



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA DE TRANSPORTES
CURSO DE GRADUAÇÃO EM ENGENHARIA CIVIL

MATHEUS FERREIRA DA ROCHA

**VISLAB: UMA FERRAMENTA DE APOIO À CALIBRAÇÃO DE MODELOS DO
SIMULADOR DE TRÁFEGO VISSIM**

FORTALEZA

2019

MATHEUS FERREIRA DA ROCHA

VISLAB: UMA FERRAMENTA DE APOIO À CALIBRAÇÃO DE MODELOS DO
SIMULADOR DE TRÁFEGO VISSIM

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia Civil do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do grau de bacharel em Engenharia Civil.

Orientador: Prof. Dr. Manoel de Castro Neto

FORTALEZA

2019

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca Universitária
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

- M378v Matheus Ferreira da, Rocha.
VISLAB: Uma ferramenta de apoio à calibração de modelos do simulador de tráfego VISSIM / Rocha Matheus Ferreira da. – 2019.
63 f. : il.
- Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Centro de Tecnologia, Curso de Engenharia Civil, Fortaleza, 2019.
Orientação: Prof. Dr. Manoel Mendonça de Castro Neto.
1. Microssimulação de tráfego. 2. Python. 3. Algoritmo genético. 4. Calibração de Microssimuladores. I. Título.

CDD 620

MATHEUS FERREIRA DA ROCHA

VISLAB: UMA FERRAMENTA DE APOIO À CALIBRAÇÃO DE MODELOS DO
SIMULADOR DE TRÁFEGO VISSIM

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia Civil do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do grau de bacharel em Engenharia Civil.

Aprovada em: 12 de Dezembro de 2019

Prof. Dr. Manoel de Castro Neto (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Mário Angelo Nunes de Azevedo Filho
Universidade Federal do Ceará (UFC)

M.e Victor Macêdo Lacerda
Universidade Federal do Ceará (UFC)

À minha família, por sua capacidade de acreditar em mim e investir em mim. Pai, por ter trabalhado tão arduamente pelo nosso futuro, ensinando que uma vida plena se dá pela dedicação e excelência. Mãe, por se dedicar diariamente pelo nosso bem-estar. À minha companheira Maria, por ter estado ao meu lado não importa o que.

AGRADECIMENTOS

Ao Prof. Dr. Manoel de Castro Neto por me orientar em meu projeto de graduação, se dedicando a melhoria contínua do projeto, e por ter me iniciado no universo da programação.

Aos meus pais por terem sacrificado o presente deles pelo meu futuro, sem o esforço deles nada disso teria sido possível.

À minha parceira engenheira civil Maria Delmiro Rocha, por estar constantemente ao meu lado ajudando a tornar essa jornada menos árdua e incentivando a desenvolver o que há de melhor em mim.

Ao meu colega engenheiro civil Gustavo Henrique Pinheiro por me ajudar a desenvolver ideias melhores e ter dedicado seu tempo no apoio técnico a este trabalho.

Ao Doutorando em Engenharia Elétrica, Ednardo Moreira Rodrigues, e seu assistente, Alan Batista de Oliveira, aluno de graduação em Engenharia Elétrica, pela adequação do *template* utilizado neste trabalho para que o mesmo ficasse de acordo com as normas da biblioteca da Universidade Federal do Ceará (UFC).

Agradeço a todos os professores por me proporcionar o conhecimento não apenas racional, mas a manifestação do caráter e afetividade da educação no processo de formação profissional, por tanto que se dedicaram a mim, não somente por terem me ensinado, mas por terem me feito aprender.

Por fim agradeço a todas as pessoas que se dedicam no seu trabalho diário tentando tornar as coisas melhores apesar de toda a dor e sofrimento atrelados a existência. Sem essas pessoas não teríamos sequer uma sociedade.

“The purpose of life is finding the largest burden
that you can bear and bearing it.”

(Jordan Peterson)

RESUMO

Para acompanhar a evolução nas metodologias de análise e calibração de redes de microssimulação de tráfego, a destacar a dissertação de (LACERDA, 2016), este trabalho propõe a criação e aplicação prática de uma ferramenta computacional de auxílio ao processo de análise de sensibilidade e calibração de modelos de microssimulação do *software* Vissim, escolhido por ter alta capilaridade no meio acadêmico e profissional, contando com uma robusta biblioteca de integração com a linguagem de programação Python, que é o *front-end* e *back-end* do VisLab. O *software* foi desenvolvido e aplicado na análise e calibração de uma rede pequena na área de Fortaleza, Ceará, possibilitando a realização de todas as análises sem necessidade de *softwares* externos, como o Excel, dando celeridade ao processo de análise. O módulo de calibração utilizando algoritmo genético realizou a calibração da rede do estudo de caso encontrando um erro de apenas 2,23% já na segunda geração. Assim, o resultado deste trabalho está disponível para toda a comunidade, na forma de um programa *open-source* no endereço <<https://github.com/matheusferreira195/VisLAB>>.

Palavras-chave: Microssimulação de tráfego. Python. Algoritmo genético. Calibração de microssimuladores.

ABSTRACT

Following the evolution of urban traffic microsimulation model's methods of calibration, highlighting the work of Lacerda (2016), this paper proposes the creation and application of a tool for helping on the effort of calibrating Vissim's traffic models. Vissim was chosen because is one of the most used softwares, as much in the academic field as in the professional field, for traffic simulation and for having a API that communicates with various languages, in special Python, that is the barebone behind VisLab's front-end and back-end. The software VisLab was developed and applied to a study case in which was calibrated a small net of Fortaleza, Ceará, making all the required analysis in one tool, eliminating the necessity of third-party programs like Excel, which grants speed and expediency to the process of calibrating a Vissim's model. It also was used the VisLab's calibration package on the study case, converging to a small error of 2,23% on the second generation. VisLab's source code is available to all community o utilize and contribute in <<https://github.com/matheusferreira195/VisLAB>>.

Keywords: Microscopic Traffic Simulation. Python. Genetic Algorithms. Micro simulators calibration.

LISTA DE FIGURAS

Figura 1 – Metodologia proposta por Lacerda (2016)	20
Figura 2 – Fluxograma de funcionamento básico de um algoritmo genético	24
Figura 3 – Fluxograma de funcionamento do <i>software</i> VISCAL	25
Figura 4 – Interface do <i>software</i> VISCAL	26
Figura 5 – Comparação dos métodos de calibração automatizados do VISCAL	26
Figura 6 – Tela do <i>software</i> GENOSIM	27
Figura 7 – Diagrama de um Experimento	29
Figura 8 – Fluxograma do AG utilizado no VisLab	32
Figura 9 – Interseções de estudo	32
Figura 10 – Volumes na Av. Humberto Monte x Rua José de Pontes	33
Figura 11 – Volumes na Av. Humberto Monte x Rua José de Pontes	33
Figura 12 – Tabela dos Tempos semafóricos na Av. Humberto Monte x Rua José de Pontes	34
Figura 13 – Tempos semafóricos na Av. Humberto Monte x Av. Jovita Feitosa	34
Figura 14 – Tabela dos Tempos semafóricos na Av. Humberto Monte x Av. Jovita Feitosa	35
Figura 15 – <i>Database esquema</i> do banco as.db (análise de sensibilidade)	37
Figura 16 – <i>Database esquema</i> do banco ga.db (calibração)	38
Figura 17 – Tela de Experimento s (Análise de Sensibilidade)	38
Figura 18 – Destaque 3: caixa de seleção de Experimento s	40
Figura 19 – Tela de Resultados da análise de sensibilidade	41
Figura 20 – Tela de configuração da calibração	42
Figura 21 – Tela de execução da calibração	43
Figura 22 – Tela principal da calibração	43
Figura 23 – Tela <i>Experiment Board</i> configurada	44
Figura 24 – Tela de configuração do Experimento 1	44
Figura 25 – Tela de configuração do Experimento 2	44
Figura 26 – Tela de configuração do Experimento 3	44
Figura 27 – Tela de configuração do Experimento 4	45
Figura 28 – Tela de configuração do Experimento 5	45
Figura 29 – Níveis de W74ax e replicações: Experimento 1	46
Figura 30 – Boxplot das médias dos níveis: Experimento 1	46
Figura 31 – Análise de Correlação (1,2): Experimento 1	47

Figura 32 – Análise de Correlação (1,4): Experimento 1	47
Figura 33 – Análise de Correlação (1,4): Experimento 1	48
Figura 34 – Intervalos de confiança para médias: Experimento 1	48
Figura 35 – Intervalos de confiança para teste de diferença de médias: Experimento 1	49
Figura 36 – Relatório do teste de diferença de médias: Experimento 1	49
Figura 37 – Níveis de W74bxAdd e replicações: Experimento 2	50
Figura 38 – Intervalos de confiança para teste de diferença de médias: Experimento 2	50
Figura 39 – Boxplot das médias dos níveis: Experimento 2	51
Figura 40 – Níveis de W74bxMult e replicações: Experimento 3	51
Figura 41 – Boxplot das médias dos níveis: Experimento 3	52
Figura 42 – Intervalos de confiança para as médias: Experimento 3	52
Figura 43 – Intervalos de confiança para teste de diferença de médias: Experimento 3	53
Figura 44 – Níveis de Agressividade e replicações: Experimento 4	54
Figura 45 – Boxplot das médias dos níveis: Experimento 4	54
Figura 46 – Análise de Correlação: Experimento 4	55
Figura 47 – Intervalos de confiança para médias: Experimento 4	56
Figura 48 – Intervalos de confiança para teste de diferença de médias: Experimento 4	56
Figura 49 – Níveis de Cautela e replicações: Experimento 5	57
Figura 50 – Boxplot das médias dos níveis: Experimento 5	57
Figura 51 – Análise de Correlação: Experimento 5	58
Figura 52 – Intervalos de confiança para médias: Experimento 5	59
Figura 53 – Intervalos de confiança para teste de diferença de médias: Experimento 5	59
Figura 54 – Resultados da calibração do Estudo de caso	60
Figura 55 – <i>Print</i> da tela de Calibração com informações detalhadas	60

LISTA DE TABELAS

Tabela 1 – Experimentos da análise de sensibilidade do estudo de caso	35
---	----

LISTA DE QUADROS

Quadro 1 – Cenários de calibração propostos por Lacerda (2016)	21
Quadro 2 – Estágios semaforicos na Av. Humberto Monte x Rua José de Pontes	34
Quadro 3 – Dicionário das variáveis da base de dados as.db	39
Quadro 4 – Dicionário das variáveis da base de dados ga.db	40

SUMÁRIO

1	INTRODUÇÃO	16
1.1	Contextualização	16
1.2	Justificativa	16
1.3	Objetivos	17
2	REVISÃO BIBLIOGRÁFICA	18
2.1	Análise de sensibilidade de modelos de microsimulação de tráfego	18
2.2	Técnicas de calibração e validação de microsimuladores de tráfego	19
2.3	Métodos meta-heurísticos aplicados a calibração de modelos de microsimulação de tráfego	21
2.3.1	<i>Algoritmos genéticos</i>	21
2.4	Aplicativos Existentes	22
2.4.1	<i>VISCAL</i>	23
2.4.2	<i>GENOSIM</i>	23
3	METODOLOGIA	28
3.1	Detalhes técnicos	28
3.2	Módulo de análise de sensibilidade	28
3.2.1	<i>Análise exploratória</i>	29
3.2.2	<i>Comparação de médias</i>	29
3.3	Módulo de calibração	31
3.4	Estudo de caso	31
3.4.1	<i>Local</i>	31
3.4.2	<i>Dados de entrada</i>	31
3.4.3	<i>Procedimento de análise</i>	35
4	RESULTADOS	36
4.1	Dicionário de dados	36
4.2	Classes	36
4.3	Módulo de Análise de Sensibilidade	36
4.3.1	<i>Função de cálculo do headway de saturação</i>	41
4.4	Módulo de calibração	42
4.5	Estudo de caso	43

4.5.1	<i>Análise de Sensibilidade</i>	43
4.5.1.1	<i>Experimento 1</i>	44
4.5.1.2	<i>Experimento 2</i>	48
4.5.1.3	<i>Experimento 3</i>	49
4.5.1.4	<i>Experimento 4 - Motorista Agressivo</i>	53
4.5.1.5	<i>Experimento 5 - Motorista Cauteloso</i>	55
4.5.2	<i>Calibração</i>	58
5	CONCLUSÕES E TRABALHOS FUTUROS	62
	REFERÊNCIAS	63

1 INTRODUÇÃO

1.1 Contextualização

Estima – se que as perdas econômicas devido aos gargalos dos sistemas de transporte urbanos causem um prejuízo de R\$ 7,6 mil por ano para cada proprietário de carro na cidade de São Paulo, onde 84% desse valor corresponde apenas pelas perdas relacionadas a tempo de deslocamento, segundo (CINTRA, 2014). Para abordar esse problema comum ao mundo moderno, estão sendo empregadas ferramentas avançadas de microsimulação computacional de sistemas de tráfego para auxiliar gestores a avaliarem cenários de intervenção e tomarem melhores decisões.

Nos casos onde o problema que os gestores lidam são complexos demais e há uma escassez de informações, as ferramentas de microsimulação de tráfego surgem como uma opção com boa relação custo-benefício, objetiva e flexível para análise de soluções e gerenciamento desses sistemas (HELLINGA, 1998). Entretanto, ainda há lacunas na literatura de como fazer a calibração e validação de tais modelos, o que motiva um esforço acadêmico no sentido de propor metodologias de calibração e validação dos modelos de microsimulação de tráfego para os contextos internacionais e nacionais. No âmbito nacional, a dissertação de Lacerda (2016) propôs um método de calibração e validação aplicados a estimação da velocidade média em vias urbanas da cidade de Fortaleza, no estado do Ceará, utilizando um *software* alemão no estado - da - arte da microsimulação de tráfego, VISSIM da empresa PTV Group.

Contudo, o processo de calibração dos modelos dos simuladores de tráfego continua sendo um processo longo, demorado e complexo, sujeito a falhas humanas na manipulação dos dados. Com isso, propõe – se nesse trabalho a elaboração de uma ferramenta de auxílio ao processo de análise de sensibilidade e calibração dos modelos de microsimulação de tráfego, permitindo ao analista obter escalabilidade, auditabilidade e agilidade no processo.

1.2 Justificativa

Com a crescente necessidade de utilização de modelos cada vez mais robustos e precisos na modelagem do tráfego urbano e rodoviário, a calibração e validação dos modelos comportamentais, em especial do *software* Vissim, que tem mais de 7000 licenças vendidas mundialmente, tornou – se uma etapa crítica no processo de análise e intervenção de redes de

tráfego veicular.

Entretanto, esse processo por muitas das vezes envolve um esforço laboral intenso por parte dos analistas, que precisam realizar vários processos de análise de dados, tornando o procedimento dispendioso e desorganizado. Devido a isso, é frequente a preferência dos analistas em fazer uma calibração ruim ou insuficiente a ter que despender os recursos humanos e operacionais à calibração, tornando a tomada de decisão de gestores deficiente.

Com isso, propõe-se uma consolidação dos principais métodos de análise de sensibilidade e calibração em um *software*, de forma a dar escalabilidade, velocidade e replicabilidade aos processos.

1.3 Objetivos

Com o objetivo geral de desenvolver uma ferramenta computacional que auxilie o processo de análise de sensibilidade e calibração de modelos de microssimulação de tráfego, surgem cinco objetivos específicos, que possibilitarão atingir o objetivo geral, a seguir.

