

**UNIVERSIDADE DE SÃO PAULO**

Instituto de Ciências Matemáticas e de Computação

**Monitoramento do descarte de resíduos sólidos usando IoT e IA**

**Bruno Sugimoto Iwami**

Dissertação de Mestrado do Programa de Mestrado Profissional em Matemática, Estatística e Computação Aplicadas à Indústria (MECAI)



SERVIÇO DE PÓS-GRADUAÇÃO DO ICMC-USP

Data de Depósito:

Assinatura: \_\_\_\_\_

**Bruno Suguimoto Iwami**

## Monitoramento do descarte de resíduos sólidos usando IoT e IA

Dissertação apresentada ao Instituto de Ciências Matemáticas e de Computação – ICMC-USP, como parte dos requisitos para obtenção do título de Mestre – Mestrado Profissional em Matemática, Estatística e Computação Aplicadas à Indústria.  
*VERSÃO REVISADA*

Área de Concentração: Matemática, Estatística e Computação

Orientador: Prof. Dr. Jó Ueyama

**USP – São Carlos**  
**Dezembro de 2022**

Ficha catalográfica elaborada pela Biblioteca Prof. Achille Bassi  
e Seção Técnica de Informática, ICMC/USP,  
com os dados inseridos pelo(a) autor(a)

I96m Iwami, Bruno Suguimoto  
Monitoramento do descarte de resíduos sólidos  
usando IoT e IA / Bruno Suguimoto Iwami; orientador  
Jó Ueyama. -- São Carlos, 2022.  
73 p.

Dissertação (Mestrado - Programa de Pós-Graduação  
em Mestrado Profissional em Matemática, Estatística  
e Computação Aplicadas à Indústria) -- Instituto de  
Ciências Matemáticas e de Computação, Universidade  
de São Paulo, 2022.

1. Rastreo. 2. Tempo Real. 3. Inteligência  
Artificial. 4. Ciência de Dados. 5. Sistemas  
Embarcados. I. Ueyama, Jó, orient. II. Título.

**Bruno Suguimoto Iwami**

## Monitoring of solid waste disposal using IoT and AI

Master dissertation submitted to the Instituto de Ciências Matemáticas e de Computação – ICMC-USP, in partial fulfillment of the requirements for the degree of the Master – Professional Masters in Mathematics, Statistics and Computing Applied to Industry. *FINAL VERSION*

Concentration Area: Mathematics, Statistics and Computing

Advisor: Prof. Dr. Jó Ueyama

**USP – São Carlos**  
**December 2022**



*Este trabalho é dedicado à todos os entusiastas, estudantes e profissionais  
no desenvolvimento de sistemas embarcados e aplicações de aprendizado de máquina.  
Apresento-lhes um sistema que une os dois universos para solução de um problema real.*





# AGRADECIMENTOS

---

---

Os agradecimentos principais são direcionados aos professores J6 Ueyama e Francisco Louzada pela oportunidade de me acolher e permitir minha participa73o no projeto resultante deste programa de p6s-gradua73o.

Agrade73o ao Caetano Mazzoni Ranieri pelo acompanhamento durante o desenvolvimento do trabalho e pelas dicas e sugest6es extremamente valiosas que foram dadas.

Agrade73o 3 Korth RFID, pelo suporte na compra de componentes que acabaram sendo utilizados no projeto final, pela oportunidade dada a mim de poder trabalhar e aprender junto com seus funcion3rios e pela flexibilidade em permitir que eu trabalhasse e ainda me dedicasse ao programa de p6s-gradua73o.

Agrade73o aos meus pais, Alcino Iwami e Maria Cristina Suguimoto Iwami, e meu irm3o, Rodrigo Suguimoto Iwami, pelo incentivo e suporte para que eu continuasse minha jornada por conhecimento e por todo o carinho pelo qual fui agraciado durante minha vida inteira.

Agrade73o 3 Maria Am3lia por todo companheirismo, paci4ncia e resili4ncia que foram fundamentais em nossa caminhada at4 ent3o. Agrade73o tamb4m por poder contar com ela nas mais diversas e adversas situa73es.



*“N3o pense que 6 capaz.  
Saiba que 6.”  
(Morpheus - Matrix)*



# RESUMO

BRUNO, S. I. **Monitoramento do descarte de resíduos sólidos usando IoT e IA.** 2022. 73 p. Dissertação (Mestrado – Mestrado Profissional em Matemática, Estatística e Computação Aplicadas à Indústria) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos – SP, 2022.

O crescimento contínuo de cidades brasileiras e de outras localidades traz consigo um problema que muitas vezes é subestimado e até classificado erroneamente como irrelevante ou não muito impactante: o despejo de entulhos em locais inadequados. Um estudo superficial foi realizado a fim de averiguar alguns impactos desta prática e foi constatado que este ato de despejo inadequado é de fato prejudicial tanto à saúde das pessoas, quanto ao meio ambiente. O despejo de entulhos em locais inadequados pode facilitar a proliferação de diversos tipos de microrganismos nocivos à saúde, além de causar diversos impactos ambientais, como enchentes durante os períodos de chuva. Tendo isto em vista, foi elaborado um sistema de rastreamento de despejo de caçambas de entulhos.

Esta monografia descreve tal sistema, em que o monitoramento é realizado em tempo real utilizando tecnologias otimizadas para atender às restrições do meio a ser instalado, bem como algumas técnicas na área de Ciência de Dados. A aplicação se desenvolveu a partir de conhecimentos na área de Sistemas Embarcados para elaboração, avaliação, integração e uso de diversos sensores em conjunto com um *Single Board Computer* (SBC), responsável pelo gerenciamento dos dados obtidos, como envio e armazenamento. Desenvolveu-se também com conhecimentos em Matemática, Estatística e Computação para análise dos dados recebidos utilizando algoritmos de Inteligência Artificial.

**Palavras-chave:** Rastreo, Tempo Real, Inteligência Artificial, Ciência de Dados, Sistemas Embarcados.



# ABSTRACT

BRUNO, S. I. **Monitoring of solid waste disposal using IoT and AI**. 2022. 73 p. Dissertação (Mestrado – Mestrado Profissional em Matemática, Estatística e Computação Aplicadas à Indústria) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos – SP, 2022.

The continuous growth of Brazilian cities results in a problem that is frequently underestimated and even mistakenly classified as irrelevant or not very impacting: the dump of trash in inappropriate places. A superficial study was carried out in order to ascertain some impacts of this act, and through this it could be confirmed that this practice is in fact harmful both to people's health and to the environment. The dump of rubbish in inappropriate places can facilitate the proliferation of different types of harmful microorganisms, in addition to causing various environmental impacts such as the occurrence of flooding in raining periods. With this in mind, a dump tracking system for dumpsters has been developed.

This dissertation describes such a system, in which monitoring is performed in real time using technologies optimised to meet the restrictions of the medium to be installed, as well as some techniques in Data Science field. The present application applied knowledge from the Embedded Systems area, for the elaboration, evaluation, integration and use of several sensors in conjunction with a SBC, responsible for managing the data obtained, such as shipping and storage. It also applied knowledge from Mathematics, Statistics and Computing, to analyse the data received using Artificial Intelligence algorithms.

**Keywords:** Tracking, Real Time, Artificial Intelligence, Data Science, Embedded Systems.





# LISTA DE ILUSTRAÇÕES

---

---

Figura 1 – Patente "Systems and methods for identifying banned waste in a municipal solid waste environment". . . . .	35
Figura 2 – Patente "Method and apparatus for monitoring waste removal and administration". . . . .	36
Figura 3 – Patente "Vehicle load sensing system". . . . .	37
Figura 4 – Patente "Vehicle load weighing system and load cells for such systems". . .	38
Figura 5 – Patente "Waste container with weight-measurement system". . . . .	39
Figura 6 – Patente "System for remote management of a network of waste containers".	40
Figura 7 – Fluxograma do sistema . . . . .	44
Figura 8 – Célula de carga e HX711 . . . . .	46
Figura 9 – Antena e <i>Tag RFID UHF</i> . . . . .	47
Figura 10 – SARA G350 . . . . .	48
Figura 11 – Raspberry Pi . . . . .	49
Figura 12 – Ponte de Wheatstone . . . . .	52
Figura 13 – Simulação do Sumo . . . . .	57
Figura 14 – Movimentação dos veículos da simulação . . . . .	59
Figura 15 – Movimentação dos veículos direcionados aos ecopontos . . . . .	60



# LISTA DE TABELAS

---

---

Tabela 1 – Tabela comparativa entre os ensaios A e B. . . . .	53
Tabela 2 – Validação cruzada do Modelo K-NN . . . . .	62
Tabela 3 – Validação cruzada do Modelo Florestas Aleatórias . . . . .	63
Tabela 4 – Validação cruzada do Modelo LSTM . . . . .	64



---

# LISTA DE ABREVIATURAS E SIGLAS

---

---

API	<i>Application Programming Interface</i>
GPS	<i>Global Positioning System</i>
GSM	<i>Global System for Mobile Communication</i>
HTTP	<i>Hypertext Transfer Protocol</i>
KNN	<i>K-Nearest Neighbors</i>
LSTM	<i>Long Short Term Memory</i>
MLP	<i>Multi Layer Perceptron</i>
NMEA	<i>National Marine Electronics Association</i>
OSM	<i>Open Street Maps</i>
RFID	<i>Radio Frequency Identification</i>
RNN	<i>Recurrent Neural Network</i>
SBC	<i>Single Board Computer</i>
SUMO	<i>Simulation of Urban Mobility</i>
SVM	<i>Support Vector Machines</i>
UART	<i>Universal Asynchronous Receiver-Transmitter</i>
UHF	<i>Ultra High Frequency</i>



# SUMÁRIO

---

---

1	<b>INTRODUÇÃO</b>	23
2	<b>FUNDAMENTAÇÃO TEÓRICA</b>	27
2.1	<b>Sistemas Embarcados</b>	27
2.2	<b>Inteligência Artificial</b>	28
2.2.1	<b><i>Aprendizado de Máquina</i></b>	28
2.2.1.1	<i>K-NN</i>	28
2.2.1.2	<i>SVM</i>	28
2.2.1.3	<i>Naive Bayes</i>	28
2.2.1.4	<i>Random Forest</i>	29
2.2.1.5	<i>Gradient Boost</i>	29
2.2.2	<b><i>Aprendizado Profundo</i></b>	30
2.2.2.1	<i>MLP</i>	30
2.2.2.2	<i>LSTM</i>	30
3	<b>TRABALHOS RELACIONADOS</b>	33
3.1	<b>Literatura</b>	33
3.2	<b>Patentes</b>	34
3.2.1	<b><i>Patente US20070262878A1</i></b>	35
3.2.2	<b><i>Patente US20170121107A1</i></b>	36
3.2.3	<b><i>Patente US20140000969A1</i></b>	37
3.2.4	<b><i>Patente US20040226755A1</i></b>	37
3.2.5	<b><i>Patente US20170211969A1</i></b>	38
3.2.6	<b><i>Patente US006360186B1</i></b>	39
3.2.7	<b><i>Diferenciais</i></b>	40
4	<b>SISTEMA DE MONITORAMENTO DE DESCARTE</b>	43
4.1	<b>Visão Geral</b>	43
4.2	<b>Célula de carga: Mecanismo para verificar se a caçamba está carregada</b>	46
4.3	<b>RFID: Antena de <i>tags</i> para ler e identificar cada caçamba individualmente</b>	47
4.4	<b>Módulo GPS/GSM: Componente de comunicação sem fio e Geolocalização em tempo real</b>	48

