no volante, quando estivesse pronto para iniciar a sua tarefa de direção. Antes do sinal positivo do pesquisador, iniciava-se a gravação dos dados no *Eye Tracker*; ao final da tentativa, invertia-se a ordem, desligando primeiro a gravação dos dados no *Eye Tracker* para, em seguida, encerrar a gravação da filmagem da tentativa.

Ao final da décima segunda repetição da tarefa, o participante receberia uma mensagem de agradecimento no smartwatch, formalizando o encerramento de sua participação.

3.4. Condições experimentais

Foram definidas quatro condições experimentais para a presente tese na qual cada uma foi relacionada, respectivamente, a um cenário de ambiente virtual homônimo desenvolvido para manipular a carga de trabalho mental.

3.4.1. CAR: Condição controle – tarefa de dirigir

Na condição CAR, o participante realizou a tarefa de seguir o carro vermelho líder à sua frente por um percurso de 2.000 metros, ou seja, até o final da simulação.

3.4.2. NOT: Condição de dupla tarefa – tarefa dupla de dirigir e ler mensagem no smartwatch

Já na condição NOT, o participante seguiu o carro líder à sua frente pelo mesmo trajeto de 2.000 metros, mas quando o condutor do veículo (voluntário participante da pesquisa) tivesse percorrido 850 metros, o pesquisador dispararia, manualmente, uma mensagem de texto, a partir do aplicativo Mensagens no computador Macintosh para o aplicativo iMessage no smartphone iPhone 5, e que, a seguir, enviava a mensagem recebida, automaticamente, ao smartwatch que vibrava e emitia uma notificação sonora característica de um sino, simultaneamente, alertando o participante para fazer a leitura da mensagem de texto no relógio.

A partir da notificação sonora e tátil da chegada da mensagem no smartwatch, o participante deveria fazer a leitura desta mensagem de texto quando achasse conveniente e, após a leitura, seguiria o percurso até o final da simulação.

3.4.3. FRE: Condição com freada abrupta do veículo líder

Na condição FRE, o participante seguiu o carro líder à frente pelo mesmo trajeto de 2.000 metros. Quando o condutor do veículo tivesse percorrido 1.000 metros, o carro líder freava bruscamente, reduzindo rapidamente a sua velocidade, criando um estímulo visual com a luz de freio no para-choque traseiro do carro líder através de uma luz vermelha.

O veículo líder ficava parado por 4 segundos. Ao identificar o perigo, o participante deveria realizar uma tomada de decisão para evitar a colisão. Caso o participante obtivesse sucesso em evitar a colisão traseira, ele deveria seguir dirigindo até o final da simulação. Caso ocorresse uma colisão, seria

apresentada uma animação na tela com o vidro do carro quebrando, o volante giraria com força e ficaria travado por alguns instantes e um som alto característico de batida de carro seria emitido. Após 8 segundos, o carro do participante seria mostrado novamente na pista e ele deveria seguir até o final da simulação.

3.4.4. FNOT: Condição com freada abrupta do carro líder e leitura de mensagem no smartwatch

Na condição FNOT, o participante seguiu o carro líder até o final da simulação. No instante em que o motorista atingisse 650 metros percorridos, o pesquisador disparava, manualmente, uma mensagem de texto, a partir do aplicativo Mensagens no Macintosh, para o aplicativo iMessage no smartphone iPhone 5. O celular, então, enviava a mensagem recebida, automaticamente, ao smartwatch para que o participante fizesse a leitura da mensagem de texto. A partir da chegada da mensagem, o participante deveria fazer a leitura desta mensagem de texto em voz alta quando achasse conveniente. A mensagem de texto demorava, em média, 6 segundos para ser recebida pelo relógio.

Quando o motorista participante da pesquisa alcançasse a marca de 1.000 metros percorridos, o carro líder freava bruscamente, reduzindo rapidamente sua velocidade (luz de freio ativada mediante frenagem) e ficava parado por 4 segundos. Após a frenagem, se obtivesse sucesso em evitar o acidente, o participante deveria continuar o percurso seguindo o carro líder até o final do percurso. Caso ocorresse um acidente, seria apresentada uma animação na tela, mostrando um vidro quebrado, som alto característico de batida de carro e o volante giraria com força para o lado esquerdo e travaria a sua movimentação de forma temporária. Após 8 segundos, o carro do participante seria mostrado novamente na pista e ele deveria seguir até o final do percurso.

3.5. Tratamento e análise dos dados

Os dados coletados foram sincronizados entre todos os equipamentos (simulador, filmagem da tentativa e *eye tracker*) e nas subseções a seguir detalhe-se a preparação e análise dos dados coletados. Detalhes sobre o processo de sincronia entre os equipamentos e a preparação dos dados para serem processados encontram-se no Apêndice 2.

3.5.1. Aleatorização dos dados coletados

Para contrabalançar os possíveis efeitos de ordem e de aprendizagem da tarefa, as tentativas foram completamente randomizadas. Para isso, utilizou-se o seguinte método: atribuiu-se, inicialmente, a cada uma das tentativas um código de 1 até 12 (Tabela 3).

A partir de um algoritmo, foram criadas 40 combinações de sequências diferentes de códigos de cenário. Cada participante, portanto, recebeu uma sequência única de combinação de tentativas contendo as 4 condições experimentais e suas respectivas repetições.

Tabela 3 - Atribuição dos códigos para criação da sequência única de tentativa para cada participante.

Condição	Cenário	Tentativa por Cenário	Código do Cenário
CAR	1	1	1
		2	2
		3	3
NOT	2	1	4
		2	5
		3	6
FRE	3	1	7
		2	8
		3	9
FNOT	4	1	10
		2	11
		3	12

A Figura 11 apresenta a tabela gerada pelo algoritmo na qual as colunas são os grupos de códigos de cenário e as linhas são as combinações da sequência de 12 tentativas experimentais para cada um dos 40 participantes. Esta tabela foi então utilizada como guia de operação de sequência de tentativas para cada participante da presente tese.

Detalhes sobre o desenvolvimento deste algoritmo, desenvolvido na linguagem de programação PHP podem ser encontrados no ANEXO I.

Figura 11 - Exemplo da composição das tentativas após o procedimento de randomização. A: tem-se tentativas (T) para cada um dos participantes (P) da pesquisa. B: Os números de 1 a 12 foram, posteriormente, substituídos por uma sigla de identificação da condição experimental, sendo C1(CAR), C2 (NOT), C3, (FRE) e C4(FNOT).

A		T1	T2	T3	T4	T5	T6	T7	T8	T9	T10	T11	T12
	P1	6	12	8	11	5	10	9	1	7	4	3	2
	P2	12	6	5	7	3	1	2	10	9	8	4	11
	P3	9	5	10	8	2	4	1	12	7	6	11	3
	P4	10	12	7	9	2	3	4	1	8	6	5	11
	P5	8	4	10	1	6	2	7	11	12	5	3	9
	P6	4	5	1	8	11	2	10	12	7	6	3	9

B		T1	T2	T3	T4	T5	T6	T7	T8	T9	T10	T11	T12
	P1	C2	C4	C3	C4	C2	C4	C3	C1	C3	C2	C1	C1
	P2	C4	C2	C2	C3	C1	C1	C1	C4	C3	C3	C2	C4
	P3	C3	C2	C4	C3	C1	C2	C1	C4	C3	C2	C4	C1
	P4	C4	C4	C3	C3	C1	C1	C2	C1	C3	C2	C2	C4
	P5	C3	C2	C4	C1	C2	C1	C3	C4	C4	C2	C1	C3
	P6	C2	C2	C1	C3	C4	C1	C4	C4	C3	C2	C1	C3

3.5.2. Pré-processamento dos dados

Cada um dos 40 participantes da pesquisa gerou, por fim, 3 grupos de dados: dados do simulador, dados da filmagem da tentativa e dados de movimento dos olhos a partir do *eye tracker*. Os dados do simulador forneceram as variáveis de desempenho do participante na tarefa primária de dirigir um veículo automotor; os dados da filmagem forneceram as variáveis de desempenho da tarefa secundária de leitura da mensagem de texto no smartwatch; os dados do *eye tracker* forneceram as variáveis de movimento dos olhos e do diâmetro da pupila.

Uma planilha chamada de “Mapa” foi então criada para organizar e identificar o participante, seu grupo e, para cada tentativa, as variáveis de interesse para o processamento posterior dos dados, especialmente, aquelas que marcam o início e o fim de cada um dos eventos de interesse em cada uma das condições experimentais, por exemplo, o início e o fim da leitura da mensagem de texto foram anotados, nesta planilha, para todas as repetições da condição NOT. Esta planilha foi, portanto, utilizada como guia para filtragem de

dados e cálculo posterior dos métodos pupilométricos, permitindo a identificação da condição experimental e seu respectivo grupo de dados.

Para os arquivos do simulador, um algoritmo na linguagem de programação Python foi desenvolvido para extrair as variáveis de desempenho da tarefa primária de dirigir o carro no ambiente virtual, assim, a partir desta matriz de dados, calcular para cada variável selecionada, a sua média e desvio padrão. Além disso, este algoritmo agrupava todas as médias e desvios em um mesmo arquivo para ser, posteriormente, utilizado na análise estatística. Detalhes sobre a implementação do referido algoritmo podem ser encontrados na seção Apêndice IV.

Para os arquivos do *eye tracker*, foi realizada uma análise inicial a partir dos dados brutos coletados. A análise foi realizada no software ASL Result Plus 6000. Assim, fez-se as seguintes configurações:

i) o período de análise dos dados foi sincronizado com o período da tentativa realizada no simulador, retirando excedentes no início e final da gravação dos dados de movimento dos olhos;

ii) Foram criadas 2 áreas de interesse: uma para o ambiente da simulação e a outra para o ambiente fora da simulação, assim, quando o participante direcionasse seu olhar para fora da área da simulação, após o estímulo da mensagem de texto no relógio, esta área de interesse seria interpretada como aquela que mapearia as fixações do olhar no relógio smartwatch;

iii) Foram definidas 2 análises a serem realizadas com os dados brutos: análise de fixações e análise da pupila.

Desse modo, cada tentativa de cada participante gerou 3 arquivos finais:

i) o primeiro, referente aos dados de movimentos dos olhos, coletados a cada 60Hz;

ii) o segundo, referente aos dados coletados das fixações do olhar realizados em cada uma das áreas de interesse, previamente definidas, ao longo da tentativa;

iii) o terceiro, referente à análise da pupila na qual fez-se a identificação de lacunas de dados referentes a piscadas (também conhecida pelo seu termo em inglês, *blinks*) e a perda temporária de rastreamento da pupila (também conhecida pelo seu termo em inglês, *pupil loss*). A partir da identificação desses dois tipos de lacunas de dados, fez-se uma interpolação de dados na qual

utilizou-se como duração mínima e máxima da piscada, respectivamente, 0.1 e 0.4 segundos e o número de amostras para cada limiar, respectivamente, 6 e 24. O mesmo critério de amostras foi utilizado para se interpolar os dados na situação de identificação de *pupil loss*.

Portanto, a partir deste pré-processamento dos dados, obteve-se o conjunto de dados necessários para realizar as análises das variáveis dependentes da presente tese. A Tabela 4 traz um resumo do resultado deste pré-processamento de dados.

Tabela 4 - Conjunto de arquivos gerados para cada procedimento de pré análise por fonte de dados.

Fonte de Dados	Arquivos	Observação
Simulador	480 arquivos	Um para cada tentativa de cada participante
Filmagem	1 arquivo	Marcações e variáveis agrupadas
<i>Eye Tracker</i>	1.440 arquivos	Três arquivos para cada tentativa: análise de fixações, análise da pupila e dados de movimento do olhar ao longo da tentativa.

3.5.3. Análise temporal

Cada tentativa de direção de veículo simulado teve em média 90 segundos de duração, entretanto, os eventos de interesse da presente tese ocorreram em um intervalo de tempo menor, assim, uma análise temporal foi definida para um intervalo de tempo de 10 segundos.

Este intervalo menor foi necessário para direcionar o estudo nos eventos de interesse da tese, filtrar os dados, reduzir a quantidade de dados, agrupar todos os eventos de interesse em um mesmo intervalo de tempo e direcionar os cálculos dos métodos pupilométricos aos eventos principais de cada uma das

condições experimentais, além disso, faz sentido diminuir o conjunto de dados já que as análises pupilares, a partir de uma estimulação, ocorrem em intervalos de tempo menores quando comparados à duração total de cada tentativa.

Marcadores temporais tanto para o início quanto para fim do período de 10 segundos referentes a cada condição experimental foram definidos. A seguir, tem-se os critérios de definição do intervalo de 10 segundos para cada uma das condições experimentais:

i) Condição CAR: condição controle, foram utilizados 10 segundos após ocorrer a estabilização da tarefa de dirigir, através de identificação de velocidade constante e manutenção do controle do veículo dentro da faixa central. O evento de interesse desta condição foi o controle e estabilidade veicular mantido pelo participante, permitindo posterior comparação com as demais condições experimentais deste trabalho;

ii) Condição NOT: condição em que ocorreu a dupla tarefa (dirigir e ler a mensagem de texto no smartwatch). O evento de interesse foi o recebimento da notificação no relógio e a leitura da mensagem de texto em sua tela, assim, o período de 10 segundos de análise desta condição ocorreu entre os 10 segundos contabilizados após a chegada da notificação da mensagem no smartwatch, situação caracterizada pelo recebimento da mensagem no smartwatch ao qual exibia um aviso sonoro proeminente e uma vibração tátil no punho do participante;

iii) Condição FRE: condição em que ocorreu a frenagem do veículo líder, exigindo do motorista percepção e reação a uma freada de emergência. O evento de interesse desta condição experimental foi a identificação do estímulo visual da frenagem do carro líder (luz de freio), percepção da frenagem do carro líder e a realização de uma resposta para evitar a situação de perigo. O carro líder parava na pista por 4 segundos, assim, a partir do primeiro instante em que o carro líder voltou a se deslocar, foi subtraído 10 segundos deste instante para formar o intervalo de análise;

iv) Condição FNOT: condição experimental que combina os eventos das condições experimentais FRE e NOT. O evento de interesse foi a resposta ao perigo enquanto o motorista fazia a leitura de uma mensagem de texto no smartwatch, desse modo, utilizou-se como referência o primeiro instante em que o carro líder voltou a se movimentar, após a sua frenagem de emergência por 4

segundos e, deste momento, foi subtraído 10 segundos para formar o intervalo de 10 segundos. Este intervalo registra o comportamento do motorista a partir do envio da mensagem de texto ao smartwatch, a leitura da mensagem e a ocorrência e resposta à freada emergencial do carro líder.

A Tabela 5 resume os critérios de filtragem dos dados para se obter o intervalo de 10 segundos da análise temporal.

Tabela 5 - Condições de definição do período de 10 segundos para realização da análise temporal.

Condição Experimental	Marcador Inicial de Referência Temporal	Marcador de Término	Filtragem
CAR	Instante em que o participante atingiu 600 metros a partir do início da tentativa.	10 segundos após o início	Depois de 600 metros + 10 segundos
NOT	Instante em que o participante recebeu a notificação de chegada da mensagem no relógio inteligente	10 segundos após o início	Depois da chegada da mensagem + 10 segundos
FRE	Primeiro instante em que o carro líder voltar acelerar depois de frear bruscamente durante 4 segundos	10 segundos antes do início	Primeiro instante pós frenagem – 10 segundos
FNOT	Primeiro instante em que o carro líder voltar acelerar depois de frear bruscamente durante 4 segundos	10 segundos antes do início	Primeiro instante pós frenagem – 10 segundos

Os dados foram filtrados a partir de um algoritmo próprio desenvolvido na linguagem de programação Python e detalhes sobre a sua implementação podem ser conferidos no Apêndice IV – Algoritmo 2. Desse modo, com os dados filtrados em um intervalo de 10 segundos, finalmente, se obteve um conjunto de dados que compreende todos os eventos de interesse da presente tese, por conseguinte, obteve-se a capacidade de isolar esses eventos para posterior

análise estatística. A próxima seção apresenta e define como os eventos foram selecionados e isolados a partir do período de análise.

3.5.4. Delineamento e seleção dos eventos a partir da análise temporal

Para melhor aplicar os métodos de pupilometria, precisou-se selecionar os eventos de interesse de acordo com cada uma das condições experimentais. Eventos são situações que ocorreram durante a condição simulada e refletem algum estímulo, ação, reação ou ocorrência, por exemplo.

A seguir, tem-se as definições dos eventos para cada uma das condições experimentais:

- i) Evento para CAR: após o participante atingir a marca de 600 metros percorridos, haveria a estabilização de sua velocidade e, conseqüentemente, do controle longitudinal e lateral do veículo, assim, nesta condição controle, definiu-se este momento de estabilização do controle veicular como início deste evento de interesse;
- ii) Eventos para NOT: ao longo do período de 10 segundos ocorre, na condição experimental NOT, uma situação de tarefa dupla na qual o participante conduz um veículo automotor e realiza a leitura de uma mensagem de texto no smartwatch. Desse modo, o evento de interesse de estudo, nesta condição, é a realização da leitura enquanto o participante dirige, concorrentemente, o veículo. Assim, o início do evento desta condição é a leitura da mensagem de texto no relógio;
- iii) Eventos para FRE: houve, nesta condição experimental, o interesse em caracterizar o comportamento da pupila a partir da percepção de um estímulo visual durante a condução do veículo automotor a partir da luz de freio do carro líder, por conseguinte, identificação de uma situação de perigo em potencial na freada de emergência deste carro líder. O início do evento de interesse, em FRE, é início do processo de frenagem pelo participante após a identificação do perigo em potencial;
- iv) Eventos para FNOT: ao longo do período de 10 segundos ocorre, em FNOT, os eventos de ii) e iii). Com o objetivo de analisar a

concorrência dos eventos, definiu-se para esta condição experimental os mesmos eventos de iii) na qual dentro deste intervalo tem-se a leitura da mensagem de texto no smartwatch mais a frenagem do carro frente a uma emergência, logo, o início do evento em FNOT é o início da frenagem pelo participante.

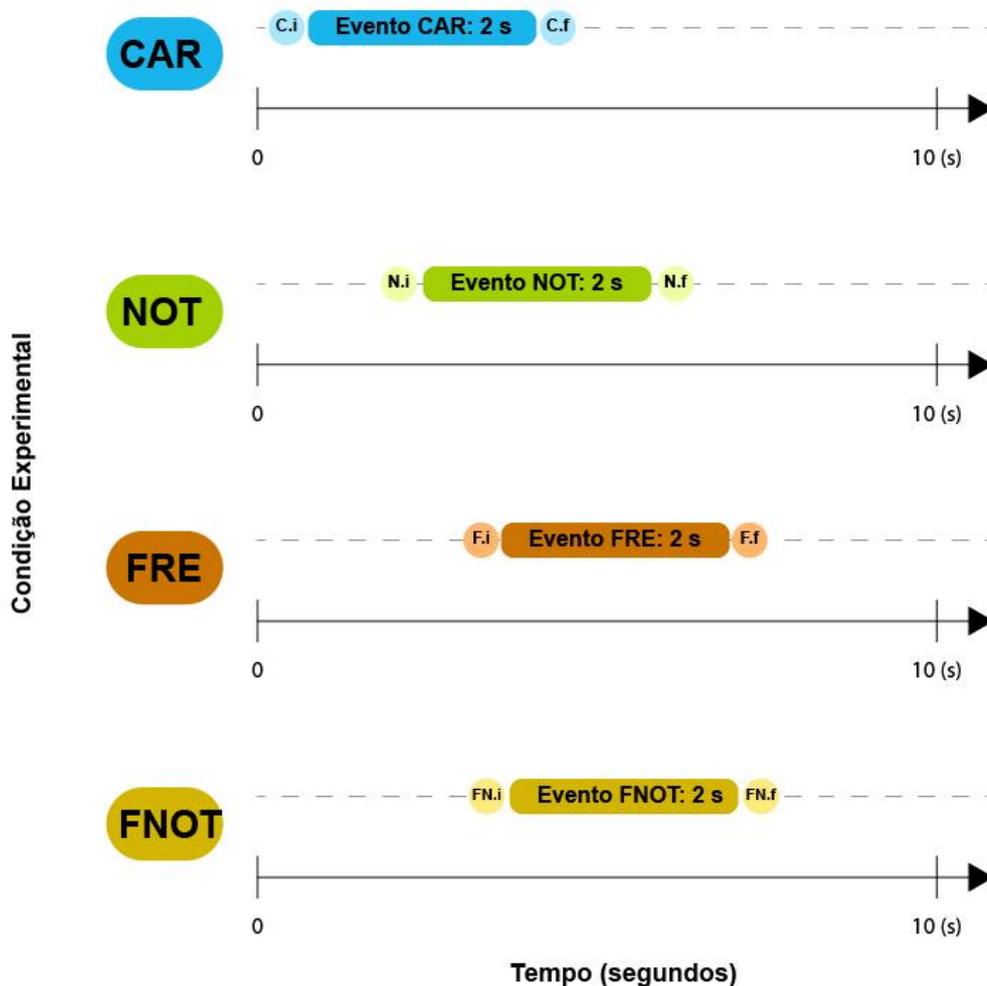
A Figura 12 mostra a forma pela qual cada evento foi obtido a partir do intervalo maior de 10 segundos e quais marcadores de tempo foram utilizados para definir o seu início dentro do intervalo original de 10 segundos.

Para satisfazer os critérios de aplicação dos métodos pupilométricos, foi definido, portanto, um período de 2 segundos de análise (Figura 12), a partir do início de cada evento de cada condição experimental. Este critério foi estabelecido a partir da revisão de literatura (Seção 2) e para que a função mãe *wavelet* Symlet 2 fosse aplicada nos métodos IPA e LHIPA para a frequência de 60Hz da coleta de dados *do eye tracker* ASL H6, aquele utilizado na presente tese.

O período de 2 segundos foi necessário e suficiente para detalhar e relacionar analítica e temporalmente os efeitos de grupo, dupla tarefa e aumento da carga de trabalho mental para cada uma das respectivas condições experimentais.

Os períodos de análise de cada evento foram obtidos a partir de algoritmos desenvolvidos na linguagem de programação Python para a presente tese e encontram-se na íntegra documentados no Apêndice IV – Algoritmo 3.

Figura 12 - Esquema ilustrativo para definição dos marcos temporais disponíveis analiticamente para definir o intervalo de dados de cada condição experimental.