- O primeiro objetivo específico é filtrar e selecionar as técnicas e metodologias para a análise de sensibilidade e calibração de modelos de microssimulação de tráfego utilizando o *software* Vissim na sua versão 11, dos modelos comportamentais de *car – following*, *lane changing* e *lateral movements*, abrangendo as técnicas de calibração automatizadas por algoritmo genético.
- O segundo objetivo específico é adaptar as técnicas e metodologias selecionadas na etapa anterior ao ambiente de desenvolvimento de *software*. Nessa etapa serão feitas adaptações que se julguem necessárias para poder consolidar as metodologias selecionadas em uma ferramenta computacional, com possíveis simplificações e traduções de algumas etapas.
- O terceiro objetivo específico é gerar o *blueprint* das funcionalidades e telas da ferramenta, que será dependente das técnicas selecionadas e adaptadas nos objetivos anteriores. Nessa etapa será feito o planejamento das funcionalidades, detalhando – se todo o esquema da operação em si, desde a concepção das telas do *software* quanto das estruturas dos bancos de dados.
- O quarto objetivo específico é codificar e documentar o *software*, em todo seu detalhamento técnico, dos cálculos feitos internamente pela ferramenta, assim como de sua utilização pelo usuário.
- O quinto e último objetivo específico é aplicar da ferramenta em um estudo de caso.

2 REVISÃO BIBLIOGRÁFICA

A fim de se desenvolver *features* relevantes aos analistas de tráfego, é necessário o estudo da literatura nos tópicos de análise de sensibilidade e calibração de microssimuladores de tráfego. Desta forma, dividiu-se esta seção para a revisão das técnicas de análise de sensibilidade, das técnicas de calibração, dos métodos de otimização heurísticos utilizados nas calibrações, finalizando com o levantamento dos estudos semelhantes já realizados.

2.1 Análise de sensibilidade de modelos de microsimulação de tráfego

A análise de sensibilidade pode ser entendida como uma técnica de estimação do impacto que determinados parâmetros de um modelo exercem em sua saída (SALTELLI *et al.*,). Em termos mais simples, pode-se definir como uma experimentação de um modelo.

Lacerda (2016) em seu trabalho propôs a análise de sensibilidade como uma ferramenta de entendimento do funcionamento dos parâmetros dos modelos do Vissim e como um critério de seleção dos parâmetros a serem inclusos na fase de calibração. Esse último caso tem como objetivo simplificar o esforço de calibração, que mesmo podendo ser automatizado, pode levar dezenas de horas. No caso do Vissim, há um total de 81 parâmetros passíveis de calibração.

Hollander e Liu (2008) sugerem que o analista escolha um número de parâmetros grande o suficiente para abranger os detalhes do fenômeno de estudo, mas pequeno o suficiente para se entender a contribuição de cada parâmetro nas medidas de desempenho. Sendo assim, Hollander e Liu (2008) sugerem que os parâmetros cuja influência nas medidas de desempenho sejam negligenciáveis devem ser excluídas da fase de calibração. Sendo assim, utiliza-se uma análise de sensibilidade para determinação de parâmetros relevantes ao estudo.

Quanto as técnicas utilizadas, Lacerda (2016) dividiu a análise em duas grandes áreas: análise uni-parâmetro, onde varia-se apenas um parâmetro por vez, técnica também chamada de "*one factor at a time*" (OFAT ou OF@T) (RAZAVI; GUPTA, 2015) e compara-se o a medida de desempenho em contraste à simulações com parâmetros em valores *default*. A outra técnica utilizada é a da análise multi-parâmetro, onde varia-se mais de um parâmetro por vez. Nesse caso, Lacerda (2016) criou perfis de condutores, onde cada perfil era uma combinação de parâmetros extremos. Por exemplo, o perfil "agressivo" representava motoristas que dirigem com pouca distância de segurança de outros veículos, associado a valores baixos de parâmetros do modelo de *car-following* de Wiedemann 74, enquanto que o perfil "cauteloso" remetia a

motoristas que dirigem com fartas distâncias de seguranças, associadas a valores de parâmetros altos.

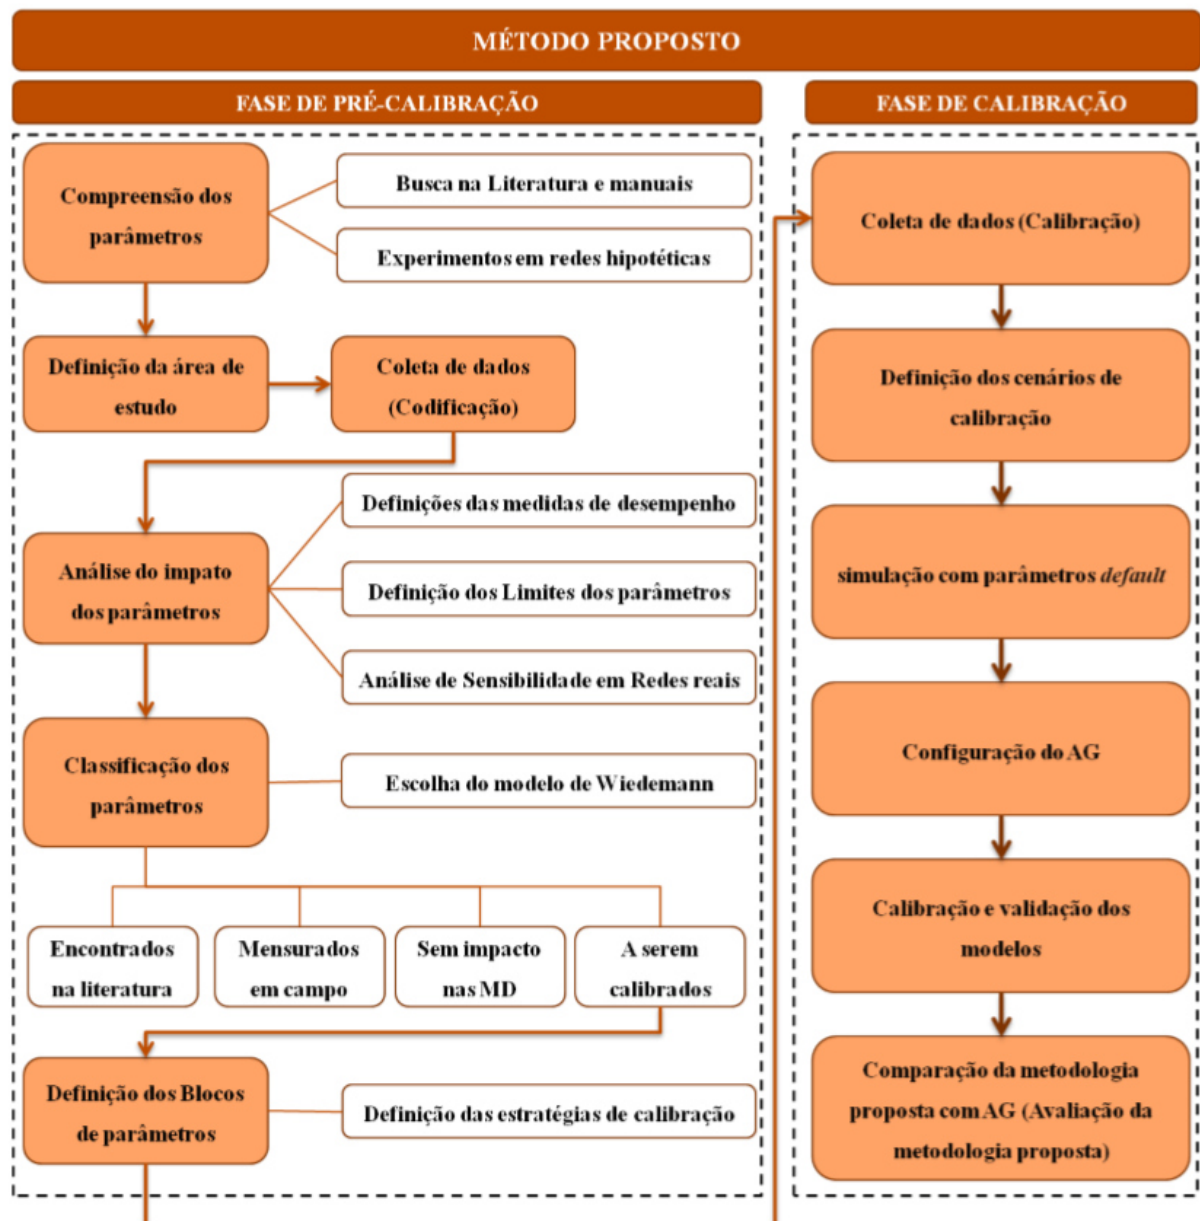
Para determinar se um valor ou perfil de parâmetro é relevante ou não, Lownes e Machemehl (2006a) utilizaram testes de diferença de médias, o mesmo que Lacerda (2016), usando uma distribuição t. Lownes e Machemehl (2006b) utilizou um teste ANOVA para a análise do impacto dos parâmetros na medida de desempenho.

2.2 Técnicas de calibração e validação de microssimuladores de tráfego

A calibração de um modelo pode ser compreendida como o ajuste deste com a realidade que se quer modelar. Fazendo uma analogia com arquearia, seria ajustar sua mira com o alvo. A validação seria uma confirmação de que esse modelo não está sobreajustado, ou seja, um modelo que apresenta resultados válidos apenas para a situação que foi calibrado. Um exemplo de sobreajuste seria uma rede que foi sobreajustada ao tráfego do pico da manhã e que não consegue representar o tráfego com um volume de entre-picos ou do pico da tarde. De qualquer forma, a literatura é vasta quanto as técnicas que podem ser utilizadas para a calibração dos modelos de tráfego do Vissim, que podem ser manuais, semi-automatizados e totalmente automatizados.

Dentre as técnicas manuais, pode-se destacar a dissertação de Lacerda (2016) por propor uma metodologia de calibração do *software* Vissim, como representado na Figura 1. Em sua metodologia, a análise de sensibilidade é feita em uma subfase da "fase de pré-calibração", denominada de "compreensão de parâmetros", onde a análise de sensibilidade é utilizada tanto para promover a maior compreensão dos parâmetros pelo analista, quanto para a escolha de quais destes serão inclusos na fase seguinte. Também nessa fase define-se a medida de ajuste, ou *goodness-of-fit*. Na fase seguinte, denominada "fase de calibração", utiliza-se de três estratégias: manual, semi-automatizada e totalmente automatizada. A estratégia manual consiste em definir um *range* de interesse para cada parâmetro incluso na calibração, de forma sequencial, e simular vários cenários até encontrar o menor erro que satisfaça o analista, por tentativa e erro. Lacerda (2016) também utilizou uma técnica de calibração semi-automatizada, onde um algoritmo genético realizava a calibração de forma simultânea de parte dos parâmetros, enquanto que a outra parte era calibrada manualmente de forma sequencial, conforme a Figura ???. Por fim, a estratégia de calibração automatizada e simultânea consiste na utilização de algum algoritmo de otimização, podendo ser algoritmo genético, *hill-climbing*, *simulated annealing*, dentre outros.

Figura 1 – Metodologia proposta por Lacerda (2016)



Fonte: (LACERDA, 2016)

Quadro 1 – Cenários de calibração propostos por Lacerda (2016)

Parâmetro / Cenário	0	1	2	3	4	5
Velocidade Desejada	Calibração Manual	Calibração Manual	Calibração Manual	AG	Calibração Manual	AG
ax	Calibração Manual	Calibração Manual	AG	AG	Calibração Manual	AG
bx_add	Calibração Manual	AG	AG	AG	Calibração Manual	AG
bx_mult	Calibração Manual	AG	AG	AG	Calibração Manual	AG
<i>Dur. Lack of attention</i>	<i>Default</i>	<i>Default</i>	<i>Default</i>	<i>Default</i>	AG	AG
<i>Prob. Lack of attention</i>	<i>Default</i>	<i>Default</i>	<i>Default</i>	<i>Default</i>	AG	AG
<i>Min. Headway front/rear</i>	<i>Default</i>	<i>Default</i>	<i>Default</i>	<i>Default</i>	AG	AG
<i>Safety Dist. Reduc. Factor</i>	<i>Default</i>	<i>Default</i>	<i>Default</i>	<i>Default</i>	AG	AG

Fonte: Lacerda (2016)

2.3 Métodos meta-heurísticos aplicados a calibração de modelos de microssimulação de tráfego

Os métodos meta-heurísticos tratam de técnicas de otimização avançadas que acham, geram ou selecionam uma heurística de otimização que forneça uma solução suficientemente adequada a um determinado problema de otimização (BIANCHI *et al.*, 2009). Geralmente são utilizados em casos onde o espaço de soluções é muito grande para ser explorado por métodos tradicionais, seja por limitações de poder computacional ou falta de informações. Entretanto, os métodos meta-heurísticos não garantem que será encontrada uma solução global do espaço de soluções (BLUM; ROLI, 2003).

2.3.1 Algoritmos genéticos

Os algoritmos genéticos são algoritmos meta-heurísticos inspirados no processo de seleção natural darwinianos, um grupo ainda maior de algoritmos de busca (HOLLAND *et al.*, 1992), cujo funcionamento básico está representado na Figura 2. Cada conjunto de soluções é chamada de indivíduo, os quais são constituídos de genes, uma representação de características únicas daquela solução. No caso dos processos de calibração, os genes seriam os parâmetros a

serem calibrados, enquanto que um indivíduo seria um conjunto de parâmetros. Por sua vez, um conjunto de indivíduos gerados na mesma iteração do processo são denominados de gerações, formadas a partir de diversas regras que podem ser diferentes de acordo com o tipo de algoritmo genético. A versão simples forma suas gerações a partir da predação dos indivíduos mais fracos, que são aqueles que tiveram um *fit* menor com a solução encontrada em campo, e do *crossover* dos indivíduos mais fortes, denominados de alfas, com os indivíduos normais, que não são nem alfas, nem fracos. A fim de evitar uma rápida conversão a uma solução local, é introduzido um fator de aleatoriedade no *crossover* dos indivíduos alfas com os normais, denominado de mutação.

Dentre as variações de algoritmos genéticos, temos os algoritmos genéticos adaptativos, chamados de AGAs, que utilizam as informações de cada geração para ajustar as probabilidades de *crossover* e mutação com o objetivo de manter a diversidade da população mantendo a capacidade de convergência (SRINIVAS; PATNAIK, 1994). Vemuri (1995) define outras três variações de algoritmo genético: o simples (gerações não – sobrepostas), o *steady – state* (gerações sobrepostas, SGA) e o *crowding – based*. O primeiro é o caso onde cada geração é completamente renovada na seguinte, tendo nenhum indivíduo completamente igual a geração anterior. Já no segundo uma fração da geração anterior passa intacta para a geração seguinte. Este algoritmo foi utilizado no trabalho de (LACERDA, 2016). Já o terceiro utiliza uma função de comparação a fim de determinar o grau de semelhança dos indivíduos novos (prole) gerados na população, em comparação com a anterior. Caso algum indivíduo da prole seja semelhante com a da geração anterior, este indivíduo será substituído pela prole. As regras de reprodução se mantêm as mesmas do SGA. Destacam – se também os trabalhos de (PARK; QI, 2005), (KIM *et al.*, 2005), (MA *et al.*, 2007), (MA; ABDULHAI, 2002) e (LACERDA, 2016), que utilizaram algoritmos genéticos na calibração de modelos de tráfego.

2.4 Aplicativos Existentes

Conforme mencionado anteriormente, a literatura apresenta uma lacuna tanto em processos de calibração e validação manuais, quanto automatizados. O processo de calibração e validação é extensivo e laborioso, muitas vezes abrindo mão da calibração de alguns modelos em favor de mais velocidade no processo. Destacam – se neste estudo dois softwares criados com o objetivo de automatizar o processo de calibração, o VISCAL e o GENOSIM, o primeiro aplicado ao software VISSIM e o segundo ao Paramics.