4.5	Raspberry Pi: Computador no caminhão para ler e enviar dados . . .	49
4.6	Inteligência Artificial (IA): Classificação da trajetória do veículo . . .	50
5	<b>MÉTODOS E RESULTADOS . . . . .</b>	<b>51</b>
5.1	Visão Geral . . . . .	51
5.2	Ensaio com a Célula de carga . . . . .	51
5.2.1	<i>Ajuste para acomodar o amplificador de tensão e o conversor A/D</i> . . . . .	51
5.2.2	<i>Amplificador e conversor A/D</i> . . . . .	52
5.2.3	<i>Resultados dos testes com o amplificador e conversor A/D</i> . . . . .	53
5.3	Ensaio com Antena e Tag RFID . . . . .	54
5.3.1	<i>Definição da faixa de frequência da antena que lê o RFID</i> . . . . .	54
5.3.2	<i>Testes de funcionamento</i> . . . . .	54
5.4	Ensaio com módulo GPS/GSM . . . . .	55
5.4.1	<i>SARA G-350: módulo GPS/GSM</i> . . . . .	55
5.5	Ensaio da aplicação de IA . . . . .	56
5.5.1	<i>Ensaio com simulador</i> . . . . .	56
5.5.2	<i>SUMO: Simulation of Urban Mobility</i> . . . . .	56
5.5.3	<i>SUMO: Arquitetura do Simulador</i> . . . . .	57
5.5.4	<i>As simulações</i> . . . . .	58
5.5.5	<i>Aplicação da Inteligência Artificial</i> . . . . .	59
6	<b>DISCUSSÃO E TRABALHOS FUTUROS . . . . .</b>	<b>65</b>
6.1	Célula de Carga . . . . .	65
6.2	Antena e tag RFID . . . . .	65
6.3	Módulo <i>GPS/GSM</i> . . . . .	66
6.4	Raspberry Pi . . . . .	66
6.5	Inteligência Artificial . . . . .	67
6.6	Servidor . . . . .	68
7	<b>CONCLUSÃO . . . . .</b>	<b>69</b>
	<b>REFERÊNCIAS . . . . .</b>	<b>71</b>



---

# INTRODUÇÃO

---

O crescimento contínuo de cidades vem acompanhado do aumento no volume de obras e construções de novos locais tanto residenciais como comerciais, as quais podem ser causadoras de diversas consequências negativas para o meio ambiente, tanto de forma direta como indireta. O ato de construir novos sítios acaba por gerar diversos tipos de materiais a serem descartados, os entulhos. O problema em análise neste trabalho é o despejo de caçambas de entulhos em locais inadequados. Vale mencionar que os materiais da análise não são exclusivamente resultantes de construções e sim qualquer tipo de material. Esta prática não é de grande notoriedade aos olhos da população, no entanto, é responsável por diversos problemas ambientais, risco à saúde pública e até à economia do país. Por esse motivo, as cidades possuem locais onde se pode descartar adequadamente este tipo de resíduo, os ecopontos.

O acúmulo de entulhos em locais inapropriados, de acordo com um estudo levantado pela [GTech \(2018\)](#), revela diversos problemas de grande impacto na sociedade, são eles:

**Obstrução de vias públicas:** o despejo dos resíduos em locais inadequados provoca a obstrução de vias públicas, isto é, prejudica a mobilidade e circulação urbana, podendo causar inclusive acidentes de trânsito;

**Poluição ambiental:** o acúmulo de lixo em locais inadequados pode poluir o solo e lençóis freáticos, o que, conseqüentemente, afeta a flora e fauna locais;

**Alagamentos e enchentes em períodos de chuva:** nesses períodos, muitos materiais são levados pelas águas pluviais, que acabam por concentrá-los nos pontos de escoamento, causando alagamentos e enchentes;

**Proliferação de doenças:** a contaminação do solo e de lençóis freáticos favorece a proliferação de mosquitos, ratos, escorpiões, entre outros insetos e animais peçonhentos.

**Prejuízos ao turismo:** além das consequências estruturais, existe o problema de poluição visual, que pode afastar possíveis visitantes e turistas;

**Aumento dos gastos públicos com limpeza urbana:** o descarte inadequado de entulhos faz com que a cidade seja obrigada a investir na solução deste problema, fazendo com que recursos que poderiam ser utilizados nas áreas de saúde, educação, segurança ou cultura sejam dedicados à limpeza urbana;

**Desvalorização de imóveis:** os locais onde o descarte inadequado de entulhos é realizado tendem a apresentar com mais ênfase os problemas citados anteriormente, o que faz com que a região seja desvalorizada comercialmente.

Existem diversos estudos a respeito desta prática de descarte inadequado, como por exemplo a seguinte notícia do jornal da Usp - Campus Ribeirão Preto:

Estudo realizado na Faculdade de Filosofia, Ciências e Letras de Ribeirão Preto (FFCLRP) da USP, em parceria com a Universidade de Brasília (UnB) e a Companhia Ambiental do Estado de São Paulo (Cetesb), analisou amostras de sedimento da Lagoa do Saibro e identificou a presença de vários contaminantes, compostos químicos chamados éteres difenílicos polibromados (PBDEs). Os PBDEs estão presentes em diversos bens de consumo, como colchões, estofamento de móveis e automóveis, carpetes, computadores, equipamentos eletrônicos, nylon, adesivos e isolantes de fios. Os valores encontrados de PBDEs na lagoa foram semelhantes aos de lagoas próximas a regiões industrializadas. (USP, 2016)

Isto é, mesmo em uma região livre de indústria constata-se uma enorme quantidade de agentes nocivos à saúde pública, como relata o professor Daniel Junqueira Dorta na mesma notícia:

O pesquisador lembra que o composto pode colocar em risco a saúde da população. “Na literatura pesquisas já demonstraram que os PBDEs podem induzir o crescimento anormal de órgãos reprodutivos femininos, ter efeitos neurotóxicos, alterações endócrinas e deficiência de aprendizagem e memória. Estamos avaliando no laboratório a toxicidade deste composto, que tem mostrado capacidade de induzir danos às células e induzir morte celular”, esclarece o professor. (USP, 2016)

Segundo a notícia do Jornal *Nacional* (2018), há registro de milhares de toneladas de entulhos sendo descartados de forma inadequada em várias cidades do país e pouquíssimas cidades (menos de vinte por cento) tratam este descarte da maneira correta. Se este resíduo fosse tratado de forma mais consciente, seria possível realizar sua reciclagem e, desta forma, obter uma economia de até 80% nos custos de novas obras através do uso de areias e pedras recicladas.

---

Algumas cidades já possuem um sistema de monitoramento de caçambas como é o caso de São Carlos ([AGORA, 2013](#)), no entanto, o sistema implantado funciona de maneira manual, ou, não automatizada. Tal sistema demanda o deslocamento de um fiscal até determinada caçamba para inserir no servidor os dados relacionados ao tipo de material, estado da caçamba (cheia, vazia, etc...), localização e regularidade.

A prefeitura da cidade de São Carlos, ciente dos diversos problemas discutidos anteriormente nesta seção, requisitou a elaboração de um projeto para que o atual sistema de controle de despejo de caçambas de entulho fosse aprimorado, melhorando sua eficácia, precisão e rastreabilidade. Este trabalho tem como objetivo descrever tal projeto.

O sistema elaborado consiste em realizar de maneira automatizada o rastreamento tanto da localização de cada caçamba de entulho, como o local de despejo/coleta de material. Desta forma, tem-se um controle mais robusto e preciso de onde os resíduos estão sendo despejados e coletados sendo indevidamente espalhados pela cidade. Portanto, é possível alertar os transportadores e/ou empresas responsáveis da prática indevida e até mesmo delegar devidas autuações.

Vale enfatizar que a elaboração do sistema em questão foi dada de forma a se reduzir ao máximo os custos de produção, isto é, torná-lo um sistema de baixo custo para viabilizar sua aquisição, instalação e utilização. Com isso, espera-se contribuir para que esta tecnologia seja amplamente difundida e instalada no maior número de cidades possível, já que desta forma estará contribuindo tanto para o meio ambiente, como para a saúde pública e até para a economia do país.

A contribuição do sistema descrito neste trabalho, no âmbito acadêmico, se dá com o estudo e utilização de técnicas do campo da Inteligência Artificial aplicadas à um contexto bem prático de sintonia com um sistema embarcado (eletrônico) responsável por coletar diversos tipos de dados e comunicar-se remotamente com um servidor encarregado de processá-los.

Finalmente, espera-se que este sistema auxilie na redução de materiais despejados inadequadamente e com isso amenizar os problemas mencionados no estudo da [GTech \(2018\)](#).

Nos capítulos seguintes encontram-se: Fundamentação Teórica (Capítulo 2), Trabalhos Relacionados (Capítulo 3), o Sistema de Monitoramento de Descarte (Capítulo 4), Métodos e Resultados (Capítulo 5), Discussão e Trabalhos Futuros (Capítulo 6) e Conclusão (Capítulo 7).



---

## FUNDAMENTAÇÃO TEÓRICA

---

A presente seção visa identificar os pontos relativos à fundamentação teórica necessária para o desenvolvimento das partes envolvidas no projeto.

### 2.1 Sistemas Embarcados

Quando se fala em Sistemas Embarcados, a primeira ideia que ocorre é a utilização de uma eletrônica dedicada à realização de uma determinada tarefa. Dada a especificidade do problema e as restrições do ambiente onde o sistema será instalado, a escolha dos componentes a serem utilizados é essencial para o funcionamento adequado da aplicação. Tal decisão acerca dos componentes a serem utilizados envolve diversos fatores, como tamanho, consumo de energia, precisão dos resultados, eficiência na realização de sua funcionalidade e custo. Como qualquer produto que utiliza uma eletrônica embarcada, o custo é essencial para sua viabilização. Tais restrições e capacidade de adaptação de determinado componente eletrônico fazem parte da fundamentação teórica do meio de sistemas embarcados do projeto (BARR, 1999).

Os tipos componentes utilizados no sistema são, basicamente, um controlador de propósito geral, sensores e módulos. O controlador é responsável por gerenciar todo o sistema e executar a lógica de operação. Já os sensores, são responsáveis por fazer uma tradução de sinais do meio físico para o meio digital. Por fim, os módulos são pequenos controladores integrados aos sensores para interfacear tarefas mais específicas. Os sensores utilizados fornecem informações como: intensidade de deformação do material (após processado pode-se estimar peso) e quantização de sinais de radiofrequência (podendo inferir informações contidas em um objeto refletor, no caso *tag RFID*). Os módulos utilizados operam tanto como receptores quanto transmissores, como o módulo GPS que identifica localização em diversos lugares e o módulo 3G, que pode receber ou enviar requisições pela Internet.