Legenda Marcados Temporais de Eventos:

C.i	Estabilização do carro após 600 metros	C.f	Estabilização do carro após 600 metros + 2s
N.i	Início da leitura da mensagem de texto no smartwatch	N.f	Início da leitura da mensagem de texto no smartwatch + 2 s
F.i	Início da frenagem pelo motorista	F.f	Início da frenagem pelo motorista + 2s
FN.i	Início da frenagem pelo motorista	FN.f	Início da frenagem pelo motorista + 2s

3.5.5. Variáveis dependentes

A partir da definição dos subintervalos apresentados na esquemática da Figura 12, seguiu-se com a definição das variáveis dependentes do estudo. Estas foram organizadas em 3 tipos:

- i) Desempenho da tarefa primária – ilustram quão bem o motorista conseguiu realizar a tarefa de controlar e conduzir o veículo longitudinal e verticalmente ao longo da tarefa;
- ii) Movimento dos olhos – indicam o foco atencional do participante durante a realização da tarefa e o tempo necessário para processá-la;
- iii) Índices de carga de trabalho mental – aplicação de métodos de pupilometria os quais permitem inferir e quantificar a carga de trabalho mental em um valor de referência à tarefa que estiver sendo realizada.

A Figura 13 resume esquematicamente as variáveis dependentes do estudo agrupadas por tipo.

Figura 13 - Variáveis dependentes da presente tese, organizadas em categoria: desempenho da tarefa primária, desempenho da tarefa secundária, movimento dos olhos e índices pupilométricos.



Todas as variáveis dependentes da presente tese foram obtidas a partir de um algoritmo específico desenvolvido na linguagem de programação Python. Os algoritmos utilizaram como entrada os dados a análise temporal com intervalo de 10 segundos para cada tentativa de cada participante. Assim, a partir disso, houve a seleção das variáveis e seus respectivos cálculos de medidas de estatística descritiva. Detalhes sobre a implementação de cada algoritmo podem ser encontrados no Apêndice IV.

O delineamento geral da presente tese, especificando as condições experimentais de pesquisa encontram-se na Tabela 6.

Tabela 6 - Delineamento experimental do estudo, especificando as condições de pesquisa e um detalhamento das respectivas tarefas.

Grupo/Amostra	Condições Experimentais	Tentativas
Experientes (n = 20)	CAR	Tentativa 1
	NOT	Tentativa 2
	FRE	Tentativa 3
Novatos (n = 20)	FNOT	

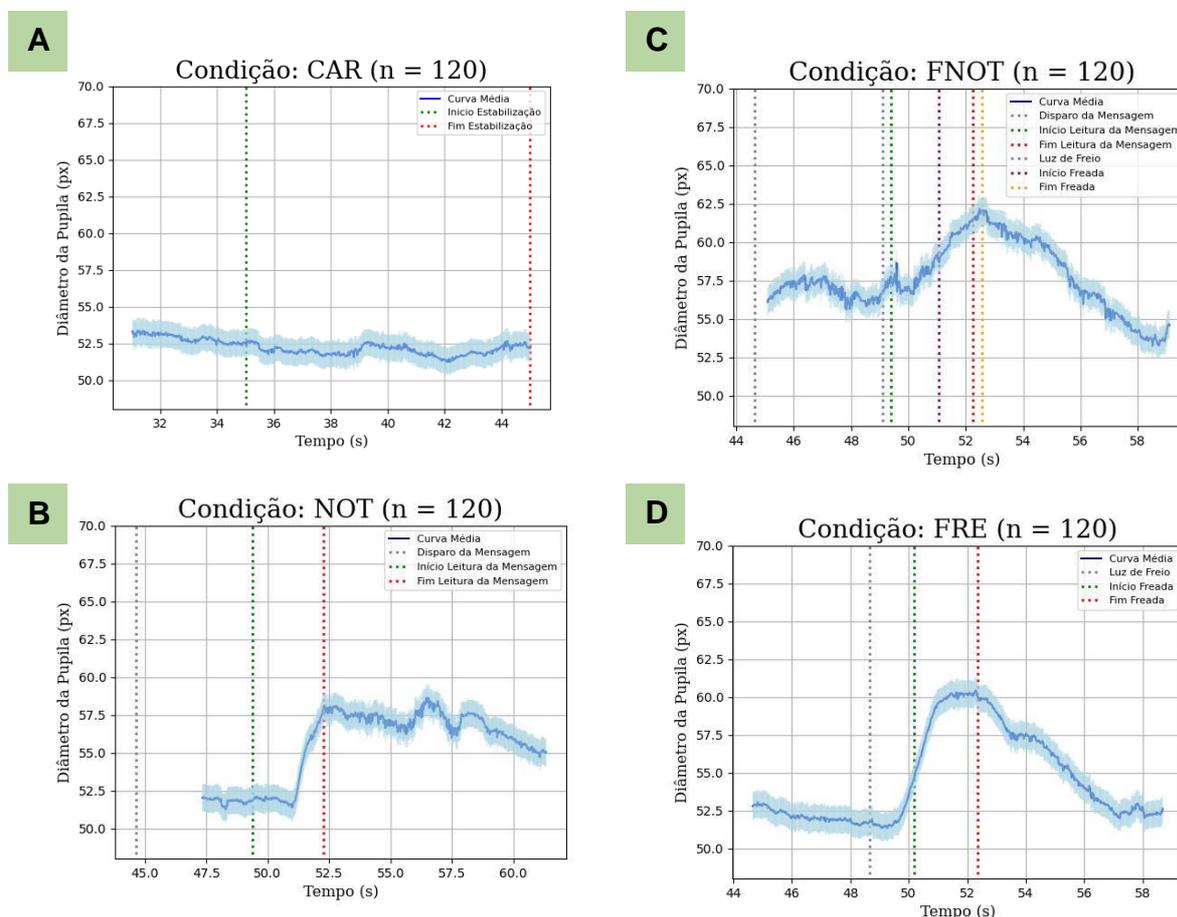
3.5.6. Análise estatística

Os dados de cada variável dependente (Figura 13) foram submetidos à análise de variância (ANOVA) de medidas repetidas de Grupo (EXP, NOV) por Condição (CAR, NOT, FRE, FNOT) por Tentativa (1, 2 e 3), com medidas repetidas nos dois últimos fatores. Apesar do fator Tentativa não estar associado às hipóteses do estudo, ele foi incluído na análise para averiguar diferenças significativas sistemáticas entre as tentativas, mesmo não esperadas, e, possivelmente, demonstrar a consistência dos outros fatores. O nível de significância adotado foi de 0,05 para todas as análises. Foram utilizados os softwares *Matlab* (*The Matworks Inc.*, versão 2021) para cálculo de variáveis e SPSS (*SPSS Inc.*, versão 2021) para as análises estatísticas necessárias. Comparações aos pares (*post-hoc*) foram realizadas através do Teste LSD de Tukey. Ajustes de probabilidade de Bonferroni e ajustes de graus de liberdade de Greenhouse-Geisser foram utilizados conforme necessário (Maxwell & Delaney, 1990).

4. RESULTADOS

A resposta da pupila foi mensurada durante os eventos característicos de cada uma das condições experimentais (CAR, NOT, FRE e FNOT). Desse modo, inicialmente, são apresentados os dados brutos do diâmetro da pupila em função do tempo durante as condições experimentais (Figura 14).

Figura 14 - Curvas médias (± 1 erro padrão) do diâmetro da pupila: A) Condição controle CAR: diâmetro da pupila após a estabilização da velocidade do carro na tentativa. B) Condição NOT: comportamento da pupila antes do início e fim médios da leitura da mensagem. C) Condição FNOT: diâmetro da pupila variando entre os diferentes eventos (freada e leitura). D) Condição FRE: Diâmetro da pupila após o acender da luz de freio e resposta motora da freada.



4.1. Aumento da carga de trabalho mental e métodos pupilométricos

O Índice de Atividade Pupilar (IPA) foi afetado significativamente pelo fator de condição experimental, $F(1, 38) = 59,701$, $p < 0,001$, $\eta_p^2 = 0,611$ (Figura 15). A análise *post-hoc* revelou que o valor de IPA foi significativamente maior em

FNOT, FRE e NOT, em comparação à condição CAR ($p_s < 0,001$); adicionalmente, FNOT e FRE foram significativamente maiores em comparação a condição NOT ($p_s = 0,008$ e $0,043$, respectivamente). Os efeitos principais e de interação não reportados para a carga de trabalho mental através do índice IPA, não alcançaram significância.

O Índice de Alta/Baixa Atividade Pupilar (LHIPA) foi afetado significativamente pelo fator de condição experimental, $F(1, 38) = 85,974$, $p < 0,001$, $\eta_p^2 = 0,449$ (Figura 16). A análise *post-hoc* revelou que o valor de LHIPA foi significativamente menor em FRE e FNOT, em comparação à condição CAR ($p_s < 0,001$); adicionalmente, FRE e FNOT, foram significativamente menores em comparação com a condição NOT ($p_s = 0,001$). Os efeitos principais e de interação não reportados para a carga de trabalho mental através do índice LHIPA, não alcançaram significância.

O valor da porcentagem de mudança do diâmetro da pupila (PMDP), métrica que representa o método de estimulação da resposta pupilar a partir de uma tarefa (TEPR), foi afetado significativamente pelo fator de condição experimental, $F(1, 38) = 40,945$, $p < 0,001$, $\eta_p^2 = 0,519$ (Figura 17). A análise *post-hoc* revelou que o valor de PMDP foi significativamente maior em FRE, FNOT e NOT, em comparação à condição CAR ($p_s < 0,001$); adicionalmente, FRE foi significativamente maior do que às condições FNOT e NOT ($p_s < 0,001$). Os efeitos principais e de interação não reportados para a carga de trabalho mental através da PMDP, não alcançaram significância.

Para a variável dependente de colisão (Figura 18), a ANOVA-rm mostrou diferença significativa para o efeito principal de condição, $F(1, 38) = 53,044$, $p < 0,001$, $\eta_p^2 = 0,583$, e da interação entre os fatores condição e grupo, $F(1, 38) = 2,694$, $p < 0,049$, $\eta_p^2 = 0,066$. A análise de *post-hoc* revelou que houve, significativamente, mais colisões para o grupo de motoristas novatos em comparação com motoristas experientes na condição experimental FRE. Adicionalmente, o *post-hoc* revelou ainda que houve mais colisões nas condições FNOT e FRE em comparação às condições experimentais CAR e NOT ($p_s < 0,001$). Os efeitos principais e de interação não reportados para a colisão entre o motorista e o carro líder, não alcançaram significância.

Figura 15 - Valor do índice IPA em função das condições experimentais.

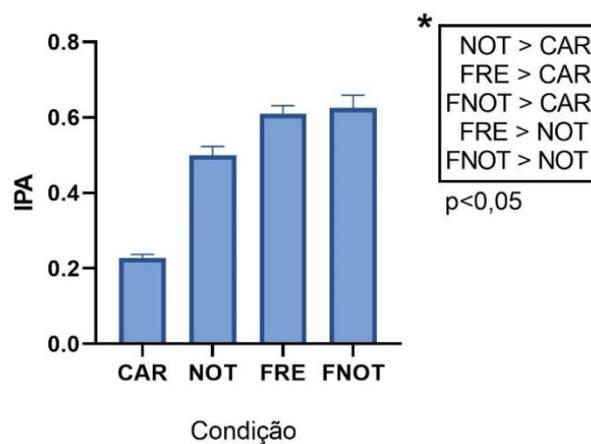


Figura 16 - Valor do índice LHIPA em função das condições experimentais.

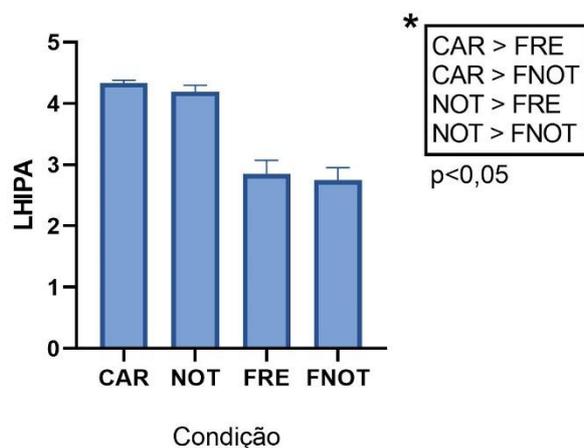


Figura 17 - Valor da porcentagem de mudança do diâmetro da pupila (PMDP) em função das condições experimentais. PMDP foi calculado em relação ao *baseline* de cada condição experimental o qual foi definido como o valor médio do diâmetro da pupila em um intervalo de 0,5 s antes do início do evento característico da condição experimental.

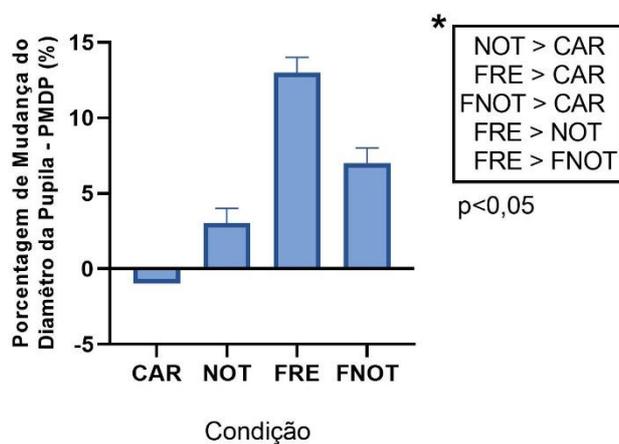
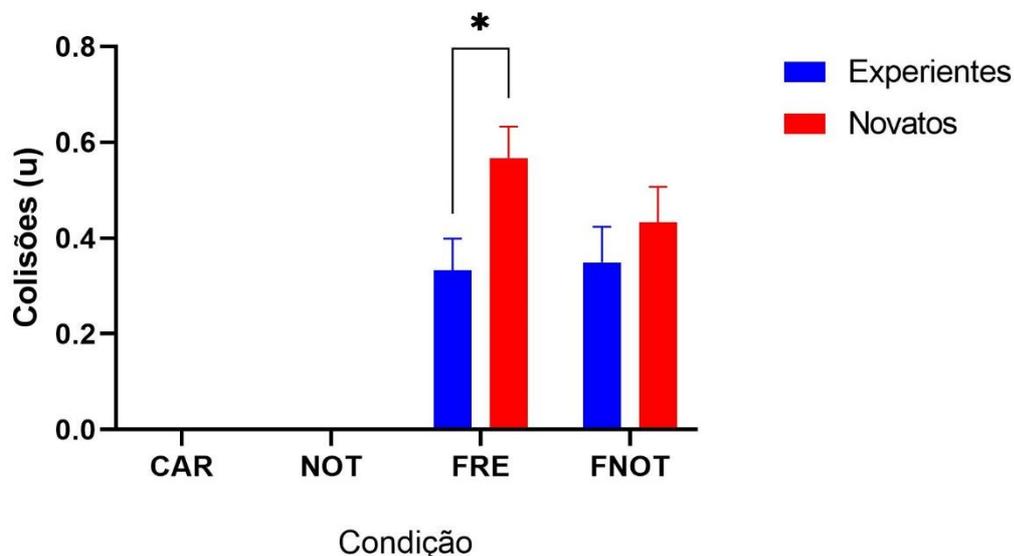


Figura 18 - Número de colisões entre o motorista e o carro líder em função das condições experimentais. As condições experimentais CAR e NOT não possuíam eventos de colisão.



Para a variável dependente de velocidade média, a ANOVA-rm mostrou diferença significativa para o efeito principal de condição, $F(1, 38) = 27,733$, $p < 0,001$, $\eta_p^2 = 0,422$, e de grupo, $F(1, 38) = 7,911$, $p < 0,008$, $\eta_p^2 = 0,172$. A análise *post-hoc* revelou que os motoristas novatos apresentaram uma velocidade média maior que os motoristas experientes, independente de condição (Figura 19). Adicionalmente, o *post-hoc* revelou que o valor da velocidade média foi significativamente menor em FNOT, FRE e NOT, em comparação com à condição CAR ($ps < 0,001$); o valor da velocidade média foi significativamente menor em FNOT na comparação com à condição NOT ($p < 0,006$). Os efeitos principais e de interação não reportados para a velocidade média, não alcançaram significância.

Para a variável dependente de variabilidade da velocidade média, a ANOVA-rm mostrou diferença significativa para o efeito principal de condição, $F(1, 38) = 79,937$, $p < 0,001$, $\eta_p^2 = 0,678$, e para a interação entre condição e grupo, $F(1, 38) = 4,015$, $p < 0,009$, $\eta_p^2 = 0,096$. A análise *post-hoc* revelou que o valor da variabilidade da velocidade média foi significativamente maior para os motoristas experientes na condição FRE em comparação com os motoristas novatos (Figura 20); adicionalmente, FNOT e FRE foram significativamente maiores enquanto NOT foi significativamente menor do que à condição CAR ($ps < 0,001$). A velocidade média foi, ainda, significativamente maior FNOT e FRE,

em comparação a condição NOT ($p < 0,001$). Os efeitos principais e de interação não reportados para a variabilidade da velocidade média, não alcançaram significância.

Figura 19 - Comparativo entre as velocidades médias dos motoristas novatos e experientes, independente de condição experimental.

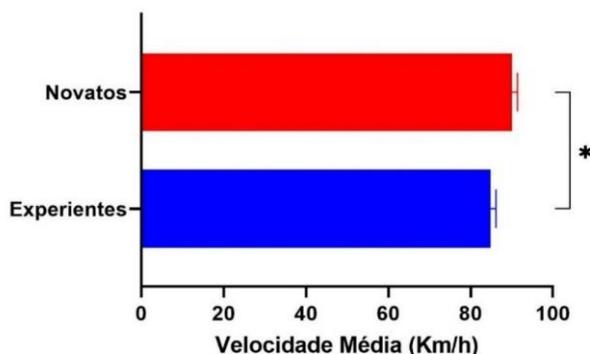
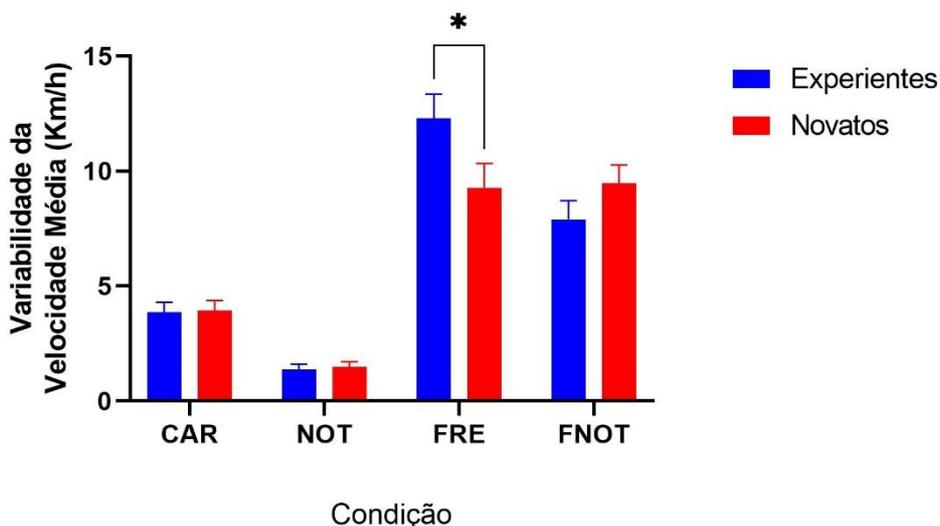


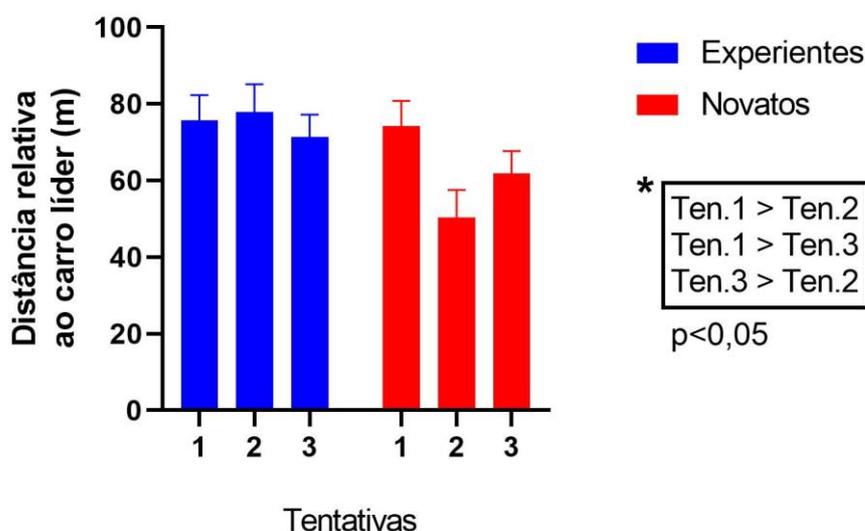
Figura 20 - Comparativo entre as variabilidades das velocidades médias dos motoristas experientes e novatos por condição experimental.



Para a variável dependente de distância relativa ao carro líder (Figura 21), a ANOVA-rm mostrou diferença significativa para o efeito principal de condição, $F(1, 38) = 40,508$, $p < 0,001$, $\eta_p^2 = 0,516$, e da interação entre tentativa e grupo, $F(1, 38) = 5,100$, $p < 0,008$, $\eta_p^2 = 0,118$. A análise *post-hoc* revelou a distância relativa ao carro líder para os motoristas novatos foi significativamente maior na tentativa 1, em comparação com às tentativas 2 e 3 ($p = 0,001$ e $0,037$, respectivamente); adicionalmente, os novatos apresentaram maior distância ao carro líder na tentativa 3 em comparação a tentativa 2 ($p < 0,045$). O *post-hoc*

revelou ainda que a distância ao carro líder foi significativamente menor em FNOT, FRE e CAR, em comparação à NOT ($p_s = 0,001, 0,001$ e $0,018$, respectivamente); e a distância ao carro líder foi significativamente menor em FNOT e FRE, em comparação à condição CAR ($p_s < 0,001$). Os efeitos principais e de interação não reportados para a distância ao carro líder, não alcançaram significância.

Figura 21 - Distância relativa ao carro líder em função das tentativas por grupos de experiência (experientes e novatos) na direção de veículo automotor.

