



UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE
CENTRO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E
DE COMPUTAÇÃO



Soft sensor veicular para medição de emissões de gases

Júlio César Melo Gomes de Oliveira

Orientador: Prof. Dr. Ivanovitch Medeiros Dantas da Silva

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e de Computação da UFRN (área de concentração: Engenharia de Computação) como parte dos requisitos para obtenção do título de Mestre em Ciências.

Número de ordem PPgEEC: M516
Natal, RN, dezembro de 2017

Universidade Federal do Rio Grande do Norte - UFRN
Sistema de Bibliotecas - SISBI
Catalogação de Publicação na Fonte. UFRN - Biblioteca Central Zila Mamede

Oliveira, Júlio César Melo Gomes de.

Soft sensor veicular para medição de emissões de gases / Júlio César Melo Gomes de Oliveira. - 2017.

53 f.: il.

Dissertação (mestrado) - Universidade Federal do Rio Grande do Norte, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica e de Computação. Natal, RN, 2017.

Orientador: Prof. Dr Ivanovitch Medeiros Dantas da Silva.

1. Poluição urbana - Dissertação. 2. Cidades inteligentes - Dissertação. 3. ODB-II - Dissertação. 4. CrowdSensing - Dissertação. I. Silva, Ivanovitch Medeiros Dantas da. II. Título.

RN/UF/BCZM

CDU 504.5

Soft sensor veicular para medição de emissões de gases

Júlio César Melo Gomes de Oliveira

Dissertação de Mestrado aprovada em 19 de dezembro de 2017 pela banca examinadora composta pelos seguintes membros:



Prof. Dr. Ivanoyich Medeiros Dantas da Silva (orientador) IMD/UFRN



Prof. Dr. Luiz Affonso Henderson Guedes de Oliveira DCA/UFRN



Prof. Dr. Daniel Gouveia Costa DTEC/UEFS

Agradecimentos

A minha família, todo apoio e incentivo que me forneceram durante todos os momentos da minha vida acadêmica.

A meu orientador Ivanovitch Medieros Dantas da Silva, pela oportunidade de trabalho que foram concedidas e toda orientação concedida.

Aos membros da banca, os professores Luiz Affonso Henderson Guedes de Oliveira e Daniel Gouveia Costa, por fazerem parte desse processo.

Aos docentes do programa de pós-graduação, pelas críticas, sugestões e apoio que foram oferecidas.

Aos colegas Jefferson Bruno, Cephas Barreto, Elton Viana e membros da Logap Sistema, por todo apoio fornecido.

Aos demais colegas de pós-graduação, pelo apoio fornecido e todos desafios que superados.

Todos os outros que de alguma forma influenciaram em minha vida acadêmica.

Resumo

Historicamente as cidades seguem modelos de planejamento reativos onde o gestor toma decisões conforme a ocorrência dos problemas. Por outro lado, o crescimento exponencial das Tecnologias da Informação e Comunicação (TIC) tem permitido que diversos sensores, dispositivos, sistemas e objetos se conectem, gerando dados que podem ser transformados em informação e usados em um paradigma de planejamento urbano mais eficiente onde as decisões podem ser tomadas antes que os problemas ocorram. Assim, nesse trabalho será desenvolvido um *software* capaz de estimar a quantidade de dióxido de carbono, a partir de leituras de sensores existentes em veículos, que irá contribuir para o planejamento proativo das cidades a partir do monitoramento da poluição veicular. Técnicas de *CrowdSensing* e um leitor *On-Board Diagnostic* (OBD-II) serão utilizados para extrair dados dos veículos em tempo real, armazenados localmente nos aparelhos que foram coletados. Por fim, podemos ver que a partir das informações obtidas, existe a possibilidade de se extrair informações a respeito do funcionamento do veículo e até mesmo realizar inferências sobre a dinâmica dos veículos nas cidades, mostrando potencial para o desenvolvimento de ferramentas auxiliares a gestão dos centros urbanos.

Palavras-chave: Cidades Inteligentes, poluição urbana, OBD-II, *CrowdSensing*.

Abstract

Traditionally, cities planning has followed reactive decision models based on the occurrence of problems. With the development and spread of communication and information technologies, the interconnection of electronic devices has opened a new era of data exchanging and processing, potentially supporting more efficient decisions in modern cities. This paper then proposes a software, capable of estimating the amount of carbon dioxide from existing sensor readings in vehicles, which aims to support more proactive planning and management of modern cities, addressing the problem of vehicular pollution monitoring. For that, a crowdsensing approach and the OBD-II standard are exploited to dynamically extract data from vehicles to be processed and delivered. Finally, we can see that with the information obtained, it is possible to extract information about the operation of the vehicle and even make inferences about the dynamics of the vehicles in the cities, showing potential for the development of auxiliary tools for the management of urban centers .

Keywords: Smart cities, Vehicular pollution, OBD-II, Crowdsensing.

Sumário

Sumário	i
Lista de Figuras	iii
Lista de Tabelas	v
1 Introdução	1
1.1 Motivação	2
1.2 Objetivo	3
1.3 Organização do trabalho	4
2 Referencial Teórico	5
2.1 Soft sensor	5
2.2 OBD	7
2.2.1 Interface de conexão OBD	8
2.2.2 CAN	8
2.2.3 Modos de operação do OBD-II	10
2.2.4 Scanners	11
3 Trabalhos relacionados	13
4 Metodologia	17
4.1 Veículo	18
4.2 Coleta de dados	18
4.3 Soft Sensor	20
4.3.1 Métodos de cálculo do CO ₂	20
4.3.2 Estimação de CO ₂	21
4.3.3 Mass Air Flow	22
4.3.4 Speed Density	23
5 Resultados	25
6 Conclusão	31
Referências bibliográficas	32

Lista de Figuras

2.1	Conector OBD-II em um veículo Toyota Etios 2015	8
2.2	Estrutura simplificada de uma rede CAN. Fonte: Autoria própria	9
2.3	Formato de um quadro CAN.	9
2.4	Fluxo de execução de um comando OBD.	10
2.5	Adaptadores OBD	12
4.1	Arquitetura do sistema	17
4.2	Fluxo de comunicação do sistema	18
4.3	Tela do aplicativo em funcionamento	19
5.1	Boxplot dados Chevrolet Agile	27
5.2	Mapa de calor trajeto Toyota Etios	29

Lista de Tabelas

2.1	Recursos do OBD-I.	7
2.2	Exemplo de aplicação de filtro.	9
2.3	Modos de Operação do OBD-II.	11
2.4	Modelos de scanners.	12
3.1	Resumo trabalhos relacionados	15
4.1	Fatores de conversão de combustível.	21
5.1	Resumo de dados coletados Chevrolet Agile	25
5.2	Estatística de dados coletados MAF	26
5.3	Estatística de dados coletados MAP	26
5.4	Resumo de dados coletados outros veículos	28
5.5	Resumo de dados coletados Etios 2015	28

Capítulo 1

Introdução

A urbanização desenfreada, aliada ao rápido crescimento populacional, tornaram-se grandes desafios ao desenvolvimento sustentável nos centros urbanos. Essas características passaram a ser alvo de estudos e colocaram em destaque um tema, até então, pouco explorado: as Cidades Inteligentes (Zanella et al. 2014). Torna-se necessária, portanto, a implementação de soluções inteligentes que facilitem o planejamento e a tomada de decisões baseados em informações estratégicas, de modo a dar uma resposta mais eficaz à dinâmica das cidades (Bonino et al. 2015).

Cidades Inteligentes são formadas pela combinação de sistemas de comunicação ubíquos, sistemas autônomos de gerenciamento, redes de sensores sem fio instalados em pontos de interesse, uma infraestrutura de comunicação robusta, além da integração de diversos serviços que compõe o cerne dos centros urbanos (energia, transporte, saúde, etc) (Soheily-Khah et al. 2016). Esses sistemas devem ser responsáveis pela coleta e integração de uma quantidade massiva de dados, constituindo a base do que conhecemos atualmente por "Internet das Coisas" (Al-Fuqaha et al. 2015). A interpretação desses dados brutos gera informação que pode ser utilizada na criação de novas aplicações, oferecendo um leque de serviços que beneficiam a sociedade e o desenvolvimento sustentável dos centros urbanos (Stankovic 2014, Monzon 2015).

Felizmente, a concepção de novas ideias e o desenvolvimento de aplicações para Cidades Inteligentes não está condicionado apenas aos governos. Esta realidade tem fomentado a criação de um novo modelo de negócio, onde o cidadão tem a liberdade de desenvolver e comercializar suas soluções (Ojo et al. 2015). Ainda que os dados coletados pelos governos não sejam abertos ao público, a extração destes pode ser realizada de diversas outras maneiras, como, por exemplo, por meio do conceito de *crowdsensing* (Bellavista & Ianniello 2015). Nessa abordagem, os sensores são representados pelas próprias pessoas, criando uma infraestrutura virtual em paralelo à infraestrutura física já existente. Os cidadãos, através de seus celulares, relógios, carros e outros *gadgets*, podem compartilhar informações que irão alimentar um sistema maior (Newman et al. 2016).

No Brasil, por exemplo, a exploração do ambiente urbano de modo a gerar dados abertos à população ainda está dando seus passos iniciais (Breitman et al. 2012), (Brito et al. 2015). Por outro lado, em alguns países, como os Estados Unidos da América, um grande volume de dados ligados à saúde, educação e transporte estão disponíveis para as pessoas, permitindo a sua utilização no desenvolvimento de soluções próprias para

problemas existentes nas cidades (Ota et al. 2015).

Outro ponto que tem contribuído para a criação de bases de dados abertas nas cidades é a popularização dos dispositivos móveis. Estes dispositivos possuem um grande potencial para o *crowdsensing* urbano, visto que são equipados com diversos sensores capazes de coletar dados como temperatura, velocidade, geolocalização, ruídos sonoros, entre outros (Wac et al. 2016). A expectativa é que novos sensores sejam embutidos nos dispositivos móveis nos próximos anos (Zhang et al. 2016). Esta gama de possibilidades permite que a própria população coopere na construção de cidades conectadas e inteligentes. Além dos dispositivos móveis, existem outros sistemas robustos que são capazes de fornecer dados relevantes para a criação de cidades mais sustentáveis, e um deles é o automóvel.

Atualmente os automóveis possuem avançados sistemas eletrônicos e computacionais interconectados por uma complexa rede de comunicação. Estes dispositivos oferecem as mais variadas informações sobre o veículo, tais como, temperatura e rotação do motor, fluxo de massa de ar, velocidade, entre outros. Dados capturados pelo sensor de massa de ar podem ser utilizados para medir a poluição emitida pelo veículo (Bonola et al. 2016), por exemplo. Ressalta-se que a emissão de gases veiculares contribui com uma das maiores parcelas da poluição do ar nos grandes centros urbanos, inclusive, com índices de poluição similares à indústria (Brienza et al. 2015).

1.1 Motivação

As emissões veiculares são geradas através das reações químicas que ocorrem no interior dos motores em sua câmara de combustão. Estes compostos são os principais responsáveis pela degradação do ar atmosférico, o que resulta em uma perda da qualidade de vida de todos os habitantes, podendo ocasionar, por exemplo, problemas respiratórios e degradação de estruturas das cidades. Esses problemas ocorrem principalmente nos grandes centros urbanos, onde a quantidade de veículos é elevada (de Vasconcellos 2000). Os gases poluentes gerados pelos veículos, também são responsáveis por problemas de maior magnitude relacionada a mudanças climáticas (Ribeiro 2000).