## 2.2 Inteligência Artificial

Quanto a análise de dados, foram considerados alguns algoritmos clássicos de Inteligência Artificial como Aprendizado de Máquina e Aprendizado Profundo provenientes das bibliotecas em Python: Scikit-learn (PEDREGOSA *et al.*, 2011) e TensorFlow (ABADI *et al.*, 2015).

### 2.2.1 Aprendizado de Máquina

Algoritmos de Aprendizado de máquina podem ser interpretados como uma mistura de estatística, probabilidade e álgebra linear (BROWNLEE, 2016).

Primeiramente, foram considerados experimentos com algoritmos mais clássicos de Aprendizado de máquina. As seguintes modelagens foram testadas: *K-Nearest Neighbors* (KNN), *Support Vector Machines* (SVM), *Naive Bayes*, *Random Forest* e *Gradient Boost*.

#### 2.2.1.1 K-NN

K-NN, ou "K Vizinhos mais próximos" é um algoritmo cujo nome é auto-explicativo. Trata-se de um modelo não-paramétrico que classifica um dado de entrada de acordo com sua semelhança com os dados de treinamento, isto é, a classificação é baseada no rótulo de maior frequência dentre os K vizinhos mais próximos do dado de teste.

É possível definir qual a função de distância será utilizada para inferir a proximidade do dado de teste com os dados de treinamento assim como o valor de K, que define a quantidade de vizinhos a se considerar durante a classificação.

#### 2.2.1.2 SVM

As "máquinas de vetores de suporte"(Support Vector Machines) tem um funcionamento baseado na relação dos dados a serem classificados com um hiper-plano (aprendido durante o treinamento). Basicamente, a ideia é aprender, durante o treinamento, os parâmetros de formação de um hiper plano cuja distância entre o ponto mais próximo (de cada classe) ao hiper-plano seja máxima.

Este algoritmo é bastante popular por sua versatilidade em se utilizar *kernels* não-lineares, podendo gerar hiper-planos de "segregação" mais precisos quando utilizando dados de entrada com maior dimensionalidade, por exemplo.

#### 2.2.1.3 Naive Bayes

O classificador *Naive Bayes* é baseado no teorema de Bayes:

$$P(h|d) = \frac{P(d|h) * P(h)}{P(d)}$$

, onde:

- $P(h|d)$  é a probabilidade da hipótese  $h$  dado  $d$ ;
- $P(d|h)$  é a probabilidade do dado  $d$  dada hipótese  $h$ ;
- $P(h)$  é a probabilidade da  $h$  ser verdadeiro;
- $P(d)$  é a probabilidade do dado  $d$ ;

Basicamente, o modelo Naive Bayes tem como resultado  $P(h|d)$  (do teorema de Bayes) dadas as probabilidades de cada dado e suas hipóteses  $P(d|h)$  calculadas durante o treinamento. Isto é, associa-se a cada classe e cada tipo de dado de entrada uma probabilidade e então, quando um novo dado é testado, calcula-se a probabilidade deste pertencer à determinada classe baseado na probabilidade de dados semelhantes (observados durante o treinamento) pertencerem à mesma classe.

#### 2.2.1.4 Random Forest

O modelo de "Florestas Aleatórias", como o nome indica, são um conjunto de árvores (de decisão). A proposta do algoritmo visa solucionar o problema de alta sensibilidade das árvores de decisão, isto é, uma pequena mudança nos dados de treinamento poder resultar em uma predição completamente diferente.

De forma a tentar minimizar o problema das árvores de decisão, o algoritmo de florestas aleatórias utiliza uma pluralidade de árvores de decisão de forma que a predição destas possuam menor correlação possível entre elas. Isto é feito considerando uma amostragem dos dados dados de treinamento para cada árvore.

Pode-se definir a quantidade de características ( $m$ ) a serem amostradas para cada árvore de decisão, recomenda-se:

- para classificação:  $m = \sqrt{p}$
- para regressão:  $m = \frac{p}{3}$

, onde  $p$  é a quantidade de características de cada dado e  $m$  a quantidade de características amostradas para cada árvore.

#### 2.2.1.5 Gradient Boost

O modelo de "Reforço de Gradiente" também é baseado em um conjunto de "sub-modelos". Diferentemente das florestas Aleatórias, este método consiste na execução consecutiva de diversas árvores de decisão, isto é, um novo "sub-modelo" é treinado de forma a melhorar a classificação do modelo anterior.

## 2.2.2 Aprendizado Profundo

Na sequência, após realizar ensaios com algoritmos de Aprendizado de Máquina, foram considerados também os algoritmos de Aprendizado Profundo, ou, Redes Neurais.

A intuição por trás das Redes neurais é de tentar imitar o cérebro humano que funciona baseado em milhões de neurônios (NIELSEN, 2015). Para isto são utilizados modelos com diversas "camadas" diferentes, responsáveis por extrair algum tipo de informação e/ou padrão dos dados de entrada.

A unidade fundamental de um modelo de rede neural é o neurônio, ou *perceptron*, que consiste, basicamente, de uma operação matemática de multiplicação e soma de cada dado de entrada com os seus pesos atribuídos, chamados de *kernel* (multiplicação) e *bias* (soma). Pode ser escrito como:

$$\sum_{i=0}^m x_i * w_i + b_i$$

, onde:

- $x$  é o dado de entrada;
- $w$  é o peso *kernel* (unidade multiplicativa);
- $b$  é o peso *bias* (unidade aditiva);

Para os ensaios considerando redes neurais profundas foi utilizada a biblioteca do TensorFlow. Neste ensaio foram consideradas duas estratégias de arquitetura de redes: *Multi Layer Perceptron* (MLP) e *Long Short Term Memory* (LSTM).

### 2.2.2.1 MLP

O Perceptron Multicamadas, também conhecido por *MLP*, consiste em *perceptrons* disponibilizados em duas ou mais camadas de forma que a saída de uma camada é diretamente utilizada como entrada da camada subsequente (SHEPHERD, 1997).

A ideia principal é que a utilização de múltiplas camadas pode representar melhor os padrões dos dados de entrada da rede.

### 2.2.2.2 LSTM

Uma sub-área do aprendizado profundo são as redes neurais recorrentes, ou *Recurrent Neural Network* (RNN), que são bastante utilizadas quando os dados de entrada possuem informações temporais importantes, isto é, existe uma dependência entre a sequência dos dados.

Diferente do Perceptron Multicamadas, as redes neurais recorrentes retém um estado que representa a informação de uma janela de contexto. Portanto, como resultado, enquanto o



Perceptron Multicamadas simplesmente mapeia um vetor de entrada para um vetor de saída, as redes neurais recorrentes podem, a princípio, mapear um histórico de entradas anteriores para cada saída (ZARGAR, 2021).

Este trabalho está mais focado no uso da rede Memória de Longo Prazo, ou, *LSTM*, que é uma variação da rede neural recorrente básica com uma mecânica para evitar o problema do desaparecimento do gradiente através da substituição da célula de unidade por uma célula de memória.

De forma geral, a célula da arquitetura Memória de Longo Prazo possui dois atributos distintos: o estado interno e os portões. O estado interno, também chamado de célula de estado, pode ser interpretado como uma borda que abrange passos adjacentes de tempo em uma unidade de peso fixo, isto faz com que enquanto o peso continue constante, os erros podem se propagar por múltiplos passos sem que o gradiente desapareça ou exploda. Já os portões são responsáveis por regular o fluxo de informação através do ajuste do estado interno e a saída da célula de memória (ZARGAR, 2021).



---

## TRABALHOS RELACIONADOS

---

### 3.1 Literatura

Como o presente trabalho tem objetivo de descrever a proposta de um novo sistema automatizado, um extenso leque de possíveis análises e estudos baseados em trabalhos encontrados na literatura é aberto, como por exemplo o trabalho de [Besse \*et al.\* \(2017\)](#) que propõe uma metodologia para prever o destino de um veículo dado um trecho de sua trajetória.

A abordagem de [Besse \*et al.\* \(2017\)](#) ocorre em duas etapas: agrupamento e classificação. Primeiro, atribui o trecho de movimentação observado à um grupo de possíveis trajetórias previamente separado. Então, extrai características do trecho observado e classifica entre as possíveis trajetórias do grupo em que foi atribuído. Os resultados obtidos mostram que tal metodologia traz performance competitiva com relação à métodos mais complexos e difíceis de se rastrear, como por exemplo os baseados em Aprendizado Profundo.

Tratando-se de um sistema que opera em tempo real é válido mencionar o trabalho de [Meyers \*et al.\* \(2021\)](#) que propõe uma metodologia de predição de destino baseado em coordenadas geográficas coletados por dois veículos em períodos de 3 e 6 meses.

A técnica utilizada por [Meyers \*et al.\* \(2021\)](#) consiste em, inicialmente, agrupar as localizações de início do percurso e, ao começar o trajeto, definir a qual grupo pertence a localização de partida do veículo. Durante seu percurso efetivo são realizadas sucessivas inferências do modelo classificador de forma a se prever qual é o destino final do veículo.

Os dados utilizados como entrada do modelo são o grupo a qual pertence o ponto de início do trajeto, o horário do dia mais próximo dos horários definidos previamente, o dia da semana em que o percurso está sendo realizado e a atual latitude e longitude do veículo. Vale mencionar que um novo modelo é treinado a cada nova trajetória. O trabalho mostra uma acurácia de mais de 90% na base de dados gerada pelo primeiro veículo (que coletou dados durante 6 meses) e mais de 70% no outro veículo (3 meses de coleta de dados).

Estes trabalhos de predição de trajeto (BESSE *et al.*, 2017) (MEYERS *et al.*, 2021) estão bastante alinhados com a problemática de alertar um despejo de entulho em local inadequado (lugares não classificados como ecopontos) pois seria possível modelar a questão de detecção de despejo infrator como um problema de desvio de rota, isto é, predizer o trajeto sendo percorrido pelos caminhões e verificar se o mesmo passará por um ecoponto ou não.

Vale citar o trabalho de Singla e Bhatia (2015) em que é proposto um sistema de monitoramento de ônibus para estimar seu tempo de chegada até determinado ponto de parada. Desta forma, pretende ajudar a população que depende de transporte público com uma estimativa de tempo mais precisa do veículo chegar ao seu ponto de embarque. Ele utiliza a técnica de agrupamento K-Means para se definir uma localização média do ponto de interesse e então pode calcular uma velocidade média até tal local.

Tal estratégia pode ser adaptada para o cenário do sistema em questão em que o local a ser agrupado pelo algoritmo do K-Means seriam os pontos de chegada dos ecopontos da cidade. Desta forma, através das coordenadas geradas pelos veículos durante sua movimentação corriqueira, seria possível estimar um tempo de chegada até o ecoponto, o qual pode servir como base para supor desvios de trajeto e até indicar possibilidade de despejos em locais inadequados (visto que o veículo não está percorrendo o trajeto ótimo até determinado ecoponto).