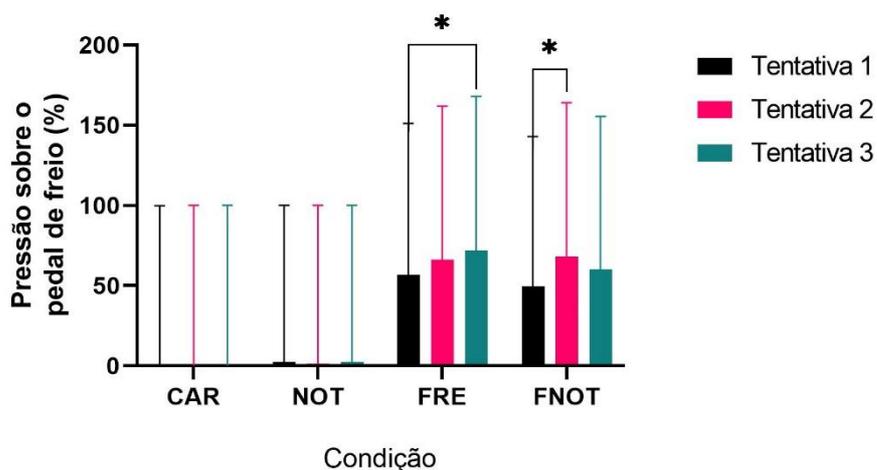


Para a variável dependente de pressão sobre o pedal de freio, a ANOVA-rm mostrou diferença significativa para o efeito principal de condição experimental, $F(1, 38) = 228,297, p < 0,001, \eta_p^2 = 0,857$, e de tentativa, $F(1, 38) = 5,023, p < 0,009, \eta_p^2 = 0,117$ e da interação entre os fatores condição e tentativa, $F(1, 38) = 2,535, p < 0,021, \eta_p^2 = 0,063$. A pressão sobre o pedal de freio é uma variável do tipo inteiro que possui valores entre 0 e 65535, significando que o pedal está completamente pressionado ou totalmente livre, respectivamente.

A análise *post-hoc* revelou que o valor da pressão sobre o pedal de freio na condição experimental FRE foi, significativamente, maior na tentativa 3, em comparação a tentativa 1 ($p < 0,026$) e o valor da pressão sobre o pedal de freio na condição FNOT foi, significativamente, maior na tentativa 2 em relação a tentativa 1 ($p < 0,014$); adicionalmente, FRE e FNOT foram significativamente

menores que ambas as condições CAR e NOT ($p_s < 0,001$). Ademais, o valor da pressão sobre o pedal de freio foi significativamente maior na tentativa 2 em relação a tentativa 1 ($p < 0,019$), independente de grupo e condição experimental (Figura 22). Os efeitos principais e de interação não reportados para a pressão sobre o pedal de freio, não alcançaram significância.

Figura 22 - Pressão sobre o pedal de freio em função da condição experimental para cada uma de suas 3 tentativas. Os dados foram normalizados entre 0 e 100 %, com 100% indicando que o pedal foi completamente pressionado (* $p < 0,05$).



A variável dependente desvio padrão do posicionamento lateral do carro do participante em relação ao meridiano da via, não foi afetada significativamente por nenhum fator principal ou interação.

Para a variável dependente do número de fixações direcionadas à área de interesse para realizar a tarefa de direção do veículo, a ANOVA-rm mostrou diferença significativa para o fator condição experimental, $F(1, 38) = 108,417$, $p < 0,001$, $\eta_p^2 = 0,740$ (Figura 23). A análise *post-hoc* revelou que o valor do número de fixações à área de interesse da tarefa de dirigir foi significativamente menor em FRE, FNOT e NOT, em comparação à condição CAR ($p_s < 0,001$).

Os efeitos principais e de interação não reportados para o número de fixações do olhar em direção à área de interesse na tarefa de dirigir, não alcançaram significância.

Para a variável dependente do número de fixações direcionadas a área de interesse fora do plano definido para a simulação da tarefa de dirigir, a ANOVA-rm mostrou diferença significativa para o fator condição, $F(1, 38) =$

47,511, $p < 0,001$, $\eta_p^2 = 0,556$. A análise *post-hoc* revelou que o valor do número de fixações direcionadas a área de interesse fora do plano definido para a simulação foi significativamente menor em CAR, FRE e FNOT, em comparação à condição NOT ($ps < 0,001$); adicionalmente, FRE e FNOT foram significativamente menores que a condição CAR ($ps = 0,011$ e $0,015$, respectivamente).

Os efeitos principais e de interação não reportados para o número de fixações do olhar fora da área de interesse da simulação, não alcançaram significância.

Figura 23 - Número de fixações do olhar na tarefa de dirigir em função das condições experimentais para a área de interesse da simulação.

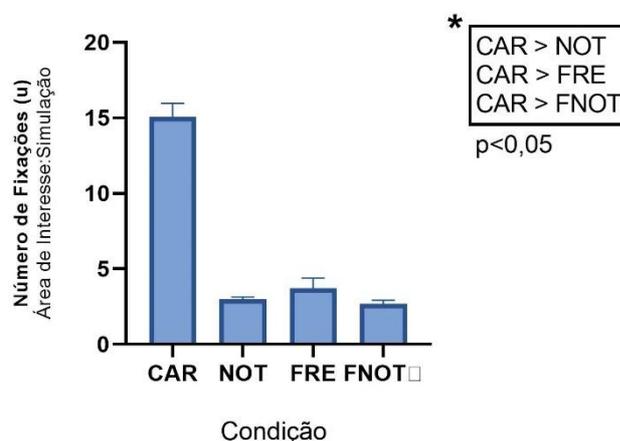
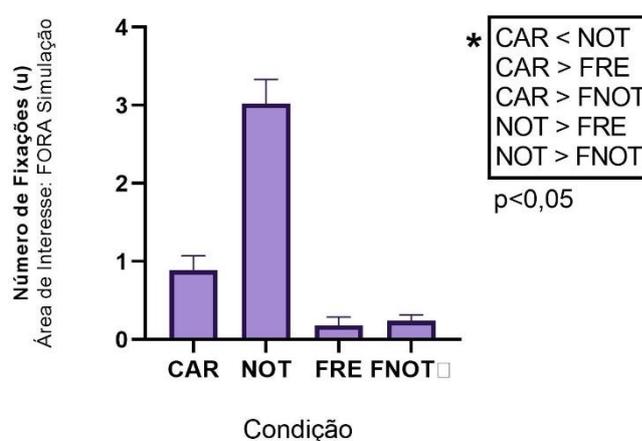


Figura 24 - Número de fixações do olhar em função das condições experimentais para a área de interesse fora da simulação.



Para a variável dependente de duração total das fixações do olhar direcionadas à área de interesse para realizar a tarefa de direção do veículo, a

ANOVA-rm mostrou diferença significativa para o fator condição, $F(1, 38) = 1775,908$, $p < 0,001$, $\eta_p^2 = 0,979$. A análise *post-hoc* revelou o valor da duração total das fixações do olhar direcionadas à área de interesse para realizar a tarefa de dirigir foi significativamente menor em FNOT, FRE e NOT, em comparação à CAR ($ps < 0,001$).

Os efeitos principais e de interação não reportados para a duração total das fixações do olhar em direção à área de interesse na tarefa de dirigir, não alcançaram significância.

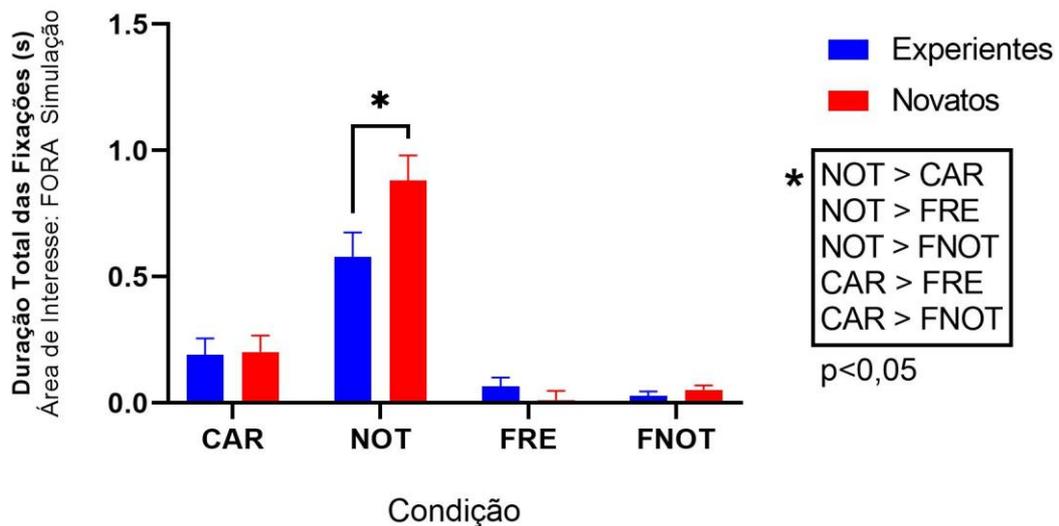
Para a variável dependente de duração total das fixações do olhar direcionadas a área de interesse fora do plano definido para a simulação da tarefa de dirigir, a ANOVA-rm mostrou diferença significativa para o fator condição, $F(1, 38) = 52,938$, $p < 0,001$, $\eta_p^2 = 0,582$ e da interação entre condição e grupo, $F(1, 38) = 3,073$, $p < 0,031$, $\eta_p^2 = 0,075$. A análise *post-hoc* revelou que na condição experimental NOT (Figura 25), o valor da duração total das fixações do olhar direcionadas às áreas de interesse fora do plano da tarefa de dirigir foi significativamente maior para os motoristas novatos em comparação aos experientes ($p < 0,034$). Adicionalmente, o valor da duração total das fixações do olhar nas áreas de interesse fora da simulação foi significativamente menor em FNOT, FRE e CAR, em comparação à condição NOT ($ps < 0,001$); já as condições FRE e FNOT foram significativamente menores que à condição CAR ($ps = 0,033$ e $0,017$, respectivamente).

Os efeitos principais e de interação não reportados para a duração total das fixações do olhar fora da área de interesse da simulação, não alcançaram significância.

Para a variável dependente de duração média das fixações do olhar direcionadas à área de interesse para realizar a tarefa de direção do veículo, a ANOVA-rm mostrou diferença significativa para o fator condição, $F(1, 38) = 26,947$, $p < 0,001$, $\eta_p^2 = 0,415$. Análise *post-hoc* revelou que o valor da duração média das fixações às áreas de interesse da direção foi significativamente menor em FNOT, FRE e NOT, em comparação à condição CAR ($ps < 0,001$); adicionalmente, FRE foi significativamente maior que a condição NOT ($p < 0,017$).

Os efeitos principais e de interação não reportados para a duração média das fixações do olhar em direção à área de interesse na tarefa de dirigir, não alcançaram significância.

Figura 25 - Duração total das fixações do olhar em função da condição experimental por grupos (experientes e novatos).



Para a variável dependente de duração média das fixações direcionadas a área de interesse fora do plano definido para a simulação da tarefa de dirigir, a ANOVA-rm mostrou diferença significativa para o fator condição, $F(1, 38) = 94,404$, $p < 0,001$, $\eta_p^2 = 0,713$. A análise *post-hoc* revelou que o valor da duração média das fixações do olhar fora da simulação foi significativamente menor em FNOT, FRE e CAR, em comparação à condição NOT ($ps < 0,001$); adicionalmente, FRE e FNOT foram significativamente menores do que CAR ($ps = 0,001$ e $0,004$, respectivamente).

Os efeitos principais e de interação não reportados para a duração média das fixações do olhar fora da área de interesse da simulação, não alcançaram significância. A variável desvio da posição lateral do carro em relação ao meridiano da via, não alcançou diferença significativa para efeitos principais e de interação.

5. DISCUSSÃO

Os objetivos da presente tese foram: investigar os efeitos da experiência do motorista e da demanda cognitiva resultante das tarefas de freada e do uso de smartwatch sobre a carga de trabalho mental durante a condução de automóvel e, neste contexto, avaliar como métodos de pupilometria (IPA, LHIPA e TEPR) são precisos para inferir às variações da carga de trabalho mental, durante a condução de automóvel envolvendo, simultaneamente, as tarefas de freada e uso do smartwatch. A partir destes objetivos, três hipóteses foram formuladas: i) a demanda cognitiva resultante de cada condição experimental afetaria a carga de trabalho mental, registrada através da pupilometria, do seguinte modo: em comparação à condição controle (somente dirigir o automóvel), haverá aumento da carga de trabalho mental nas condições de leitura da mensagem de texto no smartwatch e de freada, atingindo seu máximo na condição simultaneamente combinada de leitura e freada; ii) a maior experiência na condução de automóvel atenuaria a carga de trabalho mental dos motoristas, sendo que o grupo de motoristas experientes apresentaria menores valores em comparação com os motoristas novatos; e iii) os métodos de pupilometria IPA, LHIPA e TEPR produziram medidas de carga de trabalho mental compatíveis com as demandas cognitivas das diferentes condições experimentais. Os resultados da presente tese são discutidos nas subseções a seguir.

De modo geral, os resultados da presente tese confirmaram as hipóteses i) e iii): em i) assegurou-se que as condições experimentais foram apropriadas para manipular de modo efetivo a demanda de carga de trabalho mental e em iii) mostrou-se que os valores dos métodos de pupilometria IPA, LHIPA e TEPR refletiram esta manipulação. De outro modo, os resultados mostraram que a hipótese ii) foi refutada, uma vez que diferenças significativas não foram encontradas para os diferentes grupos de motoristas para a carga de trabalho mental, mensurada através dos métodos pupilométricos.

5.1. Efeito da demanda cognitiva nas condições experimentais

Antes de se mensurar os índices de pupilometria, houve a necessidade de avaliar se as condições experimentais propostas garantiriam que a carga de trabalho mental estava sendo manipulada apropriadamente através das

condições experimentais CAR, NOT, FRE e FNOT. Assim, discute-se a seguir o desempenho na tarefa de conduzir um veículo automotor e o movimento dos olhos os quais mostraram, respectivamente, que ao desafiar participantes manipulando a carga de trabalho mental, houve diferenças significativas entre as condições experimentais da pressão sobre o pedal de freio, da velocidade média, da variabilidade da velocidade média, da distância relativa ao carro líder e do número de colisões em relação à condição controle CAR; adicionalmente, os movimentos dos olhos indicaram que o participante desviou, momentaneamente, o seu olhar da área de interesse de apresentação da simulação a uma área fora da desta região, na qual interpretou-se, temporalmente, que o participante estaria realizando a tarefa de leitura da mensagem de texto e, assim, foram encontradas diferenças significativas na condição experimental do número de fixações do olhar em determinada área de interesse, duração média das fixações em determinada área de interesse e, por fim, na duração total das fixações em cada área de interesse.

Os resultados da presente tese indicaram que a medida em que se aumentou a demanda pelos recursos cognitivos na tarefa, respectivamente, através das condições experimentais, CAR, NOT, FRE e FNOT, houve mudança no desempenho da tarefa primária de conduzir um veículo automotor, quando diminuiu-se a velocidade média do carro do motorista e aumentou-se a variabilidade da velocidade média, independentemente de grupos.

Quando ocorre o aumento da carga mental de trabalho, há, conseqüentemente, uma piora no desempenho da tarefa primária já que os recursos cognitivos disponíveis foram solicitados para a realização da dupla tarefa. De acordo com o Teoria de Múltiplos Recursos de Wickens (2002), como as tarefas da presente tese foram, em sua essência, demandas do tipo visual e motoras para percepção e seleção de resposta motora apropriada através da visão (HURTS et al., 2011), houve conflito nos estágios de percepção - pois a memória de trabalho está em função da tarefa de dirigir e ao mesmo tempo precisa lidar com a tarefa de leitura da mensagem de texto - e em modalidade - segundo a teoria, as tarefas utilizam-se do estímulo da visão, competindo pelo uso deste canal. Quando duas ou mais tarefas competem pelos mesmos recursos, em pelo menos uma dessas duas dimensões, há interferência de uma tarefa na outra. Assim, para continuar executando uma direção segura, os

motoristas modulam, estrategicamente, uma das tarefas para conseguir compensar os recursos cognitivos necessários e realizá-las de forma concorrente, ou seja, escolhendo a velocidade do veículo e aumentando ou diminuindo a distância relativa em relação ao veículo a frente (FULLER, 2005). A velocidade média e a sua variabilidade sugerem um comportamento tático com a finalidade de manter a segurança, reduzindo as demandas da tarefa e o risco envolvido na sua realização. Este resultado está em consonância com a literatura na qual Caird et al. (2008) identificou que a estratégia mais eficiente, realizada por motoristas para reduzir as demandas da tarefa principal, é realizada através da redução da velocidade.

A distância relativa ao carro líder aumentou de CAR ($79,7 \pm 4,4$ m) para NOT ($95,0 \pm 6,1$ m) e diminuiu em FRE ($50,4 \pm 4,9$ m) e FNOT ($49,0 \pm 4,6$ m). O aumento pode ser explicado pelo comportamento de compensar a demanda extra gerada pela tarefa de leitura da mensagem de texto; assim como na variável de velocidade média, é um comportamento tático do motorista para manter a sua segurança no trânsito. Em contrapartida, em FRE e FNOT há uma diminuição da distância relativa, devido à aproximação do motorista ao carro líder, já que o carro líder se encontrava parado na via; o período de análise destas duas condições experimentais ocorreu a partir do evento de início da freada, resultando, portanto, na diminuição da distância relativa.

A variável de colisão mostrou diferença significativa para o efeito principal de condição experimental: CAR com FRE e FNOT; NOT com FRE e FNOT. Entretanto, este resultado deve-se às características de composição da tarefa de dirigir, na qual CAR e NOT não possuíam uma configuração de situação que permitiria uma colisão. O carro líder, nestas condições, não freia ao longo da tentativa, logo, a freada só ocorre em FRE e FNOT; os resultados refletem o delineamento do estudo. A ANOVA-rm mostrou efeito significativo da interação entre condição e grupo, que será detalhada em seção subsequente. O mesmo resultado ocorreu para a variável de pressão sobre o pedal de freio, na qual a diferença significativa ocorreu para o efeito principal de condição para FRE e FNOT, em comparação à CAR e NOT; as condições experimentais CAR e NOT não apresentavam uma situação de freada, assim, os resultados refletem o delineamento do estudo na qual, em FRE e FNOT, o motorista precisava

responder a uma situação de freada do carro líder. Os efeitos de interação com tentativa serão discutidos em seção subsequente.

Para garantir que houvesse um desvio atencional, a tarefa secundária de leitura de uma mensagem de texto na tela de um smartwatch foi implementada. Assim, para as variáveis dependentes de movimentos dos olhos, caracterizou-se como fixações aquelas que se iniciaram e finalizaram dentro do período de análise do evento em cada condição experimental. Logo, esta restrição refletiu no número de fixações e na duração total e média das fixações do olhar, especialmente, na condição FRE e FNOT. Adicionalmente, como descrito no método da presente tese, uma limitação do estudo foi a não possibilidade de definir uma área de interesse isolada para o direcionamento do olhar ao smartwatch, sendo esta tarefa realizada através de análise temporal, a partir do estímulo tátil e sonoro do smartwatch, sincronizados com dados do simulador e do *eye tracker*, para realizar a leitura da mensagem quando o participante direcionava o seu olhar para a área de interesse fora dos limites definidos como aqueles referentes à condição simulada. A partir deste contexto, discute-se a seguir os resultados das variáveis dependentes do número de fixações do olhar, a duração total das fixações do olhar e a duração total média das fixações do olhar.

O número de fixações do olhar registra a quantidade de fixações que ocorrem em um determinado período. Já a duração das fixações, em um período, indica onde o olhar se direcionou e ficou estacionário (SALVUCCI; GOLDBERG, 2000), as fixações ocorrem quando os olhos param de escanear o ambiente e posicionam a fóvea em uma determinada região, permitindo que um indivíduo observe um determinado ponto de interesse com mais detalhes (LI; XU; FENG, 2021). A duração das fixações, portanto, indica quanto tempo um indivíduo despendeu para adquirir informação em uma determinada localização; quanto maior a duração da fixação, mais tempo foi necessário para o processamento cognitivo daquilo que foi percebido, refletindo a dificuldade de extrair a informação na região de interesse.

No caso da presente tese, as fixações do olhar foram calculadas a partir da definição de duas áreas de interesse: ambiente simulado da direção de automóvel e ambiente fora (*outside*) da direção simulada, interpretada como a leitura da mensagem de texto no smartwatch. Os resultados mostraram que

houve diferença significativa entre o número, duração e duração média de fixações nas condições experimentais em relação à condição controle CAR, tanto para a área de interesse direcionada à direção de automóvel quanto para a leitura da mensagem de texto, confirmando, portanto, a primeira hipótese da presente tese, através da qual foi possível demonstrar que as variáveis de desempenho e de movimento dos olhos refletiram demandas de carga de trabalho mental nas condições experimentais CAR, NOT, FRE e FNOT.

De fato, utilizando-se como *baseline* o número de fixações do olhar na condição controle CAR ($15,0 \pm 0,9$) para a área de interesse da condição simulada, verifica-se que o número de fixações diminuiu com a adição de outras tarefas concorrentes com a tarefa principal de dirigir, NOT ($3,0 \pm 0,2$), FRE ($3,7 \pm 0,7$) e FNOT ($2,7 \pm 0,2$). Isto sugere que as fixações direcionadas à aquisição de informação da simulação do ambiente foram compartilhadas e direcionadas à área de interesse interpretada como leitura de texto no smartwatch. Observa-se este resultado devido a presença de fixações nas condições experimentais NOT ($3,0 \pm 0,3$) e FNOT ($0,2 \pm 0,1$) na área de interesse direcionada ao smartwatch; os dados de movimentos dos olhos sugerem a mudança do foco atencional dos motoristas quando recebiam a mensagem de texto para realizar a leitura da mensagem de texto, deslocando o seu olhar para fora da tela de apresentação do ambiente da simulação.

Os resultados mostraram ainda que houve diferença significativa na variável de duração da fixação na área de interesse direcionada à simulação de trânsito entre as condições experimentais NOT ($0,7 \pm 0,1$ s), FRE ($1,3 \pm 0,3$ s) e FNOT ($0,8 \pm 0,7$ s) em comparação com a condição controle CAR ($7,9 \pm 0,2$ s) na área de interesse da simulação. O foco atencional também é refletido na variável dependente de duração total das fixações; a duração total das fixações foi maior na condição CAR ($7,9 \pm 0,2$ s) na área de interesse da simulação, em comparação com a condição CAR ($0,2 \pm 0,1$ s) na área de interesse fora da simulação; ao mesmo tempo, a duração total das fixações foi menor na condição NOT ($0,7 \pm 0,1$ s) na área de interesse da simulação, em comparação à condição NOT na área de interesse fora da simulação. Estes resultados estão de acordo com a literatura, na qual a análise de área de interesse permite mensurar e localizar semanticamente os movimentos dos olhos, o que mostra com clareza onde o participante estava direcionando sua atenção visual (MAHANAMA et al.,

2022). Ademais, na condição CAR, não havia eventos proeminentes que estimulassem a busca de dicas visuais no ambiente; em contrapartida, em outras condições experimentais, o motorista precisava realizar uma busca visual mais ampla para perceber a freada do carro líder ou realizar a tarefa dupla de leitura na qual o número de fixações do olhar auxilia na determinação da importância semântica da tarefa (BUSWELL, 1935; YARBUS, 1967); em CAR, o motorista precisava manter sua atenção naquilo que era mais crítico para ele (RECARTE; NUNES, 2003), diminuindo a atenção da direção para buscar mais informações em outras regiões, como na área de interesse fora da simulação - interpretada como tarefa de leitura no smartwatch, nas condições em NOT e FNOT. Estes resultados estão em linha com a literatura que mostra que em situação de dupla tarefa, há expectativa de mudança do foco atencional entre a tarefa de direção e a tarefa secundária (SODHI; REIMER; LLAMAZARES, 2002; VICTOR, 2005; WIERWILLE, 1993).