2.4.1 VISCAL

O software VISCAL foi concebido com o objetivo de criar uma solução não ad – hoc, ou seja, que não fosse específica para um problema particular. Como principais características, destacam – se a opção de se escolher até 3 algoritmos de otimização, algoritmo genético, *simulated annealing* e *simultaneous perturbation stochastic approximation*, além de fazer a calibração para mais de uma medida alvo (SIAM *et al.*, 2018). O fluxograma da aplicação está ilustrado na Figura 3 , juntamente com uma tela de sua interface, na Figura 4.

Quanto as medidas de desempenho, o VISCAL permite escolher o link de análise e três medidas: velocidade, fluxo e atraso, podendo ser feita também uma análise multi-critério.

Um dos grandes destaques do trabalho de Siam *et al.* (2018) é a comparação dos três tipos de calibração disponibilizados ao usuário. Na Figura 5, percebe-se um comportamento bem distinto entre as técnicas. Enquanto que o algoritmo genético apresenta grandes platôs seguidos de melhoras bruscas no *fitness*, o *simulated annealing* o faz de forma suave, a cada iteração, enquanto que o SPSA o faz de forma errática e ruidosa.

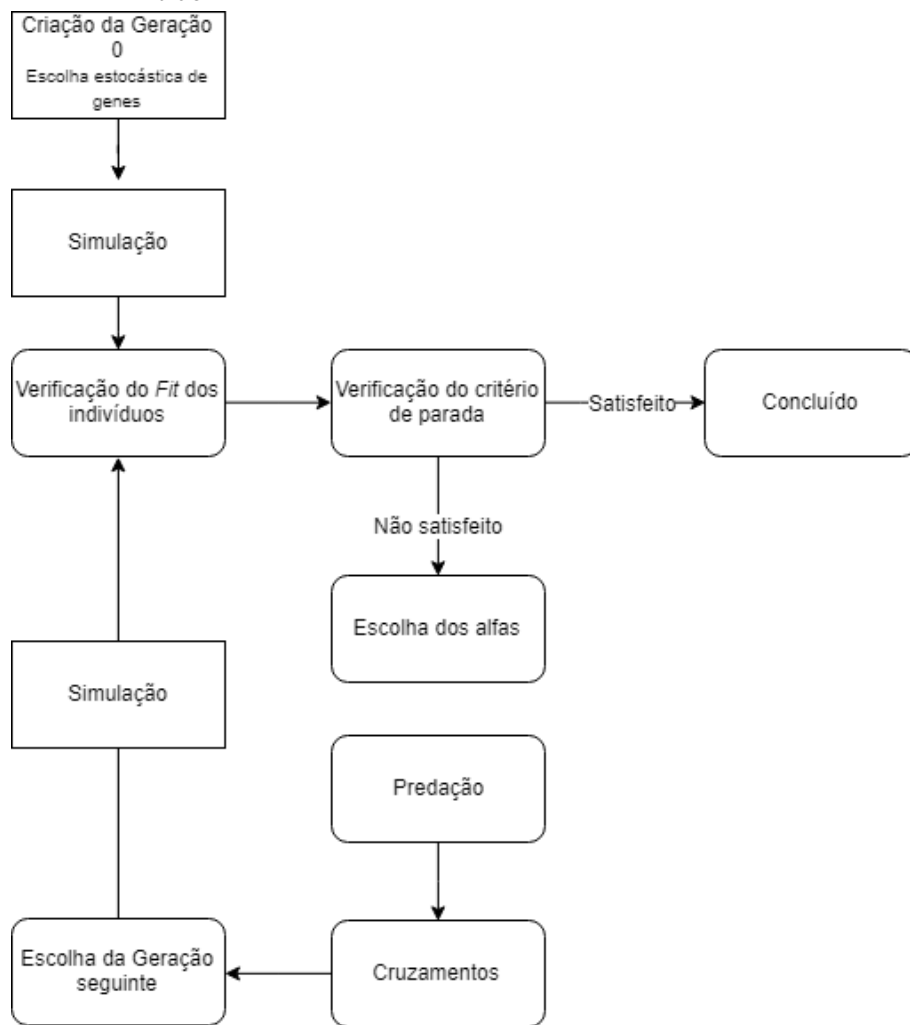
Entretanto, uma das limitações do VISCAL como ferramenta seria a falta de um módulo de exploração dos parâmetros, o que implica que o analista deveria fazer a análise de sensibilidade de forma manual.

2.4.2 GENOSIM

O software GENOSIM, amálgama dos nomes *genetic* e *simulation*, tem como proposta realizar a calibração dos modelos de *car-following*, *lane-changing* e *dynamic routing* do *software* Paramics, aplicado na cidade de Toronto, Canadá. Um destaque do trabalho de Ma e Abdulhai (2001) é permitir escolher entre três tipos de algoritmos genéticos para realizar a calibração: o simples, *steady – state* e *crowd based* (MA; ABDULHAI, 2001). Como medida de desempenho, foi utilizada apenas a contagem de veículos em dado trecho da via.

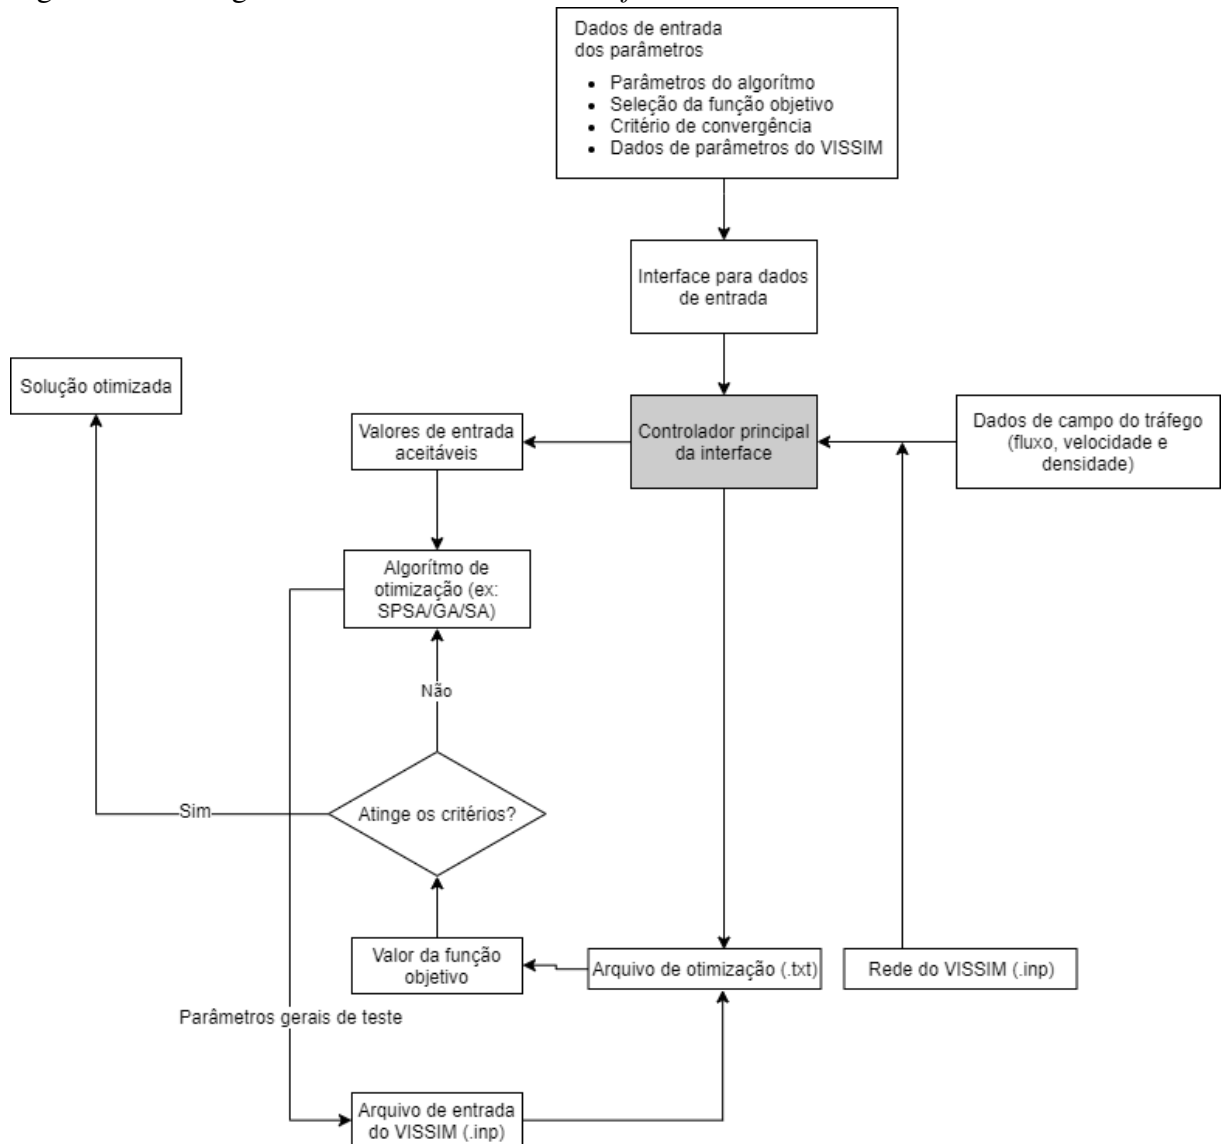
Além disso, Ma e Abdulhai (2001) também realizam a comparação entre os diferentes tipos de algoritmo genético em um estudo de caso, chegando a conclusão de que, apesar de todos os tipos serem satisfatórios, o *crowd-based* performou melhor que os outros dois tipos. Uma tela da *interface* do programa segue na Figura 6.

Figura 2 – Fluxograma de funcionamento básico de um algoritmo genético

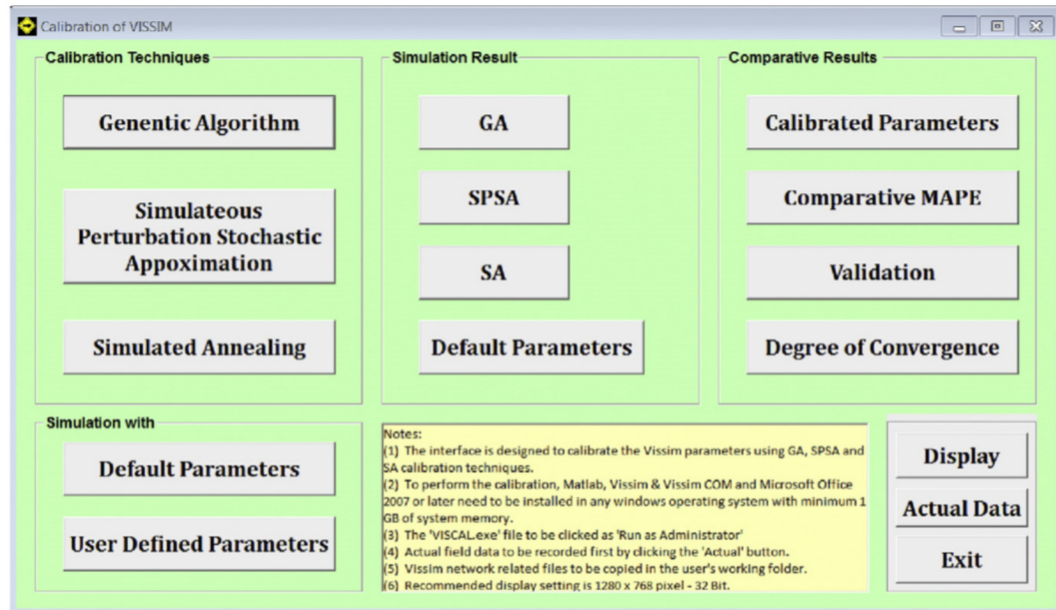


Fonte: Autor

Figura 3 – Fluxograma de funcionamento do *software* VISCAL

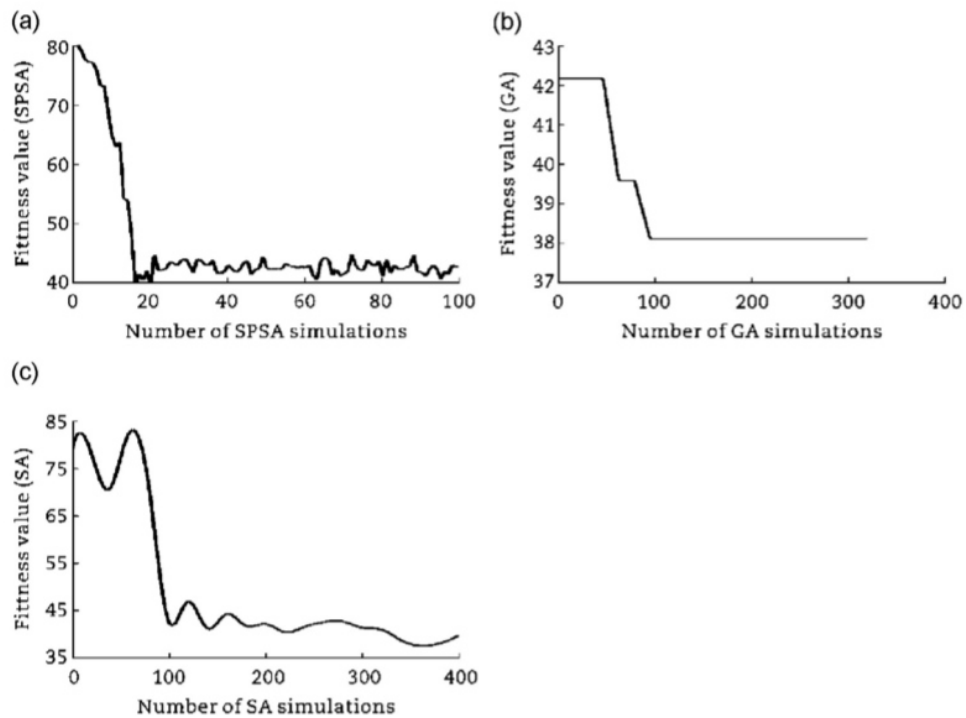


Fonte: Adaptado de (SIAM *et al.*, 2018)

Figura 4 – Interface do *software* VISCAL

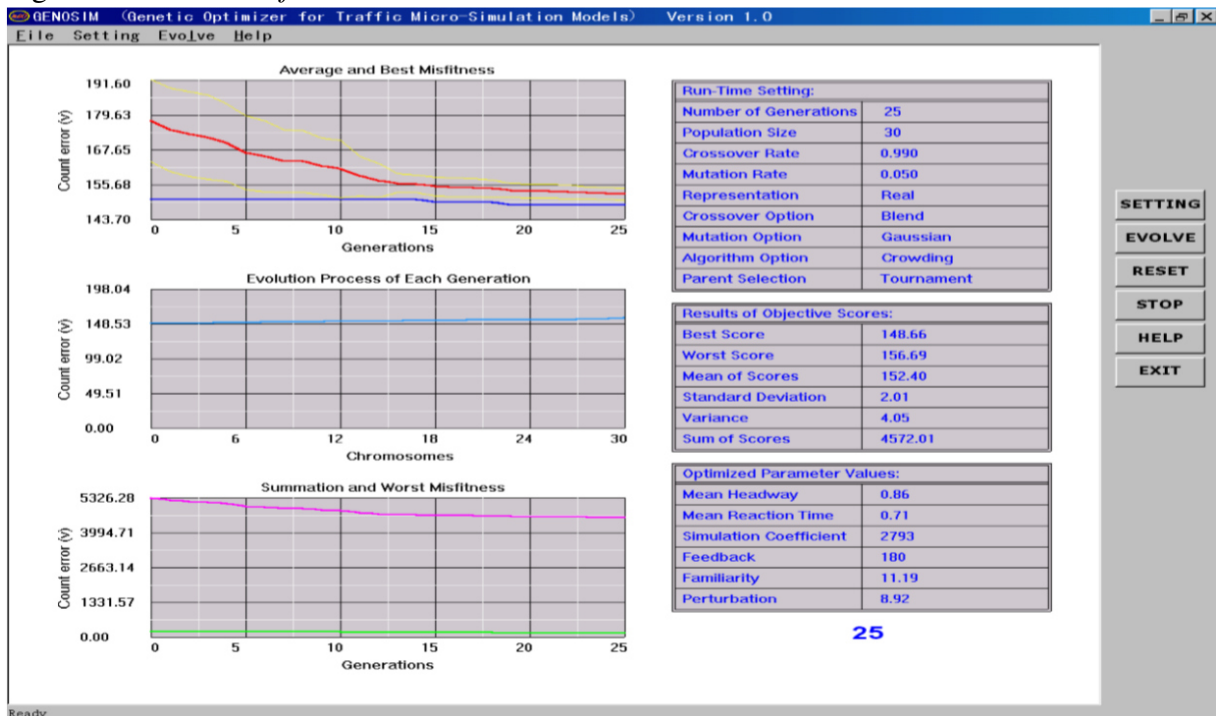
Fonte: (SIAM *et al.*, 2018)

Figura 5 – Comparação dos métodos de calibração automatizados do VISCAL



Fonte: (SIAM *et al.*, 2018)

Figura 6 – Tela do *software* GENOSIM



Fonte: (MA; ABDULHAI, 2001)

3 METODOLOGIA

Neste capítulo é abordado os detalhes técnicos de programação por trás do *back-end* e *front-end*, que são respectivamente a interface do usuário e a parte lógica do VisLab, seguido pela documentação e embasamento estatístico dos módulos de análise de sensibilidade e calibração, tendo por fim o detalhamento do estudo de caso de calibração de uma rede de tráfego urbano utilizando o VisLab.