O trabalho de Duca, Bacciu e Marchetti (2017) propõe a predição de rotas de navios utilizando um modelo *K-NN* de aprendizado de máquina e, com isto, pretende incrementar o poder de decisão dos sistemas de suporte para permissão de navegação. A ideia é utilizar coordenadas geográficas, velocidade terrestre (calculada em graus), seno e cosseno da velocidade terrestre e o tipo do navio como dados de entrada. Como saída, é esperado um classificador que indicará qual será a posição do navio após um determinado tempo, que pode ser definido pelo usuário.

A intuição de se utilizar dados de localização para predizer o próximo passo é bastante relevante na problemática que o sistema descrito nesta dissertação se propõe à resolver. Com isto seria possível identificar se o veículo estará ou não no ecoponto.

## 3.2 Patentes

Como este projeto originou um depósito de patente, vale mencionar nesta sessão, também, outras patentes encontradas durante a busca por anterioridade inventiva, *i.e.* sistemas já patenteados com certo grau de similaridade com o presente invento. Foram encontradas um total de seis patentes registradas, sendo as mesmas, não necessariamente aprovadas.

### 3.2.1 Patente US20070262878A1

A primeira patente, intitulada "Systems and methods for identifying banned waste in a municipal solid waste environment" (MARUCA; LEONE; CRONIN, U.S. Patent US20070262878A1, Nov. 2007), retrata um sistema que utiliza *tags* de identificação por radiofrequência (*RFID*), leitor *RFID*, computador de bordo, computador, banco de dados e algum tipo de rede para comunicação. O computador e o banco de dados podem ser conectados via rede e a comunicação sem fio é fornecida, por exemplo, por meio de um modem de infraestrutura celular padrão e/ou um link sem fio padrão 802.11. O sistema consiste em identificar os materiais contidos no interior dos contêineres e buscar na base de dados informações a respeito do material, podendo desta forma controlar seguramente seu descarte ou não. Um esboço da estrutura pode ser observado na Figura 1.

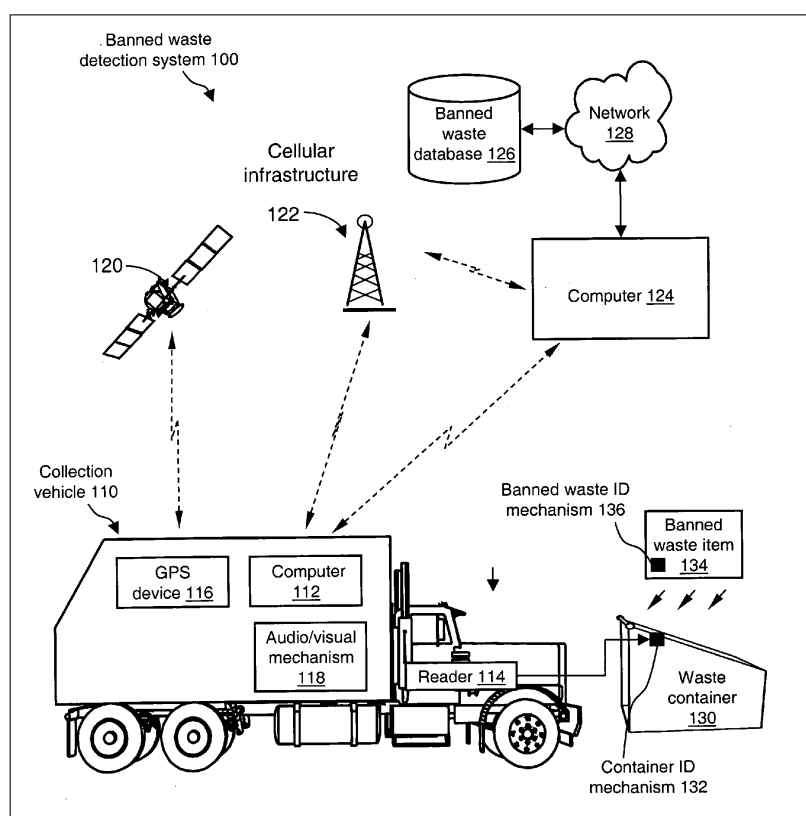


Figura 1 – Patente "Systems and methods for identifying banned waste in a municipal solid waste environment".

Maruca, Leone e Cronin (U.S. Patent US20070262878A1, Nov. 2007).

Legenda: 100: Apresentação do sistema. 110: Veículo de coleta. 112: Computador. 114: Leitor RFID. 116: Dispositivo GPS. 118: Mecanismo de interação áudio/visual. 120: Satélite GPS. 122: Infraestrutura celular. 124: Computador. 126: Base de dados. 128: Rede de conexão. 130: Caçamba de entulho. 132: Mecanismo de identificação do contêiner. 134: Item banido (a ser descartado).

### 3.2.2 Patente US20170121107A1

Com um objetivo semelhante ao do projeto proposto, a patente "Method and apparatus for monitoring waste removal and administration" (FLOOD; FISHER, U.S. Patent US20170121107A1, May 2017) descreve um método para um município conseguir controlar, rastrear e monitorar os resíduos, ou até mesmo recusá-los. O método consiste em uma organização para emitir um identificador (*tag RFID*) com permissões, a ser anexado ao respectivo recipiente (caçamba). Tal recipiente transmite um sinal ao leitor que poderá ser transportado por funcionários para registrar possíveis violações associadas à legislação. O caminhão é equipado com transdutores, antenas, sensores ou combinação dos mesmos, de modo que recebem o sinal e enviam um sinal correspondente que pode ser via cabo, sem fio ou qualquer outro meio para uma comunicação a bordo ou link de dados. O veículo possui um controlador, que pode ou não estar no interior do computador de bordo, para ativar e desativar o meio de transferência do recipiente em comunicação com o computador de bordo. O computador de bordo possui uma comunicação externa via modem ou algum outro dispositivo, demonstrada como comunicação sem fio.

Este registro prevê diversas arquiteturas de instalação de acordo com a estrutura do veículo alvo. Um exemplo dessas arquiteturas pode ser observado na Figura 2.




Figura 2 – Patente "Method and apparatus for monitoring waste removal and administration".

Flood e Fisher (U.S. Patent US20170121107A1, May 2017)

Legenda: 102: Mecanismo identificador. 200c: Veículo. 202: Caçamba do veículo. 206: Segundo coletor. 208a: Primeiro receptor. 208b: Segundo receptor. 212: Local do passageiro.

### 3.2.3 Patente US20140000969A1

O registro de [Carruthers e Rollo \(U.S. Patent US20140000969A1, Jan. 2014\)](#) (i.e., "Vehicle load sensing system") refere-se a uma metodologia de instalação de células de carga para sistemas que contam com a aferição de peso de objetos, mais especificamente, instalados em veículos. O sistema exibe as informações coletadas localmente ou em um outro ponto remoto que permita um controle central de um determinado número de veículos. Esta solução utiliza um ou mais sensores de carga que permitem a medição do peso transportado. Nesse caso, os sensores de carga podem ser localizadas no chassi, no plano do piso ou nos eixos do veículo. De forma alternativa, existe ainda uma espécie de tapete que pode ser colocado sobre o chassi ou piso do veículo com sensores de carga. Na medição do peso da carga, os sensores podem transmitir essa informação para uma unidade central de processamento que posteriormente exibirá em um *display* montado, por exemplo, no interior do veículo, ou até mesmo em um telefone celular padrão que possui uma conexão sem fio adequada. Em modalidades existentes, as informações exibidas no *display* também podem ser encaminhadas para um ponto de informação adicional externo, permitindo um controle central de um número de veículos. Essas informações podem ser transmitidas em conjunto com uma conexão do Sistema de Posicionamento Global (*GPS*).

A Figura 3 ilustra uma vista do topo de um veículo e a metodologia de instalação das células de cargas.




Figura 3 – Patente "Vehicle load sensing system".

[Carruthers e Rollo \(U.S. Patent US20140000969A1, Jan. 2014\)](#).

Legenda: 118: Localização dos sensores. 120: Processador. 124: Emissor do alerta sonoro. 126: Eixo do veículo.

### 3.2.4 Patente US20040226755A1

Muito semelhante ao registro anterior, foi encontrado o registro intitulado "Vehicle load weighing system and load cells for such systems" ([POTTEBAUM; INALSINGH, U.S. Patent](#)

US20040226755A1, Nov. 2004) que enfatiza o uso reduzido de conexões com fio utilizando um único barramento de comunicação que conecta todos os componentes do sistema ao controlador do sistema, tornando, desta forma, o sistema de pesagem de carga do caminhão resistente a violações. Uma representação do invento pode ser observado na Figura 4.

Esta patente descreve também o armazenamento de histórico e dados de calibração em uma memória contida nas células de carga e no controlador. Esta rede permite a expansão futura do sistema de medição de peso da carga, sendo possível, instalação de sistema de posicionamento global (conforme mencionado anteriormente) ao registro de recebimento e conexão com computadores externos (sem fio).




Figura 4 – Patente "Vehicle load weighing system and load cells for such systems".

Pottebaum e Inalsingh (U.S. Patent US20040226755A1, Nov. 2004).

Legenda: 1001: Sistema de pesagem em caminhão proposto. 1002: Cabine. 1003: Contêiner. 1004: Chassi. 1005: Acoplamento do contêiner. 1006: Localização das células de carga.

### 3.2.5 Patente US20170211969A1

O registro intitulado "Waste container with weight-measurement system" (WAITE *et al.*, U.S. Patent US20170211969A1, July 2017) possui a mesma finalidade dos inventos descritos anteriormente, explora ainda as considerações com relação ao recipiente que conterá o material cujo peso será aferido, afirmando que este peso deve ser conhecido previamente e que o mesmo será desconsiderado fornecendo somente a carga útil. Conta também com a possibilidade de comunicação da informação de aferição através da internet ou um sistema celular com um computador remoto que executa um software operável para manipular e exibir os dados recebidos. A Figura 5 ilustra um esquemático deste sistema.






Figura 5 – Patente "Waste container with weight-measurement system".

Waite *et al.* (U.S. Patent US20170211969A1, July 2017).

Legenda: 100: Sistema de depósito. 102: Câmara de carregamento. 104: Câmara de compactação. 106: Compactação/Armazenamento unitário. 108: Abertura da câmara. 120: Trilhas de suporte. 122: Rodas. 140: Sistema de pesagem. 146: Módulo de comunicação.

### 3.2.6 Patente US006360186B1

Já o invento "System for remote management of a network of waste containers" (DURBIN, U.S. Patent US006360186B1, Mar. 2002) revela um sistema de gerenciamento remoto de uma rede de recipientes de resíduos (Figura 6) fornecendo informações completas a um usuário sobre o status de toda rede. Em uma modalidade, existe um computador central que se comunica com todos os recipientes através de um link de comunicação e são gerenciadas por um módulo de comunicação, esse computador central tem como uma das funções atualizar dinamicamente o status de todos os recipientes, como localização, contato, transportador associado e etc. Existe ainda um módulo de exibição e um módulo de comunicação que faz interface com o dispositivo de comunicação como um modem, e que gerencia sessões de comunicação com as unidades de monitoramento da rede de recipientes para armazenar informações que são enviadas periodicamente no banco de dados.