Tomando como exemplo a cidade de Natal, capital do Rio Grande do Norte, temos a seguinte situação com relação à frota veicular: apresenta a uma das maiores frotas do Nordeste com a proporção de aproximadamente, 2 veículos para cada 5 habitantes na cidade, a nível nacional é a 16^a capital com maior frota (DENATRAN 2017). Estima-se que a cada ano a quantidade de veículos vem aumentando cerca de 5.5%. Atualmente a frota veicular estimada é de aproximadamente 387400 veículos, dos quais, 341751 se destina a veículos leves, carros movidos a gasolina, álcool ou GNV, e apenas 34801 aos veículos pesados, carros movidos a diesel, de acordo o Departamento Estadual de Trânsito do Rio Grande do Norte (DETRAN 2017) e o Departamento Nacional de Trânsito (DENATRAN 2017).

Nesse sentido, face ao crescente número de veículos nos centros urbanos, consequentemente teremos também o aumento da poluição atmosférica causada por eles. Corroborando com essa perspectiva, um estudo realizado pela *Environmental Protection Agency* (EPA) dos Estados Unidos da América, surpreendentemente, chegaram à conclusão de que um veículo de passeio, utilizando gasolina como combustível, gera em média 4 tone-

ladas de dióxido de carbono (CO₂) por ano (EPA 2008). O que indica o quão alarmante é a questão da poluição veicular urbana.

Diversos países possuem projetos e metas para redução de emissões veiculares. No Brasil, foi criado pelo Conselho Nacional do Meio Ambiente (CONAMA) o Programa de Controle da Poluição do Ar por Veículos Automotores, composto pelo: PROCONVE (automóveis, caminhões, ônibus e máquinas rodoviárias e agrícolas) e o PROMOT (motosicletas e similares) (IBAMA - *Veículos automotores* 2017). Essas iniciativas definiram prazos, limites de emissão e tecnologias para veículos nacionais e importados.

Nas últimas décadas, o CO₂ foi apontado como um dos principais responsáveis pelo efeito estufa, que resulta na elevação significativa da temperatura do nosso planeta. Dentre os danos causados ao meio ambiente podemos citar, acidificação de rios e florestas, mudanças climáticas, chuvas ácidas e o derretimento das calotas polares, juntamente com a elevação do nível dos mares, dificultando assim a vida de animais e o desenvolvimento da flora (Mábia Marellino Montalvão da Silva 2016). Os efeitos na saúde humana são causados principalmente pelas partículas deste poluente suspenso no ar. As partículas mais grossas ficam retidas no nariz e garganta, provocam incômodo, irritação nos olhos, narinas, além de facilitar a instalação de doenças no organismo, podendo ser desde gripe, renite alérgica, bronquite alérgica a poeira e asma. As partículas mais finas causam danos a parte interna do aparelho respiratório, como os alvéolos pulmonares, brônquios, traqueia, faringe e laringe. Em casos mais severos, pode provocar até mesmo o câncer de pulmão (Rice & Associates 2004).

Portanto, fica clara a necessidade de adotar soluções nos centros urbanos que permitam tornar as cidades verdadeiramente inteligentes, além de ajudar a combater problemas ocasionados pela poluição atmosférica.

1.2 Objetivo

Diante de tudo que foi exposto, vemos a possibilidade de explorar soluções que tentem ajudar na resolução de problemas ou que forneçam a capacidade de se obter informações, de modo a realizar análises e gerar novos dados que possam ser úteis para o desenvolvimento dos centros urbanos.

Assim este trabalho possui o objetivo de apresentar o desenvolvimento de um ferramenta, capaz de processar dados obtidos de veículos e estimar a quantidade de dióxido de carbono gerado durante a combustão. A coleta dos dados será feita através de um leitor OBD e utilizando técnicas de *crowdsensing*, de modo que população forneça dados coletados de seus veículos, ou seja, representa uma fonte de dados brutos para a aplicação, sendo processados para obter informações sobre a poluição veicular urbana.

Além disso, a ferramenta pode ser uma iniciativa para mudança no gerenciamento das cidades, de uma perspectiva reativa para proativa, por meio da identificação de áreas com maior quantidade de emissões de CO₂ por parte dos veículos.

1.3 Organização do trabalho

O restante deste documento é organizado da seguinte forma:

- Na Seção 2, é feita uma revisão teórica dos principais conceitos necessários para o entendimento do trabalho.
- A Seção 3, apresenta os trabalhos relacionados ao tema trabalhado.
- A estrutura de funcionamento da ferramenta e os métodos usados para obtenção da quantidade de CO₂ emitida são apresentados na Seção 4.
- Os resultados obtidos são descritos na Seção 5.
- Finalmente, temos as conclusões e algumas propostas de trabalhos futuros na Seção 6.

Capítulo 2

Referencial Teórico

Esta seção tem como objetivo realizar uma revisão teórica sobre os principais temas a serem tratados como base para o entendimento deste trabalho. Inicialmente, será dada uma explicação a respeito de *soft sensor*, expondo também algumas vantagens e desvantagens de sua utilização. Após isso, será feita uma revisão sobre o padrão OBD e suas implementações em hardware, juntamente com o protocolo CAN (*Controller Area Network*), que foram usados para o desenvolvimento do trabalho.

2.1 Soft sensor

Os sistemas de monitoramento requerem o uso de elementos que sirvam de interface com o mundo real; essas interfaces são chamadas de sensores. Sensores são dispositivos responsáveis por realizar medições ou monitoramento das variáveis de interesse, onde atualmente existem os mais diversos tipos de sensores medindo os mais diferentes tipos de variáveis.

Porém, a medição de algumas variáveis de certos processos podem ser impraticável, isso ocorre por diversos fatores, seja por inexistência de um equipamento específico para mensura-la, ou o equipamento existe, mas possui um preço muito elevado, sendo inviável a sua aquisição. Ainda em outros casos, a variável que se deseja monitorar não pode ser obtida de forma direta, mas pode ser obtido por outras formas, por exemplo, através da combinação das leituras de outros sensores.

Com a utilização de dados vindo de outros sensores, ou por meio de observações feitas sobre esses dados, durante o funcionamento do sistema, podemos calcular ou estimar a variável que antes não se podia mensurar. Deste modo podemos criar um sensor virtual ou *soft sensor*, o qual é um modelo que estima a variável desejada a partir de outros dados medidos. Na obtenção destes modelos são usados, como dados de entrada, os valores das variáveis que influenciam a variável desejada.

Ferramentas como estas, estão se tornando cada vez mais utilizados no meio industrial, principalmente para melhorar as especificações dos produtos e monitoramento dos índices das emissões de compostos poluentes (Fortuna 2007).

A utilização de *soft sensor* é um dos fatores principais para redução dos custos de sistemas de controle, pois, o custo de implementação de softwares é baixo, quando comparado à melhoria ou desenvolvimento de hardware (Albertos 2002.). Deste modo, após

se ter uma implementação que represente o sensor, pode-se também realizar uma expansão da rede dos sensores de maneira mais facilmente.

Diante do que foi apresentado, podemos citar vantagens e desvantagens, em relação à utilização de sensores virtuais. Como vantagens de sua utilização temos:

- A eliminação de ruídos e interferências que podem ocorrer na utilização de sensores reais.
- O barateamento da solução desenvolvida, pois, um sensor físico com funcionalidade implementada pelo software, pode possuir um valor elevado.
- A capacidade de substituir sensores com defeito, de maneira mais rápida, deste modo não havendo interrupção do processo.

Entre as desvantagens da utilização de sensores virtuais, podemos citar:

- Por utilizar a informação de outros sensores, é necessário que estes estejam calibrados e funcionando corretamente, pois, valores de leituras errados podem levar a estimações erradas por meio do *soft sensor*.
- Pode ser mais complexo o desenvolvimento de um *soft sensor*, do que usar uma solução que utilize um sensor diretamente.
- Ocorrência de atraso de algumas respostas, devido ao processamento dos dados usados para a estimativa.

Então como podemos ver o *soft sensor* pode ser considerado uma combinação de *hardware*, representado por outros sensores que realizam leituras e servem de parâmetros para um modelo, e um *software*, representado pela implementação de um modelo utilizando as informações das leituras, sendo capaz de realizar estimativas a respeito da variável de interesse.

O *soft sensor* pode ser obtido por diversas técnicas, desde implementação de equações matemáticas simples ou complexas, ou até mesmo através de técnicas mais avançadas como redes neurais, lógica *fuzzy* ou *deep learning*. São muitos os métodos usados para estimar variáveis através de outras variáveis medidas. Esses métodos podem ser classificados e divididos em três grandes grupos (Ljung 1987), (Ohshima 2000):

- Modelos Fenomenológicos: obtidos através de uma abordagem analítica, derivados de princípios fundamentais.
- Modelos Empíricos: provenientes de dados obtidos em laboratório.
- Modelos Caixa-Preta: obtidos de dados operacionais através da aplicação de algoritmos como redes neurais, computação nebulosa, métodos estatísticos, entre outros métodos.

Os sensores virtuais podem coexistir com as redes de comunicação, onde por meio destas, podem obter as leituras dos sensores e combina-las na variável que se deseja mensurar, por exemplo. Diante disso que foi explicado, o *soft sensor* se mostra uma boa alternativa em relação ao sensor tradicional, desde que as variáveis de entrada do modelo possam ser medidas sem problemas, e quando se é possível obter um modelo que representara o sensor capaz de fornecer a variável desejada (Lotufo F.A. 2008).

Dentro do nosso contexto o *soft sensor* desenvolvido, estimará o quanto de dióxido de carbono é gerado pelo motor, durante a combustão, de um veículo, tendo como parâmetros de entrada valores vindos de outros sensores existentes nos automóveis. Outras aplicações de *soft sensor* serão mostrados na seção 3.

2.2 OBD

De maneira geral, trata-se de uma interface de comunicação criada com o intuito de facilitar a comunicação entre os componentes eletrônicos dos veículos e o ambiente externo. Sua primeira versão foi adotada entre os anos de 1988 e 1996, e se chamava OBD-I. A primeira versão não apresentava uniformidade, cada fabricante desenvolvia sua própria solução, não existia interoperabilidade entre fabricantes diferentes.

O padrão OBD-I, por sua simplicidade, era capaz de monitorar uma quantidade limitada de componentes, os quais são listados na Tabela 2.1. De acordo com o padrão, quando uma falha era detectada, um alerta luminoso era exibido no painel do veículo, *Malfunction Indicator Lamp* (MIL), informando o condutor sobre a necessidade de realizar uma manutenção no automóvel.

Tabela 2.1: Recursos do OBD-I.

Recurso
Sensor de oxigênio
Sistema de Recirculação dos Gases de Escape
Sistema de combustível
Sistemas eletrônicos
Componentes elétricos
Códigos de erros
Informações de diagnóstico

Com o passar dos anos, o CARB chegou à conclusão de que o padrão OBD-I era insuficiente e ineficiente para realizar o diagnóstico e controle das emissões. Isto porque ele basicamente se reduzia a detectar curtos-circuitos ou interrupções nos circuitos elétricos de sensores e atuadores. Outro fator que levou à sua substituição foi que durante as inspeções eram detectados diversos casos de falsos negativos (indicavam funcionamento normal, mas, na verdade, não estavam), em outras palavras, alguns veículos que ultrapassavam os limites de emissão de poluição não eram detectados no conjunto de testes do OBD-I (Manavella 2010).

Na busca pela padronização dos sistemas de diagnóstico veicular, foi lançado nos EUA o OBD-II no ano de 1996. Essa nova versão tinha como objetivo adicionar funcionalidades que não existiam em seu predecessor e também facilitar a inspeção e manutenção veicular. A partir daquele ano, todos os fabricantes foram obrigados a seguir um padrão unificado em seus sistemas de diagnósticos. Note que daqui em diante, quando o termo OBD for referido neste texto, estará sempre sendo feito uma referência ao OBD-II, que é o padrão instalado nos carros atuais e também adotado nos testes deste trabalho.

2.2.1 Interface de conexão OBD

Devido à falta de padronização do OBD-I, não existia um local específico para se colocar o conector de diagnóstico, uma vez que cada fabricante instalava essa interface no lugar mais adequado às suas necessidades. Sendo assim, era comum encontrar a interface dentro do capô do carro, outras vezes dentro do veículo, dependendo do fabricante.