Em FNOT e FRE, o valor médio do número de fixações e da duração total das fixações não aumentaram e a duração média das fixações do olhar foram baixas na área de interesse interpretada para leitura no smartwatch, em comparação com as médias de duração direcionadas à área de interesse da simulação (condição CAR). Isso pode ter ocorrido devido a forma como os dados foram isolados na análise temporal, já que se utilizou como referência inicial o evento de freada para FRE e FNOT, assim, em FNOT, o motorista pode ter interrompido a leitura da mensagem de texto no relógio quando percebeu o estímulo da luz de freio do carro a frente, priorizando sua atenção à freada; a atenção é um recurso necessário para criar consciência da percepção (LABERGE, 1995), logo, nas condições FRE e FNOT a atenção foi direcionada para perceber o estímulo visual da freada do carro líder e, assim, responder a freada de emergência. Em NOT há, expressivamente, o direcionamento do olhar para interagir com a tarefa de leitura da mensagem de texto no smartwatch, como esperado. Além disso, essa diferença no número de fixações, duração total das fixações e duração média indica que o motorista deixou de alocar seus recursos atencionais na direção da simulação e as direcionou à realização da tarefa de leitura, já que o número de fixações e a duração das fixações do olhar aumentou na área de interesse fora do ambiente simulado após o estímulo para realizar a leitura na condição NOT ($3,0 \pm 0,3$ s). Portanto, as fixações do olhar

indicam aquilo que o motorista está direcionando sua atenção e, dessa forma, busca mais informação no ambiente para processamento cognitivo (BARRETO, 2012).

5.2. Efeito da demanda cognitiva e métodos de pupilometria

Os resultados da presente tese mostraram que a manipulação criada para desafiar participantes, aumentando a carga cognitiva necessária para realizar a dupla ou tripla tarefa de conduzir um veículo automotor, ler uma mensagem de texto em um smartwatch e, ainda, em um determinado instante, responder a uma freada de emergência de um carro líder, funcionou adequadamente. A relação entre o aumento cognitivo da demanda da tarefa e o diâmetro médio da pupila foi assim caracterizada: quanto maior a demanda cognitiva da tarefa, maior a dilatação média de resposta pupilar. Os dados brutos do diâmetro da pupila (Figura 14) mostram que estes valores foram crescentes de acordo com o aumento da demanda cognitiva das condições experimentais, aumentando nas condições NOT e FRE, em relação à condição controle (CAR), e alcançando seus valores máximos na condição FNOT, conforme esperado.

Os resultados mostraram ainda que os métodos de pupilometria foram sensíveis em identificar as demandas de carga de trabalho mental referentes às diferentes condições experimentais. O índice IPA apresentou diferença significativa entre todas as condições experimentais em comparação com a condição controle, sendo mais expressivo em FNOT ($IPA = 0,63 \pm 0,03$) e menos expressivo na condição controle CAR ($IPA = 0,22 \pm 0,1$); conforme este método sugere, quanto maior o valor do índice IPA e mais próximo de 1, maior a carga de trabalho mental refletida pela avaliação na pupila através do índice. O IPA refletiu, crescentemente, em seu índice, a demanda cognitiva da tarefa em cada condição experimental; quanto maior a demanda cognitiva imposta pela tarefa, maior o valor do índice e, conseqüentemente, maior a carga de trabalho mental exigida do motorista, independentemente de grupo. Assim, o IPA mostrou-se um indicador interessante e apropriado para identificar, progressivamente, a carga de trabalho mental durante a condução de um veículo automotor. Este resultado corrobora resultados anteriores nos quais o aumento da dificuldade da tarefa gerou aumento do índice IPA no intervalo de 0 a 1 (DUCHOWSKI et al, 2018).

Os resultados mostraram que o índice LHIPA apresentou diferenças significativas entre as condições experimentais, mas diferentemente de IPA, não houve diferença significativa entre todas as condições de forma crescente em relação à condição controle CAR.

Ao mensurar a variação da pupila a partir de um estímulo, o método TEPR é o mais tradicional em quantificar os dados brutos da reflexão pupilar em uma métrica, não sendo um índice, mas um valor que reflete a variação direta do diâmetro da pupila em relação a um patamar anterior sem o estímulo (chamado de *baseline*). A carga de trabalho mental já foi amplamente associada (BEATTY; LUCERO-WAGONER, 2000) com as variações capturadas a partir dos dados brutos do diâmetro da pupila e, na presente tese, utiliza-se TEPR pela sua tradição de uso na literatura e ser um método primitivo utilizado em pupilometria (JOSHI et al., 2016).

Conforme definido anteriormente, para se comparar indivíduos, ao invés de se utilizar o valor de TEPR, utiliza-se como sua métrica, a porcentagem média de variação do diâmetro da pupila (PMDP). A partir desta técnica, todas as condições experimentais apresentaram diferença significativa, em relação a condição controle. A variação do diâmetro da pupila na condição CAR foi uma constrição, representada pelo valor negativo, na qual a pupila reduziu o seu diâmetro em -7% em relação ao *baseline*. Na condição NOT, o diâmetro da pupila variou positivamente, representando uma dilatação em 2,5% em relação ao *baseline*. Na condição FRE a pupila dilatou 13,3% em relação ao *baseline* e na condição FNOT, a pupila dilatou 6,6% em relação ao *baseline*.

Com base nestes resultados, confirma-se a terceira hipótese; foram criadas condições experimentais que manipularam efetivamente a carga de trabalho mental, o que se refletiu nos resultados dos cálculos dos métodos de pupilometria. Possíveis causas e implicações destes resultados são discutidos a seguir.

Apesar de refletir o diâmetro da pupila na manipulação de condições experimentais, os métodos LHIPA e TEPR não corroboraram completamente resultados anteriores (DUCHOWSKI et al., 2020; HESS; POLT, 1964, KAHNEMAN; BEATTY, 1966; AHERN; BEATTY, 1979). Com base na literatura, havia a expectativa de um aumento gradual de seus valores médios, à medida em que houvesse uma demanda cognitiva aumentada na tarefa; ao aumentar-

se a dificuldade da tarefa, haveria uma diminuição progressiva do índice LHIPA e um aumento de PMDP em TEPR, em relação à condição controle.

O método LHIPA calcula o módulo do sinal do diâmetro da pupila e, a seguir, identifica os máximos locais do módulo. Então, a razão entre os coeficientes de detalhe do sinal do diâmetro da pupila é calculada (*LH:LF*, *low-high frequency ratio*, em inglês), aplicando um limite aos valores resultantes através de um limite universal. O índice LHIPA é então definido pela quantidade de número de coeficientes não nulos, dividindo-os pela duração do sinal. Em NOT e FRE o sinal varia rapidamente a frequências mais altas, em comparação à condição CAR. Assim, a partir desta resposta pupilar, quando se calcula a razão entre os coeficientes de detalhe do diâmetro da pupila em NOT e FRE, em LHIPA, tem-se uma relação baixa entre as frequências, logo, este resultado pode ser associado a ativação simpática do sistema nervoso autônomo (alta-frequência), a qual pode ser interpretado como aumento de foco atencional e esforço cognitivo (DUCHOWSKI et al., 2020), de fato, nestas duas condições experimentais ocorrem, respectivamente, a tarefa de leitura da mensagem de texto no smartwatch e a tarefa de resposta à freada do carro líder, eventos que podem necessitar de maior foco atencional. O efeito, segundo os dados do índice LHIPA, foi menor em FNOT e FRE, em comparação com NOT e CAR, ou seja, a resposta à freada pode ter exigido mais esforço cognitivo e atencional, em comparação a tarefa de leitura da mensagem de texto no smartwatch.

Quando motoristas realizam tarefas concorrentes à direção de automóvel, tem-se um risco aumentado e associado à probabilidade de se envolver em acidentes (STEVENS; MINTON, 2001); segundo a Teoria de Recursos Múltiplos de Wickens (2002), os recursos cognitivos disponíveis são limitados e a tarefa de dirigir é caracterizada como complexa e do tipo visual, espacial e manual (LAND, 2006), assim, o motorista precisa decidir a prioridade de alocação de recursos entre as tarefas. O índice LHIPA parece identificar melhor os esforços cognitivos relativos às condições com situação de freada, em comparação a CAR e NOT. Já em FRE e FNOT, não houve diferença significativa para seus índices LHIPA, atribui-se este resultado ao foco do motorista ser direcionado a evitar a colisão, apensar de se ter a tarefa de leitura da mensagem de texto no smartwatch em FNOT.

Os resultados da presente tese indicaram que a maior taxa de dilatação do diâmetro da pupila (PMDP/TEPR) ocorreu na condição experimental FRE, atribui-se este resultado, primeiramente, devido ao método calcular a taxa de variação da pupila em relação a um parâmetro base que no caso da presente tese, foi utilizado 0,5s antes do início de cada evento de interesse nas condições experimentais CAR, NOT, FRE e FNOT, assim, a partir dos dados brutos do diâmetro da pupila, nota-se que a maior variação em relação ao *baseline* definido ocorreu em FRE (Figura 14). Ao mesmo tempo, devido a tarefa exigir uma resposta a freada, pode ter ocorrido um maior esforço cognitivo na resposta à freada, em comparação com CAR. De acordo com Cherng et al. (2020), o diâmetro da pupila é regulado pela ativação do sistema nervoso autônomo simpático, induzindo dilatação do diâmetro da pupila, e pela inibição do sistema nervoso autônomo parassimpático, reduzindo o diâmetro da pupila. Logo, como a resposta pupilar a partir de uma estimulação pode ser correlacionada a carga de trabalho mental (HESS; POLST, 1964), pode atribuir este resultado a necessidade de recursos para perceber, programar e executar a resposta de freada em relação ao carro líder. Em FNOT, a variação do diâmetro da pupila no *baseline* foi menor, devido ao motorista já estar realizando a tarefa de leitura da mensagem de texto, necessitando de maior foco, assim, ao se calcular PMDP tem-se uma taxa de variação maior, em comparação com a condição CAR, mas menor que FRE ao qual seu *baseline* inicia-se a partir de uma situação de apenas dirigir. Desse modo, PMDP pode ter refletido o limiar da tomada decisão do motorista após uma escolha ser feita (DE GEE; KNAPEN; DONNER, 2014). E, no caso de FRE, a decisão do motorista foi em priorizar a resposta motora de frear o carro para não colidir com o carro líder.

5.3. Diferença entre grupos e métodos de pupilometria

Apesar de ter-se manipulado com sucesso a carga de trabalho mental na presente tese, não foram observadas diferenças significativas para o fator principal ou interação de grupo (experientes e novatos) nos métodos pupilométricos no tipo de tarefa proposta e nas condições experimentais da presente tese. Assim, a segunda hipótese foi refutada.

As tarefas das condições experimentais podem ter sido desafiadoras tanto para motoristas novatos quanto experientes pois nenhum dos participantes já

havia utilizado um smartwatch, especialmente, na tarefa de dirigir. Ao mesmo tempo, devido a habilidades já adquiridas com a prática, os motoristas experientes tiveram um desempenho melhor na realização da tarefa dupla em comparação com novatos, devido as suas estratégias táticas na condução do veículo; eles podem ter compensado a tarefa de ler a mensagem de texto controlando habilidosamente melhor o carro, por exemplo. A partir deste contexto, acredita-se que tanto IPA quanto LHIPA são bons indicadores para resumir a variabilidade do diâmetro da pupila em um período, mas considerando as tarefas da presente tese, não foram sensíveis para diferenciar grupos de experiência distintos na condução de veículo automotor. Estes resultados divergem do estudo de Gunawardena et al. (2019), no qual quatro médicos cirurgiões foram classificados por critérios de habilidades cirúrgicas e experiência nesta tarefa; nesta situação, o cirurgião com menor experiência apresentou menor índice IPA na realização de cirurgia de colecistectomia laparoscópica, em comparação com os outros três médicos mais experientes. Pode-se atribuir este resultado à característica diferente no foco atencional necessário e na distribuição das fixações do olhar na tarefa; a tarefa de dirigir exige uma busca por informação mais ampla no ambiente, enquanto a cirurgia requer um foco atencional mais restrito (GUNAWARDENA et al., 2019).

O mesmo pode ter ocorrido para a PMDP (métrica de TEPR), já que o método conseguiu refletir as variações da pupila à diferentes demandas cognitivas das condições experimentais da presente tese, contudo, não foi sensível para identificar diferença significativa entre os grupo de experiência na tarefa de dirigir com leitura da mensagem de texto e situação de freada; este resultado contraria o estudo de Szulewski, Roth e Howes (2015) no qual médicos novatos apresentaram maiores valores para TEPR enquanto respondiam questões clínicas, em comparação a médicos experientes, necessitando de mais esforço cognitivo para responder as perguntas.

Por fim, pode-se atribuir este resultado em TEPR, a tarefa da presente tese ser complexa tanto para novatos quanto para experientes, especialmente, devido aos participantes não terem experiência prévia com o smartwatch. Paxion, Galy e Berthelon (2014) caracterizam a dificuldade da tarefa a partir da quantidade de elementos diferentes presentes nela; assim, em situações muito complexas, há aumento da carga cognitiva imposta sobre o motorista,

prejudicando seu desempenho da tarefa primária de dirigir; motoristas experientes adotam uma estratégia compensatória nestes casos, reduzindo sua velocidade para corrigir o desempenho na direção de automóvel (PAXION; GALY; BERTHELON, 2014). De fato, os resultados da presente tese mostraram que ao aumentar a demanda cognitiva sobre motoristas, os experientes variaram mais a sua velocidade de forma a reduzi-la nas condições adversas, em comparação aos motoristas novatos.

5.4. Efeito da experiência na tarefa de dirigir

Os resultados da presente tese mostraram que, apesar da similaridade entre os grupos quanto à resposta pupilar, houve diferença significativa entre motoristas experientes e novatos no controle operacional do veículo e na aquisição de informação visual.

De fato, a variável dependente de velocidade média foi maior para os motoristas novatos ($v_m = 90,1 \pm 1,3$ km/h) em comparação com os motoristas experientes ($v_m = 84,9 \pm 1,3$ km/h), independentemente de condição experimental. Este resultado está de acordo com a literatura; motoristas novatos tem deficiência no controle operacional de veículos, que se reflete na dificuldade de manter a velocidade adequadamente (LEE, 2007).

Essa deficiência cria um comportamento de risco aos motoristas novatos, sendo, estes, mais propensos a se envolverem em acidentes (CREASER et al., 2015). De modo similar, os resultados da presente tese mostraram interação significativa entre condição e grupo; na condição FRE, os motoristas novatos apresentaram um valor médio de colisões maior do que os motoristas experientes. Na condição FRE – situação de freada de emergência, o motorista precisava identificar o estímulo visual da luz de freio do carro líder, perceber e preparar a resposta motora adequada para evitar uma colisão. Desse modo, a incapacidade de controlar o veículo pode levar a erros e a menos recursos atencionais disponíveis para responder adequadamente as demandas inesperadas de trânsito (PATTERN et al., 2006), como na condição experimental FRE. Essa pouca capacidade de antecipar e identificar perigos pode levar ao risco de acidentes (FISHER; POLLATSEK; PRADHAN, 2006).

Além disso, a variável dependente de desvio padrão da velocidade média mostrou interação significativa entre condição e grupo; na condição FRE, a

variabilidade da velocidade média de motoristas experientes ($\sigma_{vm} = 12,3 \pm 1,1 \text{ km/h}$) foi maior em comparação com novatos ($\sigma_{vm} = 9,3 \pm 1,1 \text{ km/h}$). Frente à situação de freada de emergência, os motoristas experientes modularam, estrategicamente, a sua velocidade a fim de evitar uma colisão. Este resultado está de acordo com a literatura, já que a maioria das colisões ocorrem devido à falta de atenção, falta de reconhecimento de perigos, erros na busca visual e seleção errada de velocidade apropriada e erros no controle e realização de manobras pelos motoristas novatos durante emergências (FERGUSON; 2003; WILLIAMS; 2003). Assim, a falta de habilidade do motorista novato pode resultar em falhas no controle operacional do veículo e em um julgamento falho de suas habilidades táticas e estratégicas.

Os resultados mostraram ainda interação significativa entre condição e grupo na variável dependente duração total da fixação do olhar em direção a área de interesse de leitura da mensagem de texto no smartwatch. Na condição NOT, os motoristas experientes apresentaram menor duração total da fixação ($DF_m = 0,6 \pm 0,1 \text{ s}$) em comparação com os novatos ($DF_m = 0,9 \pm 0,1 \text{ s}$). Há na literatura indícios de que motoristas novatos precisam de mais tempo de processamento de informação do que motoristas experientes (CRUNDALL; UNDERWOOD, 1998). Logo, o resultado está de acordo com a literatura na qual motoristas experientes tendem a ter duração da fixação do olhar menor em comparação com motoristas novatos durante a apresentação de uma situação de perigo no trânsito (CHAMPAN; UNDERWOOD, 1998). No presente estudo, ao receber a mensagem de texto no smartwatch, cria-se uma situação de atenção visual dividida na qual o motorista precisa deixar de olhar as condições de trânsito, para identificar e fazer a leitura da mensagem de texto. Para Underwood (2007), a eficiência de aquisição de informação através da busca visual é uma habilidade fundamental e que marca a transição entre motoristas novatos a experientes.

5.5. Efeito da tentativa

Os resultados da presente tese mostraram diferença entre tentativas para duas variáveis dependentes: distância relativa ao carro líder e pressão no pedal de freio. Para a variável dependente de distância relativa ao carro líder, os resultados mostraram que houve efeito de interação entre tentativa e grupo, na

qual os motoristas experientes apresentaram uma distância relativa ao carro líder ($d_{exp} = 77,8 \pm 7,3$ m) maior em comparação com os novatos ($d_{nov} = 50,3 \pm 7,3$ m) na tentativa 2, independentemente de condição experimental. Assim, esta diferença de tentativa na variável de distância ao carro líder pode ser interpretada como um ajuste de um comportamento dos motoristas experientes, ao longo das tentativas, reagindo apropriadamente após a sua experimentação a partir do seu repertório de habilidades. Para a variável dependente de pressão no pedal de freio, os resultados mostraram que houve interação significativa entre tentativa e condição experimental; na condição FRE, a tentativa 1 apresentou pressão no pedal de freio (56,9% da frenagem máxima) menor que na tentativa 3 (71,7% da frenagem máxima). Na condição FNOT, a tentativa 1 apresentou pressão no pedal de freio (49,5% da frenagem máxima) menor que na tentativa 2 (68,2% da frenagem máxima), isto é, o participante freou com mais força na tentativa 2 em comparação com a tentativa 1, independente de grupo. Esta diferença observada na variável de pressão sobre o pedal de freio pode ser atribuída a um comportamento tático dos participantes, devido a experimentação e familiarização com as condições experimentais da presente tese.

Os resultados da presente tese mostram que o diâmetro da pupila e a correspondente mensuração da carga de trabalho mental a partir dos métodos pupilométricos não foram afetados significativamente pelo fator tentativa. Isto confirma que, ao longo das tentativas, houve consistência das respostas pupilares, que compõem o foco principal deste estudo. Ainda, vale salientar que as medidas de desempenho da condução do veículo e movimento dos olhos garantiram, na presente tese, a caracterização comportamental das respostas dos motoristas frente às nas condições experimentais desenvolvidas.

6. CONCLUSÃO

A presente tese teve como objetivo investigar os efeitos da experiência do motorista e da demanda cognitiva resultante das tarefas de freada e do uso de smartwatch sobre a carga de trabalho mental durante a condução de automóvel e, neste contexto, avaliar como métodos de pupilometria (IPA, LHIPA e TEPR) são precisos para inferir às variações da carga de trabalho mental, durante a condução de automóvel envolvendo, simultaneamente, as tarefas de freada e uso do smartwatch.

Os resultados confirmaram a hipótese de que a demanda cognitiva resultante de cada condição experimental afetaria a carga de trabalho mental, registrada através da pupilometria. Em comparação à condição controle (somente dirigir o automóvel), houve aumento da carga de trabalho mental na condição de leitura da mensagem de texto no smartwatch e na condição de freada, atingindo seu máximo na condição simultaneamente combinada de leitura e freada. Assim, ficou demonstrado que as condições experimentais afetaram a carga de trabalho mental conforme esperado. Adicionalmente, foi confirmada a hipótese do estudo segundo a qual os valores dos métodos de pupilometria IPA, LHIPA e TEPR refletiriam a referida manipulação de carga de trabalho mental. Os métodos IPA e LHIPA foram precisos em resumir o período de manipulação da carga mental de trabalho, a partir das condições experimentais propostas, em uma métrica.

A segunda hipótese, segundo a qual a maior experiência na condução de automóvel atenuaria a carga de trabalho mental dos motoristas, sendo que o grupo de motoristas experientes apresentaria menores valores em comparação com os motoristas novatos, não foi confirmada. Isto mostra que os métodos de pupilometria IPA, LHIPA e TEPR não conseguiram distinguir a carga de trabalho mental dos grupos de motoristas experientes e novatos para a tarefa e condições experimentais propostas neste estudo, não significando que não há diferença entre grupos de experiência distintas na condução de automóvel, de forma geral.

O presente estudo não objetivou comparar diretamente os diferentes métodos de pupilometria devido às suas diferentes e próprias características, mas buscou-se identificar em cada método pupilométrico sua compatibilidade às crescentes demandas cognitivas impostas pelas condições experimentais. Ao

aumentar-se a demanda cognitiva nas condições experimentais, notou-se uma piora no desempenho de motoristas: diminuição da velocidade média, aumento da variabilidade da velocidade média, aumento da distância ao carro líder e aumento no número de colisões. Experientes apresentaram menor velocidade média e maior variabilidade, devido a sua estratégia de compensar no controle do veículo, a demanda extra da carga de trabalho mental. Os métodos IPA, LHIPA e TEPR foram sensíveis à manipulação da demanda cognitiva nas condições experimentais, entretanto, apesar de o aumento da demanda cognitiva nas condições experimentais terem conseguido manipular com sucesso a carga de trabalho mental, este efeito não parece ser resultante em FNOT, da somatória entre os valores de NOT e FRE para IPA e LHIPA.