Figura 6 – Patente "System for remote management of a network of waste containers".

Durbin (U.S. Patent US006360186B1, Mar. 2002).

Legenda: 12A-D: Contêiner que recebe resíduo. 38A-D: Unidade de monitoramento. 36A-D: Via de conexão. 50: Computador Central.

### 3.2.7 Diferenciais

Este projeto contesta sua legitimidade inventiva comparando tanto as invenções mencionadas individualmente quanto ao conjunto (ou combinação) das mesmas. Um ponto de grande diferencial do presente projeto em relação ao invento da seção 3.2.1 é o local de anexo dos TAGs *RFID*, que prevê a instalação dos mesmos em cada objeto contido dentro dos contêineres, o que não é adequado à problemática a ser solucionada, visto que não haverá um controle de que tipo de materiais serão carregados tornando inviável reaproveitar a invenção registrada.

O trabalho da seção 3.2.2 prevê o descarte dos itens coletados exclusivamente no caminhão de carga, ou seja, a invenção descreve um cenário em que o caminhão realiza seu trajeto coletando contêineres e descarregando seus conteúdos no próprio caminhão, no entanto, no cenário de atuação do projeto proposto, deseja-se monitorar o despejo de itens em locais inadequados e não no interior do próprio veículo. Vale mencionar ainda que o invento em análise não conta com uma aferição automática da presença de resíduos a serem descartados, diferentemente deste projeto, o qual pode obter tal informação a partir de sua célula de carga.

Já os trabalhos das seções 3.2.3, 3.2.4 e 3.2.5 estão mais relacionados à mecânica de aferição de peso e *design* da estrutura que conterà os sensores utilizados para esta finalidade, no entanto, devido ao fato de que o projeto em questão não possui finalidade comercial e que o sistema se utiliza de uma estimativa do peso somente para detectar a presença ou não de resíduos carregados, não é necessária uma instalação tão criteriosa e rigorosa a fim de garantir alta precisão na aferição de peso. Desta forma, foram utilizados somente conceitos básicos de instalação deste sistema a fim de garantir seu funcionamento. O que promove um ponto positivo no quesito "custo de instalação".

Finalmente, o trabalho da seção 3.2.6 descreve um sistema de monitoramento do estado de cada caçamba, no entanto, não prevê a movimentação das mesmas. Apesar desta característica parecer um simples detalhe, quando analisado no escopo de instalação e elaboração física do sistema, observa-se a necessidade de uma gama de alterações e adaptações. Existe também uma grande diferença no espaço de monitoramento, o qual na obra da seção 3.2.6 compreende todos os recipientes do sistema que estão conectados a todo momento e, devido à este fato, possui uma escalabilidade menor, ao passo que o projeto em questão realiza o monitoramento em tempo real somente dos recipientes que estão sendo deslocados, o que permite uma maior escalabilidade do projeto, isto é, para adicionar novos recipientes registrados seria necessário somente a fixação *tags RFID* à novas caçambas.

Analisando as invenções apresentadas, de forma coletiva, o projeto em questão utiliza vários dos componentes mencionados, no entanto, nenhuma das invenções apresentadas possuem o caráter de rastreamento de localização de onde os recipientes foram despejados, ou seja, não prevêem a identificação da localização em que os itens foram depositados.

Apesar do uso da tecnologia *RFID* estar presente nas invenções 3.2.1 e 3.2.2, um grande diferencial da proposta deste trabalho é a independência de conexão contínua com o servidor o qual não prevê um caráter restritivo para a coleta de caçambas, ou seja, não é necessária a verificação de permissão para a coleta de cada contêiner. O sistema pode funcionar de maneira autônoma e no momento em que a conexão (se perdida) for retomada fará o envio de seus dados coletados.

Um diferencial do sistema apresentado com relação ao conjunto de inventos descritos seria a possibilidade de detecção de carregamento de contêineres não devidamente identificados com *tags RFID*. Isto é possível devido ao fato de que sistema de aferição de peso trabalha em conjunto com o sistema *RFID* e, através leitura do sistema de pesagem, poder-se identificar se o veículo está carregando algum recipiente ou não e, através do sistema *RFID*, se o mesmo está devidamente identificado. Caso não esteja, pode-se gerar um alerta para fiscalização da rotulação dos recipientes.

Finalmente, este projeto, prevê uma forma totalmente automática de operação, ou seja, não é necessária a intervenção humana em nenhuma etapa de funcionamento, somente para fins de instalação.



---

# SISTEMA DE MONITORAMENTO DE DESCARTE

---

---

## 4.1 Visão Geral

Este capítulo trata da descrição técnica dos componentes utilizados no projeto em questão. O objetivo chave do projeto é o de rastrear o despejo dos entulhos de caçambas, com vistas a detectar o descarte ilegal em áreas não autorizadas, isto é, locais não classificados como ecopontos. O projeto em questão foi elaborado através da união de conhecimentos adquiridos tanto no meio acadêmico quanto profissional e essa sinergia resulta em uma contribuição para o meio ambiente, vida das pessoas e comprovação do funcionamento de diversas técnicas abordadas em conjunto. Acredita-se que o grande diferencial do sistema é o mecanismo automatizado do sistema em que não é necessária a intervenção humana na coleta de informações sobre localização do veículo ou onde o mesmo realiza seu despejo de recipientes com ou sem resíduos. Toda a operação é realizada de maneira transparente ou até mesmo invisível para o operador.

Para que tal automatização seja alcançada, foram realizados estudos, pesquisas e modificações de componentes já existentes, de forma que a proposta fosse atendida de maneira funcional e robusta (detectar possíveis adulterações no sistemas).

O sistema consiste basicamente em 4 componentes físicos, nos quais ajustes foram realizados para que pudessem operar coletivamente no rastreamento em tempo-real. São eles:

- Célula de carga;
- Antena e *tag RFID UHF*;
- Módulo *GPS/GSM*;
- *Raspberry Pi*.

A sinergia dos componentes mencionados deve resultar no Fluxograma de operação ilustrado na Figura 7.

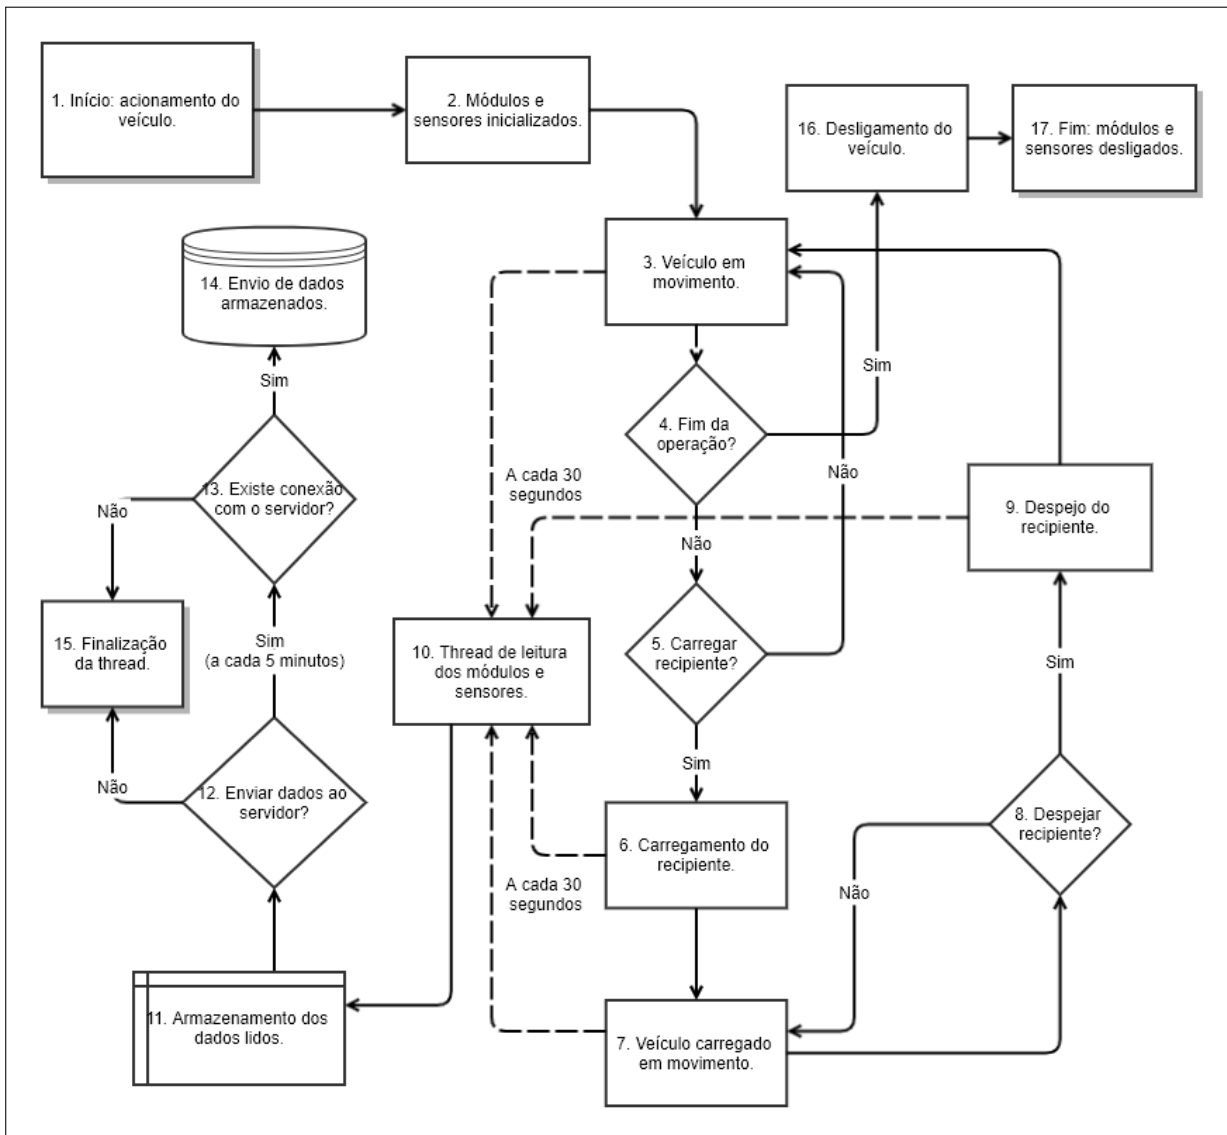


Figura 7 – Fluxograma do sistema

A seguir, as etapas descritas na Figura 7 são:

1. Início: momento em que o motorista entra no veículo e o liga;
2. Quando o veículo é ligado, os componentes são alimentados eletricamente e iniciam sua operação;
3. Veículo em movimento sem nenhum recipiente em sua carroceria;
4. Se o motorista terminou o serviço, seguir para o processo 16, caso contrário, processo 5;

5. Se o motorista encontrou um recipiente e deve carregá-lo, seguir para o processo 6, caso contrário, retornar ao processo 3;
6. Motorista realizando o processo de carregamento do recipiente na carroceria do veículo;
7. Veículo em movimento com um recipiente em sua carroceria;
8. Se o motorista deseja despejar o recipiente, seguir para o processo 9, caso contrário, retornar ao processo 7;
9. Motorista realizando o processo de descarregamento do recipiente;
10. Início assíncrono de uma *thread* para leitura dos valores dos sensores e módulos, i.e., leitor *RFID*, módulo GPS e célula de carga;
11. Armazenamento dos dados de leitura no sistema interno de arquivos;
12. Se a *Raspberry Pi* deve enviar os dados armazenados internamente ao servidor, a cada cinco minutos deve fazer o envio e seguir para o processo 13, caso contrário, seguir para o processo 15;
13. Se existe conexão com o servidor, seguir para o processo 14, caso contrário, processo 15;
14. Envio de dados armazenados internamente para o servidor através do módulo GSM;
15. Finalização da *thread* assíncrona de leitura;
16. Quando o motorista encerrou suas atividades e desligou o veículo;
17. A *Raspberry Pi* percebe que o veículo foi desligado e inicia rotina de encerramento;

Pelo fluxograma da Figura 7, o sistema deve funcionar da seguinte maneira: primeiramente o motorista entra no veículo e o liga, com isto, o sistema deve ligar automaticamente e iniciar sua operação. Então, o veículo passa a se movimentar e, ao mesmo tempo, o sistema faz a coleta de dados dos sensores (localização, leitor *RFID* e peso) e armazena-os em sua memória interna. Eventualmente o veículo fará a coleta de um recipiente e se deslocará até um ponto de despejo. Vale enfatizar que a leitura dos dados dos sensores ocorre ininterruptamente a cada trinta segundos e a cada cinco minutos tenta fazer o envio para o servidor, caso este envio não seja concluído com sucesso, estes dados ficam armazenados até que um novo envio seja realizado, o qual contemplará todos os dados que estão armazenados.

O servidor será responsável por processar os dados recebidos e acionar algum alerta no caso de um despejo em local inadequado. Após finalizar as coletas e despejos do dia, o veículo deve seguir para o estacionamento onde será desligado. Neste momento, o sistema nota o desligamento do veículo, tenta fazer um último envio de dados para o servidor e inicia seu processo interno de encerramento de operação.

Dado o descritivo de operação do sistema, as sessões que seguem visam descrever cada componente que compõe tal sistema.

## 4.2 Célula de carga: Mecanismo para verificar se a caçamba está carregada




Figura 8 – Célula de carga e HX711

A Figura 8 mostra um exemplo de configuração utilizado pelo sistema. No produto final, a placa controladora não será um Arduino, este foi utilizado somente para experimentação, porém a imagem retrata de forma clara como o sistema será conectado.

A célula de carga foi transformada em um sensor para indicar se a caçamba está ou não carregada. Uma vez que não basta instalá-la para que funcione perfeitamente e indique a presença de entulho carregado na caçamba, ajustes foram conduzidos para que a célula de carga pudesse ter o funcionamento esperado.

A célula de carga deve ser instalada na parte traseira do caminhão onde a caçamba é depositada. Desta forma, é necessário que a mesma possa determinar três estados para o caminhão: *sem caçamba*, *com caçamba vazia* ou *com caçamba cheia*. É necessário ter a informação do peso estimado de cada caçamba vazia para que a diferença possa ser calculada automaticamente e, assim, estimar se a caçamba contém entulho ou não.



### 4.3 RFID: Antena de tags para ler e identificar cada caçamba individualmente




Figura 9 – Antena e Tag RFID UHF

A Figura 9 (MONTGOMERY, NA) ilustra o funcionamento de um sistema de antenas e tags RFID. O conjunto é composto pelos três componentes mostrados: antena, leitor e tag. Basicamente, a antena é o circuito responsável pela percepção sensível da variação de sinais de frequência, o leitor é responsável por processar essa percepção de sinal captado pela antena e traduzir para valores categóricos e, finalmente, o tag é responsável por "refletir" o sinal emitido pela antena alterando-o de forma a descrever seu identificador, que será reconhecido pelo leitor.

Inicialmente, foram realizados alguns estudos de componentes e tecnologias que poderiam desempenhar o papel de identificar que uma caçamba está posicionada na parte traseira do caminhão, bem como identificar qual caçamba está em operação. Concluiu-se que antena e tag *Radio-Frequency Identification* (RFID) seriam tecnologias suficientemente robustas e precisas para a finalidade, visto que os tags não dependem de alimentação elétrica (são chamados, por este motivo, de tags passivos), podem ser resistentes a ambientes hostis, possuem uma manutenção e instalação simples, e seu custo é relativamente baixo.

Como o tag carrega uma informação ao ser identificado via procedimento de *scan* realizado pela antena, a mesma foi definida como a tecnologia para uso neste projeto. Assim, após estudos e pesquisas de produtos sobre potência da antena, alcance máximo de reconhecimento, preço, facilidade de uso e tag adequado para se utilizar em conjunto, foi definida que a caçamba será identificada por quatro tags anexadas ao seu chassi. Todos aos quatro tags armazenam o mesmo identificador da caçamba, isto é, o mesmo ID. Vale observar que o uso de mais de um tag justifica-se devido à atenuação do sinal dada pela superfície metálica onde será anexada,

garantindo, desta forma, que a leitura seja realizada com sucesso além de prover uma garantia de funcionamento em um cenário de eventual destruição de uma delas.

#### 4.4 Módulo GPS/GSM: Componente de comunicação sem fio e Geolocalização em tempo real

O sistema proposto deve coletar dados, armazená-los em seu sistema de arquivos e, posteriormente, fazer o envio de todos os dados armazenados. Os dados são compostos pelo identificador da caçamba, a data, a hora com minutos e segundos, o peso estimado e dados de localização (latitude e longitude). Estes dados são lidos a partir do momento em que o veículo é ligado e enviados a cada cinco minutos (a definir com maior exatidão), indicando assim a trajetória percorrida.

Como o sistema conta com o envio de tais dados periodicamente, é necessário utilizar uma tecnologia de comunicação sem fio, sem a necessidade de uma conexão Wi-Fi, por exemplo. Desta forma foi proposto o uso da tecnologia de telefonia celular que permitisse o envio de dados a partir de qualquer localização na cidade. Para os dados de localização, é necessário o uso de um módulo *Global Positioning System* (GPS) para capturar as coordenadas de geolocalização em tempo-real.




Figura 10 – SARA G350

A Figura 10 ilustra o componente escolhido, SARA-G350M o qual possui a funcionalidade de comunicação via 3G/4G além de possuir um módulo GPS para aquisição dos dados de localização.

## 4.5 Raspberry Pi: Computador no caminhão para ler e enviar dados

O componente escolhido para "orquestrar" o sistema foi a Raspberry Pi (PI, 2009). A Figura 11 contém uma ilustração do componente.




Figura 11 – Raspberry Pi

A Raspberry Pi é um *Single Board Computer* de baixo custo e que foi escolhido a fim de gerenciar o sistema como um todo. Este componente é responsável pela leitura de dados proveniente do HX711 contendo o valor analógico da célula de carga, controle da antena *Ultra High Frequency* (UHF) para iniciar o procedimento de *scan* por *tags* bem como coletar dados de identificação encontrados durante este procedimento e o controle do módulo *SARA-G350M*, para o envio periódico de dados lidos à um servidor *Hypertext Transfer Protocol* (HTTP).

Durante a elaboração do projeto, verificou-se a facilidade de alteração do software embarcado no Raspberry, o qual é gravado em um cartão de memória microSD, ou seja, havendo alteração de *software*, basta gerar uma nova imagem para o cartão microSD, gravá-lo e inserir novamente no componente. Esta é uma vantagem muito grande em comparação com outras placas controladoras, pois, de maneira geral, é necessário ter, na placa customizada, uma interface com os pinos de gravação, conexão de ferramentas de gravação e, em alguns casos, um computador contendo o *software* a ser gravado, tornando bastante trabalhoso o procedimento.

Na pesquisa, constatou-se uma outra vantagem no uso da Raspberry Pi, que é a possibilidade de usar um sistema Linux embarcado, que já possui um sistema de arquivos implementado e de fácil uso. O uso de outras placas controladoras demandaria a necessidade de adicionar um componente de memória externa, visto que normalmente suas memórias internas são insuficientes para aplicações que envolvem armazenamento de dados.

## 4.6 Inteligência Artificial (IA): Classificação da trajetória do veículo

O papel da inteligência artificial no projeto está relacionado à classificação da trajetória do veículo, isto é, se o mesmo está se dirigindo à um ecoponto ou não. Propõe-se a utilização de um modelo estatístico classificador que tem como dados de entrada as coordenadas geográficas discretizadas em período de tempo  $T$ . Como dado de saída para o modelo foi utilizado um rótulo 0 para indicar que o veículo não estará no ecoponto no passo seguinte, ou 1, caso contrário (caso chegue ao ecoponto). Mais detalhes serão descritos no capítulo 5.

Através do uso deste tipo de inferência, será possível acionar diferentes tipos de alertas, como forma de detecção alternativa à mecânica proposta pelo sistema, ou até mesmo como uma forma de complementar a classificação dada pela parte eletrônica. Por exemplo, se o veículo está carregado, porém a Inteligência Artificial aponta que o mesmo não está se dirigindo a um ecoponto, seria possível chamar atenção à este veículo para que fosse monitorado mais rigorosamente até que sua trajetória mude e tenha como destino um ecoponto.

---

# MÉTODOS E RESULTADOS

---

## 5.1 Visão Geral

Diversos experimentos foram conduzidos para avaliar e validar a usabilidade, desempenho e escolha dos diversos componentes do projeto a fim de se estruturar um primeiro protótipo. Esta seção descreve o desenvolvimento conferido a cada componente, bem como ensaios controlados realizados para validação dos mesmos.

## 5.2 Ensaios com a Célula de carga

### 5.2.1 *Ajuste para acomodar o amplificador de tensão e o conversor A/D*

A célula de carga a ser utilizada possui extensômetros acoplados a um circuito de Ponte de Wheatstone (EKELOF, 2001), como pode ser observado na Figura 12. O modelo foi desenvolvido para medir a intensidade de deformação do material a partir do valor de tensão obtido em seus terminais ( $V_{in}$  e  $V_{out}$ ). Foi observado que este tipo de circuito possui um valor muito baixo de tensão na saída, portanto foi preciso adicionar um componente amplificador de tensão.