Na segunda versão do OBD foi estabelecida uma padronização, sendo o conector instalado dentro do veículo, em uma localização próxima ao motorista e em alguns casos cobertos por uma pequena tampa. A Figura 2.1 exhibe uma porta de conexão OBD-II em um veículo Toyota Etios 2015, que neste caso se encontra do lado inferior esquerdo da direção.



Figura 2.1: Conector OBD-II em um veículo Toyota Etios 2015

2.2.2 CAN

Existem 5 diferentes protocolos comunicação permitidos pelo OBD, em geral, cada veículo implementa apenas um destes. Os protocolos que podem ser utilizados são: CAN (ISO 15765), PWM (SAE J1850), VPW (SAE J1850), ISO 9141-2 e KWP2000 (ISO 14230). Um *scanner* OBD típico deve implementar pelo menos estes protocolos para que a compatibilidade seja mantida.

Quando se trata de redes veiculares, a tecnologia mais difundida é o barramento CAN (*Controller Area Network*). CAN é um padrão de barramento veicular criado nos anos 1980 pela *Bosch*. Seu objetivo principal é permitir a comunicação entre diferentes *Electronic Control Unit* (Unidade de Controle Eletrônico), abreviada por *ECU*, que são unidades capazes de controlar um ou mais sistemas eletrônicos (atuadores, sensores) do veículo. São exemplos de *ECUs* a unidade de controle de freios, motor, injeção eletrônica e *Anti-lock Braking System* (ABS).

A Figura 2.2 representa a estrutura de uma rede CAN. Nota-se a presença de um barramento central, permitindo comunicação *half-duplex*, o que significa que as informações são trocadas em ambas as direções, mas não simultaneamente, dado que a política de controle de acesso ao meio garante que apenas um dispositivo transmite um quadro de dados no barramento por vez.




Figura 2.2: Estrutura simplificada de uma rede CAN. Fonte: Autoria própria

Com o intuito de garantir que as unidades de controle conversem adequadamente entre si, há a necessidade de um protocolo de comunicação. O protocolo CAN funciona de forma assíncrona e serial. Os quadros de dados transmitidos pela rede possuem campos que fornecem informações sobre o seu próprio conteúdo, como ilustrado na Figura 2.3, onde é descrito um típico quadro CAN.




Figura 2.3: Formato de um quadro CAN.

O campo *Identificador* indica o tipo conteúdo do quadro, e os dados contidos nele são utilizados em duas ocasiões: para decidir qual quadro é mais prioritário e quais módulos devem aceitar a sua recepção. O protocolo CAN não é baseado em endereço, mas sim em mensagem, o que implica que quando uma mensagem é enviada, esta é recebida por todos os módulos CAN ligados ao barramento, no entanto, cada módulo deve decidir se a aceitará ou não. Para um melhor entendimento, basta saber que os módulos CAN possuem máscaras e filtros que são aplicados ao identificador do quadro. A máscara é usada para determinar quais bits do identificador devem ser comparados com o filtro. Se a comparação par-a-par for bem-sucedida, o quadro é aceito pelo módulo. Um exemplo simples e didático pode ser visto abaixo:

Tabela 2.2: Exemplo de aplicação de filtro.

Máscara	11111111100
Filtro	00000000000
ID quadro 1	00000000010
ID quadro 2	00000000100

A máscara do módulo representado na Tabela 2.2 indica que do bit mais significativo do identificador (bit 10) ao bit 2, seus pares correspondentes no filtro devem ser iguais, exceto para os bits 1 e 0, cujos valores não importam. Desta forma, após a aplicação da máscara e comparação com o filtro, somente o quadro 1 teria a recepção aceita pelo módulo em questão.

2.2.3 Modos de operação do OBD-II

Os veículos possuem módulos heterogêneos que conseguem se comunicar uns com os outros graças a protocolos de comunicação como o CAN, no entanto, os fabricantes têm a liberdade de fazer suas escolhas quando estão desenvolvendo a rede de comunicação do veículo.

Um determinado fabricante pode escolher o identificador 0x3DF para requisitar a velocidade atual do veículo, enquanto um outro fabricante pode decidir pelo identificador 0x2F4. Portanto, numa rede CAN não há padronização de identificadores, máscaras ou filtros, muito menos do posicionamento dos dados dentro de uma mensagem. Aí então entra em ação o padrão OBD-II. Ele define identificadores-padrão (identificadores genéricos) para um grande número de requisições. São estes identificadores que um *scanner* deve conhecer e ser capaz de enviar pela rede.

De acordo com a especificação OBD, o *PID* (*parameter ID*) para requisitar a velocidade atual do veículo é 010D (01 corresponde ao modo de operação e 0D à requisição de velocidade) para todo veículo que implementa o OBD-II. A Figura 2.4 exibe o fluxo de execução de um comando que visa obter a velocidade instantânea do veículo. Na figura temos um fluxograma mostrando o caminho percorrido por uma mensagem OBD, desde a requisição inicial em uma aplicação, por exemplo, até o momento que a correspondente *ECU* envia a resposta. Abaixo da figura encontra-se uma explicação com mais detalhes sobre cada etapa.

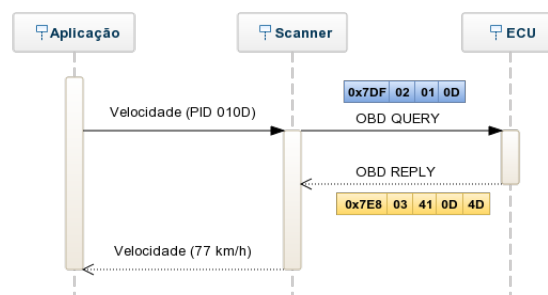


Figura 2.4: Fluxo de execução de um comando OBD.

1. O *scanner* recebe o *PID 010D* e envia pela porta OBD-II uma mensagem do tipo *QUERY* (*ID 0x7DF*) contendo: campo indicando o número de *bytes* no campo de dados | campo de dados com o *PID* | e o comando. Exemplo: [0x7DF 02 01 0D].
2. Todos os módulos receberão a mensagem, mas apenas o módulo ou módulos habilitados a lidar com tal requisição respondem.
3. A mensagem enviada pelo módulo é do tipo *REPLY* (*ID entre 0x7E8 e 0x7EF*) e seu conteúdo compreende: número de *bytes* no campo de dados | *PID* que gerou a requisição | modo de operação + constante 40 | velocidade do carro em hexadecimal. Exemplo de resposta para requisição de velocidade: [0x7E8 03 41 0D 4D].

Os PIDs foram criados seguindo um padrão. Os dois primeiros dígitos correspondem ao modo de operação, e os dois seguintes ao tipo de informação que se deseja obter. Existem 10 modos de operação, mas não significa que todo veículo, tampouco todo *scanner* oferece suporte a todos eles. A abrangência de cada modo de operação é descrita na Tabela 2.3.

Tabela 2.3: Modos de Operação do OBD-II.

Modo	Descrição
1	Este modo é utilizado para obter as informações em tempo real fornecidas pela ECU conectada aos sensores e atuadores do motor.
2	Quando algum erro é detectado, todas as informações oferecidas pela ECU do motor são armazenadas (diz-se que os dados são congelados) com o objetivo de se realizar uma análise posterior do status do veículo naquele dado instante.
3	Usado para requisitar todos códigos de erro armazenados no veículo. Usado para requisitar todos códigos de erro armazenados no veículo, ou seja, os dados congelados. É muito útil para os <i>scanners</i> , dado que é possível identificar erros e suas causas.
4	Responsável por limpar os códigos de erro armazenados.
5	Oferece informações de diferentes sensores de O ₂ espalhados pelo motor do veículo
6	Oferece informações relacionadas ao monitoramento não-contínuo, isto é, informações de testes realizados quando o veículo é ligado ou desligado, por exemplo.
7	Este modo é mais avançado, não sendo implementado por qualquer <i>scanner</i> . Oferece informações de teste feitos enquanto o veículo está ligado. Muito utilizado durante a inspeção de emissão de poluentes.
8	Mais um modo avançado. Comandos podem ser enviados para que o veículo execute alguma ação. A partir da ação, o técnico pode executar algum teste a fim de verificar a ligação entre a ação e o problema do veículo.
9	Utilizado para obter informações sobre o veículo, como o VIN (<i>Vehicle Identification Number</i>), que se trata do identificador do veículo, também informações sobre o software do veículo e dados do motor.
10	Este modo é utilizado para acessar informações de emissão e tem muita utilidade durante inspeções que visam encontrar falhas relacionadas aos sistemas de redução da poluição veicular.

2.2.4 Scanners

Scanners ou adaptadores são dispositivos que se conectam diretamente à porta OBD e permitem que aplicações se comuniquem com os veículos, isto é, o *scanner* age como um intermediário. A interface de comunicação oferecida pelos *scanners*, bem como os

modos de operação que eles implementam são características que influenciam diretamente no preço dos mesmos. A Tabela 2.4 exibe os adaptadores OBD que possuem melhor custo-benefício.

Tabela 2.4: Modelos de scanners.

Comunicação Scanner-Applicativos	Adaptador	Preço
<i>bluetooth</i>	ELM327	USD 9
<i>bluetooth</i>	ERUSUN <i>bluetooth</i> Mini OBD2	USD 11
USB	OBDLink SX USB	USD 30
Wi-Fi	OBDLink MX Wi-Fi	USD 80

Os carros atuais possuem geralmente dois ou três barramentos CAN. O primeiro é o barramento de diagnóstico (*High Speed CAN/HS-CAN*), que possui alta velocidade (*até 1 mbps*), e é utilizado por módulos que exigem comunicação em tempo real e alta prioridade na entrega das mensagens, como mensagens ligadas ao sistema ABS (*anti-lock braking system*), módulos de controle do motor e informações de emissão. O segundo, por sua vez, é o barramento de controle (*Medium Speed CAN/MS-CAN*), que oferece velocidade mediana (*até 125 kbps*) e é por onde trafegam requisições capazes de controlar determinadas funcionalidades críticas do automóvel, como a trava das portas, controle dos vidros, ligamento/desligamento do motor, etc. Por último, temos o barramento de conforto (*Single Wire CAN/SW-CAN*), que se trata de um barramento de baixa velocidade (*até 88.3 kbps*) por onde trafegam mensagens menos prioritárias, como requisições direcionadas ao módulo dos cintos de segurança e dos retrovisores (Brown & White 2012).

Adaptadores que suportam SW-CAN e MS-CAN custam mais caro, e normalmente são compatíveis apenas com fabricantes específicos, como é o caso do OBDLink MX Wi-Fi, cujo preço médio é de USD 80.00 e permite comunicação com barramentos Ford e GM.

Alguns outros adaptadores oferecem formas de conectividade muito práticas, e preços mais acessíveis, como é o caso do ELM327, que permite conexão *bluetooth* e custa em média USD 9.00. No entanto, este adaptador somente consegue se comunicar com o barramento de diagnóstico (HS-CAN). Os *scanners* ELM327 e OBDLink MX Wi-Fi podem ser vistos na Figura 2.5.



Figura 2.5: Adaptadores OBD

Capítulo 3

Trabalhos relacionados

O monitoramento da poluição urbana a partir das emissões dos poluentes veiculares é uma tarefa complexa. Envolve desafios desde a captura das emissões de gases nos veículos, a transmissão dos dados pela infraestrutura de comunicação das cidades, até o armazenamento, geração e visualização da informação processada. Esta seção tem como objetivo apresentar alguns trabalhos que tratam sobre controle e monitoramento de emissões veiculares, além de aplicações com sensores virtuais.