Os métodos pupilométricos se mostraram promissores na quantificação dos recursos cognitivos necessários à realização de uma determinada tarefa, especialmente, o método IPA, o qual refletiu quantitativamente o comportamento observado nos dados bruto do sinal da pupila, isto é, este método se mostrou mais preciso em refletir o comportamento da pupila em um índice. Desse modo, a partir destes métodos, pode-se definir um limiar para aumento da carga de trabalho mental em uma determinada tarefa, seguindo princípios ergonômicos de preservar a saúde, eficiência, eficácia e segurança dos operadores, ao identificar a carga de trabalho mental a partir da pupila, tem-se como criar mecanismos inteligentes de avaliação do estado cognitivo do operador, em tempo real, para evitar erros, piora do desempenho e até mesmo fadiga.

Trabalhos futuros poderão investigar outros efeitos na aplicação dos métodos de pupilometria, seja no aprofundamento do uso dos métodos IPA, LHIPA e TEPR, seja no avanço em outros métodos que utilizam informações adicionais como os movimentos dos olhos, as fixações e os movimentos microsacádicos. Ademais, sugere-se ainda, a investigação de um modelo de inteligência artificial que combine e contraste os referidos métodos com outras variáveis de desempenho da tarefa, para que assim, possa-se criar um modelo preditivo da carga de trabalho mental.

7. REFERÊNCIAS

- Abdullah, N. L. et al. Smartwatches para monitoramento de sinais vitais: uma revisão sistemática. *Revista Brasileira de Enfermagem*, v. 73, n. 3, 2020.
- ABERGO. Associação Brasileira de Ergonomia. Norma ERG BR 1002 - Código de Deontologia do Ergonomista Certificado. Disponível em: <http://www.abergo.org.br/arquivos/normas_ergbr/norma_erg_br_1002_deontologia.pdf> [2003]. Acessado em: 08. ago. 2015.
- ADDISON, Paul S.; WALKER, James; GUIDO, Rodrigo C. Time--frequency analysis of biosignals. *IEEE engineering in medicine and biology magazine*, v. 28, n. 5, p. 14-29, 2009.
- AHERN, Sylvia K.; BEATTY, Jackson. Physiological signs of information processing vary with intelligence. *Science*, v. 205, p. 1289-1292, 1979.
- AHERN, Sylvia; BEATTY, Jackson. Pupillary responses during information processing vary with Scholastic Aptitude Test scores. *Science*, v. 205, n. 4412, p. 1289-1292, 1979.
- AHLSTROM, Ulf; FRIEDMAN-BERG, Ferne J. Using eye movement activity as a correlate of cognitive workload. *International journal of industrial ergonomics*, v. 36, n. 7, p. 623-636, 2006.
- ALNÆS, Dag et al. Pupil size signals mental effort deployed during multiple objects tracking and predicts brain activity in the dorsal attention network and the locus coeruleus. *Journal of vision*, v. 14, n. 4, p. 1-1, 2014.
- Al-Qassab, A. M. et al. Smartwatches para avaliação e gestão da saúde: uma revisão. *Revista Brasileira de Tecnologia da Informação e Saúde*, v. 26, n. 3, 2020.
- ANDREASSI, John L. Pupillary response and behavior. In: *Psychophysiology*. Psychology Press, 2013. p. 244-259.
- APPLIED SCIENCE LABORATORIES. *Eye Tracker Systems Manual ASL Eye-Trac 6 D6 Desk Mounted Optics v1*. 03. 2008.
- BAILEY, Brian P.; IQBAL, Shamsi T. Understanding changes in mental workload during execution of goal-directed tasks and its application for interruption management. *ACM Transactions on Computer-Human Interaction (TOCHI)*, v. 14, n. 4, p. 1-28, 2008.
- BALDWIN, Carryl L.; COYNE, Maria T. Mental workload as a function of traffic density: Comparison of physiological, behavioral, and subjective indices. In: *Driving Assesment Conference*. University of Iowa, 2003.
- BARRETO, Ana Margarida. Eye tracking como método de investigação aplicado às ciências da comunicação. *Revista Comunicando*, v. 1, n. 1, p. 168-186, 2012.
- BEATTY, J.; LUCERO-WAGONER, B. (2000). The pupillary system. *Handbook of Psychophysiology*, p. 142-162, 2000.
- BEATTY, Jackson et al. The pupillary system. *Handbook of psychophysiology*, v. 2, n. 142-162, 2000.

BEATTY, Jackson. Task-evoked pupillary responses, processing load, and the structure of processing resources. *Psychological bulletin*, v. 91, n. 2, p. 276, 1982.

BEATTY, Jackson; KAHNEMAN, Daniel. Pupillary changes in two memory tasks. *Psychonomic Science*, v. 5, n. 10, p. 371-372, 1966.

BODALA, Indu P. et al. Cognitive workload estimation due to vague visual stimuli using saccadic eye movements. In: 2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE, 2014. p. 2993-2996.

BOFF, Kenneth R.; LINCOLN, Janet E. *Engineering Data Compendium. Human Perception and Performance, Volume 1*. 1988.

BRADSHAW, John L. Load and pupillary changes in continuous processing tasks. *British Journal of Psychology*, v. 59, n. 3, p. 265-271, 1968.

BROOKHUIS, Karel A.; DE WAARD, Dick. Assessment of drivers' workload: Performance and subjective and physiological indexes. In: *Stress, workload, and fatigue*. CRC press, 2000. p. 321-333.

BROOKHUIS, Karel A.; DE WAARD, Dick. The use of psychophysiology to assess driver status. *Ergonomics*, v. 36, n. 9, p. 1099-1110, 1993.

BROOKHUIS, Karel A.; LOUWERENS, Jan Willem; O'HANLON, J. F. The effect of several antidepressants on EEG and performance in a prolonged car driving task. *Sleep*, v. 84, p. 129-131, 1985.

BUSWELL, Guy Thomas. *How people look at pictures: a study of the psychology and perception in art*. 1935.

CAIN, Brad. *A review of the mental workload literature*. 2007.

CAIRD, Jeff K. et al. A meta-analysis of the effects of cell phones on driver performance. *Accident Analysis & Prevention*, v. 40, n. 4, p. 1282-1293, 2008.

CANTIN, Vincent et al. Mental workload when driving in a simulator: Effects of age and driving complexity. *Accident Analysis & Prevention*, v. 41, n. 4, p. 763-771, 2009.

CARVALHAIS, J. D. *WP2-Pilot Dependent Measures-Internal Deliverable*. 2002.

CHAPMAN, Peter R.; UNDERWOOD, Geoffrey. Visual search of driving situations: Danger and experience. *Perception*, v. 27, n. 8, p. 951-964, 1998.

CHAPMAN, Peter; UNDERWOOD, Geoffrey; ROBERTS, Katharine. Visual search patterns in trained and untrained novice drivers. *Transportation Research Part F: Traffic Psychology and Behaviour*, v. 5, n. 2, p. 157-167, 2002.

CHEN, Fang et al. Eye-based measures. In: *Robust Multimodal Cognitive Load Measurement*. Springer, Cham, 2016. p. 75-85.

CHEN, Siyuan; EPPS, Julien. Using task-induced pupil diameter and blink rate to infer cognitive load. *Human-Computer Interaction*, v. 29, n. 4, p. 390-413, 2014.

CHENG, Adam et al. Resuscitation education science: educational strategies to improve outcomes from cardiac arrest: a scientific statement from the American Heart Association. *Circulation*, v. 138, n. 6, p. e82-e122, 2018.

COOPER, George E.; HARPER, Robert P. The use of pilot rating in the evaluation of aircraft handling qualities. National Aeronautics and Space Administration, 1969.

CREASER, Janet I. et al. Are cellular phone blocking applications effective for novice teen drivers?. *Journal of safety research*, v. 54, p. 75. e29-78, 2015.

CRUNDALL, David E.; UNDERWOOD, Geoffrey. Effects of experience and processing demands on visual information acquisition in drivers. *Ergonomics*, v. 41, n. 4, p. 448-458, 1998.

CRUNDALL, David et al. Some hazards are more attractive than others: Drivers of varying experience respond differently to different types of hazard. *Accident Analysis & Prevention*, v. 45, p. 600-609, 2012.

DA SILVA, Fátima Pereira. Mental workload, task demand and driving performance: what relation? *Procedia-Social and Behavioral Sciences*, v. 162, p. 310-319, 2014.

DE ALWIS EDIRISINGHE, Viveka. Estimating mental workload of university students using eye parameters. 2017.

DE GEE, Jan Willem; KNAPEN, Tomas; DONNER, Tobias H. Decision-related pupil dilation reflects upcoming choice and individual bias. *Proceedings of the National Academy of Sciences*, v. 111, n. 5, p. E618-E625, 2014.

DE WAARD, Dick; STUDIECENTRUM, Verkeerskundig. The measurement of drivers' mental workload. Groningen University. Traffic Research Center Netherlands, p. 125, 1996.

DEERY, Hamish A. Hazard and risk perception among young novice drivers. *Journal of safety research*, v. 30, n. 4, p. 225-236, 1999.

DEMBERG, Vera; SAYEED, Asad. The frequency of rapid pupil dilations as a measure of linguistic processing difficulty. *PloS one*, v. 11, n. 1, p. e0146194, 2016.

DEWING, Wende L.; JOHNSON, Sara M.; STACKHOUSE, Stirling P. Interaction of non-driving tasks with driving. 1995.

DUCHOWSKI, Andrew T. et al. The index of pupillary activity: Measuring cognitive load vis-à-vis task difficulty with pupil oscillation. In: *Proceedings of the 2018 CHI conference on human factors in computing systems*. 2018. p. 1-13.

DUCHOWSKI, Andrew T. et al. The low/high index of pupillary activity. In: *Proceedings of the 2020 CHI Conference on Human Factors in Computing Systems*. 2020. p. 1-12.

ENGSTRÖM, Johan et al. A conceptual framework and taxonomy for understanding and categorizing driver inattention. Brussels, Belgium: European Commission, 2013.

ENGSTRÖME, I. et al. Jeunes Conducteurs novices, Éducation et formation du conducteur. Etude Bibliographique. Rapport VTI A, v. 491, 2003.

EWING, K. C.; GRACE, M. S.; LIAO, C.-C. The relationship between driver distraction and cognitive workload. In: *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, v. 60, n. 1, p. 72-76, 2016.

FERGUSON, Susan A. Other high-risk factors for young drivers—how graduated licensing does, doesn't, or could address them. *Journal of safety research*, v. 34, n. 1, p. 71-77, 2003.

FISHER, Donald L.; POLLATSEK, A. P.; PRADHAN, Abhishek. Can novice drivers be trained to scan for information that will reduce their likelihood of a crash?. *Injury Prevention*, v. 12, n. suppl 1, p. i25-i29, 2006.

FISHER, Donald L.; POLLATSEK, Alexander; HORREY, William J. Eye behaviors: how driving simulators can expand their role in science and engineering. 2011.

FOOTE, Stephen L.; MORRISON, John H. MODULATION OF CORTICAL FUNCTION. 1986.

FULLER, Ray. Towards a general theory of driver behaviour. *Accident analysis & prevention*, v. 37, n. 3, p. 461-472, 2005.

GIANG, Wayne CW; CHEN, Huei-Yen Winnie; DONMEZ, Birsen. Smartwatches vs. Smartphones: Notification Engagement while Driving. *International Journal of Mobile Human Computer Interaction (IJMHCI)*, v. 9, n. 2, p. 39-57, 2017.

GOLDWATER, Bram C. Psychological significance of pupillary movements. *Psychological bulletin*, v. 77, n. 5, p. 340, 1972.

GOPHER, Daniel; DONCHIN, Emanuel. Workload: An examination of the concept. 1986.

GOTARDI, G. C.; SCHOR, P.; NAVARRO, M. ; RODRIGUES, S. T. . Efeitos de ansiedade e reinvestimento sobre o comportamento do olhar de motoristas experientes e novatos. In: VIII Congresso Brasileiro de Comportamento Motor, 2016, João Pessoa, Paraíba, Brasil. VIII Congresso Brasileiro de Comportamento Motor. São Paulo: Brazilian Journal of Motor Behavior, 2016. v. 10. p. 45-45.

GUNAWARDENA, Nishan et al. Assessing surgeons' skill level in laparoscopic cholecystectomy using eye metrics. In: Proceedings of the 11th ACM Symposium on Eye Tracking Research & Applications. 2019. p. 1-8.

HAAPALAINEN, Eija et al. Psycho-physiological measures for assessing cognitive load. In: Proceedings of the 12th ACM international conference on Ubiquitous computing. 2010. p. 301-310.

HAHNEMANN, Daniel; BEATTY, Jackson. Pupillary responses in a pitch-discrimination task. *Perception & Psychophysics*, v. 2, n. 3, p. 101-105, 1967.

HAKEREM, G. Pupillography. A manual of psychophysiological methods, p. 335-349, 1967.

HANCOCK, Peter A.; CHIGNELL, Mark H. Mental workload dynamics in adaptive interface design. *IEEE transactions on Systems, Man, and Cybernetics*, v. 18, n. 4, p. 647-658, 1988.

HANCOCK, Peter A.; VERWEY, Willem B. Fatigue, workload and adaptive driver systems. *Accident analysis & prevention*, v. 29, n. 4, p. 495-506, 1997.

HART, Sandra G.; STAVELAND, Lowell E. Development of NASA-TLX (Task Load Index): Results of empirical and theoretical research. In: *Advances in psychology*. North-Holland, 1988. p. 139-183.

HESS, Eckhard H.; POLT, James M. Pupil size in relation to mental activity during simple problem-solving. *Science*, v. 143, n. 3611, p. 1190-1192, 1964.

HOCKEY, G. M.; GAILLARD, Anthony WK; COLES, Michael (Ed.). *Energetics and human information processing*. Springer Science & Business Media, 1986.

HOCKEY, G. Robert J. Compensatory control in the regulation of human performance under stress and high workload: A cognitive-energetical framework. *Biological psychology*, v. 45, n. 1-3, p. 73-93, 1997.

HOCKEY, G. Robert J. Compensatory control in the regulation of human performance under stress and high workload: A cognitive-energetical framework. *Biological psychology*, v. 45, n. 1-3, p. 73-93, 1997.

HOEDEMAEKER, M. Summary Description of Workload Indicators: WP1 Workload Measures. Human Machine Interface and the Safety of Traffic in Europe Growth Project. GRD1-2000-25361. HASTE. Institute for Transport Studies. Leeds, UK: University of Leeds, 2002.

HOLMQVIST, Kenneth et al. *Eye tracking: A comprehensive guide to methods and measures*. OUP Oxford, 2011.

HORREY, William J.; WICKENS, Christopher D. Examining the impact of cell phone conversations on driving using meta-analytic techniques. *Human factors*, v. 48, n. 1, p. 196-205, 2006.

HURTS, Karel; ANGELL, Linda S.; PEREZ, Miguel A. The distracted driver: Mechanisms, models, and measurement. *Reviews of human factors and ergonomics*, v. 7, n. 1, p. 3-57, 2011.

IMTIAZ, Ahmed S.; MUELLER, Jessica; STANLEY, Laura. Driving Behavior Differences among Early Licensed Teen, Novice Teen, and Experienced Drivers in Simulator and Real World Potential Hazards. In: IIE Annual Conference. Proceedings. Institute of Industrial and Systems Engineers (IISE), 2014. p. 3994.

Instituto de Pesquisa Economica Aplicada, IPEA. Acesso em: 07/08/2022

INTERNATIONAL DATA CORPORATION - IDC. Smartwatch market share by vendor: Q4 2021. Framingham, MA: IDC, 2022. Disponível em: <https://www.idc.com/promo/smartwatch-market-share>. Acesso em: 27 dez. 2022.

IPEA. Instituto de Pesquisa Economia Aplicada. Custos dos acidentes de trânsito no Brasil: estimativa simplificada com base na atualização das pesquisas do IPEA sobre custos de acidentes nos aglomerados urbanos e rodovias. Disponível em: https://www.ipea.gov.br/portal/images/stories/PDFs/TDs/td_2565.pdf. Acesso em: 07. Ago. 2022.

IQBAL, Shamsi T.; ZHENG, Xianjun Sam; BAILEY, Brian P. Task-evoked pupillary response to mental workload in human-computer interaction. In: CHI'04 extended abstracts on Human factors in computing systems. 2004. p. 1477-1480.

JIANG, Xianta et al. Pupil responses during discrete goal-directed movements. In: Proceedings of the SIGCHI Conference on Human Factors in Computing Systems. 2014. p. 2075-2084.

JOHNSON, Addie; PROCTOR, Robert W. *Attention: Theory and practice*. Sage, 2004.

JORNA, Peter GAM. Spectral analysis of heart rate and psychological state: A review of its validity as a workload index. *Biological psychology*, v. 34, n. 2-3, p. 237-257, 1992.

JOSHI, Siddhartha et al. Relationships between pupil diameter and neuronal activity in the locus coeruleus, colliculi, and cingulate cortex. *Neuron*, v. 89, n. 1, p. 221-234, 2016.

JUST, Marcel A.; CARPENTER, Patricia A. The intensity dimension of thought: pupillometric indices of sentence processing. *Canadian Journal of Experimental Psychology/Revue canadienne de psychologie expérimentale*, v. 47, n. 2, p. 310, 1993.

KAHNEMAN, D. Beatty J. Pupil diameter and load on memory. *Science*, v. 154, n. 1583, p. 1885, 1966.

KAHNEMAN, Daniel. *Attention and effort*. Englewood Cliffs, NJ: Prentice-Hall, 1973.

KIRSCHNER, Paul A. Cognitive load theory: Implications of cognitive load theory on the design of learning. *Learning and instruction*, v. 12, n. 1, p. 1-10, 2002.

KIRSCHNER, Paul A.; KIRSCHNER, Femke; PAAS, Fred. *Cognitive load theory*. 2009.

KLINGNER, Jeff. Fixation-aligned pupillary response averaging. In: *Proceedings of the 2010 symposium on eye-tracking research & applications*. 2010. p. 275-282.

KOSS, Michael C. Pupillary dilation as an index of central nervous system α 2-adrenoceptor activation. *Journal of pharmacological methods*, v. 15, n. 1, p. 1-19, 1986.

KRUGER, Jan-Louis; STEYN, Faans. Subtitles and eye tracking: Reading and performance. *Reading Research Quarterly*, v. 49, n. 1, p. 105-120, 2014.

LABERGE, David. *Attentional processing: The brain's art of mindfulness*. Harvard University Press, 1995.

LAENG, Bruno; SIROIS, Sylvain; GREDEBÄCK, Gustaf. Pupillometry: A window to the preconscious?. *Perspectives on psychological science*, v. 7, n. 1, p. 18-27, 2012.

LAND, Michael F. Eye movements and the control of actions in everyday life. *Progress in retinal and eye research*, v. 25, n. 3, p. 296-324, 2006.

LEE, John D. Technology and teen drivers. *Journal of safety research*, v. 38, n. 2, p. 203-213, 2007.

LEHTONEN, Esko et al. Effect of driving experience on anticipatory look-ahead fixations in real curve driving. *Accident Analysis & Prevention*, v. 70, p. 195-208, 2014.

LI, Fan; XU, Gangyan; FENG, Shanshan. Eye Tracking Analytics for Mental States Assessment—A Review. In: *2021 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*. IEEE, 2021. p. 2266-2271.

LIU, YILI. Quantitative assessment of effects of visual scanning on concurrent task performance. *Ergonomics*, v. 39, n. 3, p. 382-399, 1996.

LOEWENFELD, Irene E.; LOWENSTEIN, Otto. *The pupil: Anatomy, physiology, and clinical applications*. Butterworth-Heinemann, 1993.

LOWENSTEIN, Otto. *The pupil*. The eye, 1962.

LOWENSTEIN, Otto; FEINBERG, Richard; LOEWENFELD, Irene E. Pupillary movements during acute and chronic fatigue: A new test for the objective evaluation of tiredness. Federal Aviation Agency, Office of Aviation Medicine, 1963.

MAHANAMA, Bhanuka et al. Eye Movement and Pupil Measures: A Review. *Frontiers in Computer Science*, v. 3, p. 733531, 2022.

MALATERRE, GILLES. Error analysis and in-depth accident studies. *Ergonomics*, v. 33, n. 10-11, p. 1403-1421, 1990.

Marques, M. P. et al. Intervenções baseadas em smartwatch para atividade física: uma revisão sistemática e metanálise. *Revista Brasileira de Atividade Física e Saúde*, v. 26, 2021. Disponível em: <https://rbafs.org.br/RBAFS/article/view/15559>. Acesso em: 27 dez. 2022.

MARSHALL, S. P.; DAVIS, C. L.; KNUST, S. R. The index of cognitive activity: estimating cognitive effort from pupil dilation. San Diego, CA: EyeTracking Inc, 2004.

MARSHALL, Sandra P. Identifying cognitive state from eye metrics. *Aviation, space, and environmental medicine*, v. 78, n. 5, p. B165-B175, 2007.

MARSHALL, Sandra P. The index of cognitive activity: Measuring cognitive workload. In: *Proceedings of the IEEE 7th conference on Human Factors and Power Plants*. IEEE, 2002. p. 7-7.

MARSHALL, Sandra P.; PLEYDELL-PEARCE, Christopher W.; DICKSON, Blair T. Integrating psychophysiological measures of cognitive workload and eye movements to detect strategy shifts. In: *36th Annual Hawaii International Conference on System Sciences*, 2003. *Proceedings of the. IEEE*, 2003. p. 6 pp.

MATTHEWS, Gerald et al. The psychometrics of mental workload: Multiple measures are sensitive but divergent. *Human factors*, v. 57, n. 1, p. 125-143, 2015.

MAXWELL, S. E.; DELANEY, H. D. Designing experiments and analyzing data: a model comparison approach. Belmont, CA: Wadsworth, 1990.

MAY, James G. et al. Eye movement indices of mental workload. *Acta psychologica*, v. 75, n. 1, p. 75-89, 1990.

MICHON, John A. A critical view of driver behavior models: what do we know, what should we do?. In: *Human behavior and traffic safety*. Springer, Boston, MA, 1985. p. 485-524.

MITCHELL, Diane K. Mental workload and ARL workload modeling tools. Army Research Lab Aberdeen Proving Ground MD, 2000.

MORAY, Neville. Where is capacity limited? A survey and a model. *Acta psychologica*, v. 27, p. 84-92, 1967.

MORENO, Roxana Ed; PARK, Babette. Cognitive load theory: Historical development and relation to other theories. 2010.

MOURANT, Ronald R.; ROCKWELL, Thomas H. Strategies of visual search by novice and experienced drivers. *Human factors*, v. 14, n. 4, p. 325-335, 1972.