Figura 12 – Ponte de Wheatstone

Outro problema encontrado foi a falta de uma entrada analógica na Raspberry Pi, que trabalha somente com entradas digitais. Como o principal componente "orquestrador" já havia sido definido, foi necessário investigar o problema. A solução encontrada foi adicionar um componente conversor analógico-digital com um amplificador de sinal embutido para o funcionamento do procedimento de pesagem.

Foram estudadas várias possibilidades de componentes para se adequar ao projeto levando em consideração facilidade de implementação, integração, constituição do sistema físico, que facilitaria uma produção em escala do sistema, e seu preço, para não encarecer demasiadamente e desnecessariamente a solução. Muitas opções cogitadas fariam necessidade de se projetar uma placa personalizada para fixar o componente amplificador junto ao conversor analógico-digital. No entanto, após algumas pesquisas de produtos, foi definido que o componente eleito como melhor candidato em termos de custo-benefício para atender à aplicação seria o conversor HX711. Vide Figura 8.

### 5.2.2 Amplificador e conversor A/D

Definido o componente a ser utilizado, foi feita a compra de uma unidade deste e realizado um ensaio reduzido, ou seja, rotinas de testes utilizando uma célula de carga com capacidade máxima de até 50 Kg. Os ensaios de teste mostraram que o componente HX711 possui um ruído relativamente alto em comparação com outros componentes que desempenham o mesmo papel. Para contornar este problema, foram realizadas algumas pesquisas e estudos de procedimentos na literatura e com profissionais da área, a fim de sanar o problema do ruído.

A solução mais simples, direta e menos custosa escolhida foi a adição de um filtro de sinais a nível de *software* embarcado. Para isto, foi conduzida uma busca na literatura por trabalhos relacionados à filtragem de sinais e optou-se pela utilização do Filtro de Kalman (KALMAN, 1960). Sua implementação foi realizada em código C nativo sem o uso de bibliotecas adicionais e externas devido à restrições de microcontroladores com relação à capacidade de

memória interna disponível para gravar binários compilados e até memória *heap* e *stack* para execução de rotinas. Optou-se por esta abordagem mais otimizada e enxuta devido à velocidade de leitura. Como o Filtro de Kalman trabalha com um ajuste de erro estatístico, quanto maior a quantidade de dados, menor o viés na estimativa do valor médio.

### 5.2.3 Resultados dos testes com o amplificador e conversor A/D

Após a implementação do filtro e escrevendo um *software* embarcado de pesagem com 4000 divisões de peso. Consequentemente, para uma célula de 50 Kg, sua variação de peso é mostrada em passos de 12.5 gramas (os pesos mostrados são múltiplos de 12.5 gramas). Aferiu-se uma precisão de aproximadamente 4 divisões, ou seja, colocando-se 5 Kg (certificados pelo Inmetro), o peso convertido oscilava entre 4,950 Kg a 5,050 Kg. Nesse cenário, a célula de carga foi posicionada sobre um pano, necessário para que houvesse deformação na parte móvel da célula.

Foi realizado um outro teste, utilizando, desta vez, uma plataforma (certificada pelo Inmetro) contendo uma célula de carga com capacidade máxima de 20 Kg (neste cenário o valor da divisão foi de 5g). A precisão obtida nesse teste foi melhor, possuindo uma variação inferior a uma divisão, ou seja, colocando nos mesmos 5 Kg, a oscilação girou em torno de 4,995 Kg a 5,005 Kg (porém, sempre tendendo a 5 Kg com o arredondamento da divisão).

Os resultados dos ensaios estão sumarizados na tabela 1.

Ensaio	Capacidade(kg)	Mínima variação (kg)	Máxima variação (kg)	g/div
A	50	4.950	5.050	12.5
B	20	4.995	5.005	5

Tabela 1 – Tabela comparativa entre os ensaios A e B.

A: utilização somente da célula de carga sem plataforma adicional

B: utilização da célula de carga em conjunto com uma plataforma certificada pelo INMETRO.

Os principais pontos observados durante os ensaios foram:

**O funcionamento do HX711:** validou-se que seu uso atenderia aos requisitos da aplicação;

**A robustez do sistema:** validou-se que mesmo com uma montagem mais rústica, foi possível obter uma precisão aceitável;

**O funcionamento do Filtro de Kalman:** validou-se que seu uso é indispensável para a aplicação;

A partir destes resultados, concluiu-se que o HX711 atenderia perfeitamente à aplicação, visto que não será necessária uma precisão tão alta quanto às obtidas nos ensaios com componentes certificados pelo Inmetro. Em outras palavras, no cenário da aplicação, deseja-se apenas

inferir se a caçamba está ou não carregada, e a precisão constatada é suficientemente grande para se garantir esta informação. Desta forma, utilizando esse sensor de peso, é possível determinar se a caçamba está se deslocando com ou sem entulho em sua carroceria.

## 5.3 Ensaios com Antena e Tag RFID

### 5.3.1 Definição da faixa de frequência da antena que lê o RFID

Após definir que a tecnologia utilizada seria o *Radio Frequency Identification* (RFID), a pesquisa passou para a fase de definir a faixa de frequência com que sua antena operará, já que a faixa de operação utilizada impacta na determinação da distância máxima de leitura dos *tags* e a aplicação necessita de uma distância de leitura do sinal de aproximadamente cinco metros entre a antena e o *tag*.

Alguns estudos e consultas às especialistas (técnicos das empresas fornecedoras do equipamento), apontaram que a faixa de frequência de operação da antena que atenderia a aplicação seria de 860 a 960 MHz, caracterizando um sistema de Antena e *tag UHF*.

Além da frequência de operação, foi necessário estipular a intensidade do sinal com que a antena deveria operar. Estudos e pesquisas com fornecedores apontaram que esta deveria ter um ganho de pelo menos 9 *dBi* para que a distância de leitura desejada fosse atingida.

O maior obstáculo encontrado no desenvolvimento foi a aquisição deste componente, visto que é um equipamento específico e de custo relativamente alto. Chegou-se a conclusão de que seria mais viável a importação do componente diretamente da China com fornecedores conhecidos.

### 5.3.2 Testes de funcionamento

Com a chegada da antena específica, iniciou-se o procedimento de testes de leitura via terminal de configuração executado em um computador e conectado via cabo Ethernet com a antena. Vale mencionar que a antena escolhida possui um leitor integrado internamente. Foram realizados testes simples de funcionamento, ou seja, a verificação da leitura dos *tags* pela antena e a máxima distância de leitura possível. É importante enfatizar que este teste foi conduzido em um ambiente fechado, uma sala de aproximadamente 50m<sup>2</sup> contendo diversos equipamentos eletrônicos, havendo ciência de que a presença de equipamentos eletrônicos no local poderia interferir negativamente na performance de leitura da antena. Outra observação a se considerar, é que os *tags* utilizados não eram específicos para aderência em superfície metálica.

O teste conduziu-se da seguinte maneira: posicionou-se a antena verticalmente e apontada para o eixo horizontal na direção dos *tags*, que foram testados em diversas posições relativas à antena. O pesquisador segurou o equipamento com o *tag* na altura de suas mãos:



- Com os braços estendidos para cima;
- De costas em relação à antena;
- De lado em relação à antena.

As leituras foram realizadas com sucesso, validando o funcionamento mínimo da antena de forma que a aplicação pudesse ser conduzida. A máxima distância medida nas condições descritas foi de aproximadamente sete metros, cenário em que o pesquisador segurou os *tags* com os braços estendidos para cima.

É válido ressaltar que uma distância de sete metros de captura é mais do que suficiente para o funcionamento da aplicação, visto que a caçamba estará a uma distância máxima de dois metros e possuirá quatro *tags*. Isso valida a proposta usando a antena com os *tags* neste processo de identificação. Vale adicionar também que, nesse aspecto, espera-se que o cenário real não apresente desempenho muito inferior ao do teste realizado, visto que a antena sempre estará direcionada aos *tags* e estes serão *tags* específicos para aderência em superfície metálica, possuindo um ganho de sinal maior para contornar o problema de atenuação de sinal devido à superfície instalada.

Desta forma, validou-se o funcionamento mínimo do componente e que o mesmo poderia ser utilizado na aplicação.

## 5.4 Ensaios com módulo GPS/GSM

### 5.4.1 SARA G-350: módulo GPS/GSM

Um estudo foi realizado levando-se em consideração o custo do componente, custo de implantação (necessidade de placa customizada ou não) e facilidade de uso (facilitando correções e adição de novos recursos na posteridade). A opção mais viável atendendo aos fatores mencionados anteriormente foi o módulo *SARA-G350M* fornecido pela empresa *U-blox* ([U-BLOX, 2020](#)), que contém tanto o módulo *GPS* quanto o módulo *Global System for Mobile Communication* (GSM) em uma única placa. Seu custo se mostrou mais viável que a importação de outros módulos equivalentes da China e outros países e juntamente com sua facilidade de comunicação (protocolo *AT*) tornou-o em um ótimo candidato ao projeto.

Uma unidade de amostra foi enviada pela empresa *U-blox* para que pudessem ser realizados testes e verificar se seu desempenho atenderia à aplicação. O módulo comunica-se via *Universal Asynchronous Receiver-Transmitter* (UART), com um conversor interno *UART/micro-USB*, para acesso da interface de comandos *AT* (comandos em texto do Terminal) e por padrão envia coordenadas de *GPS* seguindo o protocolo *National Marine Electronics Association* (NMEA).

Um simples teste de funcionamento foi conduzido com o componente da u-blox (Figura 10): o componente foi conectado a um computador e comunicado via *software* para “tradução” de porta serial (*Realterm*). Com isso, foi possível fazer a leitura de suas coordenadas GPS (padrão *NMEA*) que já vem configurado de fábrica.

## 5.5 Ensaios da aplicação de IA

### 5.5.1 Ensaios com simulador

De forma a tornar possível o estudo de técnicas a serem utilizadas na aplicação final foi elaborada uma estrutura de simulação. Através da mesma, é possível trabalhar com dados gerados virtualmente e muito próximos à dados reais, isto é, gerar dados que atendam um comportamento que seria observado na prática. Por exemplo, simular uma mudança na rota de um veículo considerando coordenadas do mundo real de uma determinada cidade e, então, levar em consideração este padrão de comportamento para o estudo de técnicas apropriadas baseadas em uma análise quantitativa e qualitativa dos dados.

Vale enfatizar que o propósito do simulador nesta aplicação é de simplesmente gerar os dados de localização dos veículos e que as implementações no simulador são voltadas somente para o direcionamento dos veículos (para se deslocarem em direção aos ecopontos).

### 5.5.2 SUMO: Simulation of Urban Mobility

O *software* escolhido para simular a mobilidade dos veículos foi o *Simulation of Urban Mobility* (SUMO) (LOPEZ *et al.*, 2018). Com este simulador, é possível gerar um ambiente totalmente controlado, desde a definição de movimentação de veículos, até controle de semáforos e pedestres. A ideia principal da simulação é gerar coordenadas de geolocalização discretizadas no tempo que descrevem a trajetória de veículos, sendo possível trabalhar com dados representativos sem a necessidade de instalação física do sistema em veículos operários.