Em relação ao controle de emissões, várias medidas estão sendo tomadas pelos países, na busca por soluções que diminuam as emissões de gases causadores do efeito estufa. Em especial, destaca-se o acordo firmado pela Organização das Nações Unidas (ONU) na *Conference of Parties (COP-21)*, nomeado de Acordo de Paris, onde os 195 países membros ratificaram a necessidade de manter o aquecimento global em índices sustentáveis para o planeta (Maroto-Valer 2016, Morgan 2016). Vale ressaltar que devido à predominância dos veículos motorizados no setor de transportes, em associação ao limitado uso de tecnologias de controle de emissões, os automóveis têm se tornado uma das maiores fontes de poluição urbana e consequentemente principais influenciadores do efeito estufa (Han et al. 2015, Wu et al. 2016).

A preocupação em relação à poluição veicular não é recente, teve início nos Estados Unidos em meados dos anos 60. Naquele período, o Comitê de Administração dos Recursos do Ar da Califórnia (CARB) criou uma legislação direcionada à redução da poluição por veículos automotores. Os primeiros resultados foram a implantação do sistema *Positive Crankcase Ventilation (PCV)*, que além de evitar o desperdício de combustível reduzia a emissão de hidrocarbonetos no ar (Faiz et al. 1996). Nas décadas de 70 e 80, houve também melhorias significativas como a inserção do controle eletrônico nos sistemas de injeção e ignição e o sistema de recirculação de gases de escape. Essas soluções reduziram significativamente a emissão de óxidos de nitrogênio (NO_x). Esses gases são nocivos a saúde humana sendo responsáveis por problemas no sistema respiratório (Manavella 2010).

O advento dos sistemas eletrônicos automotivos ocorreu no mesmo período em que o CARB e a Agência de Proteção Ambiental (EPA - *Environmental Protection Agency*) definiam resoluções para controle das emissões. Esses eventos impulsionaram a criação de um sistema capaz de autodiagnosticar e alertar o motorista sobre eventuais defeitos em componentes eletrônicos ou nos sistemas de controle de emissão. Esse sistema foi batizado de *On-board diagnostics (OBD)* e teve sua primeira versão lançada em 1988,

quando passou a ser obrigatória em todos os novos veículos que circulariam no estado da Califórnia a partir daquele ano (Hernandez-Alcantara et al. 2016). Desde 1996, todos os carros fabricados e vendidos nos Estados Unidos são obrigados a possuir o sistema OBD. A União Europeia adotou medida similar em 2003 enquanto o Brasil, Rússia e China previstos a partir de 2010 (Ferris 2009).

Recentemente, diversos trabalhos na literatura têm explorado o potencial do OBD para extrair dados dos veículos e gerar informação útil que podem ser utilizadas no monitoramento da poluição em cidades inteligentes. Em (Zeng et al. 2015), os autores realizaram um estudo sobre a influência da distância percorrida e velocidade média do veículo no consumo de combustível. A partir de técnicas de *Machine Learning* foi possível prever o consumo de combustível para determinados trechos a serem percorridos. Os mesmos autores estenderam a ideia, criando o conceito de *Eco-driving* (Zeng et al. 2016). A partir da previsão do consumo de combustível e conseqüentemente a emissão de CO₂ (estimadas a partir de aproximações lineares do consumo de combustível), rotas entre dois pontos são traçadas considerando além da distância, os poluentes emitidos pelos veículos. Em ambas soluções, os dados coletados via OBD são armazenados localmente no veículo através de um *Secure Digital (SD) card* e processados de forma off-line por uma aplicação.

Sistemas de autodiagnostico foram criados com o objetivo de realizar um controle mais eficaz das emissões de gases tóxicos, detecção de problemas elétricos, químicos ou mecânicos nos veículos (Hernandez-Alcantara et al. 2016). Com o passar do tempo, a exploração desses sistemas tornou-se mais acessível aos usuários comuns. A vasta documentação em sites de fabricantes e o fornecimento de detalhes em manuais veiculares foram as principais causas da sua popularização (AbuAli 2015). Atualmente é possível encontrar um número razoável de trabalhos acadêmicos e soluções comerciais que se utilizam do sistema de autodiagnostico OBD para criar serviços ou dispositivos que beneficiam o motorista (Taha & Nasser 2015).

Outro trabalho interessante desenvolvido por pesquisadores do Instituto de Tecnologia Eletrônica da Coreia do Sul (Jung & Choi 2011), consistiu na estimacão de CO₂ emitido no meio ambiente por veículos equipados com a interface OBD. O projeto possui algumas características semelhantes ao discutido nesse texto, no entanto, existem certas disparidades. A primeira diferença está relacionada ao fato de que a aplicacão de (Jung & Choi 2011) não realiza monitoramento das emissões de CO₂ em tempo real. Para poder estimar, eles precisam fazer um percurso de alguns quilômetros em um carro de modo a coletar alguns dados por meio da interface do veículo. Utilizando os dados medidos, como a informacão da distância percorrida e a quantidade de combustível consumido, eles são capazes de mensurar a emissão de CO₂ média para aquele trajeto. A segunda diferença é que a aplicacão proposta neste trabalho pode se comunicar com servidores distantes por meio da internet, enviando informacões instantâneas sobre a mediçã das emissões de CO₂ pelo veículo.

No Brasil, tivemos também a exploracão do tema de emissões veiculares, um trabalho com uma abordagem diferente do apresentado aqui, porém, com a mesma finalidade de identificar áreas com maior incidência de emissões veiculares (Manzoli 2009). Para obtençã dos dados, os autores utilizaram um sensor acoplado ao escapamento do veículo o que dificulta a escalabilidade da proposta.

Por fim, na tabela 3.1 é apresentado um resumo comparativo entre os trabalhos, discutidos nessa seção, podendo ser visualizados as suas principais semelhanças e diferenças. A coluna trabalho faz referência aos trabalhos mostrados anteriormente e a segunda coluna apresenta um resumo quanto a utilização de características usadas pelos autores.

Tabela 3.1: Resumo trabalhos relacionados

Trabalho	OBD
1. (Zeng et al. 2015)	Não foi utilizado, ao invés disso realizaram leituras diretamente do CAN
2. (Zeng et al. 2016)	Foi utilizado para realizar as leituras dos sensores veiculares
3. (Jung & Choi 2011)	Foi utilizado para realizar as leituras dos sensores veiculares
4. (Manzoli 2009)	Não foi utilizado, ao invés disso utilizaram um sensor acoplado ao escapamento
Trabalho	Tempo real
1. (Zeng et al. 2015)	Não funciona em tempo real, realizaram estimação após um período de coleta
2. (Zeng et al. 2016)	Não funciona em tempo real, dados processados off-line
3. (Jung & Choi 2011)	Funciona em tempo real, à medida que os dados eram coletados era estimado o CO ₂
4. (Manzoli 2009)	Não funciona em tempo real, dados processados off-line
Trabalho	Armazenamento dos dados
1. (Zeng et al. 2015)	Dados armazenados em um servidor local
2. (Zeng et al. 2016)	Dados coletados em Cartão SD, e armazenados em um servidor local
3. (Jung & Choi 2011)	Armazenados diretamente em um computador que está dentro do veículo e conectado a saída do adaptador OBD
4. (Manzoli 2009)	Armazenados diretamente em um computador que está dentro do veículo e conectado a saída do sensor
Trabalho	Sensores observados
1. (Zeng et al. 2015)	Nível de combustível, RPM
2. (Zeng et al. 2016)	Nível de combustível, MAF, velocidade, aceleração, posição do acelerador
3. (Jung & Choi 2011)	MAF
4. (Manzoli 2009)	Analisador de gás

Além desses trabalhos, podemos ainda destacar dois outros trabalhos onde os autores fazem uso de sensores virtuais para obter informações relacionadas a veículos, mostrando assim o potencial desse tipo de ferramenta. O primeiro desenvolvido por um grupo da universidade de *West Virginia*, desenvolveram uma rede neural capaz de estimar o quanto de oxido de nitrogênio é gerado no momento da combustão de um motor a diesel, utilizando informações da pressão do combustível como entrada para a rede neural (Traver M. L. 2000). Ao final puderam ver que uma comparação entre um sensor real e o sensor virtual desenvolvido, possuíam respostas bem parecidas.

O segundo trabalho desenvolvido por um grupo brasileiro, traz o desenvolvimento

de um sensor virtual, utilizado para a estimação da temperatura do óleo dos motores de automóveis (Guilherme 2016). Para isso o autor obteve um modelo físico do sistema de lubrificação do motor, juntamente com os efeitos existentes das trocas de calor. Ao término do trabalho, mostrou-se que o modelo obtido era viável para ser um estimador da temperatura do óleo de motor de automóvel em funcionamento.

A partir da discussão acima fica claro que existem lacunas para serem resolvidas. Dentro deste contexto temos este trabalho que surge com a proposta de ser uma plataforma capaz de realizar:

- Monitoramento da quantidade de dióxido de carbono gerado na combustão.
- Fusão de dados provenientes de diversas fontes.
- Habilitar inferência estatística dos dados.
- Cálculo do nível de poluição a partir de métodos que utilizam dados de sensores indiretos, em outras palavras, sensores que não calculam diretamente a emissão de CO₂.

Capítulo 4

Metodologia

Esta seção tem como objetivo apresentar o desenvolvimento do trabalho, onde será mostrado a estrutura geral do funcionamento do sistema, etapas de coleta, armazenamento e os métodos usados para realizar a estimativa do CO₂.

O alvo de estudo desse trabalho são os veículos. Como já dito anteriormente, os automóveis contribuem com uma grande parcela na poluição do ar, e isso deve-se aos gases gerados a partir da queima de combustíveis fósseis. Portanto, o referido trabalho propõe uma apresentar a proposta de uma ferramenta para monitoramento da quantidade de CO₂ gerado por parte do motor do veículo. Esse trabalho é parte de uma iniciativa do Projeto Smart Metropolis, cujo foco é o gerenciamento de frotas veiculares. Uma visão geral dessa iniciativa é descrita na Figura 4.1.




Figura 4.1: Arquitetura do sistema

Através de uma visão sistêmica, esta parte da iniciativa de gerenciamento de frotas veiculares divide-se em 3 componentes principais: os veículos equipados com leitores OBD-II, aplicação mobile e o *soft sensor* responsável pela estimativa de CO₂. Com os dados coletados é possível estimar o quanto de CO₂ está sendo emitido por um veículo ou conjuntos de veículos, com base nos métodos que serão apresentados a partir da seção rebsubsec:co2calculation. Os detalhes sobre o funcionamento de cada um dos outros componentes são dados nas subseções 4.1 e 4.2.

4.1 Veículo

Para que seja possível realizar a coleta dos dados, o veículo monitorado deve possuir obrigatoriamente uma interface de comunicação OBD. A aplicação mobile utiliza essa interface para poder obter informações das unidades de controle do veículo.

Conforme mencionado na Seção 2.2.4, existem *scanners bluetooth*, Wi-Fi, serial, entre outros. Pensando na relação custo-benefício, foi adotado durante todo o desenvolvimento do projeto o *scanner* ELM327. Seu custo é baixo, ele implementa o modo de operação 1 e ainda conta com um módulo *bluetooth*, permitindo que qualquer aplicação de smartphone possa se conectar facilmente.

As informações necessárias ao cálculo da poluição veicular são todas fornecidas por uma mesma ECU, que é a unidade de controle do motor. A partir das informações vindas de diversos sensores, podemos estimar o quanto de dióxido de carbono é gerado para uma certa quantidade de combustível que é queimada.

4.2 Coleta de dados

Para realizar a coleta dos dados, será necessário o uso de uma aplicação para dispositivos móveis. Devido à limitação dos *scanners* OBD, apenas a versão 2 e 3 do *bluetooth* são suportadas. A título de registro, está sendo utilizado o sistema operacional Android. Devido à comunicação entre o dispositivo e o veículo ser via *bluetooth*, é necessário manter uma distância máxima entre 10 e 15 metros para não ocorrer falhas na comunicação.