3.1 Detalhes técnicos

O *software* foi desenvolvido em ambiente Windows, usando como *back-end* Python 3.6 e *front-end* o pacote nativo de Python 3.6, Tkinter. Para todas as manipulações de dados serão utilizados os pacotes Pandas, Numpy, Statistics e Sqlite.

Para visualização de dados, foi utilizado o pacote matplotlib. Como a maior parte das funcionalidades do *software* precisariam interagir com o Vissim, foi usado o pacote pywin32, que permite criar uma conexão COM (*Component Object Module*) com o python, permitindo também o acesso a todas as variáveis do Vissim e a automatização de tarefas.

Para o armazenamento de dados foi utilizado bancos de dados SQLite, devido sua facilidade de desenvolvimento e por permitir a usuários finais explorarem de forma simplificada os bancos de dados, utilizando por exemplo o *software* DB Browser. O seu código-fonte será aberto, com licença GPL 3.0.

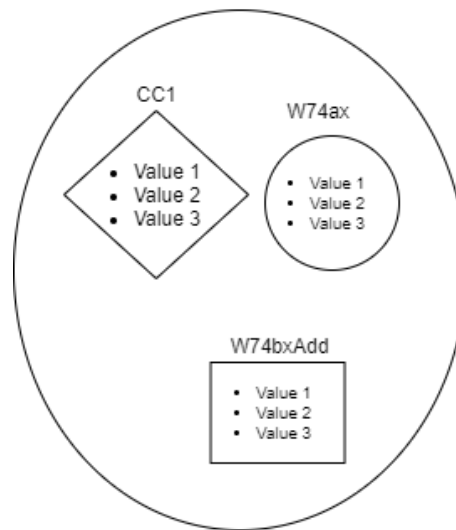
Pesquisadores interessados em contribuir podem acessar o código-fonte em github.com/matheusfe. O projeto será mantido pelo autor, adicionando novas *features* conforme *feedback* dos usuários.

3.2 Módulo de análise de sensibilidade

Esse módulo foi baseado no processo de calibração utilizado na dissertação de Lacerda (2016). Para adaptar a dinâmica dos perfis de parâmetros utilizada nessa dissertação, criará-se um artifício denominado de "experimento". Um experimento poderá ser um conjunto de parâmetros e/ou um *range* de parâmetros. A Figura 7 detalha processo.

Quanto a análise estatística dos resultados gerados, dividirá-se em dois grandes campos: a análise exploratória, que tem por fim gerar *insights* ao analista, e análise comparativa de médias, que dará evidências ao analista de que determinada configuração de parâmetros tem impacto nas medidas de desempenho de forma significativa, comparada a outra configuração.

Figura 7 – Diagrama de um Experimento
Experimento



Fonte: Autor

3.2.1 *Análise exploratória*

A análise exploratória, que consiste na exploração inicial dos dados gerados pelas simulações, em busca de inconsistências, *outliers* e padrões, poderá ser feita de duas formas:

- Gráfico de linhas;
- *Boxplot* de médias;

O gráfico de linhas conterà a medida de desempenho para cada replicação de todas as configurações do experimento. O *boxplot* de médias conterà o *boxplot* das médias das replicações para todas as configurações de um dado experimento.

3.2.2 *Comparação de médias*

A comparação de médias conterà quatro tipos de análises:

- Análise de correlação entre duas configurações de parâmetros;
- Intervalo de confiança para as médias;
- Relatório de diferença de médias;
- Intervalo de confiança para a diferença de médias;

O objetivo dessas análises e visualizações é evidenciar ao analista configurações que impactam as medidas de desempenho. Portanto, o primeiro passo é determinar se há ou não dependência entre as amostras das configurações, que no caso seriam replicações de uma simulação do Vissim. Para isso, fará-se um teste de correlação linear entre as duas amostras,

representado de forma gráfica pelo gráfico de pontos e reta de ajuste, juntamente com o coeficiente de correlação R. Essas análises serão feitas através do pacote Scipy, especificamente pela função "scipy.stats.linregress".

O intervalo de confiança é feito através de uma distribuição t-student, devido o desconhecimento da variância populacional. Computacionalmente, fará-se através da função "scipy.stats.t.interval". De acordo com a documentação oficial do pacote, o cálculo é feito através da Equação 3.1, retirada de (TRIOLA, 2008) . Todas as análises serão feitas para um nível de significância de 95%.

$$E = t_{\alpha/2} \frac{s}{\sqrt{N}} \quad (3.1)$$

No relatório da diferença de médias será mostrado ao usuário em texto a média de cada configuração, juntamente com o desvio padrão e o coeficiente de correlação R juntamente com a estatística de teste P para a hipótese nula de que tal coeficiente é zero, pela função "scipy.stats.pearsonr". Desse ponto o algoritmo determinará se a correlação é relevante ou não, ou seja, se a estatística de teste P é menor que o grau de confiança de 95%. Caso seja, fará-se um teste de diferença de médias pareadas pela distribuição t de Student, calculada de acordo com a Equação 3.2 , que é a função "scipy.stats.ttest_rel". Se for maior, evidenciando que não há correlação nas médias, fará-se o teste de médias para amostras independentes, utilizando também a função t de Student, conforme a Equação 3.3. A função computacional nesse caso seria a "scipy.stats.ttest_ind". Ambas as Equações 3.2 e 3.3 forma retiradas de Triola (2008).

$$t = \frac{\bar{d} - \mu_d}{\frac{s_d}{\sqrt{N}}} \quad (3.2)$$

$$t = \frac{(\bar{x}_1 - \bar{x}_2) - (\bar{\mu}_1 - \bar{\mu}_2)}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}} \quad (3.3)$$

O intervalo de confiança para a diferença de médias é o gráfico dos intervalos gerados no relatório de forma gráfica.

3.3 Módulo de calibração

A calibração foi feita através de um algoritmo genético (AG) de classe *crowding-based* modificado. O fluxo de funcionamento da calibração está ilustrado na Figura 8 . Em conjunto, foi feita uma interface que permitirá o usuário adicionar configurações do mecanismo do AG, alimentando um banco de dados em SQLite. A saída do processo é um gráfico mostrando o *fitness* do melhor indivíduo de cada geração, acompanhado de um relatório mostrando as informações dos seus genes. Para a formação das gerações $n+1$, o alfa passaria intacto para a geração seguinte, 19% dos indivíduos cruzariam com o alfa, ou seja, teriam 50% de chance de copiarem um gene do alfa, enquanto que os 80% dos indivíduos restantes seriam gerados aleatoriamente. Como medida de erro, foi utilizado o Erro Percentual Aritmético Médio (EPAM), definido na Equação 3.4. Nesse caso, x é referente ao valor coletado em campo e y ao valor simulado.

$$EPAM = \frac{(x - y)}{x} \quad (3.4)$$

3.4 Estudo de caso

O estudo de caso foi realizado em uma rede com dois grandes cruzamentos no bairro Parquelândia, em Fortaleza-CE.

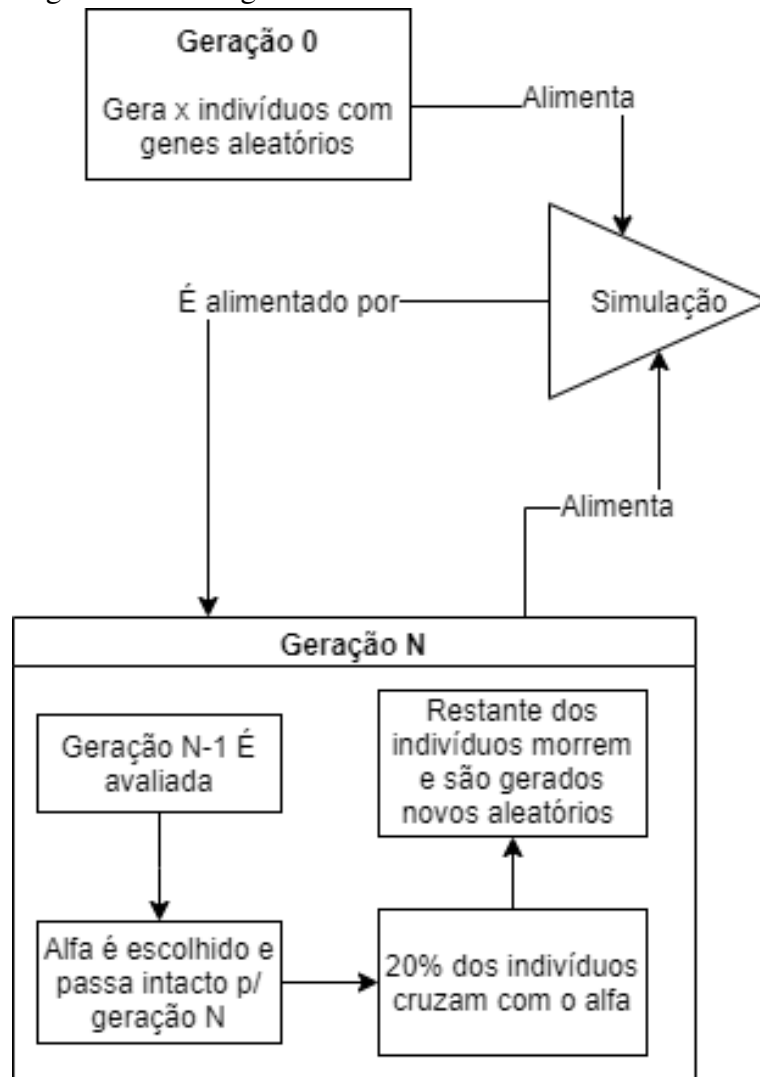
3.4.1 Local

O local de estudo compreende duas interseções semaforicas na avenida Humberto Monte, sendo a interseção com a rua José de Pontes e ao sul a avenida Jovita Feitosa, conforme ilustrado na Figura 9 .

3.4.2 Dados de entrada

Foram utilizados dados coletados no horário de 12h-13h. Para o estudo em questão, são utilizados os dados de volumes nas aproximações das interseções, os tempos semaforicos e os *headways* de saturação. Esse horário e local da via foram escolhidos devido a disponibilidade de dados.

Figura 8 – Fluxograma do AG utilizado no VisLab



Fonte: Autor

Figura 9 – Interseções de estudo



Fonte: Autor

Os volumes nas aproximações foram representados nas Figuras 10 e 11. Estes foram coletados através de contadores manuais.

Já os tempos semafóricos foram obtidos juntamente com o Controle de Tráfego em Área de Fortaleza (CTAFOR). Estão representados graficamente nas Figuras 2, 12, 13 e 14 .

Figura 10 – Volumes na Av. Humberto Monte x Rua José de Pontes



Fonte: Autor

Figura 11 – Volumes na Av. Humberto Monte x Rua José de Pontes



Fonte: Autor

Quadro 2 – Estágios semafóricos na Av. Humberto Monte x Rua José de Pontes



Fonte: Autor

Figura 12 – Tabela dos Tempos semafóricos na Av. Humberto Monte x Rua José de Pontes

PLANO 3	TEMPOS (s)				ESTAGIOS	
	VERDE	AMARELO	VERM.GERAL	VERMELHO	F1	0
LINKS						
6041 / 6043	46	4	2	52	F2	52
6042	22	4	2	76	F3	76
Pedestres	VERDE	VERM. INT.	VERMELHO			
P1	45	7	52			
P1/ P2 / P3	17	7	80			
Ciclistas	VERDE	VERM. PISC.	VERM. TOTAL	VERMELHO		
C1	46	4	2	52		

Fonte: Autor

Figura 13 – Tempos semafóricos na Av. Humberto Monte x Av. Jovita Feitosa



Fonte: Autor

Os *headways* de saturação foram obtidos por contagem manual, a partir do 3º veículo da fila no semáforo. No caso o *headway* de interesse é o da interseção Humberto Monte / José de Pontes, na aproximação Norte. Este foi utilizado na calibração do modelo. O *headway* tem valor médio de 2,38 segundos, para todas as faixas. O local e faixas foram escolhidos devido disponibilidade de dados.

Figura 14 – Tabela dos Tempos semafóricos na Av. Humberto Monte x Av. Jovita Feitosa

PLANO 3	TEMPOS (s)				ESTAGIOS	
	LINKS	VERDE	AMARELO	VERM.GERAL	VERMELHO	
	3242	35	4	3	102	F1 F2 42
	3245	46	4	2	92	F3 95
	3244/3246	43	4	3	94	
	3241	88	4	2	50	
	3243	85	4	3	52	

Fonte: Autor

3.4.3 Procedimento de análise

A análise do estudo de caso foi simplificada para fins de demonstração do uso do VisLab em uma situação prática. Dado isso, foi realizada a calibração de três parâmetros do modelo de *car-following*: W74ax, W74bxAdd e W74bxMult.

Normalmente, a escolha dos parâmetros seria derivada da análise de sensibilidade, porém devido as simplificações deste estudo de caso, foi feita uma análise de sensibilidade para determinar se esses três parâmetros causam impactos significativos na medida de desempenho quando comparados com os valores *default*.

Sendo assim, a análise de sensibilidade foi definida por cinco experimentos, detalhados na Tabela 1. Os experimentos W74ax, W74bxAdd e W74bxMult tem passo um de mudança de parâmetros.

Tabela 1 – Experimentos da análise de sensibilidade do estudo de caso

Experimento	Parâmetro	Domínio
1-W74ax	W74ax	1-4
2-W74bxAdd	W74bxAdd	1-10
3-W74bxMult	W74bxMult	1-10
4-Cauteloso + Default	W74ax W74bxAdd W74bxMult	1 e 2, 1 e 3, 1 e 3
5-Agressivo + Default	W74ax W74bxAdd W74bxMult	2 e 4, 3 e 10, 3 e 10

Fonte: o Autor, 2019.