MULDER, G. The concept and measurement of mental effort. In: *Energetics and human information processing*. Springer, Dordrecht, 1986. p. 175-198.

MULDER, Gijsbertus et al. A psychophysiological approach to working conditions. *Engineering psychophysiology: Issues and applications*, p. 139-159, 2000.

NAVON, David; GOPHER, Daniel. On the economy of the human-processing system. *Psychological review*, v. 86, n. 3, p. 214, 1979.

NEUMANN, David L. Effect of varying levels of mental workload on startle eyeblink modulation. *Ergonomics*, v. 45, n. 8, p. 583-602, 2002.

O'DONNELL, R.; EGGEMEIER, F. Workload assessment methodology. *Handbook of Perception and Human Performance*. Volume 2. Cognitive Processes and Performance. KR Boff, L. Kaufman and JP Thomas. ed: John Wiley and Sons, Inc, 1986.

ÖSTLUND, J.; TORNROS, J. WP1-Driving Performance Measures. 2002.

PAAS, Fred et al. Cognitive load measurement as a means to advance cognitive load theory. In: *Educational psychologist*. Routledge, 2016. p. 63-71.

PAAS, Fred GWC; VAN MERRIËNBOER, Jeroen JG. Instructional control of cognitive load in the training of complex cognitive tasks. *Educational psychology review*, v. 6, n. 4, p. 351-371, 1994.

PALINKO, Oskar et al. Estimating cognitive load using remote eye tracking in a driving simulator. In: *Proceedings of the 2010 symposium on eye-tracking research & applications*. 2010. p. 141-144.

PAMMER, Kristen et al. Expert drivers are better than non-expert drivers at rejecting unimportant information in static driving scenes. *Transportation research part F: traffic psychology and behaviour*, v. 59, p. 389-400, 2018.

PATTEN, Christopher JD et al. Driver experience and cognitive workload in different traffic environments. *Accident Analysis & Prevention*, v. 38, n. 5, p. 887-894, 2006.

PAXION, Julie; GALY, Edith; BERTHELON, Catherine. Mental workload and driving. *Frontiers in psychology*, v. 5, p. 1344, 2014.

PEREIRA DA SILVA, M. F. *Aprendizagem e Comportamentos na Condução Automóvel. Learning and Behaviours in Automobile Driving*. Faculty of Psychology and Sciences of Education. University of Coimbra. Coimbra. 2003.

PEYSAKHOVICH, Vsevolod; VACHON, François; DEHAIS, Frédéric. The impact of luminance on tonic and phasic pupillary responses to sustained cognitive load. *International Journal of Psychophysiology*, v. 112, p. 40-45, 2017.

PHILLIPS, Matthew H.; EDELMAN, Jay A. The dependence of visual scanning performance on search direction and difficulty. *Vision research*, v. 48, n. 21, p. 2184-2192, 2008.

PIGNONI, Giovanni; KOMANDUR, Sashidharan. Development of a quantitative evaluation tool of cognitive workload in field studies through eye tracking. In: *International Conference on Human-Computer Interaction*. Springer, Cham, 2019. p. 106-122.

POLIKAR, Robi et al. The wavelet tutorial. 1996.

POMPLUN, Marc; SUNKARA, Sindhura. Pupil dilation as an indicator of cognitive workload in human-computer interaction. In: Human-Centered Computing. CRC Press, 2019. p. 542-546.

PRADHAN, Anuj Kumar et al. Using eye movements to evaluate effects of driver age on risk perception in a driving simulator. *Human factors*, v. 47, n. 4, p. 840-852, 2005.

PRADHAN, Ashoke Kumar et al. Can younger drivers be trained to scan for information that will reduce their risk in roadway traffic scenarios that are hard to identify as hazardous?. *Ergonomics*, v. 52, n. 6, p. 657-673, 2009.

PRIBRAM, Karl H.; MCGUINNESS, Diane. Arousal, activation, and effort in the control of attention. *Psychological review*, v. 82, n. 2, p. 116, 1975.

PROCTOR, Robert W. et al. Stimulus-response compatibility for moving stimuli: Perception of affordances or directional coding?. *Journal of Experimental Psychology: Human Perception and Performance*, v. 19, n. 1, p. 81, 1993.

RAJKOWSKI, J. Correlations between locus coeruleus (LC) neural activity, pupil diameter and behavior in monkey support a role of LC in attention. *Soc. Neurosc., Abstract*, Washington, DC, 1993, 1993.

RAJKOWSKI, Janusz et al. Activation of monkey locus coeruleus neurons varies with difficulty and performance in a target detection task. *Journal of neurophysiology*, v. 92, n. 1, p. 361-371, 2004.

RAYNER, Keith. Eye movements in reading and information processing. *Psychological bulletin*, v. 85, n. 3, p. 618, 1978.

RECARTE, Miguel A.; NUNES, Luis M. Effects of verbal and spatial-imagery tasks on eye fixations while driving. *Journal of experimental psychology: Applied*, v. 6, n. 1, p. 31, 2000.

RECARTE, Miguel A.; NUNES, Luis M. Mental workload while driving: effects on visual search, discrimination, and decision making. *Journal of experimental psychology: Applied*, v. 9, n. 2, p. 119, 2003.

REGAN, Michael A.; LEE, John D.; YOUNG, Kristie. *Driver distraction: Theory, effects, and mitigation*. CRC press, 2008.

REID, Gary B.; NYGREN, Thomas E. The subjective workload assessment technique: A scaling procedure for measuring mental workload. In: *Advances in psychology*. North-Holland, 1988. p. 185-218.

REIMER, Bryan et al. An on-road assessment of the impact of cognitive workload on physiological arousal in young adult drivers. In: *Proceedings of the 1st international conference on automotive user interfaces and interactive vehicular applications*. 2009. p. 115-118.

RODRIGUES, S. T. O movimento dos olhos e a relação percepção-ação. In: TEIXEIRA, L. A. (Org.). *Avanços em comportamento motor*. Rio Claro, SP: Movimento, 2001. p. 122-146.

RUFF, Stefan. Driver Cognitive Workload: A Comprehensive Multi-measure Approach. Technische Universitaet Berlin (Germany), 2017.

SALTHOUSE, Timothy A.; ELLIS, Cecil L. Determinants of eye-fixation duration. The American journal of psychology, p. 207-234, 1980.

SALVUCCI, Dario D.; GOLDBERG, Joseph H. Identifying fixations and saccades in eye-tracking protocols. In: Proceedings of the 2000 symposium on Eye tracking research & applications. 2000. p. 71-78.

SANDERS, A. F. Towards a model of stress and human performance. Acta psychologica, v. 53, n. 1, p. 61-97, 1983.

SCHWALM, Maximilian; KEINATH, Andreas; ZIMMER, Hubert D. Pupillometry as a method for measuring mental workload within a simulated driving task. Human Factors for assistance and automation, v. 1986, p. 1-13, 2008.

SHI, Q.; LU, C.; LIU, W. Mental workload measurement for vigilance task using physiological indices. In: INTERNATIONAL CONFERENCE ON COMPUTATIONAL INTELLIGENCE AND SECURITY, 3., 2009, Beijing. Proceedings... Beijing: IEEE, 2009.

SIEGENTHALER, Eva et al. Task difficulty in mental arithmetic affects microsaccadic rates and magnitudes. European Journal of Neuroscience, v. 39, n. 2, p. 287-294, 2014.

SILVA, G. A., Ergonomia cognitiva do uso de relógio inteligente durante condução simulada de automóvel: movimento dos olhos e desempenho de motoristas experientes e novatos. Dissertação (Mestrado) – Universidade Estadual Paulista. Faculdade de Arquitetura, Artes e Comunicação, Bauru, 2018

SILVA, G. A., PASCHOARELLI, L. C., MEDOLA, F. O., RODRIGUES, S. T. Avaliação qualitativa da usabilidade e motivações de usuários de relógios inteligentes. Blucher Engineering Proceedings, v. 3, n. 3, p. 1104-1113, 2016.

SINGH, Mahipal; SINGH, L. P.; BAJWA, Manjinder. A COMPREHENSIVE SURVEY ON LATEST RESEARCH TRENDS IN COGNITIVE ERGONOMICS. SCHNEIDER, Walter; SHIFFRIN, Richard M. Controlled and automatic human information processing: I. Detection, search, and attention. Psychological review, v. 84, n. 1, p. 1, 1977.

SODHI, Manbir; REIMER, Bryan; LLAMAZARES, Ignacio. Glance analysis of driver eye movements to evaluate distraction. Behavior Research Methods, Instruments, & Computers, v. 34, p. 529-538, 2002.

STANTON, Neville Anthony et al. (Ed.). Handbook of human factors and ergonomics methods. CRC press, 2004.

STRAYER, David L.; DREWS, Frank A.; JOHNSTON, William A. Cell phone-induced failures of visual attention during simulated driving. Journal of experimental psychology: Applied, v. 9, n. 1, p. 23, 2003.

SUMMALA, Heikki; LAMBLE, Dave; LAAKSO, Matti. Driving experience and perception of the lead car's braking when looking at in-car targets. Accident Analysis & Prevention, v. 30, n. 4, p. 401-407, 1998.

SWELLER, John. Cognitive load theory. In: Psychology of learning and motivation. Academic Press, 2011. p. 37-76.

SWELLER, John. Some cognitive processes and their consequences for the organisation and presentation of information. *Australian Journal of psychology*, v. 45, n. 1, p. 1-8, 1993.

SWELLER, John; VAN MERRIENBOER, Jeroen JG; PAAS, Fred GWC. Cognitive architecture and instructional design. *Educational psychology review*, v. 10, n. 3, p. 251-296, 1998.

SZULEWSKI, Adam; ROTH, Nathan; HOWES, Daniel. The use of task-evoked pupillary response as an objective measure of cognitive load in novices and trained physicians: a new tool for the assessment of expertise. *Academic Medicine*, v. 90, n. 7, p. 981-987, 2015.

TOKUDA, Satoru et al. Using saccadic intrusions to quantify mental workload. In: *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*. Sage CA: Los Angeles, CA: SAGE Publications, 2009. p. 809-813.

TOKUDA, Satoru. An investigation into the relationship between saccadic intrusion and mental workload. 2009. Tese de Doutorado. Wichita State University.

TREAT, John R. et al. Tri-level study of the causes of traffic accidents. Volume 1, Causal factor tabulations and assessments. United States. National Highway Traffic Safety Administration, 1977.

TSANG, Pamela S.; VIDULICH, Michael A. Mental workload and situation awareness. 2006.

UNDERWOOD, Geoffrey. Visual attention and the transition from novice to advanced driver. *Ergonomics*, v. 50, n. 8, p. 1235-1249, 2007.

UNDERWOOD, Geoffrey; NGAI, Athy; UNDERWOOD, Jean. Driving experience and situation awareness in hazard detection. *Safety science*, v. 56, p. 29-35, 2013.

VICTOR, Trent. Keeping eye and mind on the road. 2005. Tese de Doutorado. Acta Universitatis Upsaliensis.

VIDULICH, M. A.; TSANG, P. S. Mental workload and situation awareness.(chap. 8), and Salvendy, G.(Ed.). *Handbook of Human Factors and Ergonomics*. 2012.

VOGELS, Jorrig; DEMBERG, Vera; KRAY, Jutta. The index of cognitive activity as a measure of cognitive processing load in dual task settings. *Frontiers in Psychology*, v. 9, p. 2276, 2018.

WEBER, Pavel et al. Assessing Cognitive Load via Pupillometry. In: *Advances in Artificial Intelligence and Applied Cognitive Computing*. Springer, Cham, 2021. p. 1087-1096.

WHIPPLE, Beverly; OGDEN, Gina; KOMISARUK, Barry R. Physiological correlates of imagery-induced orgasm in women. *Archives of sexual behavior*, v. 21, n. 2, p. 121-133, 1992.

WICKENS, Christopher D. Attention to attention and its applications: A concluding view. *Attention: From theory to practice*, p. 239-249, 2007.

WICKENS, Christopher D. et al. *Engineering psychology and human performance*. Routledge, 2021.

WICKENS, Christopher D. Multiple resources and mental workload. *Human factors*, v. 50, n. 3, p. 449-455, 2008.

WICKENS, Christopher D. Multiple resources and performance prediction. *Theoretical issues in ergonomics science*, v. 3, n. 2, p. 159-177, 2002.

WICKENS, Christopher D. The structure of attentional resources. *Attention and performance VIII*, v. 8, p. 239-257, 1980.

WIERWILLE, Walter W. Demands on driver resources associated with introducing advanced technology into the vehicle. *Transportation Research Part C: Emerging Technologies*, v. 1, n. 2, p. 133-142, 1993.

WILLIAMS, Allan F. Teenage drivers: patterns of risk. *Journal of safety research*, v. 34, n. 1, p. 5-15, 2003.

Wu, X. et al. Programas de intervenção baseados em smartwatch para melhoria da saúde: uma revisão sistemática e metanálise. *Revista Brasileira de Promoção da Saúde*, v. 34, n. 3, 2021.

WYATT, Harry J. The form of the human pupil. *Vision research*, v. 35, n. 14, p. 2021-2036, 1995.

Xia, J. et al. Soluções baseadas em smartwatch para aplicações em saúde: uma revisão. *Revista Brasileira de Informática em Saúde*, v. 4, n. 1, 2021.

YARBUS, Alfred L.; YARBUS, Alfred L. Eye movements during perception of complex objects. *Eye movements and vision*, p. 171-211, 1967.

YERKES, Robert Mearns et al. The relation of strength of stimulus to rapidity of habit-formation. 1908.

YOUNG, Mark S. et al. State of science: mental workload in ergonomics. *Ergonomics*, v. 58, n. 1, p. 1-17, 2015.

YOUNG, Mark S.; STANTON, Neville A. Mental workload. In: *Handbook of human factors and ergonomics methods*. CRC Press, 2004. p. 416-426.

ZHANG, Harry; SMITH, Matthew RH; WITT, Gerald J. Identification of real-time diagnostic measures of visual distraction with an automatic eye-tracking system. *Human factors*, v. 48, n. 4, p. 805-821, 2006.

ZIJLSTRA, F. R. H.; VAN DOORN, L. The construction of a scale to measure perceived effort. *University of Technology*, 1985.

APÊNDICES

APÊNDICE I – Configuração de hardware e software

Para fazer a coleta de dados durante o procedimento experimental, foi utilizada uma arquitetura de configuração e integração entre os hardwares de forma customizada, conectando os seguintes computadores utilizados nesta tese: o Dell Precision Tower 5811 (PC1), o notebook Macbook Pro 13" 9,2 (MAC1) e o Computador Asus (PC2). Desse modo, permitindo que eles trabalhassem em conjunto para atender os requisitos do procedimento experimental deste trabalho.

O objetivo desta configuração foi exibir o painel de controle do Simulador STISIM Drive, a ser utilizado pelo pesquisador no monitor Dell de 19", exibir na televisão Samsung de 46" o ambiente simulado para o participante conduzir o veículo virtual, replicar a mesma imagem do ambiente simulado e, em tempo real, no monitor Samsung de 15", para o pesquisador acompanhar a simulação e replicar a mesma imagem do ambiente simulado e, também em tempo real, no canal de vídeo de estímulo do software do equipamento ASL Eye Tracker 6000.

Foi configurada uma rede de computadores privada, através do roteador D-Link 524G, com acesso à internet, para garantir a comunicação sem fio entre o computador MAC1 e o smartphone iPhone 5, permitindo, assim, que não houvesse nenhuma interferência com outros equipamentos eletrônicos e fosse minimizado quaisquer possibilidades de latência na troca de mensagens entre esses dois equipamentos.

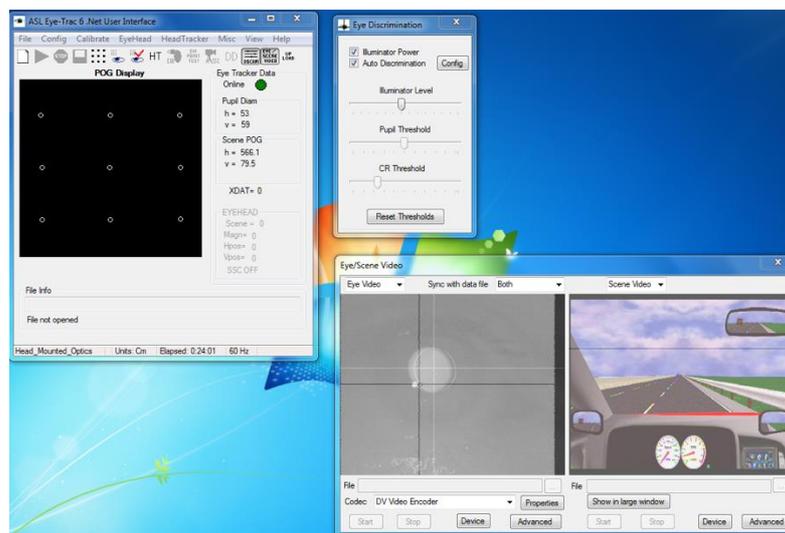
O PC2 ficou responsável pela captura de medida do movimento dos olhos de cada participante através de um Eye Tracker. O Eye Tracker ASL H6 possui, é construído sob o fator forma de capacete, contém uma câmera que filma o ambiente e está posicionada na parte frontal do capacete acima da região da testa. Uma segunda câmera fica perpendicular ao eixo de rotação vertical da cabeça. Ela é responsável pela detecção da posição da pupila e da reflexão da córnea numa imagem de vídeo do olho, na qual uma pequena fonte de luz infravermelho é refletida na superfície da córnea através de uma lente, que fica acoplado ao suporte fixo da cabeça de quem utiliza o Eye Tracker.

Assim, há uma câmera que filma o olho do sujeito e uma segunda câmera que filma a cena que o sujeito está vendo; no caso do presente estudo, esta segunda entrada de vídeo foi substituída pelo vídeo da cena gerada pelo simulador de automóvel.

Na imagem da câmera do olho, as posições relativas da pupila e da reflexão na córnea foram identificadas em tempo real pelo software ASL Eye Tracker 6000 (Figura 15), com base nos seus distintos níveis de contraste. A seguir, os centroides da pupila e da reflexão na córnea foram calculados e suas coordenadas horizontais e verticais (em unidades de vídeo) foram utilizadas para determinar a linha do olhar em relação ao sistema óptico do aparato.

Com base na posição da linha do olhar e em informações oriundas do procedimento de calibração, o sistema gera um cursor que é adicionado a cada quadro de imagem da câmera da cena, para indicar onde o sujeito está olhando naquele instante (Rodrigues, 2001). Este sistema possui ainda um aparato magnético que mede o movimento da cabeça (posição e orientação tridimensionais) e, com calibração adicional, possibilita a integração entre os dados dos olhos e cabeça e esses dados são adquiridos a uma frequência 60 Hz.

Figura 26 - Imagem do software ASL Eye Tracker 6000 mostrando o painel de controle (superior esquerdo), o painel de ajustes de brilho e contraste da câmera responsável pela captura do movimento dos olhos (centro acima) o painel (inferior direito) que mostra em tempo real o olho do participante com as marcações das linhas de detecção da pupila e da córnea do olho (esquerda) e a cena que ele está observando na televisão Samsung 46" (direita).



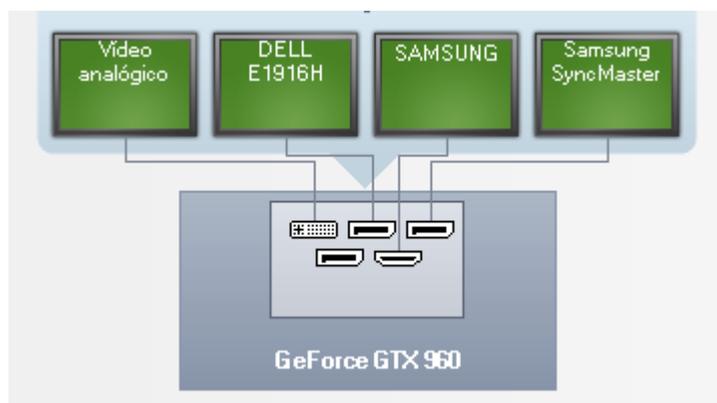
Foi instalada uma placa Nvidia GTX 960 no PC1. Esta placa de vídeo possui 5 conexões de saídas de vídeo independentes, permitindo que cada uma delas seja configurada para clonar a exibição de outra saída de vídeo ou

estender a área de trabalho do computador, de forma que esta seja uma tela de exibição adicional.

Em uma das saídas de vídeo, do tipo Display Port, foi conectado um adaptador de Display Port para VGA e na conexão VGA foi instalado o monitor Samsung de 15". Na saída de vídeo HDMI foi conectada a televisão Samsung de 46"; na saída de vídeo DVI foi conectado um adaptador de DVI para VGA e, nesta conexão ainda, foi conectada a "entrada" do Splitter através do cabo VGA de 10 metros e em outra saída de vídeo Display Port foi conectado um monitor Dell de 19". A Figura 16 mostra um esquema das saídas de vídeo e suas respectivas conexões.

A "saída 1" do Splitter foi conectada ao hardware de gerenciamento do Eye Tracker que, por conseguinte, foi conectado ao computador Asus, garantindo assim a conexão de vídeo entre o PC1 e o PC2.

Figura 27 - Esquema mostrado pelo software de Painel de Controle da placa de vídeo Nvidia, mostrando as 5 conexões de saída (3 Display Port, 1 HDM e 1 DVI) e o nome do monitor que está conectado aquela conexão. Observa-se na imagem o Monitor Dell de 19", a televisão Samsung de 46", o monitor Samsung de 15" e o cabo de 10 metros que se conecta no Splitter de vídeo.



O monitor Dell de 19" do PC1 foi configurado como principal e a área de trabalho na TV Samsung de 46" estendida. Através do software de gerenciamento da placa de vídeo Nvidia, configuraram-se as saídas de vídeo do monitor Samsung e do cabo de 10 metros para clonar a imagem exibida na TV. Deste modo, o pesquisador consegue acompanhar a tentativa do participante ao mesmo tempo em que se verifica as informações no painel de gerenciamento do

software simulador sobre cada tentativa de direção no simulador em tempo real, antecipando e verificando se o participante está realmente realizando corretamente a tarefa que a ele foi dada. A Figura 17 mostra os quatro canais de vídeo em funcionamento e nota-se a mesma imagem sendo exibida em tempo real em 17A, 17B e 17C.

Figura 28 - A: Imagem da televisão Samsung de 46" exibindo a imagem do simulador. B: Tela de controle do pesquisador mais a tela de replicação da imagem que o participante vê na televisão. C: Imagem do olho do participante mais a replicação da tela que o participante está observando.