O aplicativo foi desenvolvido com a intenção de obter o máximo possível de informações dos veículos, particularmente os dados do modo de operação 1 (Tabela 2.3). Uma função opcional, requer que o smartphone esteja conectado com a internet, contribuindo para uma base de dados, que armazenará os dados coletados de cada veículo. Para a versão utilizada nesse trabalho, os dados coletados foram armazenados localmente no dispositivo.

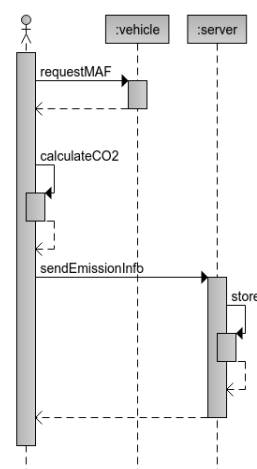


Figura 4.2: Fluxo de comunicação do sistema

O diagrama mostrado na Figura 4.2 mostra o funcionamento da comunicação entre a aplicação e o veículo. Os detalhes do funcionamento são mostrados abaixo.

- A aplicação envia uma requisição de conexão para o adaptador ELM327 via *blue-tooth*. Com a comunicação estabelecida a aplicação pode enviar comandos OBD.
- A aplicação requisita alguns dados dos sensores, por exemplo, para o nosso caso solicita o MAF, para obter a quantidade de ar entrando no motor.
- A aplicação recebe a resposta, e a plataforma calculará o CO₂ emitido pelo veículo. O detalhamento dos métodos usados para o cálculo será mostrado na seção 4.3.1.

Para se obter o valor do CO₂ emitido pelo métodos apresentados nesse trabalho, o veículo monitorado precisa implementar o comando OBD **0110** (MAF), **010B** (MAP), **010F** (IAT) e o **010C** (RPM).

Na Figura 4.3 temos uma imagem do aplicativo em funcionamento, o aplicativo ainda se encontra em desenvolvimento, porém, já está em um nível funcional, onde podemos ver todas as leituras do que é retornado por ele. Podemos ver, por exemplo, o combustível que o veículo usa e qual o seu nível atual, as rotações por minuto. Para o nosso trabalho os valores de importância são do fluxo da massa de ar do veículo, temperatura de entrada e pressão do ar.

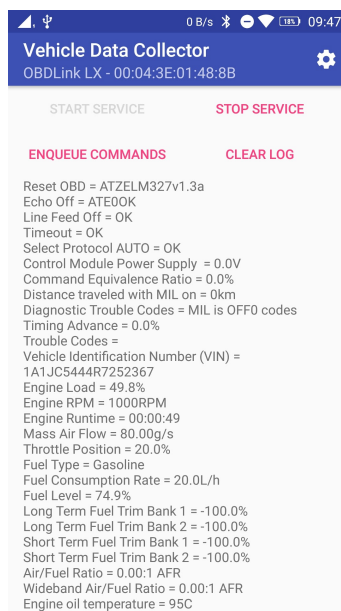


Figura 4.3: Tela do aplicativo em funcionamento

Vale ressaltar que os comandos OBDS mesmo fazendo parte do conjunto de PIDs padrão podem não ser suportados por alguns veículos. Isso pode acontecer por causa dos fabricantes usarem um código customizado ao invés do padrão.

4.3 Soft Sensor

4.3.1 Métodos de cálculo do CO₂

Para obter uma melhor eficiência e reduzir as emissões do motor do veículo, a quantidade de ar que entra deve ser calculada corretamente. Esta subseção tem como objetivo mostrar alguns métodos que o veículo utiliza para determinar tal quantidade de ar. Esse é um dos principais procedimentos usados pela ferramenta monitoramento da poluição veicular urbana desenvolvida.

A ECU pode controlar diversos sistemas que realizam a tarefa de definir a quantidade de ar necessária para a combustão ter o maior rendimento. Adicionalmente, a ECU pode determinar a temperatura e pressão do ar, o valor do λ atual do veículo, além do próprio fluxo de ar que o motor requisita em um determinado momento.

Os principais métodos usados para obter tais valores são: *Alpha-N*, *Speed Density* e o *Mass Air Flow*.

- *Alpha-N*: um método raramente utilizado nos dias atuais. O *Alpha* consiste no ângulo do sensor de posição do acelerador e o *N* refere-se a velocidade do motor (rotações por minuto). O método não estima o fluxo de ar diretamente, mas usa um mapeamento entre o *Alpha* e o *N*, para obter tal valor. Pode ser considerado um método simples e foi desenvolvido originalmente para motores usados em corridas (Stroes 2000-2002).
- *Speed Density*: este método realiza uma estimativa da massa de ar com base na lei dos gases ideais. Para isso, utiliza leituras dos sensores de temperatura e pressão do ar existente no veículo, além de usar a eficiência volumétrica do motor. Esse método pode ser encontrado associado ao sensor MAP, sensor de pressão absoluta. Neste trabalho podemos usar a sigla para MAP, para representá-lo em alguns momentos.
- *Mass Air Flow*: este método usa diretamente o sensor fluxo de massa de ar (*Mass Air Flow*) ou abreviado como MAF, presente nos veículos para obter o valor da massa de ar, o valor retornado é em unidade de massa/tempo.

Os métodos que serão utilizados, nesse trabalho, para obter a quantidade de ar que entra no momento da combustão, são os dois últimos itens apresentados. Realizando uma breve comparação entre estes dois métodos, podemos ver que o *Speed Density*, possui uma complexidade matemática maior que o MAF, enquanto o sensor MAF, que é usado diretamente pelo terceiro método apresentado, pode não ser encontrado em todos os veículos.

Para realizar a estimativa do CO₂, foi usado a linguagem de programação *Python*, com o ambiente de desenvolvimento *Jupyter Notebook*. Esta ferramenta combina compilação de códigos, RTF (*Rich Text Format*), funções matemáticas, plotagem de gráficos e mapas, entre outras funcionalidades que facilitam uso de códigos e a análise dos dados, em um mesmo ambiente. Uma curiosidade o nome *Jupyter* é derivado dos nomes Julia, Python, e R, que eram as linguagens suportadas inicialmente pela plataforma.

4.3.2 Estimação de CO₂

A ideia base para obter a quantia de CO₂ emitida pelos veículos, usada nesse trabalho, parte do princípio de conhecer a quantidade de ar que entra no motor no momento da combustão. Obtendo esse valor aplica-se o método a ser apresentado a seguir.

Inicialmente temos que entender o conceito por trás da relação ar-combustível. Para uma certa quantidade de combustível, existe uma certa quantia de oxigênio necessária para que a combustão seja a ideal. Este fator é chamado de relação ou proporção ar-combustível, do inglês *air fuel ratio* (AFR). Para a combustão da gasolina, o valor considerado como mistura ideal possui uma relação ar-combustível, em um determinado momento de funcionamento, de 14.7:1. Em outras palavras, é necessário 14.7 kg de ar para cada 1 kg de combustível que entra na câmara de combustão. Já nos veículos a álcool, esta mistura é de 9:1. Enquanto nos veículos movidos a diesel esse valor é de 14.6:1.

Matematicamente podemos descrever o AFR pela Equação 4.1, onde é representado apenas uma divisão entre a massa de ar e a massa do combustível.

$$AFR = \frac{m_{ar}}{m_{combustível}} \quad (4.1)$$

A partir da relação ar-combustível (AFR), podemos reescrever para a Equação 4.2, onde MAF representa o fluxo de ar de um determinado instante e Combustível representa a quantidade de combustível.

$$AFR = \frac{MAF(g/s)}{Combustível(g/s)} \quad (4.2)$$

O padrão OBD estabelece códigos para obter a massa de ar (MAF) ou nos dá acesso a outros sensores que permitem obter tal valor, mas não para obter diretamente a quantidade de combustível injetada, o que seria ideal para o nosso caso. Dessa forma, considerando que o AFR é um valor conhecido, e que é possível extrair o MAF através do OBD, a massa de combustível pode ser encontrada através do desenvolvimento da Equação 4.3.

$$Combustível(g/s) = \frac{MAF(g/s)}{AFR} \quad (4.3)$$

A unidade de medida do MAF e do Combustível são g/s, e o valor do AFR é uma constante. Os principais combustíveis usados nos veículos são gasolina, diesel e etanol. A Tabela 4.1 descreve os principais valores da quantidade de dióxido de carbono seja gerado para 1 litro de um certo combustível, o AFR e a densidade desse combustível.

Tabela 4.1: Fatores de conversão de combustível.
Fonte: (Hill et al. 2012), (IEEP 2010), (InnovateMotors 2014)

Combustível	CO ₂ PL	AFR	Densidade (ρ)
Gasolina	2310 g/L	14.7:1	737 g/L
Diesel	2660 g/L	14.6:1	850 g/L
Etanol	1510 g/L	9.0:1	789 g/L

É necessário encontrar o volume de combustível injetado, visto que combustível na Equação 4.2 representa a massa do combustível, e não seu volume. Portanto, a fim de calcular o CO₂ emitido, é preciso converter a massa do combustível em volume. A coluna Densidade (ρ) da Tabela 4.1 exibe a densidade dos combustíveis por litro. O cálculo para obtenção do volume é descrito na Equação 4.4.

$$V_{\text{comb}}(L/s) = \frac{\text{Combustível}(g/s)}{\text{Densidade}(g/L)} \quad (4.4)$$

Como dito anteriormente, a emissão de CO₂ está intimamente ligada ao volume de combustível queimado. O cálculo final da massa de CO₂ é descrito na Equação 4.5, onde o volume do combustível (V_{comb}) é multiplicado pela massa de dióxido de carbono (CO₂PL) gerada após a queima de 1 litro do combustível em questão, resultando na estimativa da massa de CO₂ emitida no ambiente por segundo.

$$CO_2(g/s) = V_{\text{comb}}CO_2PL \quad (4.5)$$

4.3.3 Mass Air Flow

Na subseção anterior foi visto, o método a ser usado no trabalho para estimar a quantidade de CO₂, e inicialmente vimos que era necessário conhecer o valor da quantidade de ar, que estava entrando no motor no momento da combustão. Uma das maneiras de se encontrar esse valor é via sensor *mass air flow*.

O sensor *mass air flow*, ou fluxo da massa de ar, é um sensor capaz de converter a quantidade de ar que entra no motor para um nível de tensão. Essa informação é útil para manter a relação estequiométrica com o combustível. Esse sensor é normalmente é localizado diretamente na entrada de ar do veículo. Existem dois tipos principais de sensor MAF atualmente, o *hot wire* e o *Vane*.

O sensor do tipo *hot wire*, é composto por um fio que está aquecido por um circuito elétrico, o objetivo do funcionamento desse tipo de sensor é manter a temperatura do fio constante. A medida que o ar passa pelo sensor, o fluxo de ar aumenta e temperatura do fio baixa, quando a temperatura do fio diminui sua resistência também diminui, e isso implica em um aumento da corrente da elétrica para aquecer a fio novamente. De acordo com a variação da corrente, a ECU pode determinar o quanto de ar está entrando para a combustão, e assim, envia a quantidade adequada de combustível para a câmara de combustão (Bell 1998).

O sensor do tipo *Vane*, ele é mais antigo que o *hot wire*, por conta disso é mais mecânico também. Este sensor é composto por um *flap* que bloqueia a entrada de ar, à medida que o ar entra ele vai empurrando o *flap*, que está preso a um potenciômetro (sensor de posição), quando ocorre uma variação da posição, representa uma variação na resistência, e está indica uma diferença de tensão. Semelhante ao *hot wire* a variação da tensão é interpretado pela ECU para determinar o quanto de ar está entrando para a combustão, e assim, envia mais ou menos combustível para a câmara de combustão (Bell 1998).

Para veículos que possuem esse sensor, é possível se obter o valor do MAF diretamente via OBD, retorno possui uma unidade do tipo g/s, podendo ser usado diretamente

na metodologia de estimação exibida na subseção anterior 1, e assim obter o valor do CO₂ que gerado durante a combustão.