Portanto, não serão calibrados aqueles valores cujo teste de hipótese para a diferença de médias com os valores de parâmetros *default* não apresente evidências suficientes para rejeitar a hipótese nula de que a diferença de suas médias é diferente de zero.

Já a calibração foi feita com os parâmetros que forem escolhidos da análise de sensibilidade, em um algoritmo genético com 10 gerações, indivíduos e replicações.

4 RESULTADOS

4.1 Dicionário de dados

O VisLab conta com duas estruturas de dados principais: o banco de dados "as.db" e "ga.db", para armazenar informações relativas a análise de sensibilidade e calibração, respectivamente. São estruturas de dados relacionadas, em SQLite. Os *database schemas* das duas bases podem ser visualizadas nas Figuras 15 e 16 além dos Quadros 3 e 4 com o título, tipos de campo e descrição.

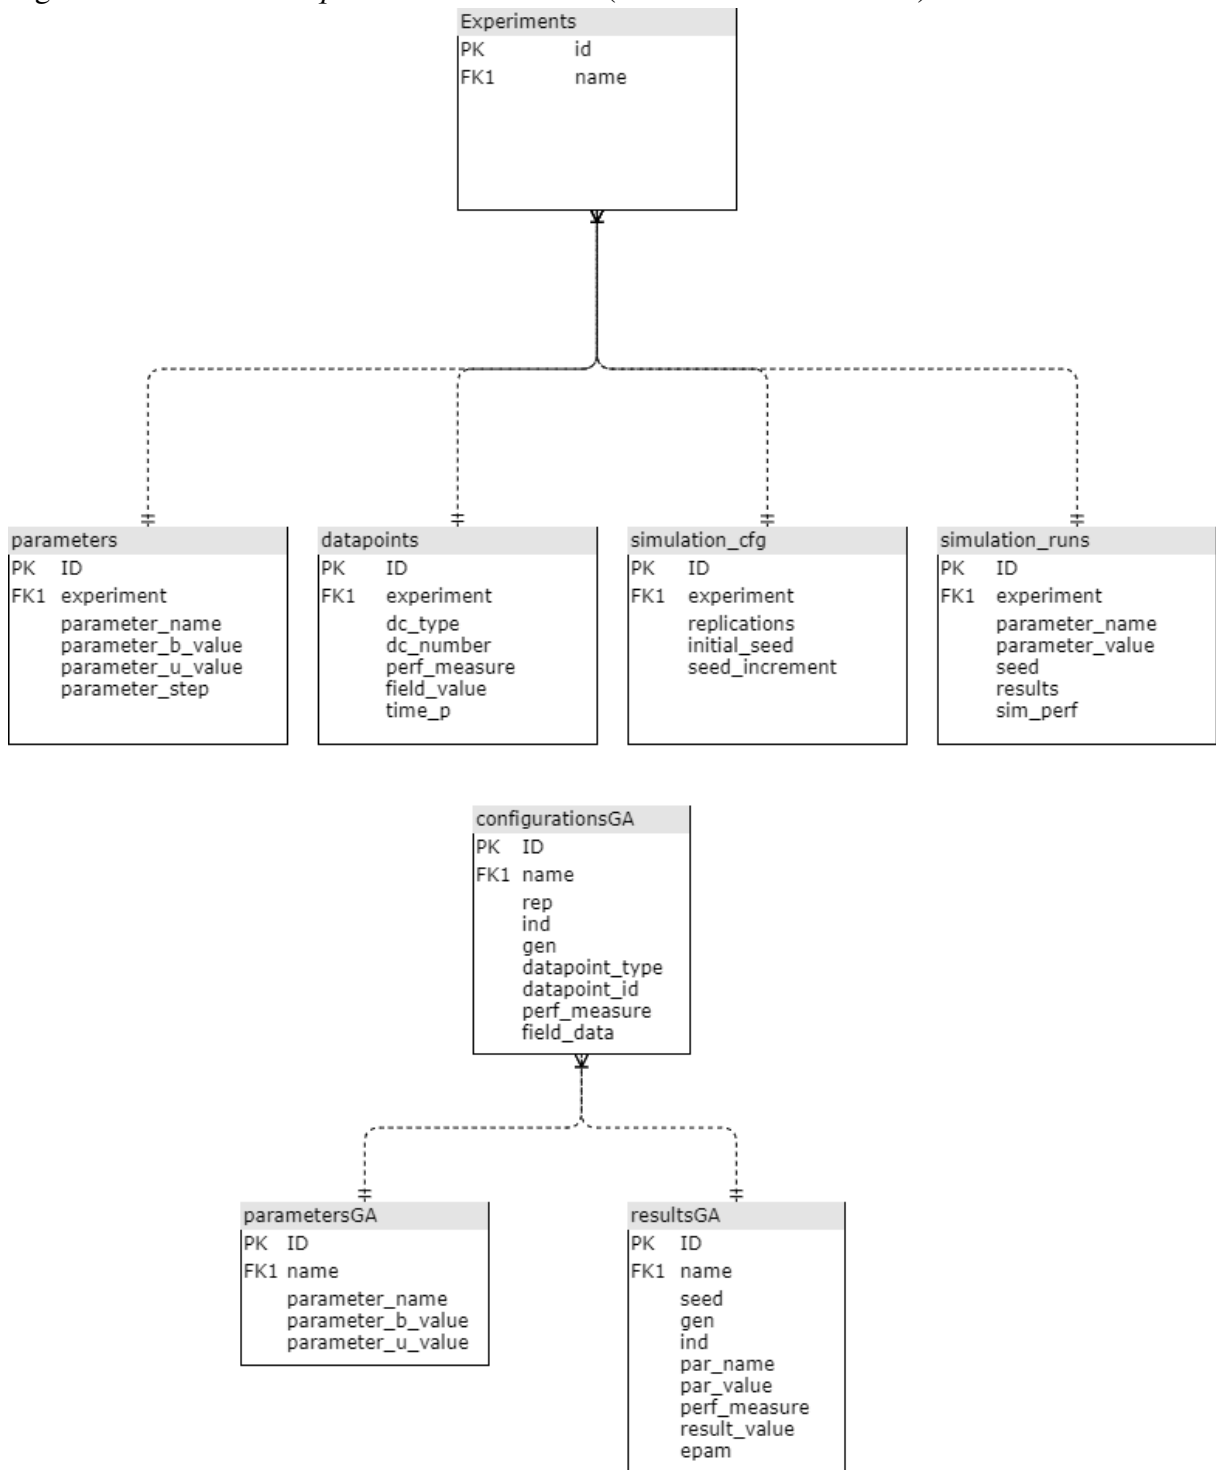
4.2 Classes

Por ser um *software* com GUI (*Graphical User Interface*) se faz necessário o uso de programação orientada a objetos (O.O.P). Por isso, foram criadas diferentes classes para as telas e funcionalidades. O programa conta com uma classe pai, "VisLab", que contém uma função similar a um *controller* no modelo REST. Essa função "*show_frame*" troca as telas do *software* conforme o desejo do usuário. A classe *StartPage* abriga os *widgets* e *layouts* da página inicial do *software*, onde a partir dela pode-se acessar as classes *ExperimentsPage*, *ResultsPage* e *CalibrationPage*, que cuidam respectivamente das páginas de Experimentos de análise de sensibilidade, resultados da análise de sensibilidade e página de calibração.

4.3 Módulo de Análise de Sensibilidade

O módulo de análise de sensibilidade, na Figura 17, contém quatro itens principais: o quadro resumo de Experimentos (destaque 1), que exibe alguns *status* dos Experimentos e o botão de configuração dos Experimentos (destaque 2), que abre a tela indicada na Figura 24. Nessa tela, o usuário pode inserir o ponto de análise da rede de interesse, que é um *measurement* do Vissim, que por sua vez pode ser um conjunto de *data collectors* ou *time travel collectors*, assim como *queue counters*. Ao selecionar o ponto de dados de interesse, o usuário pode selecionar a medida de desempenho, que muda de acordo com o ponto de dados. Um destaque seria a opção de selecionar o *headway* de saturação para os *data collectors*, que é uma medida de desempenho bastante utilizada pelos analistas e que não é fornecida de forma nativa pelo Vissim. Em seguida, o usuário pode escolher o parâmetro a ser avaliado, o *range* de níveis a serem alterados e quantas replicações fazer para um mesmo nível de parâmetro. Cada Experimento

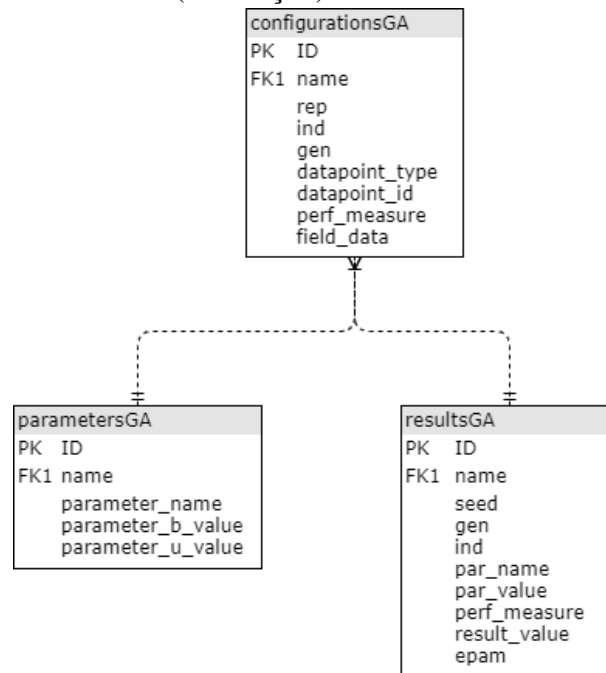
Figura 15 – Database schema do banco as.db (análise de sensibilidade)



Fonte: Autor.

pode conter vários parâmetros com vários níveis. O *software* gerará uma lista com todas as combinações de parâmetros possíveis e rodará as simulações correspondentes. Caso o usuário não queira rodar certos níveis, poderá editar manualmente a base sa.db e excluir os níveis não desejados na tabela "simulation_cfg". Portanto, caberá ao analista julgar o *trade-off* de realizar análises detalhadas que tenham altos custos de processamento, já que a combinação

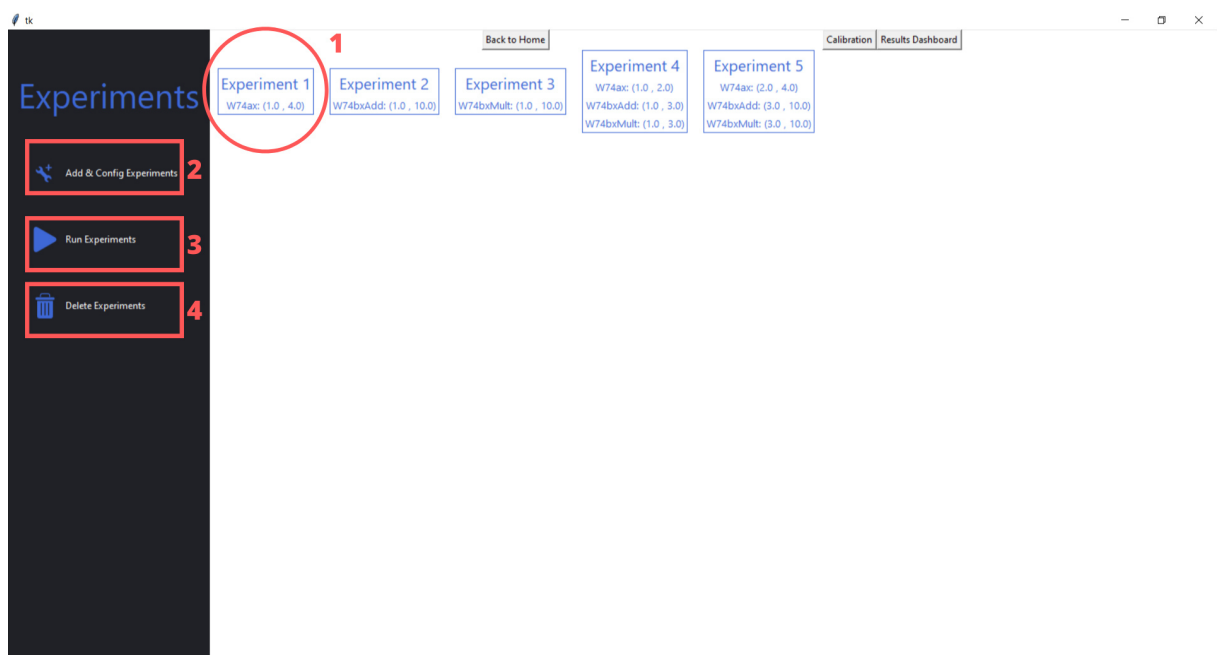
Figura 16 – *Database schema* do banco ga.db (calibração)



Fonte: Autor.

de parâmetros poderá crescer de forma exponencial. O destaque 3 abre uma caixa de diálogo para seleção dos Experimentos a serem simulados de forma sequencial, poupando ao analista a necessidade de manualmente selecionar um novo Experimento para simular, conforme a Figura 18. O destaque 4 é uma simples caixa de diálogo para exclusão de Experimentos.

Figura 17 – Tela de Experimentos (Análise de Sensibilidade)



Fonte: Autor.

Quadro 3 – Dicionário das variáveis da base de dados as.db

Tabela	Variável	Tipo	Descrição
experiments	id	PK - INTEGER	Identificador dos Experimentos de A.S
experiments	name	TEXT	Nome definido pelo usuário para o Experimento
parameters	ID	PK - INTEGER	Indexador da linha
parameters	experiment	FK - INTEGER	Chave de ligação com a tabela experiments
parameters	parameter_name	TEXT	Nome do parâmetro do modelo de microsimulação
parameters	parameter_b_value	REAL	Limite inferior do valor do parâmetro
parameters	parameter_u_value	REAL	Limite superior do valor do parâmetro
parameters	parameter_step	REAL	Passo de mudança do parâmetro
datapoints	ID	PK - INTEGER	Indexador da linha
datapoints	experiment	FK - INTEGER	Chave de ligação com a tabela experiments
datapoints	dc_type	TEXT	Tipo de data point da rede de simulação
datapoints	dc_number	INT	Identificador do data point, definido no Vissim
datapoints	perf_measure	TEXT	Nome da medida de desempenho
datapoints	field_value	REAL	Valor da medida de desempenho
datapoints	time_p	TEXT	Agregação de tempo dos resultados
simulation_cfg	ID	PK - INTEGER	Indexador da linha
simulation_cfg	experiment	FK - INTEGER	Chave de ligação com a tabela experiments
simulation_cfg	replications	INTEGER	Quantidade de replicações da simulação
simulation_cfg	initial_seed	INTEGER	Valor inicial da semente aleatória
simulation_cfg	seed_increment	INTEGER	Incremento da semente aleatória
simulation_runs	ID	PK - INTEGER	Indexador da linha
simulation_runs	experiment	FK - INTEGER	Chave de ligação com a tabela experiments
simulation_runs	parameter_name	TEXT	Nome do parâmetro selecionado e simulado
simulation_runs	parameter_value	REAL	Valor do parâmetro selecionado e simulado
simulation_runs	parameter_value	REAL	Valor do parâmetro selecionado e simulado

Fonte: Autor.