No PC1 também foi conectado, instalado e configurado, através de uma porta USB, o acessório Gamer da Logitech (modelo G27) – no qual seu volante, câmbio e pedais foram previamente acoplados ao Cockit e, neste computador, foi instalado o software simulador de direção de automóvel STISIM DRIVE versão 3.14.01.

O roteador com rede sem fio D-Link 524G foi instalado e configurado para ser acessado exclusivamente pelos equipamentos: PC1, MAC1, iPhone 5 e relógio inteligente Apple Watch Series 1. Este equipamento de rede estava habilitado para acessar a internet da universidade para que também fosse possível ter à rede mundial de computadores, para a simulação de troca de mensagens entre os eletrônicos conectados nesta rede. Desta forma, houve a comunicação sem fio entre esses equipamentos, garantindo a troca de dados, e, portanto, minimizando efeitos de latência.

No computador MAC1 foi instalado o aplicativo “Notas” - um editor de texto – e o aplicativo de mensagens instantâneas “Mensagens” ambos da fabricante Apple. O aplicativo “Mensagens” permite a comunicação entre pessoas que utilizam qualquer produto da fabricante Apple de forma gratuita e através da internet; este aplicativo é fornecido gratuitamente mediante a compra de um dos

equipamentos desta fabricante de eletrônicos. Assim, para haver uma comunicação fluida entre MAC1 e o celular smartphone, 2 contas de acesso (chamada de Apple Id) a este mensageiro de mensagens instantâneas da Apple foram disponibilizadas: uma para o pesquisador e a outra para o participante voluntário da pesquisa. A mesma conta de participante foi utilizada para todos os voluntários da pesquisa.

O celular smartphone iPhone 5 foi configurado para trabalhar em conjunto com o relógio inteligente Apple Watch através de sua conexão sem fio via Bluetooth. O relógio Apple Watch Series 1 é necessariamente dependente de um telefone celular do tipo smartphone do mesmo fabricante para realizar algumas tarefas, processar um volume maior de dados e acessar a internet, por exemplo.

A câmera Nikon D5100, com a lente Nikkor DX FX 18-55mm e o microfone Rode VideoMic Go conectado em sua entrada auxiliar de áudio para microfones, foi utilizada. O microfone é do tipo direcional com uma maior sensibilidade de captação de áudio do que o microfone já existente na câmera.

Este microfone permitiu que fossem gravados áudios a uma certa distância, de forma nítida e com uma boa clareza e volume de captura de áudio. A câmera possui três níveis (baixo, médio e alto) de sensibilidade de volume de captura de áudio para microfones externos; neste experimento foi utilizado o nível médio.

A câmera foi acoplada a um tripé e posicionada perpendicularmente e, aproximadamente, a 1 metro de distância do banco do Cockpit em uma angulação de 120 graus. A lente e microfone foram direcionados ao rosto do participante e a abertura da lente foi configurada para exibir, em sua imagem, o participante sentado realizando a movimentação dos pedais, volante e câmbio. A câmera foi configurada para funcionar no modo filmadora.

APÊNDICE II – Método de randomização

Para contrabalançar os possíveis efeitos de ordem, as tentativas foram completamente randomizadas. Nesta operação, atribuiu-se a cada uma das tentativas um código de 1 até 12 (Tabela 5).

Através de um algoritmo (ANEXO I) feito na linguagem de programação PHP, fez-se uma lista com conjuntos de tentativas para cada um dos 40 participantes de cada experimento; assim, a ordem das tentativas foi estabelecida para cada participante (Tabela 6).

Tabela 7 - Nomeação exemplo das condições de direção para cada grupo para gerar conjuntos de sequência de condição de forma aleatória pelo algoritmo.

Condição	Cenário	Tentativa por Cenário	Código do Cenário
<i>CON1</i>	1	1	1
		2	2
		3	3
<i>CON2</i>	2	1	4
		2	5
		3	6
<i>CON3</i>	3	1	7
		2	8
		3	9
<i>CON4</i>	4	1	10
		2	11
		3	12

Tabela 8 - Exemplo da composição das tentativas após o procedimento de randomização. Na tabela, tem-se tentativas (T) para cada um dos participantes (P) da pesquisa. Os números de 1 a 12 representam os códigos para as possíveis condições e suas repetições.

	T1	T2	T3	T4	T5	T6	T7	T8	T9	T10	T11	T12
P1	6	12	8	11	5	10	9	1	7	4	3	2
P2	12	6	5	7	3	1	2	10	9	8	4	11
P3	9	5	10	8	2	4	1	12	7	6	11	3
P4	10	12	7	9	2	3	4	1	8	6	5	11
P5	8	4	10	1	6	2	7	11	12	5	3	9
P6	4	5	1	8	11	2	10	12	7	6	3	9

APÊNDICE III – Tratamento de dados

1. Tratamento de dados: simulador

A partir da seleção de dados descrita acima, serão extraídas as seguintes variáveis dependentes de cada experimento. Será criada, assim, uma planilha de dados no Microsoft Excel contendo essas variáveis para cada participante e suas tentativas.

2. Tratamento de dados: filmagem

Cada tentativa de cada participante, será filmado com a câmera Nikon D5100 e utilizado o microfone direcional Rode VideoMic Go para capturar a voz do participante quando este falar em voz alta (GIANG; CHEN; DONMEZ, 2017) o endereço recebido no relógio inteligente. Através do software para computadores Macintosh Final Cut Pro X e a partir dos arquivos de vídeo das condições que possuem a tarefa de leitura de mensagem de cada participante, será feita análise das ondas de áudio do vídeo para os instantes nos quais o participante receberá a mensagem de texto no relógio inteligente, o instante no qual o participante iniciará a leitura desta mensagem e o instante no qual o participante terminará de fazer a leitura da mensagem de texto enviada pelo pesquisador.

Depois, no mesmo software de edição de vídeo, serão feitos dois cortes no vídeo da filmagem da tentativa do participante: o primeiro corte será do início da filmagem até o primeiro frame no qual a imagem do painel do carro para o participante estiver nitidamente visível na televisão Samsung 46"; o segundo corte será feito a partir do último frame no qual a imagem do painel do carro do participante estiver nitidamente visível na TV até o final do vídeo. Estes dois cortes permitirão que o vídeo da filmagem da tentativa fique sincronizado com os dados obtidos através do simulador STISIM Drive. Após a preparação do vídeo, será utilizado o equalizador gráfico de áudio para modificar as características das ondas do áudio gravado (Figura 19), para separar e visualizar o instante no qual ocorrerá o som da chegada da mensagem para o participante (Figura 18.B).

Figura 29 - Apêndice: Comparativo entre os canais de áudio. A: Canal de áudio de uma tentativa sem filtro. B: Canal de áudio de uma tentativa com o filtro para realçar o instante da chegada da mensagem ao relógio inteligente. C: Canal de áudio de uma tentativa com o filtro para realçar o período em que o participante leu a mensagem de texto.

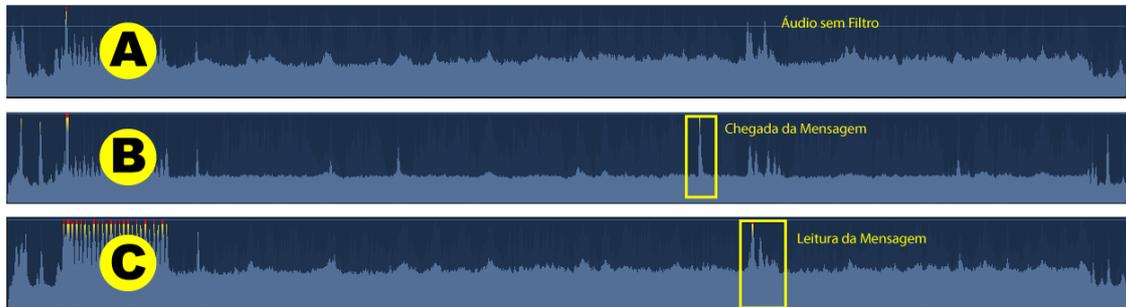


Figura 30 - Apêndice: A: Características do filtro de áudio aplicado ao vídeo da filmagem da tentativa para visualizar o instante auditivo em que chegou à mensagem de texto no relógio do participante. B: Características do filtro de áudio aplicado ao vídeo da filmagem da tentativa para visualizar o instante auditivo em que o participante iniciou e finalizou a leitura mensagem de texto no relógio do participante.



Um segundo filtro será criado no equalizador gráfico de áudio do software Final Cut Pro X para destacar as bandas de áudio nas quais forem nitidamente visíveis os instantes nos quais o participante iniciará e finalizará a leitura da mensagem de texto (Figura 18.C).

Estes dados serão utilizados para calcular a diferença do início da leitura da mensagem de texto e o momento no qual a mensagem de texto será recebida pelo participante, caracterizando a variável de latência. De mesmo modo, a diferença entre os instantes de final e início da leitura da mensagem de texto no eletrônico de pulso caracterizarão a variável de duração da leitura. Estes valores serão incluídos na tabela de resultados do participante em sua respectiva planilha no software Microsoft Excel.

3. Tratamento de dados: movimento dos olhos

O Eye Tracker ASL H6 exportará os seguintes arquivos para análise: um vídeo do olho em movimento durante a gravação dos dados, um vídeo da cena que o olho está observando e um cursor da respectiva localização do olhar na cena e um arquivo de dados numéricos brutos contendo diversas variáveis referentes à movimentação do olho e da cabeça.

Através do software de análise ASL Results Plus, serão importados os arquivos do movimento do olho e da cabeça para todas as tentativas de cada participante. Para cada tentativa serão feitos, primeiramente, dois cortes no vídeo: um no início da tentativa e o segundo no final da tentativa. Estes cortes seguirão a mesma regra daqueles que foram feitos no vídeo da filmagem externa da tentativa pela câmera Nikon, ou seja, o primeiro corte acontecerá no primeiro frame no qual aparecia nitidamente a imagem do painel do carro do simulador para o participante e o segundo corte será no último frame nítido da imagem do painel do carro do simulador para o participante. Desta forma, serão sincronizados os dados do áudio, do simulador e do movimento dos olhos e cabeça, criando o mesmo intervalo de coleta de dados para os dados brutos em todos os equipamentos utilizados para coleta de dados.

A partir deste novo intervalo de dados para o movimento do olho e cabeça, será definida no software de análise uma área de interesse interna, que envolverá toda a região visível da cena do simulador na televisão Samsung. Adicionalmente, será definida como região de interesse externa à área total visível e não visível pelo canal de vídeo do campo visual do participante, subtraindo a área de interesse interna. Esta definição é necessária para caracterizar o interesse do olhar do participante.

Será aplicada na tabela de dados resultantes da coleta com o Eye Tracker, a mesma seleção temporal para definir os 10 segundos de dados a serem analisados na tentativa para extração das variáveis desejadas. De forma análoga e adaptada do estudo de Giang, Chen e Donmez (2017), será definido que quando o participante direcionar o seu olhar para fora da região de interesse interna e em direção ao lado esquerdo do seu campo visual, ele estará com foco atencional direcionado ao relógio inteligente nas condições de pesquisa.

APÊNDICE IV – Algoritmos

1. Algoritmos para manipular os dados do simulador:

```
import numpy as np
import pandas as pd
import os
import csv

def getMeanStdSim(file, varCollIndex, limInferior, limSuperior):

    matrix = []
    selected_elements = []
    stdVar = []

    with open(file, "r") as file:
        for line in file:
            if "Dynamic block" not in line:
                continue
            for i, line in enumerate(file):
                if i<3:
                    continue
                if ("0 0 0" in line):
                    break
                columns = line.strip().split()
                matrix.append(columns)
    matrix = np.array(matrix, dtype=object)

    columnTime = matrix[:, 0]
    columnVar = matrix[:, varCollIndex]

    for i in range(len(columnVar)):
        if (float(columnTime[i])>=limInferior and float(columnTime[i])<=limSuperior):
            if varCollIndex ==3 and float(columnTime[i])-float(columnTime[i-1])>6:
                selected_elements.append(float(0))
                break
            else:
                selected_elements.append(float(columnVar[i]))

    column_mean = np.mean(selected_elements)
    column_std = np.std(selected_elements)

    if np.isnan(column_mean):
        column_mean=0
    if np.isnan(column_std):
        column_std=0

    print(column_mean)
    print(column_std)
```

```

return column_mean, column_std

def get_files(folder):
    files = []
    # Traverse all folders in the given folder
    for f in os.listdir(folder):
        # Check if the current item is a directory
        if os.path.isdir(os.path.join(folder,f)):
            # Traverse the sub-directory
            files.extend(get_files(os.path.join(folder, f)))
        else:
            # Add the file to the list
            files.append(os.path.join(folder,f))
            #print(file)

    #checkIfPupilFile(f)
    return files

def getParticipantsList():

    dataMapFile = "H:\Meu Drive\Doutorado\Dados\DadosRawFinal_Doutorado.xlsx"
    participantsList = []

    df = pd.read_excel(dataMapFile)
    for row in df.iterrows():
        if row[1][0] not in participantsList:
            participantsList.append(row[1][0])

    return participantsList

def getSimVarValues(varIndex, varName):

    path = r"H:\Meu Drive\Doutorado\Dados\DadosSimulador"
    dataMapFile = "H:\Meu Drive\Doutorado\Dados\DadosRawFinal_Doutorado.xlsx"
    folderOutput = "H:\Meu Drive\Doutorado\Dados\Variaveis"
    saveFile = folderOutput + '\ ' + varName + ".csv"
    file = ""
    fileHeader = ['participante', 'grupo', 'tentativa', 'condicao', varName, 'str'+varName]
    fileList = []

    g = open(saveFile, "w")
    g.write(fileHeader[0] + ',' + fileHeader[1] + ',' + fileHeader[2] + ',' + fileHeader[3] + ',' + fileHeader[4] + ',' + fileHeader[5] + '\n')

    df = pd.read_excel(dataMapFile)
    for row in df.iterrows():

        folderPath = path + "\ " + row[1][0]

```

```

for f in get_files(folderPath):
    if ".Dat" in f and ("_T" in f):
        fileList.append(f)
for w in fileList:
    if row[1][2] in w:
        file = w
print(file)
if row[1][3] == "CAR":
    timeMarkerIN = float(str(row[1][12]).replace(',','.'))
    timeMarkerOUT = float(str(row[1][13]).replace(',','.'))
    mean , std = getMeanStdSim(file, varIndex, timeMarkerIN, timeMarkerOUT)
    g.write(row[1][0] + "," + row[1][1] + "," + row[1][2] + "," + row[1][3] + "," + str(mean) + "," + str(std) + "\n")

elif row[1][3] == "NOT":
    timeMarkerIN = float(str(row[1][5]).replace(',','.')) #inicio da leitura da mensagem de texto
    timeMarkerOUT = float(str(row[1][6]).replace(',','.')) #fim da leitura da mensagem de texto
    mean, std = getMeanStdSim(file, varIndex, timeMarkerIN, timeMarkerOUT)
    g.write(row[1][0] + "," + row[1][1] + "," + row[1][2] + "," + row[1][3] + "," + str(mean) + "," + str(std) + "\n")

elif row[1][3] == "FRE" :
    timeMarkerIN = float(str(row[1][11]).replace(',','.')) #Inicio da freada
    timeMarkerOUT = float(str(row[1][14]).replace(',','.')) #fim da freada
    mean, std = getMeanStdSim(file, varIndex, timeMarkerIN, timeMarkerOUT)
    g.write(row[1][0] + "," + row[1][1] + "," + row[1][2] + "," + row[1][3] + "," + str(mean) + "," + str(std) + "\n")

elif row[1][3] == "FNOT":
    timeMarkerIN = float(str(row[1][11]).replace(',','.')) #inicio da freada
    timeMarkerOUT = float(str(row[1][14]).replace(',','.')) #fim da freada
    mean, std = getMeanStdSim(file, varIndex, timeMarkerIN, timeMarkerOUT)
    g.write(row[1][0] + "," + row[1][1] + "," + row[1][2] + "," + row[1][3] + "," + str(mean) + "," + str(std) + "\n")

g.close()

```

2. Algoritmos para manipular os dados da pupila

```

def create10SPupilFile():

    dataMapFile = "H:\Meu Drive\Doutorado\Dados\DadosRawFinal_Doutorado.xlsx"
    folderInput = "H:\Meu Drive\Doutorado\Dados\Teste Interpolacao\"

    timeMarkerIN = 0
    timeMarkerOUT = 0
    filterIN = 10

    df = pd.read_excel(dataMapFile)
    for row in df.iterrows():
        print(row[1][1])

```

```

file = folderInput + row[1][0] + " - " + row[1][2] + " - " + "Pupil.txt"
print(file)

if row[1][3] == "CAR":
    timeMarkerIN = row[1][12]
    timeMarkerOUT = row[1][13]
    print(timeMarkerIN)
    print(timeMarkerIN-filterIN)
    print(timeMarkerIN+filterIN)
    group = row[1][1]
    createFileWithMarker(file, timeMarkerIN-5, timeMarkerIN+filterIN, group)

elif row[1][3] == "NOT":
    print(timeMarkerIN)
    timeMarkerIN = row[1][5]
    timeMarkerOUT = row[1][6]
    group = row[1][1]
    createFileWithMarker(file, timeMarkerIN-5, timeMarkerIN+filterIN, group)

elif row[1][3] == "FRE":

    timeMarkerIN = row[1][11]
    timeMarkerOUT = row[1][14]
    group = row[1][1]
    print(timeMarkerIN)
    createFileWithMarker(file, timeMarkerIN-5, timeMarkerIN+filterIN, group)
elif row[1][3] == "FNOT":
    timeMarkerIN = row[1][4]
    timeMarkerOUT = row[1][14]
    group = row[1][1]
    print(timeMarkerIN)
    createFileWithMarker(file, timeMarkerIN-5, timeMarkerIN+filterIN, group)

def createFileWithMarker(file, timeIn, timeOut, group):

    outputDir = "H:\Meu Drive\Doutorado\Dados\cogLoadCalcFiles\\"

    fileName = file.split("\\")
    print("File: " + fileName[5])
    group = "Todos"
    saveFile = outputDir + fileName[5].replace('.txt','.csv')
    fileHeader = ['time_secs', 'scaled_pupil_d']

    g = open(saveFile, "w")
    g.write(fileHeader[0] + "," + fileHeader[1] + "\n")

    df = pd.read_csv(file, sep=',')
    cont = 0

```

```

for row in df.iterrows():
    if float(row[1]['time_secs']) >= float(timeIn) and float(row[1]['time_secs']) <= float(timeOut) and
float(row[1]['scaled_pupil_d'] > 0): #checar se o periodo mudar para o valor final
        cont = cont + 1
        g.write(str(row[1]['time_secs']) + "," + str(row[1]['scaled_pupil_d']) + "\n")

g.close()
print("cont>>> "+str(cont))

```

3. Algoritmos para calcular carga mental de trabalho

```

def modmax(d):
    # compute signal modulus
    m = [0.0]*len(d)
    for i in range(len(d)):
        m[i] = math.fabs(d[i])

    # if value is larger than both neighbours , and strictly
    # larger than either, then it is a local maximum
    t = [0.0]*len(d)
    for i in range(len(d)):
        ll = m[i-1] if i >= 1 else m[i]
        oo = m[i]
        rr = m[i+1] if i < len(d)-2 else m[i]
        if (ll <= oo and oo >= rr) and (ll < oo or oo > rr):
            # compute magnitude
            t[i] = math.sqrt(d[i]**2)
        else:
            t[i] = 0.0

    return t

def ipa(d, t1, t2):
    # obtain 2-level DWT of pupil diameter signal d
    try:
        (cA2,cD2,cD1) = pywt.wavedec(d,'sym2','per',level=2)
    except ValueError:
        return

    # get signal duration (in seconds)
    tt = t1 - t2

    # normalize by 1/2j, j=2 for 2-level DWT
    cA2[:] = [x / math.sqrt(4.0) for x in cA2]
    cD1[:] = [x / math.sqrt(2.0) for x in cD1]
    cD2[:] = [x / math.sqrt(4.0) for x in cD2]

```

```

# detect modulus maxima, see Listing 2
cD2m = modmax(cD2)

# threshold using universal threshold  $\lambda_{univ} = \hat{\sigma} \sqrt{2 \log n}$ 
# where  $\hat{\sigma}$  is the standard deviation of the noise
 $\lambda_{univ} = np.std(cD2m) * math.sqrt(2.0 * np.log2(len(cD2m)))$ 
cD2t = pywt.threshold(cD2m,  $\lambda_{univ}$ , mode='hard')

# compute IPA
ctr = 0
for i in range(len(cD2t)):
    if math.fabs(cD2t[i]) > 0: ctr += 1
IPA = float(ctr)/tt

return IPA

def lhipa(d, t1, t2):
    # find max decomposition level
    w = pywt.Wavelet('sym2')
    maxlevel = \
        pywt.dwt_max_level(len(d), filter_len=w.dec_len)

    # set high and low frequency band indices
    hif, lof = 1, int(maxlevel/2)
    #print (hif)
    #print (lof)

    # get detail coefficients of pupil diameter signal d
    cD_H = pywt.downcoef('d', d, 'sym2', 'per', level=hif)
    cD_L = pywt.downcoef('d', d, 'sym2', 'per', level=lof)

    # normalize by  $1/\sqrt{2^i}$ 
    cD_H[:] = [x / math.sqrt(2**hif) for x in cD_H]
    cD_L[:] = [x / math.sqrt(2**lof) for x in cD_L]

    # obtain the LH:HF ratio
    cD_LH = cD_L
    for i in range(len(cD_L)):
        index = math.floor( ( (2**lof)/(2**hif) ) * i )
        cD_LH[i] = cD_L[i] / cD_H[index]

    # detect modulus maxima
    cD_LHm = modmax(cD_LH)

    # threshold using universal threshold  $\lambda_{univ} = \hat{\sigma} \sqrt{2 \log n}$ 
    # where  $\hat{\sigma}$  is the standard deviation of the noise
     $\lambda_{univ} = \$ 
        np.std(cD_LHm) * math.sqrt(2.0 * np.log2(len(cD_LHm)))