4.3.4 Speed Density

O segundo método de estimação usado nesse trabalho, pode ser considerado mais complexo que o anterior. É realizada tendo como base a lei dos gases ideais, também chamada equação de estado do gás ideal (gás perfeito). Na referida lei, observam-se uma série de relações entre a temperatura, pressão e o volume do gás que dão lugar à lei dos gases ideais, enunciada pela primeira vez por Émile Clapeyron, em 1834, a equação 4.6 é a representação matemática dessa lei. Ao longo do trabalho podemos chama-lo de MAP.

$$PV = nRT \quad (4.6)$$

A ideia por trás do *speed density* é achar a quantidade de mols (n), de uma quantidade de ar durante a etapa de entrada de ar para a combustão, a Equação 4.7, mostra como se obtém esse valor via a lei dos gases.

$$n = \frac{PV}{RT} \quad (4.7)$$

O n representa o número de mols, podemos encontrar a quantia de massa de ar, por meio da Equação 4.8, onde obtemos a massa de ar em gramas.

$$massa_de_ar = n * massa_molar_do_ar \quad (4.8)$$

A partir da Equação 4.8, podemos isolar o n, obtendo o número de mols como uma razão da massa do ar e da sua massa molar, e este valor pode ser substituído na lei dos gases ideais de modo a obter a Equação 4.9.

$$\frac{massa_de_ar}{massa_molar_do_ar} = \frac{PV}{RT} \quad (4.9)$$

Por fim, obtemos a massa de ar ao multiplicarmos os termos resultantes da manipulação inicial da lei dos gases ideais pela massa molar do ar, como pode ser visto na Equação 4.10, que servirá de base para a equação utiliza para obtenção da quantidade de CO₂.

$$massa_de_ar = \frac{PV}{RT} * massa_molar_do_ar \quad (4.10)$$

Os termos da Equação 4.10, são explicados a seguir:

- P - Representa a pressão na câmara de combustão, pode ser obtido por meio do sensor MAP (pressão absoluta) em KPa.
- V - Está relacionado com as cilindradas do veículo pode ser em litros ou unidades de volume (cm³).
- R - A constante dos gases ideais, seu valor é aproximadamente $8.3145 \frac{J}{mol * K}$.
- T - É temperatura do gás, pode ser obtido pelo IAT (Temperatura absoluta) em K.

- Massa Molar do Ar - O valor constante igual a $28.87 \frac{g}{mol}$, nas equações seguintes a massa molar do ar será abreviado para *mma*.

Todavia, a Equação 4.10 só é válida se o motor estiver com uma Eficiência Volumétrica (EV) de 100%. A eficiência volumétrica (EV) é a relação entre o volume de mistura ar-combustível que cada cilindro admite e a capacidade volumétrica nominal do cilindro. Por exemplo, em um motor 2.0 litros de 4 cilindros, cada cilindro tem uma capacidade volumétrica nominal de $500cm^3$, mas devido às perdas na admissão, o cilindro só admite, digamos, $400cm^3$. Assim, este motor tem 80% de eficiência volumétrica. A eficiência volumétrica pode ser encontrada pela seguinte relação:

$$EV = \frac{V_{Entrada}}{V_{Motor}} * 100\% \quad (4.11)$$

- $V_{Entrada}$ - Representa o volume de ar nos cilindros.
- V_{Motor} - É o volume total suportado pelo motor.

Com isso devemos levar em consideração a eficiência volumétrica do motor juntamente com o volume, assim a Equação 4.10 se torna a Equação 4.12.

$$massa_de_ar = \frac{P * V * EV * mma}{R * T} \quad (4.12)$$

Com isso utilizando a equação modificada da lei dos gases ideais, mostrada pela equação 4.12, devemos calcular o fluxo de ar que está entrando no motor no momento da combustão. Para obter tal valor, deve-se encontrar a quantos RPM (Rotação Por Minutos) o motor está funcionando, este valor pode ser obtido via OBD-II.

Durante esta operação, se consideramos um motor de quatro tempos, existem duas etapas de entrada de ar, ou seja, em seu ciclo completo ocorre entrada de ar duas vezes, assim podemos obter o número de vezes que o ar entra por segundo, através da relação $\frac{RPM}{2*60}$, e com isso o nosso cálculo do fluxo de ar mostrado pela equação 4.13, que corresponde a um valor equivalente ao obtido diretamente pelo sensor MAF.

$$Fluxo_de_Ar = \frac{P * V * EV * RPM * mma}{120 * R * T} \quad (4.13)$$

Como dito anteriormente, os valores de T, P e o RPM são obtidos pelos sensores via OBD-II, V é calculado de acordo com as cilindradas do veículo e o EV poderá ser assumido como um valor constante, por exemplo, considerar que o motor está trabalhando a 80% de sua eficiência.

Após obtermos o valor da massa de ar, aplicamos a estimativa do método mostrado na subseção anterior, para encontrarmos a quantidade de CO₂ emitida pelo veículo.

Capítulo 5

Resultados

Tendo como base tudo que foi apresentado anteriormente, a validação dos métodos, foi realizada após uma etapa de coleta dos dados veiculares, onde para realizar a estimação da quantidade dos CO₂, como já dito anteriormente, foi utilizado um código em Python, que utiliza as informações vindas de sensores existentes nos veículos.

Os dados foram coletados ao durante um período de aproximadamente dois meses, em trajetos do dia a dia dos voluntários, que realizaram essa coleta com seus veículos. A etapa de coleta dos dados, ocorreu de modo mais intensivo entre os meses de agosto e setembro de 2017. A tabela 5.1 possui um resumo dos dados coletados do Chevrolet Agile do ano de 2012, durante os testes o veículo foi abastecido com gasolina. Para este veículo, o período da coleta dos dados ocorreu no final da tarde.

Tabela 5.1: Resumo de dados coletados Chevrolet Agile

Horário	Duração	Amostras	CO ₂ MAF	CO ₂ MAP
1. 16/08	20 min	134	188.54g	223.52g
2. 20/08	17 min	199	185.01g	204.95g
3. 23/08	35 min	246	355.26g	384.07g
4. 01/09	17 min	111	180.90g	209.80g
5. 10/09	14 min	106	181.07g	199.71g
6. 11/09	19 min	133	203.20g	212.35g
Total	122 min	929	1293.98g	1434.40g

Na tabela temos os resultados, obtidos por ambos os métodos de estimação, apresentados na seção 4.3.3, para seis percursos realizados pelo voluntário. Este veículo possuía uma vantagem em relação aos demais outros veículos utilizados, pois, o *scanner* OBD retornava as leituras para ambos os sensores de MAF e MAP, assim sendo possível comparar os dois métodos de estimação. Ao vermos a quantidade total de dióxido de carbono gerado na tabela 5.1, temos uma diferença de aproximadamente 100g de CO₂ a mais de acordo com o método MAP.

Resumidamente temos, os experimentos foram realizados em dias diferentes com horários aleatórios, trafegando por partes da cidade diferentes. Para o ambos os métodos foram coletados 929 amostras de CO₂. A estimação via MAF obteve um total de aproximadamente 1.300kg, enquanto a utilização do MAP gerou aproximadamente 1.430kg

CO₂ emitidos.

Com base nesses dados podemos obter estatísticas, que possam ajudar a analisar o comportamento desse conjunto e nos permita realizar um melhor comparação. Informações em termos da média e das medidas de variabilidade podem ser vistos na Tabela 5.2 e 5.3, para os métodos de estimação MAF e MAP respectivamente.

Tabela 5.2: Estatística de dados coletados MAF

Horário	Máximo	Mínimo	Média	Desvio	Variância
1. 16/08	4.22	0	1.42	0.81	0.64
2. 20/08	7.66	0	0.93	0.97	0.93
3. 23/08	4.34	0	1.44	0.86	0.74
4. 01/09	4.83	0	1.64	0.95	0.91
5. 10/09	4.08	0	1.71	0.89	0.79
6. 11/09	5.98	0	1.52	0.91	0.81

Tabela 5.3: Estatística de dados coletados MAP

Horário	Máximo	Mínimo	Média	Desvio	Variância
1. 16/08	5.19	0	1.68	0.74	0.86
2. 20/08	4.23	0	1.03	0.91	0.82
3. 23/08	4.22	0	1.56	0.74	0.56
4. 01/09	5.56	0	1.91	1.01	1.02
5. 10/09	4.14	0	1.89	0.86	0.73
6. 11/09	4.09	0	1.58	0.41	0.63

Primeiramente ao observar Tabelas 5.2 e 5.3 podemos perceber que, mesmo ao aplicar métodos diferentes ao conjunto de dados que possuem mesmos valores, os valores obtidos pela estimação de dióxido de carbono gerado na combustão, possuem diferenças significativas.

Analisando melhor as Tabelas 5.2 e 5.3, vemos que os valores de emissões obtidos pela estimação via MAP, de modo geral, são maiores que os valores obtidos por meio do MAF. Como mostrado na seção 4.3.3, a estimação utilizando o MAP leva em consideração diversas leituras vindas dos sensores existentes nos veículos, isso tornar o método mais sensível, por exemplo, a variação de pressão e temperatura do ar. Em dias mais frios, pode ocorrer dos valores de CO₂ gerados serem maiores. Outra situação que podemos destacar, seria com relação a locais que estão a uma altitude mais elevada, pois, isso ocasiona diminuição da pressão do ar atmosférico, deste modo gerando valores menores de CO₂ gerados pelo motor. Outro problema que pode ocorrer é com relação à calibração dos demais sensores utilizados.

As informações mostradas nas tabelas acima podem ser mais bem visualizadas através de *boxplots*, mostrado na Figura 5.1. O *boxplot* também conhecido como diagrama de caixa, é uma ferramenta cuja função principal é mostrar certas informações de um