A próxima tela desse módulo seria a de resultados, representada na Figura 19 . Há um botão para poder gerar uma tela maior com o gráfico de interesse do analista, pois para

Quadro 4 – Dicionário das variáveis da base de dados ga.db

Tabela	Variável	Tipo	Descrição
configurationsGA	id	PK - INTEGER	Identificador das configurações do A.G
configurationsGA	name	FK - TEXT	Nome definido pelo usuário para a configuração do A.G
configurationsGA	rep	INTEGER	Quantidade de replicações
configurationsGA	ind	INTEGER	Quantidade de indivíduos
configurationsGA	gen	INTEGER	Quantidade de gerações
configurationsGA	datapoint_type	TEXT	Tipo de data point da rede para coleta de dados
configurationsGA	datapoint_id	INTEGER	Identificador do data point da rede para coleta de dados
configurationsGA	perf_measure	TEXT	Medida de desempenho alvo
configurationsGA	field_data	REAL	Valor de campo da medida de desempenho alvo
parametersGA	id	PK - INTEGER	Identificador das configurações do A.G
parametersGA	name	FK - TEXT	Nome definido pelo usuário para a configuração do A.G
parametersGA	parameter_name	TEXT	Nome do parâmetro (gene)
parametersGA	parameter_b_value	REAL	Limite inferior do valor do parâmetro (gene)
parametersGA	parameter_u_value	REAL	Limite superior do valor do parâmetro (gene)
resultsGA	id	PK - INTEGER	Identificador das configurações do A.G
resultsGA	name	FK - TEXT	Nome definido pelo usuário para a configuração do A.G
resultsGA	seed	INTEGER	Semente aleatória usada na simulação
resultsGA	gen	INTEGER	Geração simulada
resultsGA	ind	INTEGER	Indivíduo simulado
resultsGA	par_name	TEXT	Nome do parâmetro simulado
resultsGA	par_value	REAL	Valor do parâmetro simulado
resultsGA	perf_measure	TEXT	Nome da medida de desempenho alvo simulada
resultsGA	result_value	REAL	Valor da medida de desempenho alvo simulada
resultsGA	epam	REAL	Erro percentual médio da medida de desempenho alvo simulado

Fonte: Autor.

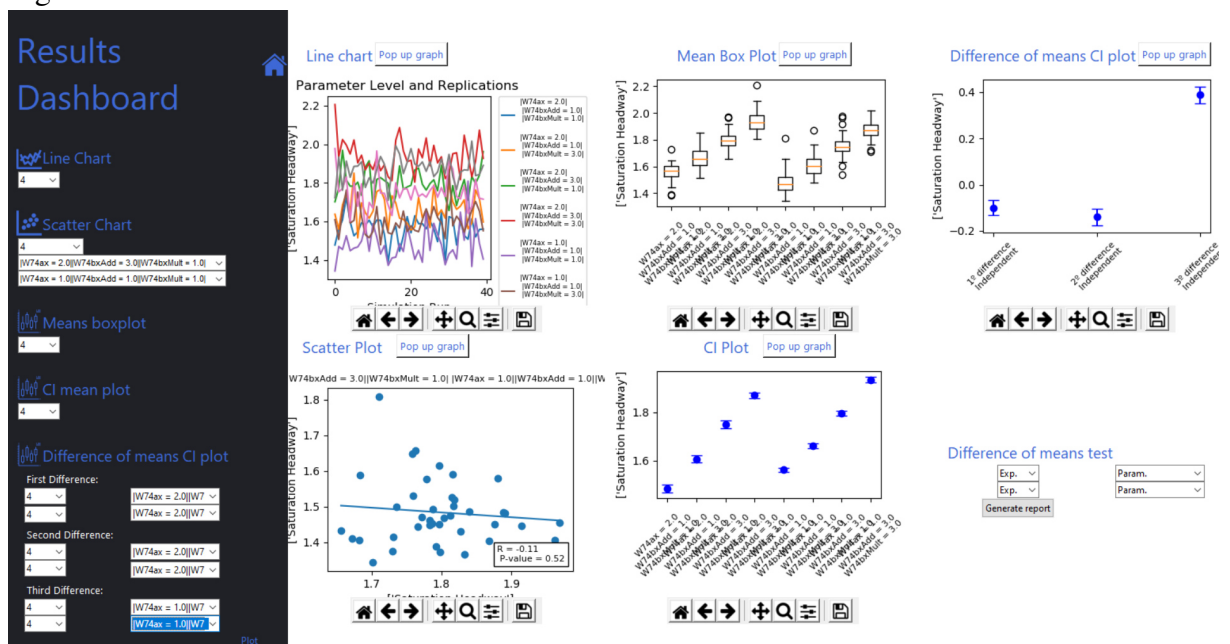
Figura 18 – Destaque 3: caixa de seleção de Experimento s

png.pdf png.png png.jpg png.mps png.jpeg png.jbig2 png.jb2 png.PDF png.PNG png.JPG png.JPEG png.JBIG2 png.JB2 png.ep

Fonte: Autor.

Experimentos complexos necessita-se de maior espaço para poder abrigar as análises. Os detalhes dos cálculos estatísticos por trás de cada análise podem ser conferidos no capítulo 3.2. Os gráficos *Line Chart*, *Means boxplot* e *CI mean plot* exibem resultados referentes a todos os níveis simulados para um Experimento, não permitindo portanto a comparação de diferentes Experimentos. Entretanto, os gráficos *Scatter Chart* e *Difference of means CI plot* permitem a comparação de dois e três Experimentos concomitantes, respectivamente. O relatório *Difference of means test* também permite esse tipo de análise, para um par de níveis de parâmetros. Este relatório permite que seus resultados sejam copiados e colados em editores de texto e de dados, como o Excel. Todos os gráficos podem ser formatados e salvos como imagem, para serem utilizados em relatórios e apresentações pelos analistas. O *layout* de cada gráfico e a sua interpretação foi abordada na seção 4.5, através de um estudo de caso.

Figura 19 – Tela de Resultados da análise de sensibilidade



Fonte: Autor.

4.3.1 Função de cálculo do headway de saturação

O cálculo da medida de desempenho *headway* de saturação, comentado anteriormente, é realizado através da função *"calculate_shdwy"*. Esta função explora todos os arquivos .mer e .lsa exportados pelo Vissim ao fim de cada replicação, que contém respectivamente dados dos *data collectors* e tempos semafóricos da rede. A função identifica os intervalos de verde e vermelho da rede, extraindo o *headway* do quarto veículo da fila.

4.4 Módulo de calibração

O módulo de calibração contém três opções: a configuração do algoritmo genético (Figura 20), a de simulação em si (Figura 21) e da exibição dos resultados da simulação (Figura 22), integrada na tela principal.

A primeira tela permite ao usuário definir os pontos de dados a serem utilizados no cálculo do *fitness*, a medida de desempenho e o valor de campo, juntamente com os parâmetros a serem calibrados e o espaço de busca dos parâmetros, definidos por um limite superior e inferior. Cada configuração pode ser salva como um perfil de calibração para posteriormente ser utilizado ou referenciado.

A segunda tela é simplesmente uma caixa de seleção do perfil de calibração criado na etapa anterior. Ao iniciar a calibração, todas as simulações serão executadas pelo Vissim, processo que pode levar algumas dezenas de horas a depender do tamanho da rede e da complexidade da calibração. Quanto mais gerações, indivíduos e replicações, mais acurado será o resultado e mais simulações demandará a calibração, podendo tornar o processo demorado.

A terceira tela exibe os resultados da calibração, em forma de um gráfico cujo eixo X exibe as gerações e o Y a evolução do *fitness* do alfa de cada geração. Na maioria dos casos esse gráfico exibirá um comportamento em formato de hóquei invertido, partindo de um erro inicial alto nas primeiras gerações para um erro baixo poucas gerações depois, de forma brusca. Aliada a este gráfico tem-se informações dos genes do melhor indivíduo de toda a calibração, assim como sua geração, EPAM e número de indivíduo.

Figura 20 – Tela de configuração da calibração

Genetic Algorithm configuration

Config calibration

Select saved config preset: (don't select if you want start a new one)

Preset name:

Number of generations:

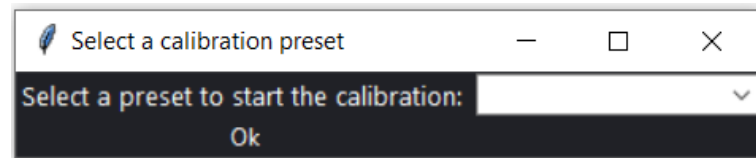
Number of individuals:

Number of replications:

Data Point:

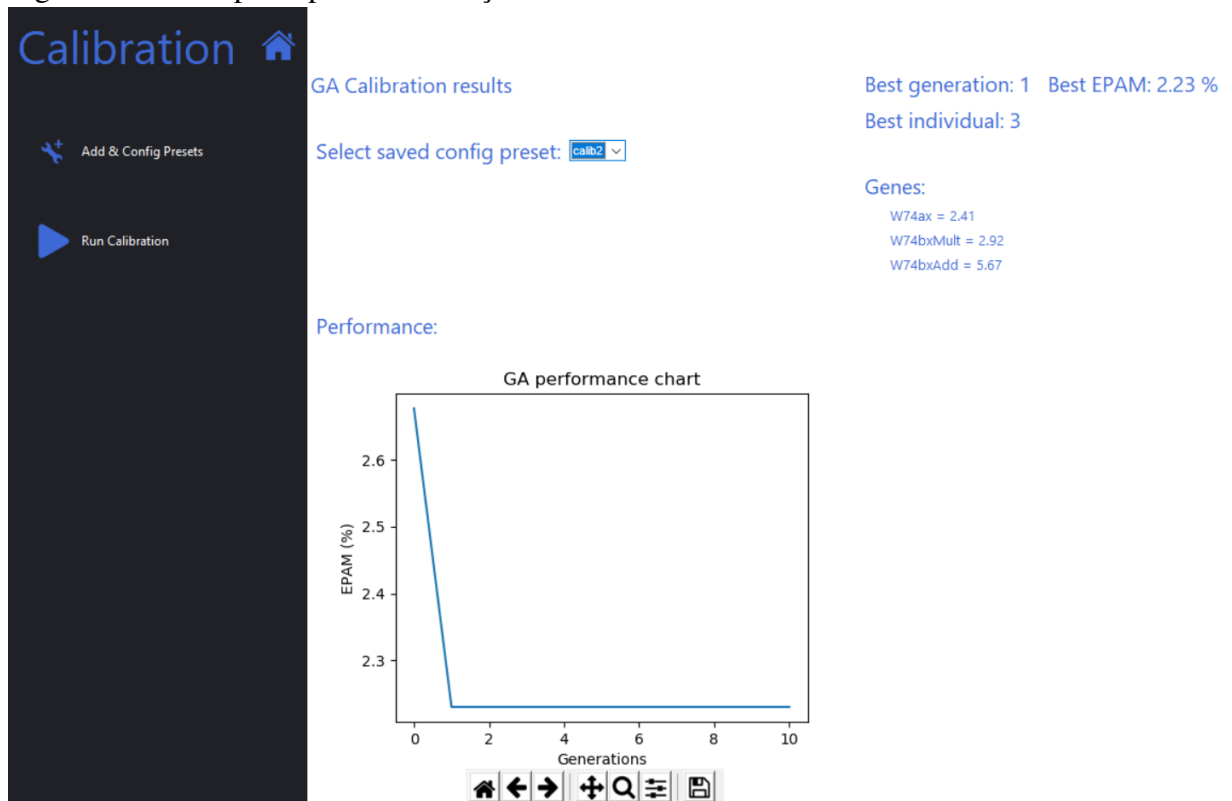
Fonte: Autor.

Figura 21 – Tela de execução da calibração



Fonte: Autor.

Figura 22 – Tela principal da calibração



Fonte: Autor.

4.5 Estudo de caso

4.5.1 Análise de Sensibilidade


Como definido no capítulo 3.4, a análise de sensibilidade foi realizada através dos cinco Experimentos definidos na Tabela ???. No VisLab, o primeiro passo a ser dado é carregar a rede de simulação, através do botão "Open Vissim net file (.inpx)". Com isso, é possível obter os dados dos pontos de coleta da rede. Na tela "Experiment Board", definiu-se os cinco Experimentos mencionados anteriormente, ilustrado nas Figuras 23, 24, 25, 26, 27, 28.

Após a simulação de todos os Experimentos, pode-se gerar os resultados na tela *Results*, introduzida na seção 4.3. A análise foi dividida por Experimento, nas seções a seguir.

Figura 23 – Tela *Experiment Board* configurada


Fonte: Autor.

Figura 24 – Tela de configuração do Experimento 1




Fonte: Autor.

Figura 25 – Tela de configuração do Experimento 2



Fonte: Autor.

Figura 26 – Tela de configuração do Experimento 3



Fonte: Autor.

4.5.1.1 Experimento 1

O parâmetro W74ax do modelo de *car-following* simula a distância estática que um motorista tende a deixar de outros. Por isso, é um parâmetro que costuma afetar o desempenho de interseções semaforizadas. No Experimento 1 esse parâmetro foi alterado de 1 à 4, com passo 1, como todos os outros Experimentos, onde para cada nível do parâmetro foram feitas 40 replicações. A partir da Figura 29 gerada a baixo, que mostra a evolução do *headway* de saturação durante as replicações, podemos ver que há uma relação entre o aumento do valor do W74ax com o *headway* de saturação. Como um maior W74ax implica em distâncias maiores entre os veículos quando parados, é natural esperar um aumento no tempo que os motoristas

Figura 27 – Tela de configuração do Experimento 4

The screenshot displays the configuration interface for Experiment 4, titled "Edit experiment". It features three vertically stacked panels, each representing a different data collector. Each panel includes the following elements:

- Data Points:** A dropdown menu for "Data Collector / 1" (set to "Saturation Headway"), a dropdown for "Add time interval number or aggregation" (set to "avg"), and a text input for "Add the field data to compare" (set to "2.39"). A "Save Changes" button is located to the right.
- Simulation Configs:** A section for "How many runs?" (set to "10"), "Set initial seed" (set to "42"), and "Set increment" (set to "1").
- Parameters:** A table with columns for "Parameters", "Inferior Limit", "Superior Limit", and "Step".

Parameters	Inferior Limit	Superior Limit	Step
W74ax: Average standstill distance (Wiedemann 74)	1.0	2.0	1.0
W74bvAdd: Additive factor for security distance (Wi	1.0	3.0	2.0
W74bvMult: Multiplicative factor for security distan	1.0	3.0	2.0

Fonte: Autor.

Figura 28 – Tela de configuração do Experimento 5

The screenshot displays the configuration interface for Experiment 5, titled "Edit experiment". It features three vertically stacked panels, each representing a different data collector. Each panel includes the following elements:

- Data Points:** A dropdown menu for "Data Collector / 1" (set to "Saturation Headway"), a dropdown for "Add time interval number or aggregation" (set to "avg"), and a text input for "Add the field data to compare" (set to "2.39"). A "Save Changes" button is located to the right.
- Simulation Configs:** A section for "How many runs?" (set to "10"), "Set initial seed" (set to "42"), and "Set increment" (set to "1").
- Parameters:** A table with columns for "Parameters", "Inferior Limit", "Superior Limit", and "Step".

Parameters	Inferior Limit	Superior Limit	Step
W74ax: Average standstill distance (Wiedemann 74)	2.0	4.0	2.0
W74bvAdd: Additive factor for security distance (Wi	3.0	10.0	7.0
W74bvMult: Multiplicative factor for security distan	3.0	10.0	7.0

Fonte: Autor.

levariam para sair do repouso e atravessar a interseção.