```

```
cD_LHt = pywt.threshold(cD_LHm,lambdauniv,mode="less")
```

```
--
```

```
# get signal duration (in seconds)
```

```
tt = t1 - t2
```

```
-
```

```
# compute LHIPA
```

```
ctr = 0
```

```
for i in range(len(cD_LHt)):
```

```
    if math.fabs(cD_LHt[i]) > 0: ctr += 1
```

```
LHIPA = float(ctr)/tt
```

```
return LHIPA
```

```
#####
```

```
def cognitiveLoadCalc():
```

```
    folderInput = "H:\Meu Drive\Doutorado\Dados\cogLoadCalcFiles"
```

```
    folderOutput = "H:\Meu Drive\Doutorado\Dados\Variaveis"
```

```
    dataMapFile = "H:\Meu Drive\Doutorado\Dados\DadosRawFinal_Doutorado.xlsx"
```

```
    saveFile = folderOutput + '\ipa.csv'
```

```
    saveFile2 = folderOutput + '\lhipa.csv'
```

```
    fileHeader = ['participante', 'grupo', 'tentativa', 'condicao', 'IPA']
```

```
    fileHeader2 = ['participante', 'grupo', 'tentativa', 'condicao', 'LHIPA']
```

```
    g = open(saveFile, "w")
```

```
    h = open(saveFile2, "w")
```

```
    g.write(fileHeader[0] + ',' + fileHeader[1] + ',' + fileHeader[2] + ',' + fileHeader[3] + ',' + fileHeader[4] + '\n')
```

```
    h.write(fileHeader2[0] + ',' + fileHeader2[1] + ',' + fileHeader2[2] + ',' + fileHeader2[3] + ',' + fileHeader2[4] + '\n')
```

```
    ipaCAR = []
```

```
    ipaNOT = []
```

```
    ipaFRE = []
```

```
    ipaFNOT = []
```

```
    lhipaCAR = []
```

```
    lhipaNOT = []
```

```
    lhipaFRE = []
```

```
    lhipaFNOT = []
```

```
    df = pd.read_excel(dataMapFile)
```

```
    for row in df.iterrows():
```

```
        file = folderInput + "\\ " + row[1][0] + " - " + row[1][2] + " - " + "Pupil.csv"
```

```

if row[1][3] == "CAR":
    timeMarkerIN = float(str(row[1][12]).replace(',','.'))
    timeMarkerOUT = float(str(row[1][13]).replace(',','.'))
    IPA = calcIndice(file, timeMarkerIN-0.5, timeMarkerOUT)
    LHIPA = calcIndice2(file, timeMarkerIN-0.5, timeMarkerOUT)
    ipaCAR.append(IPA)
    lhipaCAR.append(LHIPA)
    g.write(row[1][0] + "," + row[1][1] + "," + row[1][2] + "," + row[1][3] + "," + str(IPA) + "\n")
    h.write(row[1][0] + "," + row[1][1] + "," + row[1][2] + "," + row[1][3] + "," + str(LHIPA) + "\n")

```

```

elif row[1][3] == "NOT":
    timeMarkerIN = float(str(row[1][5]).replace(',','.')) #inicio da leitura da mensagem de texto
    timeMarkerOUT = float(str(row[1][6]).replace(',','.')) #fim da leitura da mensagem de texto
    IPA = calcIndice(file, timeMarkerIN-0.5, timeMarkerOUT)
    LHIPA = calcIndice2(file, timeMarkerIN-0.5, timeMarkerOUT)
    ipaNOT.append(IPA)
    lhipaNOT.append(LHIPA)
    g.write(row[1][0] + "," + row[1][1] + "," + row[1][2] + "," + row[1][3] + "," + str(IPA) + "\n")
    h.write(row[1][0] + "," + row[1][1] + "," + row[1][2] + "," + row[1][3] + "," + str(LHIPA) + "\n")

```

```

elif row[1][3] == "FRE" :
    timeMarkerIN = float(str(row[1][11]).replace(',','.')) #Inicio da freada
    timeMarkerOUT = float(str(row[1][14]).replace(',','.')) #fim da freada
    IPA = calcIndice(file, timeMarkerIN-0.5, timeMarkerOUT)
    LHIPA = calcIndice2(file, timeMarkerIN-0.5, timeMarkerOUT)
    ipaFRE.append(IPA)
    lhipaFRE.append(LHIPA)
    g.write(row[1][0] + "," + row[1][1] + "," + row[1][2] + "," + row[1][3] + "," + str(IPA) + "\n")
    h.write(row[1][0] + "," + row[1][1] + "," + row[1][2] + "," + row[1][3] + "," + str(LHIPA) + "\n")

```

```

elif row[1][3] == "FNOT":
    timeMarkerIN = float(str(row[1][11]).replace(',','.')) #inicio da freada
    timeMarkerOUT = float(str(row[1][14]).replace(',','.')) #fim da freada
    IPA = calcIndice(file, timeMarkerIN-0.5, timeMarkerOUT)
    LHIPA = calcIndice2(file, timeMarkerIN-0.5, timeMarkerOUT)
    ipaFNOT.append(IPA)
    lhipaFNOT.append(LHIPA)
    g.write(row[1][0] + "," + row[1][1] + "," + row[1][2] + "," + row[1][3] + "," + str(IPA) + "\n")
    h.write(row[1][0] + "," + row[1][1] + "," + row[1][2] + "," + row[1][3] + "," + str(LHIPA) + "\n")

```

```

g.close()
h.close()

```

```

def calcIndice(file, tStart, tPeriod):

```

```

    count = 0
    lowestTime = tStart
    highestTime = tStart

```

```

d = []

df = pd.read_csv(file, sep=',')
for row in df.iterrows():

    timeValue = float(row[1]['time_secs'])
    pupilSize = float(row[1]['scaled_pupil_d'])

    if ( (pupilSize > 0) and (timeValue >= tStart) and (timeValue <= tPeriod) ):
        if count == 0:
            lowestTime = timeValue

        if timeValue > highestTime:
            highestTime = timeValue

        count += 1
        d.append(pupilSize)

ipacalc = ipa(d, highestTime, lowestTime)

return ipacalc

```

```

def calcIndice2(file, tStart, tPeriod):

```

```

    count = 0
    lowestTime = tStart
    highestTime = tStart
    d = []

    df = pd.read_csv(file, sep=',')
    for row in df.iterrows():

        timeValue = float(row[1]['time_secs'])
        pupilSize = float(row[1]['scaled_pupil_d'])

        if ( (pupilSize > 0) and (timeValue >= tStart) and (timeValue <= tPeriod) ):
            if count == 0:
                lowestTime = timeValue

            if timeValue > highestTime:
                highestTime = timeValue

            count += 1
            d.append(pupilSize)

    lhpacalc = lhpa(d, highestTime, lowestTime)

```

```
return lhipacalc
```

4. Algoritmos para manipular dados de movimentos dos olhos

```
def fixations(file, timeIN, timeOUT):
```

```
    matrixDriving = []
```

```
    matrixSmartwatch = []
```

```
    with open(file, "r") as file:
```

```
        for i, line in enumerate(file):
```

```
            if i==0:
```

```
                continue
```

```
            if len(line.strip())==0:
```

```
                break
```

```
            columns = line.strip().split()
```

```
            if columns[9] == "Driving" and float(columns[11])>=timeIN and float(columns[11])<=timeOUT:
```

```
                matrixDriving.append(float(columns[12]))
```

```
            if columns[9] == 'OUTSIDE' and float(columns[10])>=timeIN and float(columns[10])<=timeOUT:
```

```
                matrixSmartwatch.append(float(columns[11]))
```

```
matrixDriving = np.array(matrixDriving, dtype=object)
```

```
matrixSmartwatch = np.array(matrixSmartwatch, dtype=object)
```

```
fixDurAOI1 = np.sum(matrixDriving)
```

```
fixDurAOI2 = np.sum(matrixSmartwatch)
```

```
fixDurMeanAOI1 = np.mean(matrixDriving)
```

```
fixDurMeanAOI2 = np.mean(matrixSmartwatch)
```

```
fixNumAOI1 = np.size(matrixDriving)
```

```
fixNumAOI2 = np.size(matrixSmartwatch)
```

```
if np.isnan(fixDurAOI1):
```

```
    fixDurAOI1 = 0
```

```
if np.isnan(fixDurAOI2):
```

```
    fixDurAOI2 = 0
```

```
if np.isnan(fixDurMeanAOI1):
```

```
    fixDurMeanAOI1 = 0
```

```
if np.isnan(fixDurMeanAOI2):
```

```
    fixDurMeanAOI2 = 0
```

```
if np.isnan(fixNumAOI1):
```

```

    fixNumAOI1 = 0
if np.isnan(fixNumAOI2):
    fixNumAOI2 = 0

results = [fixDurAOI1, fixDurMeanAOI1, fixNumAOI1]
results2 = [fixDurAOI2, fixDurMeanAOI2, fixNumAOI2]

return results, results2

def calcFixations(file, AOI):

    dataMapFile = "H:\\Meu Drive\\Doutorado\\Dados\\DadosRawFinal_Doutorado.xlsx"
    folderInput = "H:\\Meu Drive\\Doutorado\\Dados\\PD Analysis"
    folderOutput = r"H:\\Meu Drive\\Doutorado\\Dados\\Variaveis"

    saveFile = folderOutput + '\\ ' + 'fixationDuration'+ str(AOI) + ".csv"
    saveFile2 = folderOutput + '\\ ' + 'fixationMeanDur' + str(AOI) + ".csv"
    saveFile3 = folderOutput + '\\ ' + 'fixationCount' + str(AOI) + ".csv"

    fileHeader = ['participante', 'grupo', 'tentativa', 'condicao', 'AOI', 'fixDuration']

    g = open(saveFile, "w")
    h = open(saveFile2, "w")
    i = open(saveFile3, "w")

    g.write(fileHeader[0] + ',' + fileHeader[1] + ',' + fileHeader[2] + ',' + fileHeader[3] + ',' + fileHeader[4] + ',' +
fileHeader[5] + '\n')
    h.write(fileHeader[0] + ',' + fileHeader[1] + ',' + fileHeader[2] + ',' + fileHeader[3] + ',' + fileHeader[4] + ',' +
'FixMeanDur' + '\n')
    i.write(fileHeader[0] + ',' + fileHeader[1] + ',' + fileHeader[2] + ',' + fileHeader[3] + ',' + fileHeader[4] + ',' +
'FixCount' + '\n')

    df = pd.read_excel(dataMapFile)
    for row in df.iterrows():

        file = folderInput + '\\ ' + row[1][0] + "\\ " + row[1][0] + " - " + row[1][2] + " - " + "Fix.txt"

        if row[1][3] == "CAR":
            timeMarkerIN = float(str(row[1][12]).replace(',','.'))
            timeMarkerOUT = float(str(row[1][13]).replace(',','.'))

            fixDriving, fixSmartwatch = fixations(file, timeMarkerIN-0.5, timeMarkerOUT-0.5)

            if AOI == 'Driving':
                g.write(row[1][0] + "," + row[1][1] + "," + row[1][2] + "," + row[1][3] + "," + str(AOI) + ',' +
str(fixDriving[0]) + "\n")
                h.write(row[1][0] + "," + row[1][1] + "," + row[1][2] + "," + row[1][3] + "," + str(AOI) + ',' +
str(fixDriving[1]) + "\n")

```

```

        i.write(row[1][0] + "," + row[1][1] + "," + row[1][2] + "," + row[1][3] + "," + str(AOI) + ',' +
str(fixDriving[2]) + "\n")
        if AOI == 'OUTSIDE':
            g.write(row[1][0] + "," + row[1][1] + "," + row[1][2] + "," + row[1][3] + "," + str(AOI) + ',' +
str(fixSmartwatch[0]) + "\n")
            h.write(row[1][0] + "," + row[1][1] + "," + row[1][2] + "," + row[1][3] + "," + str(AOI) + ',' +
str(fixSmartwatch[1]) + "\n")
            i.write(row[1][0] + "," + row[1][1] + "," + row[1][2] + "," + row[1][3] + "," + str(AOI) + ',' +
str(fixSmartwatch[2]) + "\n")

elif row[1][3] == "NOT":
    timeMarkerIN = float(str(row[1][5]).replace(',','.')) #inicio da leitura da mensagem de texto
    timeMarkerOUT = float(str(row[1][6]).replace(',','.')) #fim da leitura da mensagem de texto

    fixDriving, fixSmartwatch = fixations(file, timeMarkerIN-0.5, timeMarkerOUT-0.5)

    if AOI == 'Driving':
        g.write(row[1][0] + "," + row[1][1] + "," + row[1][2] + "," + row[1][3] + "," + str(AOI) + ',' +
str(fixDriving[0]) + "\n")
        h.write(row[1][0] + "," + row[1][1] + "," + row[1][2] + "," + row[1][3] + "," + str(AOI) + ',' +
str(fixDriving[1]) + "\n")
        i.write(row[1][0] + "," + row[1][1] + "," + row[1][2] + "," + row[1][3] + "," + str(AOI) + ',' +
str(fixDriving[2]) + "\n")
        if AOI == 'OUTSIDE':
            g.write(row[1][0] + "," + row[1][1] + "," + row[1][2] + "," + row[1][3] + "," + str(AOI) + ',' +
str(fixSmartwatch[0]) + "\n")
            h.write(row[1][0] + "," + row[1][1] + "," + row[1][2] + "," + row[1][3] + "," + str(AOI) + ',' +
str(fixSmartwatch[1]) + "\n")
            i.write(row[1][0] + "," + row[1][1] + "," + row[1][2] + "," + row[1][3] + "," + str(AOI) + ',' +
str(fixSmartwatch[2]) + "\n")

elif row[1][3] == "FRE" :
    timeMarkerIN = float(str(row[1][11]).replace(',','.')) #Inicio da freada
    timeMarkerOUT = float(str(row[1][14]).replace(',','.')) #fim da freada

    fixDriving, fixSmartwatch = fixations(file, timeMarkerIN-0.5, timeMarkerOUT-0.5)

    if AOI == 'Driving':
        g.write(row[1][0] + "," + row[1][1] + "," + row[1][2] + "," + row[1][3] + "," + str(AOI) + ',' +
str(fixDriving[0]) + "\n")
        h.write(row[1][0] + "," + row[1][1] + "," + row[1][2] + "," + row[1][3] + "," + str(AOI) + ',' +
str(fixDriving[1]) + "\n")
        i.write(row[1][0] + "," + row[1][1] + "," + row[1][2] + "," + row[1][3] + "," + str(AOI) + ',' +
str(fixDriving[2]) + "\n")
        if AOI == 'OUTSIDE':
            g.write(row[1][0] + "," + row[1][1] + "," + row[1][2] + "," + row[1][3] + "," + str(AOI) + ',' +
str(fixSmartwatch[0]) + "\n")

```

```
h.write(row[1][0] + "," + row[1][1] + "," + row[1][2] + "," + row[1][3] + "," + str(AOI) + ';' +
str(fixSmartwatch[1]) + "\n")
i.write(row[1][0] + "," + row[1][1] + "," + row[1][2] + "," + row[1][3] + "," + str(AOI) + ';' +
str(fixSmartwatch[2]) + "\n")
```

```
elif row[1][3] == "FNOT":
```

```
timeMarkerIN = float(str(row[1][11]).replace(',','.')) #inicio da freada
```

```
timeMarkerOUT = float(str(row[1][14]).replace(',','.')) #fim da freada
```

```
fixDriving, fixSmartwatch = fixations(file, timeMarkerIN-0.5, timeMarkerOUT-0.5)
```

```
if AOI == 'Driving':
```

```
g.write(row[1][0] + "," + row[1][1] + "," + row[1][2] + "," + row[1][3] + "," + str(AOI) + ';' +
str(fixDriving[0]) + "\n")
```

```
h.write(row[1][0] + "," + row[1][1] + "," + row[1][2] + "," + row[1][3] + "," + str(AOI) + ';' +
str(fixDriving[1]) + "\n")
```

```
i.write(row[1][0] + "," + row[1][1] + "," + row[1][2] + "," + row[1][3] + "," + str(AOI) + ';' +
str(fixDriving[2]) + "\n")
```

```
if AOI == 'OUTSIDE':
```

```
g.write(row[1][0] + "," + row[1][1] + "," + row[1][2] + "," + row[1][3] + "," + str(AOI) + ';' +
str(fixSmartwatch[0]) + "\n")
```

```
h.write(row[1][0] + "," + row[1][1] + "," + row[1][2] + "," + row[1][3] + "," + str(AOI) + ';' +
str(fixSmartwatch[1]) + "\n")
```

```
i.write(row[1][0] + "," + row[1][1] + "," + row[1][2] + "," + row[1][3] + "," + str(AOI) + ';' +
str(fixSmartwatch[2]) + "\n")
```

```
g.close()
```

```
h.close()
```

```
i.close()
```

ANEXOS

ANEXO I – Algoritmo para gerar as sequencias de tentativas

```
<?php
```

```
function randomGen($min, $max, $quantity) {  
    $numbers = range($min, $max);  
    shuffle($numbers);  
    return array_slice($numbers, 0, $quantity);  
}
```

```
echo (randomGen(1,12,55));  
for($i=1;$i<=55;$i++){  
    print_r( randomGen(1, 12, 12));  
}  
?>
```

ANEXO II – Formulário de seleção e classificação de participantes

Dados Condução de Veículos

- **Você possui Carteira Nacional de Habilitação (CNH)?**

() Sim () Não

- **Você dirige:**

() Carro () Moto () Carro e Moto () Outro?

- **Há quanto tempo você tem a CNH?**

- **Você dirige carro toda semana?** () Sim () Não

Se sim, há quanto tempo você dirige carro toda semana?

- **Quantos dias por semana você dirige carro?**

- **Em média, quantos quilômetros você dirige carro por dia?**

- **Com que frequência você dirige carro em estradas ou rodovias?**

() Nunca

() Raramente (1 viagem a cada 6 meses)

() Mensalmente (no mínimo 1 viagem por mês)

() Semanalmente (no mínimo 1 viagem por semana)

() Diariamente

ANEXO III – Temo de Consentimento Livre e Esclarecido



Universidade Estadual Paulista “Júlio de Mesquita Filho”

Faculdade de Arquitetura, Artes e Comunicação

Programa de Pós-graduação em Design

LIVIA - Laboratório de Informação, Visão e Ação

TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO

(TERMINOLOGIA OBRIGATÓRIO EM ATENDIMENTO A RESOLUÇÃO 196/96 –CNS-MS)

A pesquisa “ERGONOMIA COGNITIVA DO USO DE SMARTWATCH DURANTE CONDUÇÃO SIMULADA DE AUTOMÓVEL: MOVIMENTO DOS OLHOS E DESEMPENHO DE MOTORISTAS” tem como objetivo Identificar como o uso de relógios inteligentes afetam a condução de automóvel de motoristas experientes e novatos no trânsito, através da análise de movimento dos olhos e do desempenho de motoristas ao volante enquanto utilizam um relógio inteligente.

Para a coleta de dados será utilizado um sistema de medidas do movimento dos olhos e cabeça, por meio de câmeras, a direção de automóvel será em situação simulada. Nenhum dos procedimentos será invasivo e não causará desconforto algum ou risco à sua saúde, tendo em vista que as atividades a serem realizadas fazem parte do cotidiano da maioria das pessoas com habilitação de veículos. Toda a sessão será gravada em áudio e vídeo, porém, nenhuma informação pessoal, imagem ou identificação dos participantes será divulgada na pesquisa. Em caso de dúvidas, você será totalmente esclarecido pelos responsáveis da pesquisa antes e durante a realização do experimento, além da possibilidade de entrar em contato por um dos meios divulgados abaixo.

Este “Termo de Consentimento Livre e Esclarecido” atende a Resolução 196/96-CNS-MS e o “Código de Deontologia do Ergonomista Certificado – Norma ERG BR 1002 – ABERGO”.

Eu, _____, RG _____ - SSP/_____, estando ciente das informações acima lidas, concordo em participar da pesquisa “**ERGONOMIA COGNITIVA DO USO DE SMARTWATCH DURANTE CONDUÇÃO SIMULADA DE AUTOMÓVEL: MOVIMENTO DOS OLHOS E DESEMPENHO DE MOTORISTAS**” e entendo que as informações cedidas por mim são confidenciais, autorizando a sua divulgação no meio científico e acadêmico de forma anônima e global, tendo a minha identidade totalmente preservada. Estou ciente de que sou voluntário e, portanto, não receberei nenhum benefício por participar desta pesquisa, bem como não terei ônus algum. Tenho total liberdade para aceitar ou recusar fazer parte deste estudo e sei que a minha recusa, em qualquer momento do experimento, não acarretará nenhum prejuízo para mim.

Bauru, ____ de _____ de 2022.

Assinatura do participante

Pesquisador Gustavo de Andrade Silva

Prof . Dr. Sergio Tosi Rodrigues
(orientador)

ANEXO IV – Formulário de Caracterização de Participante

Estudo sobre a condução de veículos em Ambiente Simulado, utilizando relógio inteligente.

Dados Participante

Sequência # _____

Grupo _____

Nome Completo			
Idade		Celular	
Gênero	<input type="checkbox"/> Feminino <input type="checkbox"/> Masculino		
E-mail			
Profissão			
Peso (Kg)		Altura (cm)	
Data/Hora	__/__/2017 - __:__		
Teste Oftalmológico	D() E() Ambos()		

- Você tem algum problema oftalmológico? Sim Não

Se sim, qual problema? _____

Olho direito Olho esquerdo Ambos

- Faz uso de alguma forma de correção para visão?

Lentes Óculos

- Você toma algum medicamento de uso contínuo?

Se sim, qual?

- Você utiliza ou já utilizou relógio de pulso comum? Sim Não

- Em qual braço você utiliza ou utilizou relógio de pulso?

Esquerdo Direito

- Você possui um celular do tipo smartphone? () Sim () Não

Se sim, quais seriam os 5 aplicativos que você mais utiliza neste aparelho?

- Você possui ou já utilizou um relógio inteligente (smartwatch)?

() Sim, possuo () Sim, já utilizei () Não

Se sim, por quanto tempo você utilizou este relógio? _____

Se sim, qual foi a sua motivação para comprá-lo?

Se sim, qual(ais) aplicativos você mais usa no relógio?

Se sim, qual(ais) funcionalidades você mais usa no seu relógio inteligente?

Dados Condução de Veículos

- Você cometeu e recebeu multa por alguma infração de trânsito desde que recebeu a sua CNH (exemplo, excesso de velocidade, estacionar em local proibido dentre outros)?

Se sim, quando e qual foi a infração?

- Você se envolveu em algum acidente de trânsito desde que recebeu a sua CNH? Liste todos que você lembrar, por favor.

Se sim, qual o motivo do acidente?

Se sim, quando este acidente ocorreu?

- No último ano, você cometeu alguma infração de trânsito ou se envolveu em algum acidente enquanto estava dirigindo?

- Com que frequência você utiliza o seu celular enquanto está dirigindo?

- Nunca
- Raramente (1 ou 2 duas vezes por semana)
- Algumas vezes (de 3 a 5 vezes por semana)
- Regularmente (de 6 a 10 vezes por semana)
- Sempre (mais de 10 vezes por semana)

- Se você tem o hábito de utilizar o seu celular enquanto dirige, qual atividade ou quais aplicativos você utiliza enquanto está dirigindo?