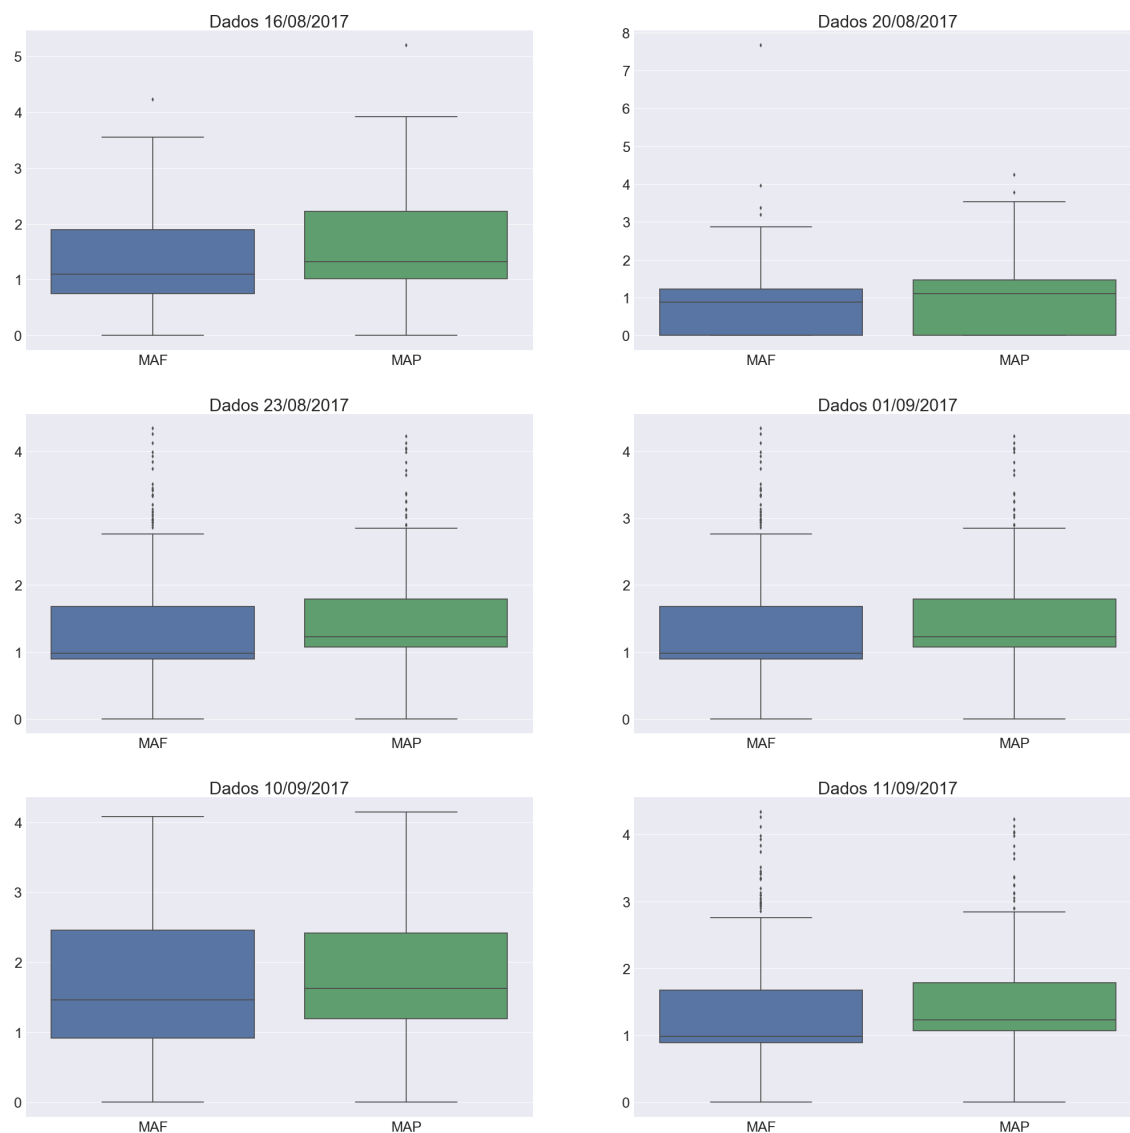


Figura 5.1: Boxplot dados Chevrolet Agile

conjunto de dados, por exemplo, dispersão, assimetria e medidas discrepantes, facilitando principalmente a visualização de tais informações.

Os *boxplots* acima, no fornecem informações interessantes. Primeiramente podemos ver, que em praticamente todos os conjuntos de dados a grande maioria dos dados de CO₂ estimados, são valores acima da mediana. Outro ponto intrigante, é com relação à quantidade de pontos discrepantes (*outliers*), pode-se ver que em metade dos conjuntos apresenta uma quantidade considerável de pontos discrepantes, com esse comportamento, e para o nosso caso são valores acima do máximo.

Adicionalmente as informações de CO₂ estimadas do Agile, também realizamos a estimação de outros veículos, com isso podemos ver a possibilidade de se realizar tal procedimento para diversos tipos de automóveis, com combustíveis diferentes. A tabela 5.4, apresenta algumas estimações para outros veículos. Lembrando que diferentemente

do Agile, para esses outros automóveis, só conseguimos realizar a estimaco via MAF ou MAP, pois, eles no possuem ambos os sensores.

Tabela 5.4: Resumo de dados coletados outros veculos

Veculo	Combustvel	Sensor	Amostras	CO ₂
Volkswagen Voyage	Gasolina	MAP	93	122.87g
Ford Ecosport	Gasolina	MAP	137	197.33g
Fiat Palio	lcool	MAP	379	483.37g
BMW X6	Gasolina	MAP	209	486.21g
Peugeot 208 Allure	lcool	MAP	179	283.71g
Honda Fit	Gasolina	MAP	617	521.83g
Toyota Etios	Gasolina	MAF	303	325.05g
Nissan Versa	Gasolina	MAF	169	269.80g
Toyota Corolla	Gasolina	MAF	691	2185.45g
Total			2777	4874.75g

De acordo com mostrado na Tabela 5.4, temos uma noo de uma situao mais real, onde diversos veculos diferentes trafegam dentro do seu dia a dia, em que cada um contribui para uma parcela da quantidade de CO₂ emitida. Os veculos mostrados na tabela realizaram percursos de tempos e distncias variadas, emitindo quase 5 kg de dixido de carbono. Notamos tambm que um veculo Toyota Corolla, foi responsvel por quase metade da quantidade total de CO₂, isso pode ser indicativo de algum possvel problema, eltrico ou mecnico no motor veculo, ou at mesmo representar a baixa qualidade do combustvel utilizado.

Tendo em posse os valores obtidos, da quantidade de CO₂ gerados pelo motor, podemos realizar diversas anlises e obter novos resultados, e assim fornecer informao para a gerao de novas soluoes.

A Tabela 5.5, apresenta outros resultados obtidos pelo mtodo do MAF, nesse caso, do veculo Toyota Etios 2015, usando gasolina como combustvel. Ressaltando que este veculo foi utilizado apenas a estimaco via MAF, pois, ele no possui um sensor MAP.

Tabela 5.5: Resumo de dados coletados Etios 2015

Horrio	Durao	Amostras	CO ₂
1. 17/05	19 min	294	251.37g
2. 19/05	19 min	288	245.68g
3. 23/05	18 min	271	236.28g
Total	56 min	853	733.33g

Onde para este ltimo conjunto apresentado, temos a coleta de dados de trs dias diferentes, com horrios semelhantes o incio da manh, o veculo esteve em operao por aproximadamente uma hora gerando mais de meio quilo de CO₂.

Realizando um mapeamento das emisses atravs de mapas de calor, e assim termos uma ideia melhor do que ocorreu e ns d novas informaoes para novas analises, como

pode ser visto nas Figura 5.2, representado o trajeto percorrido pelo veículo, referente ao dia 17/05 já apresentados resumidamente na Tabela 5.5. Onde as cores mais próximas ao vermelho representam locais com maior incidência, enquanto os tons mais próximos de verde são as áreas com menor quantidade de emissões. No mapa o marcador azul representa o ponto inicial do trajeto e verde o fim, além de ser um percurso do cotidiano do motorista.

Ressaltando que a utilização das bibliotecas do Python, por exemplo a *folium*, permitem que possamos criar mapas de calor de modo simples, para realizar uma melhor análise dos dados obtidos.

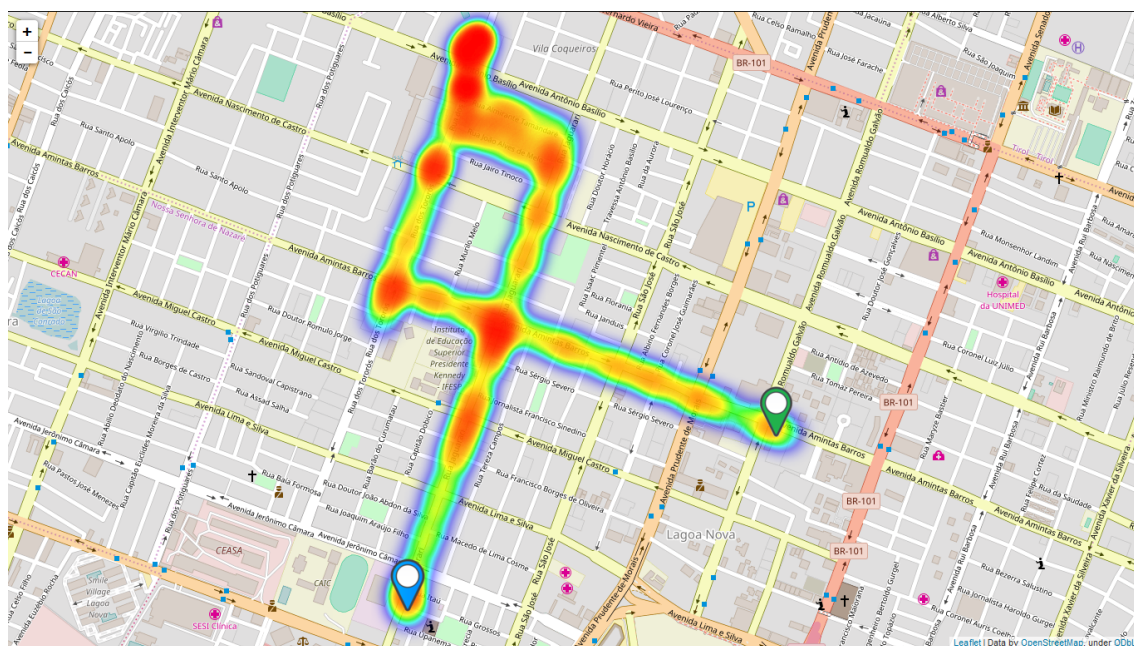


Figura 5.2: Mapa de calor trajeto Toyota Etios

Analisando a Figura 5.2, podemos ver que os locais com maior incidência podem ser identificados como cruzamentos e locais onde o veículo permaneceu parado por algum tempo, devido a semáforos e ao trânsito. Em trechos onde ocorre um fluxo mais fluido como no trecho em direção ao marcador verde, percebemos que a quantidade de CO_2 emitida diminuí, em relação a outros pontos do mesmo trajeto.

Devemos levar em consideração que os métodos apresentados nos fornecem estimativas de valores de CO_2 gerados pelo motor, no momento da combustão, o valor real liberado para o meio, é maior que esse valor estimado, pois antes de chegar ao ecossistema externo ao veículo, os gases poluentes passam pelo conversor catalítico e este é responsável por tratar os gases e transformá-los em gases menos nocivos a nossa saúde, e esses são liberados para o meio ambiente (McCartney 2003).

De modo geral o catalisador, converte o monóxido de carbono, que é altamente tóxico, em dióxido de carbono, que só nos afeta em grande quantidade, resultando em mais CO_2 liberado pelo veículo. Mesmo assim, os locais reais com maior incidência de CO_2 emitidos para atmosfera pelo veículo, serão os locais onde a estimativa gerou níveis maiores

para a quantidade de CO₂ gerados pelo motor.

Com isso, nós podemos listar alguns pontos interessantes sobre os resultados apresentados na Figura 5.2, com relação às áreas de maior incidência.

- Durante os momentos de partida, de estacionamento ou parado em semáforos, o veículo por se encontrar em uma área menor tendendo a ser mais afetada pela poluição.
- Locais intermediários das rotas devido há existência de engarrafamentos ou a presença de um trânsito mais pesado.
- Momentos em que o veículo teve a velocidade reduzida para atravessar cruzamentos e lombadas, também causou o aumento da emissão dos gases.

Capítulo 6

Conclusão

A poluição da atmosfera é um problema tanto para o meio ambiente, quanto para a saúde dos seres vivos. Diante disso podemos considerar que o monitoramento de áreas poluidoras em um ambiente urbano é um requisito eminente para o desenvolvimento das chamadas Cidades Inteligentes, onde os veículos representam uma das principais fontes poluidoras.

O presente trabalho, teve como objetivo apresentar métodos de estimação da quantidade de dióxido de carbono, referente ao valor gerado durante o momento da combustão de veículo. A partir destes valores podemos mostrar análises e novas soluções geradas a partir das estimações obtidas.

A utilização dos dois métodos, o *mass air flow* e o *speed density*, permite que tenhamos acesso a uma quantidade maior de veículos para realizarmos a coleta dos dados, pois, é comum que os veículos possuam apenas um dos dois sensores. Com os valores das quantidades de CO₂, podemos obter novos resultados, como o apresentado na Figura 5.2, que representa o mapeamento das emissões gerada durante um trajeto do veículo, mostrando que é realmente possível explorar a massa de dados coletada de veículos, para a criação de novas soluções e ferramentas. Tais itens podem facilitar o desenvolvimento sustentável dos centros urbanos e assim melhorar a qualidade de vida para todos.