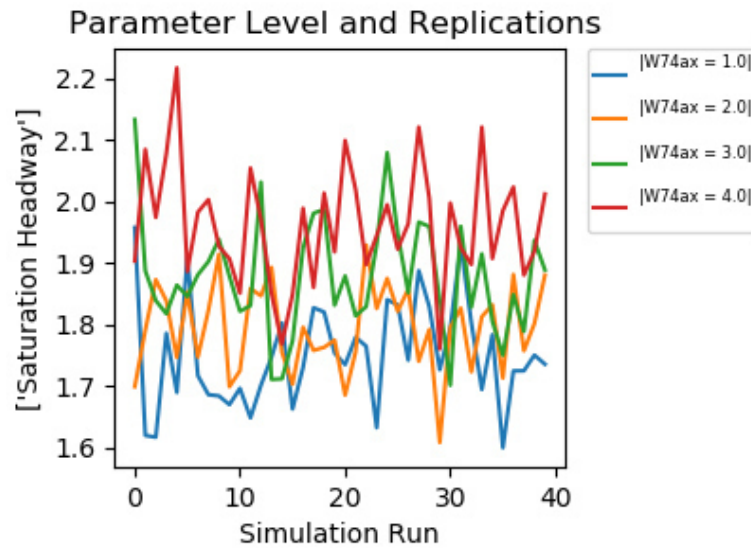
A Figura 30, do *boxplot* das médias de *headway* de saturação das simulações reforçam a tese de que o W74ax impacta de forma significativa as medidas de desempenho.

Vale ressaltar que todas as figuras e gráficos inclusos nesse estudo de caso foram gerados pelo VisLab.

A análise de correlação entre os resultados dos pares de níveis (1,2), (1,4) e (2,4), que compreendem ao menor valor com o *default*, menor com o maior e maior com o *default*, respectivamente, indica que todas as análises de comparação de médias serão independentes, pois não há padrão de correlação nos dois conjuntos de dados. Os Figuras 31,32 33 suportam as afirmativas.


A análise de correlação é necessária para verificar se os dados tem alguma outra

Figura 29 – Níveis de W74ax e replicações: Experimento 1



Fonte: Autor.

Figura 30 – Boxplot das médias dos níveis: Experimento 1



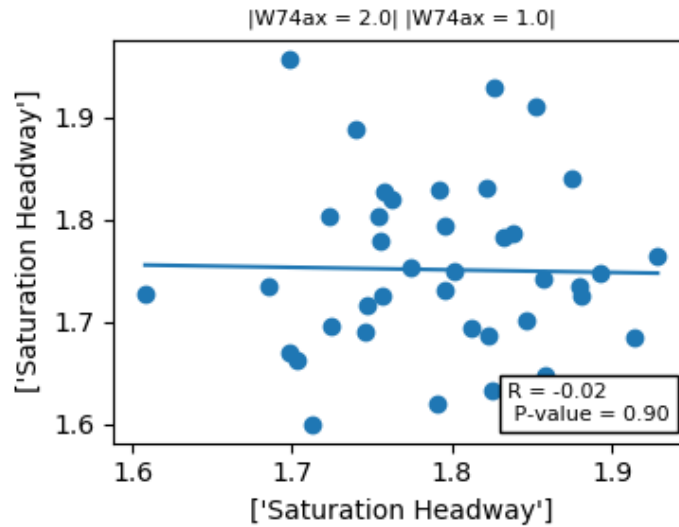
Fonte: Autor.

correlação que não seja linear. Como o teste de diferença de médias usa apenas a correlação linear para determinar se as amostras são pareadas ou não, é importante que o analista cheque se os dados realmente não tem correlação entre si ou se seguem uma correlação não-linear.

Entretanto, o intervalo de confiança das médias, visualmente representado no Figura 34, indica que para $W74ax = 1$, não há diferença significativa em relação ao valor *default*, que é 2 para o W74ax e 3 para o W74bxAdd/W74bxMult, o que não acontece para valores mais altos que o *default*.

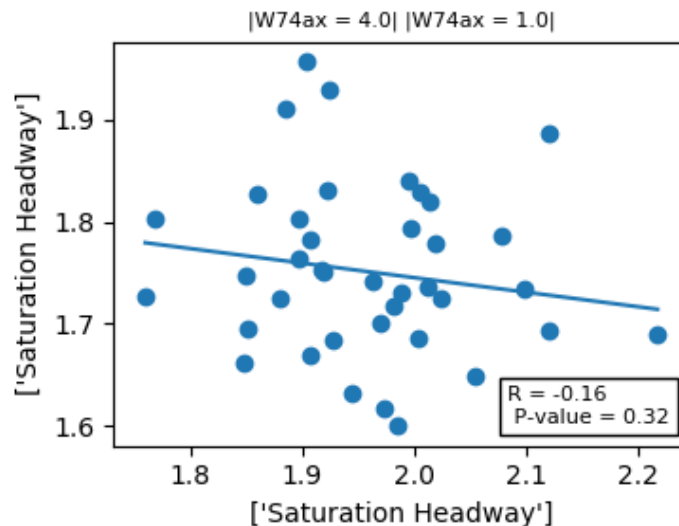
Por fim, o teste de diferença de médias foi feito entre três pares de níveis: 1º:(1,2), 2º:(4,2) e 3º:(1,4), sendo que os dois primeiros tem por objetivo avaliar se há diferença entre o

Figura 31 – Análise de Correlação (1,2): Experimento 1



Fonte: Autor.

Figura 32 – Análise de Correlação (1,4): Experimento 1

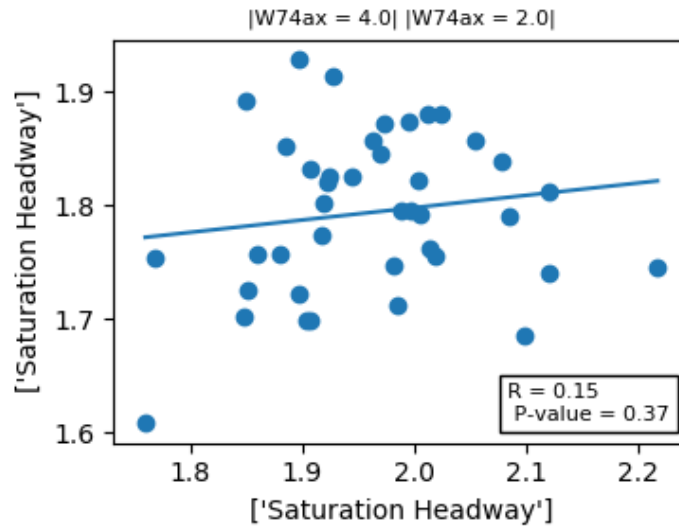


Fonte: Autor.

valor modificado e o *default*. A Figura 35 indica que a primeira diferença está muito próxima de ser nula, devido a quase inclusão do zero no intervalo de confiança. Já entre o valor *default* e máximo e entre mínimo e máximo, pode-se descartar com segurança a hipótese de que as médias das diferenças são nulas. Para determinar se a primeira diferença é significativa ou não, gerou-se o relatório de diferença de médias, na Figura 36, de onde pode-se concluir de que a diferença é significativa, já que seu *p-value* é menor que o valor crítico de 0.025.


Portanto, conclui-se que o parâmetro W74ax impacta a *headway* de saturação da rede de análise e deve ser incluso na calibração.

Figura 33 – Análise de Correlação (1,4): Experimento 1



Fonte: Autor.

Figura 34 – Intervalos de confiança para médias: Experimento 1




Fonte: Autor.

4.5.1.2 Experimento 2

O Experimento 2 avalia o impacto do parâmetro $W74bxAdd$, que é o componente multiplicativo da distância dinâmica entre veículos quando esses estão em movimento. Devido seu comportamento, infere-se que deve impactar a saída dos veículos da interseção, pois quanto menor esse parâmetro, menor o *headway* deixado entre os veículos quando em movimento.

Testa-se as hipóteses de forma similar ao Experimento 1. Primeiramente, as análises exploratórias nas Figuras 37 e 38 indicam que há diferenças entre os níveis de parâmetros.

Figura 35 – Intervalos de confiança para teste de diferença de médias: Experimento 1



Fonte: Autor.

Figura 36 – Relatório do teste de diferença de médias: Experimento 1

T test: paired sample mean difference		
	Variable 1	Variable 2
Mean	1.7505880243326046	1.7939439187742583
Variance	0.007245474528245591	0.005012077729590819
Observation	40	
Pearson Correlation	-0.020585707605121985	
Type test	Independent	
Mean difference hypothesis	0	
Degrees of freedom	39	
Stat t	-2.4767163387745623	
Two-tailed teste p-value	0.015497902792339365	

Copy to clipboard

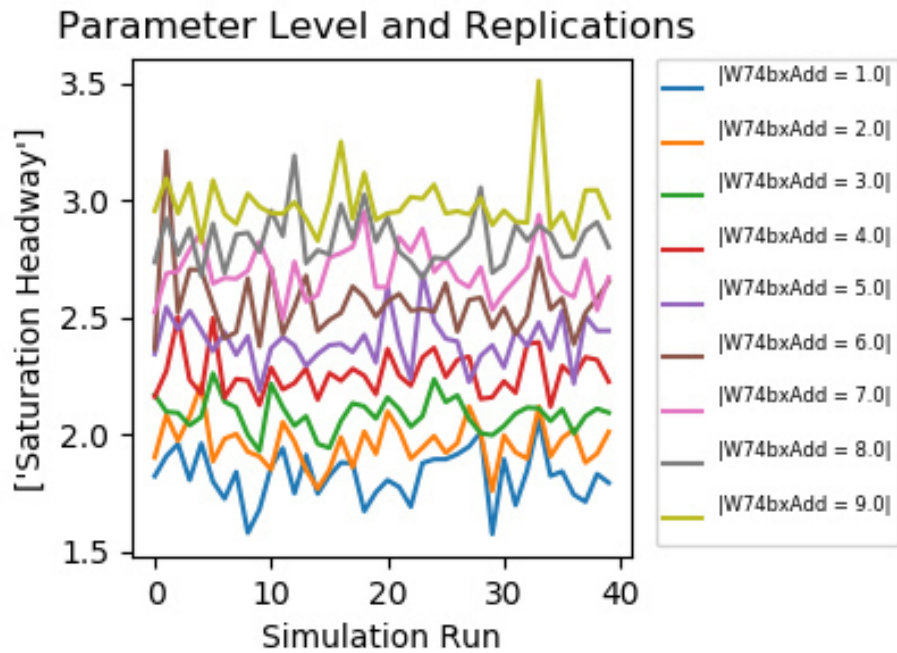
Fonte: Autor.

Para confirmar essas evidências, prossegue-se para a análise de diferença de médias. Para simplificar as análises, foi feita uma análise resumida e mais direta. Dividiu-se os níveis entre três grupos de diferenças, a 1º:(1,3), 2º:(10,3) e 3º:(1,10). Na Figura 39 pode-se concluir que de fato há diferenças significativas entre os níveis, já que nenhum dos intervalos de confiança para o teste da diferença de médias inclui o zero.

4.5.1.3 Experimento 3


O Experimento 3 compete a análise do parâmetro W74bxMult. Esse parâmetro é a parcela multiplicativa da distância dinâmica entre veículos quando em movimento, variando da

Figura 37 – Níveis de W74bxAdd e replicações: Experimento 2



Fonte: Autor.

Figura 38 – Intervalos de confiança para teste de diferença de médias: Experimento 2




Fonte: Autor.

mesma forma que o Experimento 2, de 1 à 10.

A análise exploratória dos resultados do Experimento 3 pode ser vista nas Figuras 40 e 41. A partir dessas figuras, observa-se que há evidências de comportamento similar aos Experimentos 1 e 2, já que há uma diferença acentuada na medida de desempenho conforme


Figura 39 – Boxplot das médias dos níveis: Experimento 2



Fonte: Autor.

aumenta-se o valor do W74bxMult.


Figura 40 – Níveis de W74bxMult e replicações: Experimento 3



Fonte: Autor.

Para confirmar as hipóteses levantadas, parte-se para a análise do intervalo de confiança das médias e de suas diferenças. A Figura 42 indica que há diferença significativa entre os níveis, apesar de serem menores que nos Experimentos anteriores. Já a Figura 43 confirma

Figura 41 – Boxplot das médias dos níveis: Experimento 3




Fonte: Autor.

que para os três pares de diferenças, 1º:(1,3), 2º:(10,3) e 3º:(1,10), há evidências suficientes para rejeitar a hipótese nula de que não há diferença entre essas médias.


Dessa forma, o parâmetro W74bxMult será incluso na calibração.

Figura 42 – Intervalos de confiança para as médias: Experimento 3



Fonte: Autor.

Figura 43 – Intervalos de confiança para teste de diferença de médias:
Experimento 3



Fonte: Autor.

4.5.1.4 Experimento 4 - Motorista Agressivo

Os Experimentos multi-parâmetro são necessários para identificar novas sinergias entre os parâmetros, onde podem ocorrer situações em que a análise uni-parâmetro não detecta que determinado parâmetro tem impacto na medida de desempenho, mas uma análise multi-parâmetro evidencia que há, ou seja, que o parâmetro se comporta de forma diferente quando alterado com outros parâmetros.

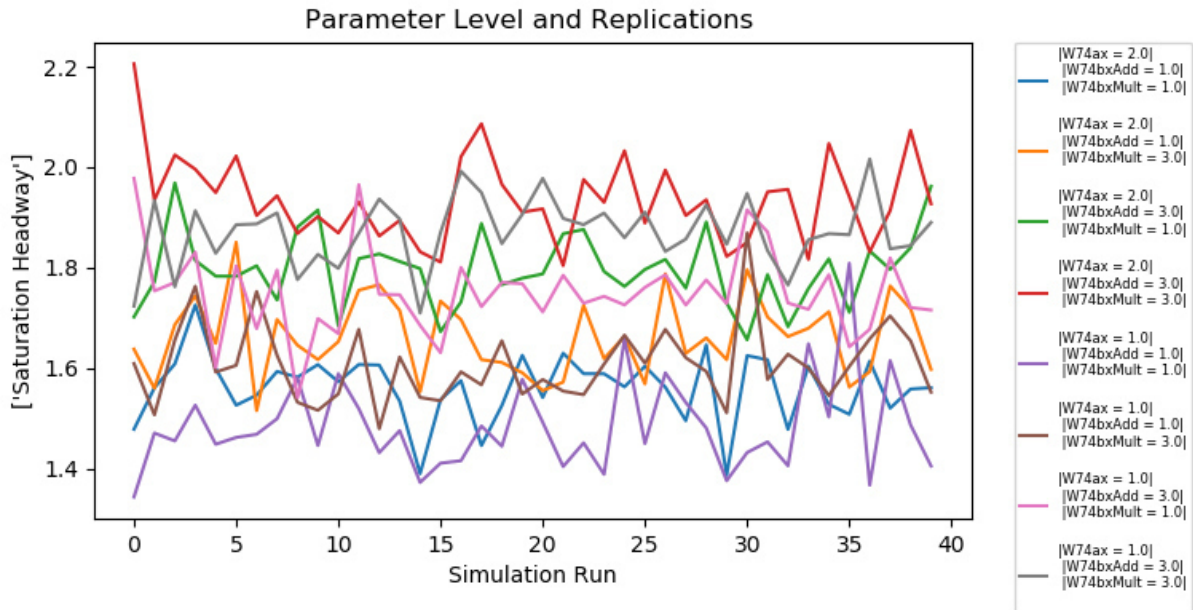
Apesar de os Experimentos 1-3 confirmarem a necessidade da inclusão dos parâmetros W74ax, W74bxAdd e W74bxMult, fará-se os Experimentos 4 e 5 para fins de demonstração da ferramenta.

Seguindo o padrão das análises anteriores, começa-se pela análise exploratória do Experimento . As Figuras 44 e 45 indicam que há um impacto da combinação de W74ax, W74bxAdd e W74bxMult, embora W74ax pareça impactar menos quando variado individualmente.

A análise de correlação da Figura 46 para os dois níveis mais críticos, o *default* e com valores mínimos, indica que não há nenhuma correlação entre os níveis e portanto, que as amostras não são pareadas.


O intervalo de confiança de médias da Figura 47 revela um comportamento interes-

Figura 44 – Níveis de Agressividade e replicações: Experimento 4



Fonte: Autor.

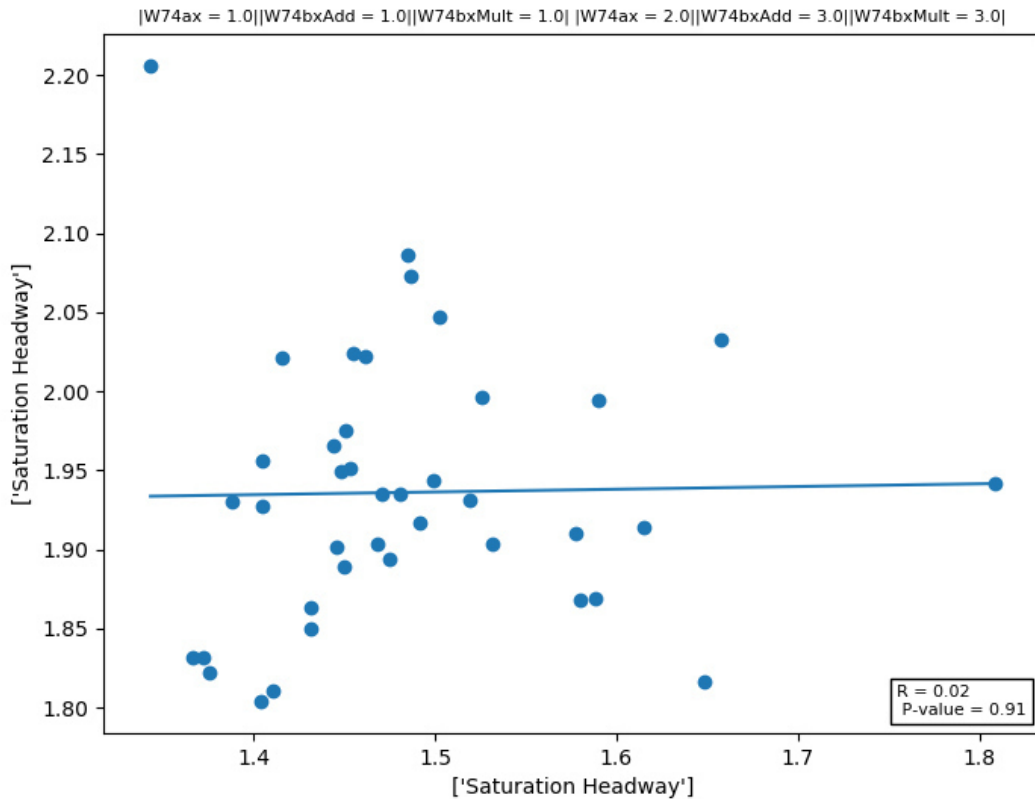
Figura 45 – Boxplot das médias dos níveis: Experimento 4



Fonte: Autor.

sante dos parâmetros: alterar apenas o W74ax parece impactar menos o *headway* de saturação do que alterar o W74bxAdd e W74bxMult.

Figura 46 – Análise de Correlação: Experimento 4




Fonte: Autor.

Já o intervalo de confiança para o teste de diferença de médias, na Figura 48, confirma que de fato há impacto na medida de desempenho para o perfil de parâmetros simulados. A primeira diferença é do *default* com o nível (1,1,1), a segunda do *default* com o nível (2,1,3), ou seja, alterando apenas o W74bxAdd, e a terceira diferença é entre o *default* e W74bxMult (2,3,1).

4.5.1.5 Experimento 5 - Motorista Cauteloso


O perfil cauteloso compreende os valores máximos dos parâmetros W74ax, W74bxAdd e w74bxMult. A ideia é representar um motorista que deixaria grandes distâncias de segurança dos veículos ao redor. Com isso, estima-se que o *headway* de saturação seja mais elevado. A análise exploratória do Experimento , nas Figuras 49 e 50 , indicam que há um impacto da combinação de W74ax, W74bxAdd e W74bxMult, embora não hajam diferenças visíveis na medida de desempenho quando se altera apenas um parâmetro. Isso indica que há uma sinergia entre os três parâmetros.

Figura 47 – Intervalos de confiança para médias: Experimento 4



Fonte: Autor.


Figura 48 – Intervalos de confiança para teste de diferença de médias: Experimento 4



Fonte: Autor.


A análise de correlação da Figura 51 para os dois níveis mais críticos, o *default* e com valores máximos, indica que não há nenhuma correlação entre os níveis e portanto, que as

Figura 49 – Níveis de Cautela e replicações: Experimento 5



Fonte: Autor.

Figura 50 – Boxplot das médias dos níveis: Experimento 5




Fonte: Autor.

amostras não são pareadas.

O intervalo de confiança de médias da Figura 52 indica que algumas combinações de parâmetros parecem ser equivalentes, apesar de terem valores diferentes entre si, como se a

Figura 51 – Análise de Correlação: Experimento 5



Fonte: Autor.


diminuição de um fosse compensada pelo aumento de outro. Esse detalhe do funcionamento do modelo é importante, pois uma ferramenta de calibração como o algoritmo genético pode chegar a uma solução ótima local aonde a combinação dos parâmetros é improvável de ser observada em campo, com valores extremos dos parâmetros.

O intervalo de confiança para o teste de diferença de médias, na Figura 53, confirma que de fato há impacto na medida de desempenho para o perfil de parâmetros simulados. A primeira diferença é do *default* com o nível (10,10,10), a segunda do *default* com o nível (2,10,10), ou seja, deixando apenas o W74ax em seu valor *default*, e a terceira diferença é entre o *default* e W74bxMult (4,3,3). Entretanto, a 3ª diferença parece ser bem próxima de zero, indicando que o W74ax isoladamente poderia ter menos impacto no *headway* de saturação.

4.5.2 Calibração


A calibração foi feita utilizando os parâmetros W74ax, W74bxAdd, W74bxMult, conforme consta detalhes na seção 3.4. Os resultados da calibração são exibidos nas Figuras 54

Figura 52 – Intervalos de confiança para médias: Experimento 5



Fonte: Autor.

Figura 53 – Intervalos de confiança para teste de diferença de médias: Experimento 5




Fonte: Autor.

e 55 .

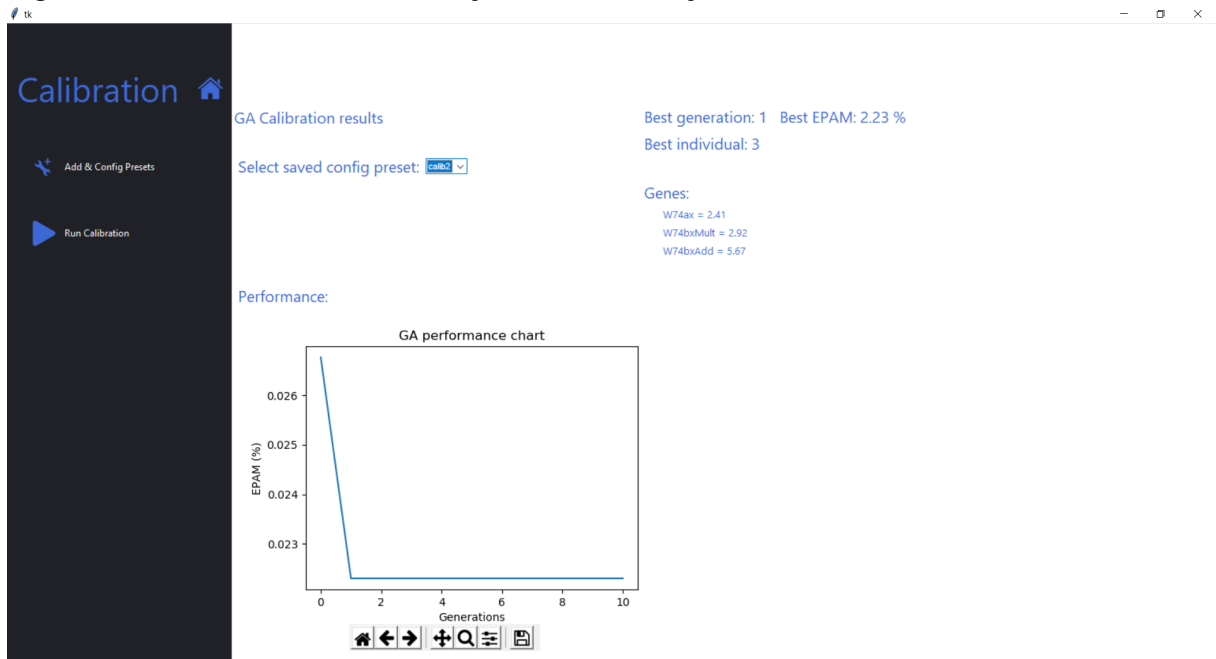
Portanto, o melhor alfa encontrado teve erro de 2.23%, já obtido na geração 1, a

Figura 54 – Resultados da calibração do Estudo de caso



Fonte: Autor.

Figura 55 – Print da tela de Calibração com informações detalhadas



Fonte: Autor.

segunda a ser simulada. Os algoritmos genéticos aplicados a pequenas redes tendem a encontrar as soluções de forma rápida. Entretanto, o valor encontrado não foi superado pelas 8 gerações seguintes. Entretanto, foi utilizado um valor pequeno de indivíduos e gerações. Os genes do alfa foram de 2,41 para o W74ax, 2,92 para o W74bxAdd e 5,67 para o W74bxMult.

Entretanto, um valor de 5,67 para o W74bxMult parece ser incoerente com um valor de W74bxAdd de 2,92. Esse fato evidencia a convergência do algoritmo genético em mínimos locais que apresentam combinações de parâmetros improváveis e incoerentes. Esse

comportamento também foi levantado no trabalho de Lacerda (2016).

5 CONCLUSÕES E TRABALHOS FUTUROS

O desenvolvimento do VisLab foi possível devido o atual nível das técnicas de calibração de modelos de microssimulação de tráfego. De fato, várias de suas *features* foram arquitetadas seguindo o *framework* de análise de Lacerda (2016), com o qual foi possível a criação de dois módulos robustos de análise com interface ao Vissim, de análise de sensibilidade e calibração. O estado atual da ferramenta já permite a análise expediente de redes de diversos tamanhos, reduzindo o trabalho dos analistas de tráfego.

Para demonstrar a potencialidade da aplicação, foi feito um estudo de caso com uma rede real da cidade de Fortaleza, Ceará, onde a ferramenta permitiu a análise totalmente *in-house*, sem a necessidade de *softwares* externos como Excel, o que dramaticamente simplifica o processo de calibração. A possibilidade de executar conjuntos de simulações em lote e de forma organizada também contribuiu para a redução do tempo de análise.

Entretanto, para se explorar o máximo de potencialidades de ferramentas como o Python e o Vissim, sugere-se para trabalhos futuros o desenvolvimento de um pacote, ou *library*, em Python que permitam a analistas com experiência em programação a criação de fluxos automatizados de análise e calibração de redes de microssimulação, empregando as técnicas de otimização no estado-da-arte.

REFERÊNCIAS

- BIANCHI, L.; DORIGO, M.; GAMBARDELLA, L. M.; GUTJAHR, W. J. A survey on metaheuristics for stochastic combinatorial optimization. **Natural Computing**, Springer, v. 8, n. 2, p. 239–287, 2009.
- BLUM, C.; ROLI, A. Metaheuristics in combinatorial optimization: Overview and conceptual comparison. **ACM computing surveys (CSUR)**, Acm, v. 35, n. 3, p. 268–308, 2003.
- CINTRA, M. Os custos dos congestionamentos na cidade de são paulo. 2014.
- HELLINGA, B. R. Requirements for the calibration of traffic simulation models. **Proceedings of the Canadian Society for Civil Engineering**, v. 4, p. 211–222, 1998.
- HOLLAND, J. H. *et al.* **Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence**. [S.l.]: MIT press, 1992.
- HOLLANDER, Y.; LIU, R. The principles of calibrating traffic microsimulation models. **Transportation**, Springer, v. 35, n. 3, p. 347–362, 2008.
- KIM, S.-J.; KIM, W.; RILETT, L. R. Calibration of microsimulation models using nonparametric statistical techniques. **Transportation Research Record**, SAGE Publications Sage CA: Los Angeles, CA, v. 1935, n. 1, p. 111–119, 2005.
- LACERDA, V. **Estimação da Velocidade Média em Vias Urbanas com Uso do Microssimulador VISSIM**. Dissertação (Mestrado) — Dissertação (Mestrado em Engenharia de Transportes). Programa de Pós . . . , 2016.
- LOWNES, N. E.; MACHEMEHL, R. B. Sensitivity of simulated capacity to modification of vissim driver behavior parameters. **Transportation Research Record**, SAGE Publications Sage CA: Los Angeles, CA, v. 1988, n. 1, p. 102–110, 2006.
- LOWNES, N. E.; MACHEMEHL, R. B. Vissim: a multi-parameter sensitivity analysis. In: IEEE. **Proceedings of the 2006 Winter Simulation Conference**. [S.l.], 2006. p. 1406–1413.
- MA, J.; DONG, H.; ZHANG, H. M. Calibration of microsimulation with heuristic optimization methods. **Transportation Research Record**, SAGE Publications Sage CA: Los Angeles, CA, v. 1999, n. 1, p. 208–217, 2007.
- MA, T.; ABDULHAI, B. Genetic algorithm-based combinatorial parametric optimization for the calibration of microscopic traffic simulation models. In: IEEE. **ITSC 2001. 2001 IEEE Intelligent Transportation Systems. Proceedings (Cat. No. 01TH8585)**. [S.l.], 2001. p. 848–853.
- MA, T.; ABDULHAI, B. Genetic algorithm-based optimization approach and generic tool for calibrating traffic microscopic simulation parameters. **Transportation research record**, SAGE Publications Sage CA: Los Angeles, CA, v. 1800, n. 1, p. 6–15, 2002.
- PARK, B.; QI, H. Development and evaluation of a procedure for the calibration of simulation models. **Transportation Research Record**, SAGE Publications Sage CA: Los Angeles, CA, v. 1934, n. 1, p. 208–217, 2005.

- RAZAVI, S.; GUPTA, H. V. What do we mean by sensitivity analysis? the need for comprehensive characterization of “global” sensitivity in earth and environmental systems models. **Water Resources Research**, Wiley Online Library, v. 51, n. 5, p. 3070–3092, 2015.
- SALTELLI, A.; RATTO, M.; ANDRES, T.; CAMPOLONGO, F.; CARIBONI, J.; GATELLI, D.; SAISANA, M.; TARANTOLA, S. **Global sensitivity analysis: the primer John Wiley & Sons; 2008**. [S.l.]: February.
- SIAM, M. R. K.; NASRIN, S.; HADIUZZAMAN, M.; MUNIRUZZAMAN, S. M.; HAQUE, N. Viscal: Heuristic algorithm based application tool to calibrate microscopic simulation parameters. **Journal of Traffic and Transportation Engineering (English Edition)**, Elsevier, v. 5, n. 1, p. 28–43, 2018.
- SRINIVAS, M.; PATNAIK, L. M. Adaptive probabilities of crossover and mutation in genetic algorithms. **IEEE Transactions on Systems, Man, and Cybernetics**, IEEE, v. 24, n. 4, p. 656–667, 1994.
- TRIOLA, M. F. Introdução à estatística. In: **Introdução à estatística**. [S.l.: s.n.], 2008.
- VEMURI, V. R. Multi-niche crowding for multi-modal search. **Practical handbook of genetic algorithms-New frontiers**, CRC Press Inc., v. 2, p. 6–10, 1995.