Os resultados ainda demonstraram que a solução pode ser útil também no controle de tráfego nas cidades, haja visto que áreas com maior concentração de poluição geralmente compreendem cruzamentos, semáforos e regiões congestionadas (em horários específicos). Este potencial poderia ser explorado pelos gestores das cidades de modo a realizar um melhor gerenciamento das vias com grande tráfego, mostrando potencial da plataforma para outras análises.

Além disso, a informação da quantidade de CO₂, está ligada diretamente com a eficiência da combustão do motor, ou seja, se um veículo libera quantidades muito altas, pode ser um indicativo de que o veículo apresenta algum problema elétrico ou mecânico, ou até mesmo um indicativo para a qualidade do combustível usado.

Por último, destacamos algumas propostas de trabalhos futuros, inicialmente o estudo e desenvolvimento de uma estratégia para calcular o teor de combustível em veículos flex, com o objetivo de tornar os cálculos de emissão mais precisos no caso de veículos que utilizem combustíveis combinados, além de verificar o funcionamento da ferramenta com outras classes de automóveis.

Referências Bibliográficas

- AbuAli, N. (2015), Advanced vehicular sensing of road artifacts and driver behavior, *em* ‘2015 IEEE Symposium on Computers and Communication (ISCC)’, pp. 45–49.
- Al-Fuqaha, A., M. Guizani, M. Mohammadi, M. Aledhari & M. Ayyash (2015), ‘Internet of things: A survey on enabling technologies, protocols, and applications’, *IEEE Communications Surveys Tutorials* **17**(4), 2347–2376.
- Albertos, P.; Goodwin, G.C. (2002.), ‘Virtual sensors for control applications’, *Annual Review in Control* **v.26**, p. 101–112.
- Bell, A.G. (1998), *Four-stroke performance tuning*, 2^a edição, Haynes Publishing, Sparkford.
- Bellavista, Paolo, Giuseppe Cardone Antonio Corradi Luca Foschini & Raffaele Ianniello (2015), *Crowdsensing in Smart Cities: Technical Challenges, Open Issues, and Emerging Solution Guidelines*, IGI Global, capítulo 15, pp. 316–338.
- Bonino, D., M. T. D. Alizo, A. Alapetite, T. Gilbert, M. Axling, H. Udsen, J. A. C. Soto & M. Spirito (2015), Almanac: Internet of things for smart cities, *em* ‘Future Internet of Things and Cloud (FiCloud), 2015 3rd International Conference on’, pp. 309–316.
- Bonola, Marco, Lorenzo Bracciale, Pierpaolo Loreti, Raul Amici, Antonello Rabuffi & Giuseppe Bianchi (2016), ‘Opportunistic communication in smart city: Experimental insight with small-scale taxi fleets as data carriers’, *Ad Hoc Networks* **43**, 43 – 55. Smart Wireless Access Networks and Systems for Smart Cities.
- Breitman, Karin, Percy Salas, Marco Antonio Casanova, Daniel Saraiva, Vinicius Gama, Jose Viterbo, Regis Pires Magalhaes, Ednylton Franzosi & Miriam Chaves (2012), ‘Open government data in brazil’, *IEEE Intelligent Systems* **27**(3), 45–49.
- Brienza, Simone, Andrea Galli, Giuseppe Anastasi & Paolo Bruschi (2015), ‘A low-cost sensing system for cooperative air quality monitoring in urban areas’, *Sensors* **15**(6), 12242.
URL: <http://www.mdpi.com/1424-8220/15/6/12242>
- Brito, Kellyton dos Santos, Marcos Antônio da Silva Costa, Vinicius Cardoso Garcia & Silvio Romero de Lemos Meira (2015), ‘Is brazilian open government data actually open data?: An analysis of the current scenario’, *Int. J. E-Planning Res.* **4**(2), 57–73.
URL: <http://dx.doi.org/10.4018/ijep.2015040104>

- Brown, Roger & Samuel White (2012), Evaluation of camry hs-can pre-crash data, Relatório técnico, SAE Technical Paper.
- de Vasconcellos, E.A. (2000), *Transporte urbano nos países em desenvolvimento: reflexões e propostas*, Annablume.
URL: <https://books.google.com.br/books?id=rkb-RA72qD8C>
- DENATRAN (2017), Disponível em: <http://www.denatran.gov.br/index.php/estatistica/610-frota-2017>. Acessado em: 01-06-2017.
- DETRAN (2017), Disponível em: http://www2.detran.rn.gov.br/externo/est_Tipo.asp. Acessado em: 01-06-2017.
- EPA (2008), Average annual emissions and fuel consumption for gasoline-fueled passenger cars and light trucks, em ‘Office of Transportation and Air Quality’, pp. 2–5.
- Faiz, Asif, Christopher S Weaver & Michael P Walsh (1996), *Air pollution from motor vehicles: standards and technologies for controlling emissions*, World Bank Publications.
- Ferris, David H. (2009), ‘Global obd legislation update (worldwide requirements)’, Disponível em: <http://www.sae.org/events/training/symposia/obd/presentations/2009/d1daveferris.pdf>. Acessado em: 08-04-2017.
- Fortuna, L., Graziani S. Rizzo A. Xibilia M.G. (2007), *Soft Sensors for Monitoring and Control of Industrial Processes*, Springer-Verlag London.
- Guilherme, Roger Tadeu Gondim (2016), Sensor virtual para estimação de temperatura do Óleo em motores de combustão interna de automóveis, Dissertação de mestrado, Universidade de São Paulo.
- Han, Ke, Hongcheng Liu, Vikash V. Gayah, Terry L. Friesz & Tao Yao (2015), ‘A robust optimization approach for dynamic traffic signal control with emission considerations’, *Transportation Research Part C: Emerging Technologies* .
- Hernandez-Alcantara, Diana, Juan C. Tudon-Martinez, Luis Amesquita, Carlos A. Vivas-Lopez & Rubian Morales-Menendez (2016), ‘Modeling, diagnosis and estimation of actuator faults in vehicle suspensions’, *Control Engineering Practice* **49**, 173 – 186.
- Hill, Nikolas, H Walker, S Choudrie & K James (2012), ‘Guidelines to defra/decc’s ghg conversion factors for company reporting: Methodology paper for emission factors, department for environment’, *Food and Rural Affairs (Defra)* .
- IBAMA - Veículos automotores (2017), Disponível em: <http://www.ibama.gov.br/emissoes/veiculos-automotores?view=default>. Acessado em: 20-05-2017.
- IEEP (2010), ‘Subsidy level indicators for the case studies’, pp. 1–2.

- InnovateMotors (2014), 'Digital air/fuel ratio (lambda) meter', pp. 2–3.
- Jung, Kyung-Kwon & Woo-Seung Choi (2011), 'Estimation of vehicle's co2 emission using obd-ii interface', *Journal of the Korea Society of Computer and Information* **16**(12), 167–174.
- Ljung, L. (1987), *System Identification: Theory for the User*, Prentice-Hall.
- Lotufo F.A., Garcia C (2008), 'Sensores virtuais ou soft sensors: Uma introdução', *DIN-CON* pp. p. 101–112.
- Manavella, H J (2010), *Diagnóstico automotivo avançado. Injeção/ignição eletrônica. Sistemas OBDII*, MTE-THOMSON.
- Manzoli, Anderson (2009), Análise das emissões veiculares em trajetos urbanos curtos com localização por gps, Tese de doutorado, Escola de Engenharia, Universidade de São Paulo.
- Maroto-Valer, M. Mercedes (2016), 'Cop-21 and ccs: A tale of two cities', *Greenhouse Gases: Science and Technology* **6**(2), 161–162.
URL: <http://dx.doi.org/10.1002/ghg.1604>
- McCartney, Kevin S (2003), 'Catalytic converter theory, operation and testing', Disponível em: <http://www.bearriverconverters.com/data/CatOpp.pdf>. Acessado em: 11-10-2017.
- Monzon, A. (2015), Smart cities concept and challenges: Bases for the assessment of smart city projects, em 'Smart Cities and Green ICT Systems (SMARTGREENS), 2015 International Conference on', pp. 1–11.
- Morgan, Jamie (2016), 'Paris cop 21: Power that speaks the truth?', *Globalizations* pp. 1–9.
- Mábia Marelino Montalvão da Silva, Lays Xavier Da Silva, Milleny Almeida Silva Thainá Guimarães Duarte Ana Cláudia Alves de Oliveira (2016), 'Efeitos do dióxido de carbono na saúde e no meio ambiente'.
- Newman, Russell, Victor Chang, Robert John Walters & Gary Brian Wills (2016), 'Web 2.0 the past and the future', *International Journal of Information Management* **36**(4), 591 – 598.
- Ohshima, M.; Tanigaki, M. (2000), 'Quality control of polymer production processes', **10**(1).
- Ojo, Adegboyega K., Edward Curry & Fatemeh Ahmadi Zeleti (2015), A tale of open data innovations in five smart cities, em '48th Hawaii International Conference on System Sciences, HICSS 2015, Kauai, Hawaii, USA, January 5-8, 2015', pp. 2326–2335.

- Ota, M., H. Vo, C. Silva & J. Freire (2015), A scalable approach for data-driven taxi ride-sharing simulation, *em* 'Big Data (Big Data), 2015 IEEE International Conference on', pp. 888–897.
- Ribeiro, S.K.; Costa, C.V.; David E.G.; Real M.V.; D'Agosto M.A (2000), *Transporte e mudanças climáticas*, Mauad.
- Rice, Susan A. & Inc. Associates (2004), 'Human health risk assessment of co2: Survivors of acute high-level exposure and populations sensitive to prolonged low-level exposure', *3rd Annual conference on carbon sequestration* .
- Soheily-Khah, Saeid, Ahlame Douzal-Chouakria & Eric Gaussier (2016), 'Generalized k-means-based clustering for temporal data under weighted and kernel time warp', *Pattern Recognition Letters* **75**, 63 – 69.
- Stankovic, J. A. (2014), 'Research directions for the internet of things', *IEEE Internet of Things Journal* **1**(1), 3–9.
- Stroes, G. (2000-2002), 'Alpha-n explanation', Disponível em: <http://www.bayareamotorsport.com/alphan.html>. Acessado em: 15-03-2017.
- Taha, A. E. M. & N. Nasser (2015), Utilizing can-bus and smartphones to enforce safe and responsible driving, *em* '2015 IEEE Symposium on Computers and Communication (ISCC)', pp. 111–115.
- Traver M. L., Atkinson C. M., Atkinson R. J. (2000), 'A neural network-based virtual nox sensor for diesel engines', *West Virginia University, Mechanical and Aerospace Engineering Dept., Morgantown* .
- Wac, K., M. Cummings & J. Dey (2016), 'E2euberim: end-to-end service management framework for anything-as-a-service', *IEEE Communications Magazine* **54**(3), 54–60.
- Wu, X., Y. Wu, S. Zhang, H. Liu, L. Fu & J. Hao (2016), 'Assessment of vehicle emission programs in china during 1998-2013: Achievement, challenges and implications', *Environmental Pollution* **214**, 556–567.
- Zanella, A., N. Bui, A. Castellani, L. Vangelista & M. Zorzi (2014), 'Internet of things for smart cities', *IEEE Internet of Things Journal* **1**(1), 22–32.
- Zeng, Weiliang, Tomio Miwa & Takayuki Morikawa (2016), 'Prediction of vehicle {CO₂} emission and its application to eco-routing navigation', *Transportation Research Part C: Emerging Technologies* **68**, 194 – 214.
- Zeng, Weiliang, Tomio Miwa & Takayuki Moriwaka (2015), 'Exploring trip fuel consumption by machine learning from gps and can bus data', *Journal of the Eastern Asia Society for Transportation Studies* **11**, 906–921.

- Zhang, B., K. Ren, G. Xing, X. Fu & C. Wang (2016), 'Sbvlc: Secure barcode-based visible light communication for smartphones', *IEEE Transactions on Mobile Computing* **15**(2), 432–446.