A primeira estrutura de simulação foi baseada no mapa da cidade de São Carlos, utilizando a ferramenta automática do *SUMO* para captura do mapa de qualquer região baseado no *Open Street Maps* (OSM). A Figura 13 ilustra a ferramenta em funcionamento durante a execução de uma simulação mostrando as proximidades do bairro onde se encontra o campus 1 da USP em São Carlos.

Após definir o local de análise foram realizados diversos estudos na *Application Programming Interface* (API) em Python do *SUMO* para que fosse possível controlar elementos da simulação, isto é, adicionar veículos, definir trajetórias, ajustar tempo de simulação, entre outros. O *SUMO* oferece APIs em Python e C++, no entanto, a linguagem Python foi escolhida devido à vasta gama de bibliotecas que fornecem ferramentas para análises estatísticas e aprendizado de máquina.

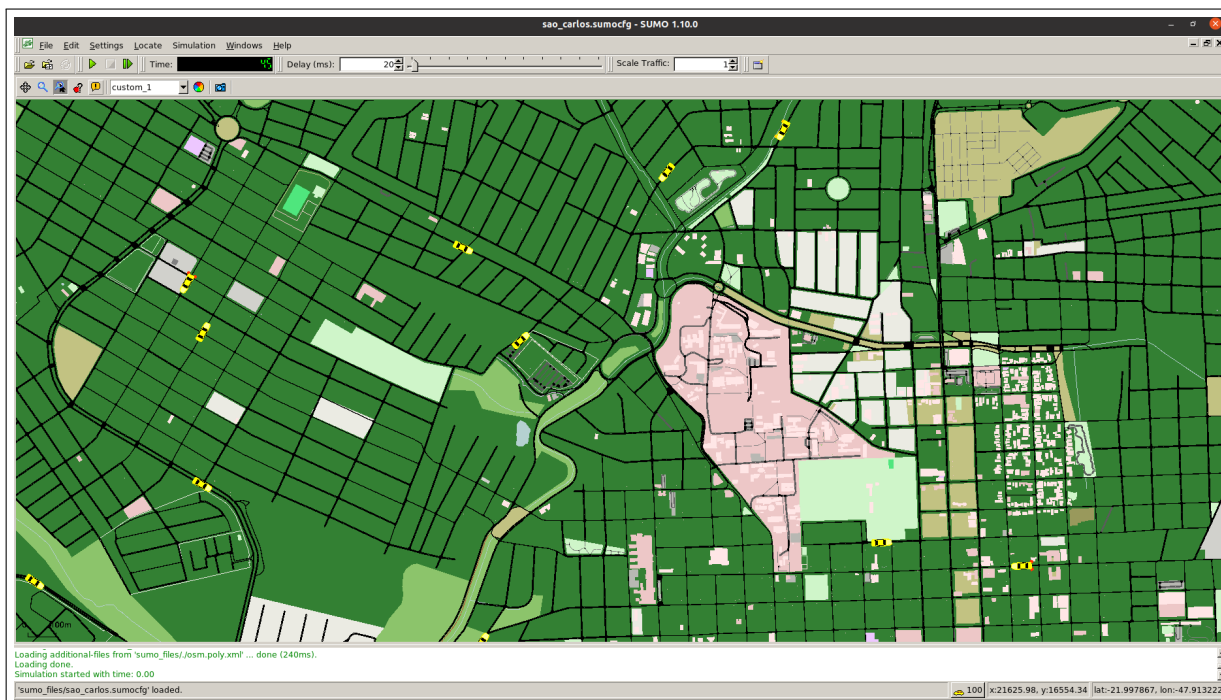


Figura 13 – Simulação do Sumo

### 5.5.3 SUMO: Arquitetura do Simulador

Foi elaborada uma arquitetura de software para fazer o uso da *API* do *SUMO* de forma mais organizada e escalável. Tal arquitetura é centralizada em basicamente três componentes: simulador, controlador e veículo.

O simulador é responsável por gerenciar a simulação como um todo: desde seu início através do uso da *API*, como seus passos durante o laço principal e o armazenamento de dados que ocorre ao final. Esta etapa de inicialização contempla também a definição de alguns parâmetros do simulador, como por exemplo, o intervalo de tempo em que os registros de posições geográficas são salvos (de cada veículo), número de *threads* para acelerar o processamento, entre outros.

Para gerenciar os trajetos a serem percorridos pelos veículos, foi criada uma outra entidade, o Controlador. Este é responsável por designar a localização alvo de cada veículo, se definidos previamente, caso contrário, os veículos da simulação são adicionados para se moverem aleatoriamente pelo mapa em análise.

Por fim, foi definida uma classe para os veículos da simulação, que são as entidades que possuem o atributo identificador bem como métodos para se direcionarem a determinado ponto, de acordo com o especificado previamente, e são acionados pelo controlador.

Além disto, para facilitar a alteração de parâmetros de simulação o sistema foi elaborado com base em arquivos de configuração. Estes arquivos podem ser analisados com o uso da biblioteca padrão da linguagem Python, o *configparser*.

Os arquivos de configuração são divididos em campos referentes à cada parte da simulação, como a *API* a ser utilizada, as configurações da simulação e objetos de análise.

#### 5.5.4 As simulações

Primeiro foram definidos três ecopontos da cidade de São Carlos e suas respectivas coordenadas geográficas para adicionar no arquivo de configuração do simulador. Então, foram definidos alguns parâmetros da simulação, como o número de passos da simulação, "largura" do passo, máximo número de veículos, número de veículos controlados e semente de aleatoriedade.

O número de passos da simulação define quantas iterações serão realizadas. Cada passo corresponde à movimentação dos veículos por determinado período de tempo. Além disto, a cada passo, é verificado, internamente pelo *SUMO*, se o número máximo de veículos foi atingido. Caso não tenha atingido, um novo veículo é adicionado.

A "largura" do passo refere-se ao intervalo de tempo em segundos em que as informações de geolocalização são coletadas. Isto é, se considerar uma largura de passo de 10 segundos, as coordenadas geográficas geradas para cada veículo seriam equivalentes a nova localização do veículo passados 10 segundos no mundo real. Ou seja, em 6 passos de largura de 10 segundos gerariam 6 coordenadas geográficas do veículo ao longo de um minuto de movimentação no mundo real.

O máximo número de veículos é definido previamente e influencia na lógica de geração de veículos no simulador. Ao atingir o número máximo, o simulador para de adicionar veículos. Quando um veículo termina seu trajeto (por padrão, aleatório) ele é removido da simulação, então, na próxima iteração, um novo veículo é adicionado.

O número de veículos controlados é um parâmetro que define a quantidade de veículos que será direcionado para os ecopontos. O controlador é responsável por este gerenciamento considerando o número de ecopontos disponíveis e a quantidade de veículos a serem redirecionados.

Finalmente, a semente de aleatoriedade é responsável por controlar o determinismo da simulação, isto é, se executada com a mesma semente, os resultados devem ser iguais. Quando uma semente de aleatoriedade é fixada, a geração de rotas e locais onde os veículos são gerados são sempre os mesmos.

Para a primeira simulação realizada, foram considerados 1000 passos de simulação, com largura de 5 segundos, um número máximo de veículos igual a 50, total de 12 veículos controlados e semente de aleatoriedade *1234*. Ao fim da simulação, computaram-se as coordenadas e os identificadores dos veículos e constatou-se que passaram um total de 309 veículos sendo 12 deles controlados para que se direcionassem aos ecopontos e os outros 297 se movimentaram de maneira aleatória. Como foram um total de 1000 passos sendo cada passo um intervalo de tempo de 5 segundos, a simulação gerou dados equivalentes ao monitoramento de tráfego de aproximadamente uma hora e vinte minutos no mundo real.

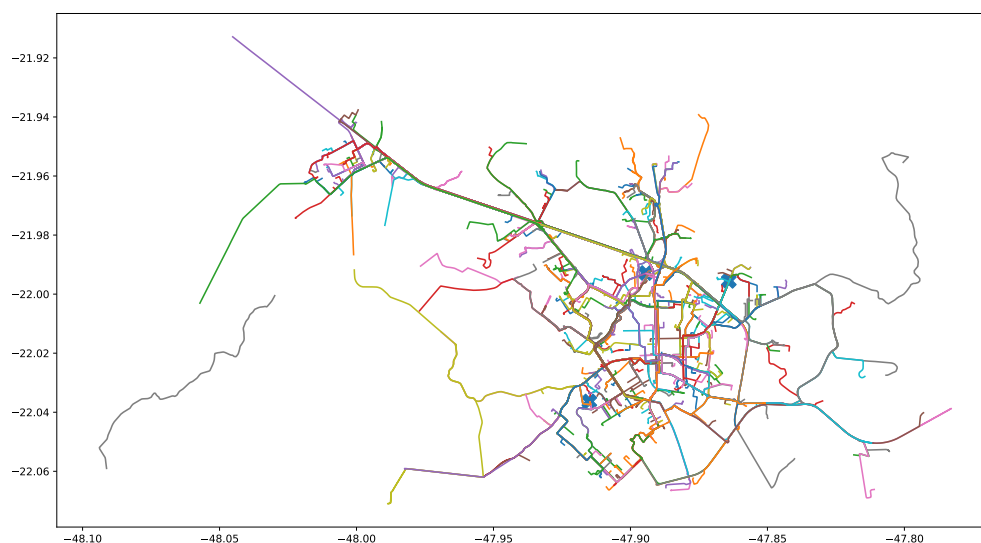


Figura 14 – Movimentação dos veículos da simulação

A Figura 14 mostra o trajeto que os veículos percorreram durante a simulação e os "X" em azul são os locais dos ecopontos. Os eixos das abscissas e ordenadas representam respectivamente a longitude e latitude dos pontos.

Observa-se, na Figura 15 somente a movimentação os veículos que tinham o objetivo de chegar nos ecopontos. E os "X" em vermelho marcam o ecoponto.

### 5.5.5 Aplicação da Inteligência Artificial

Comprovado o funcionamento do simulador, foi iniciada a etapa de aplicação de algoritmos de inteligência artificial. A inspiração maior veio do trabalho de [Duca, Bacciu e Marchetti \(2017\)](#), que faz a previsão de localização de navios após um intervalo de tempo  $T$  dados suas coordenadas geográficas e velocidades.

Foi realizada uma abordagem semelhante, contudo, o modelo deve estimar se o veículo estará ou não no ecoponto no passo seguinte do simulador, no caso,  $T$  seria igual a 1. Foram utilizados passos de 5 segundos e as 5 últimas coordenadas geográficas e velocidades de cada veículo, portanto, quer-se saber se dados 25 segundos de movimentação, no 30º segundo o veículo estará no ecoponto ou não.

Para a geração de dados suficientes para um aprendizado estatístico, foram executadas diversas simulações seguindo os padrões adotados na primeira simulação, com exceção do número de veículos controlados, os quais foram aumentados. Tal adaptação justifica-se pelo fato dos veículos com movimentação aleatória sempre atingirem seu objetivo e novos eram adicio-

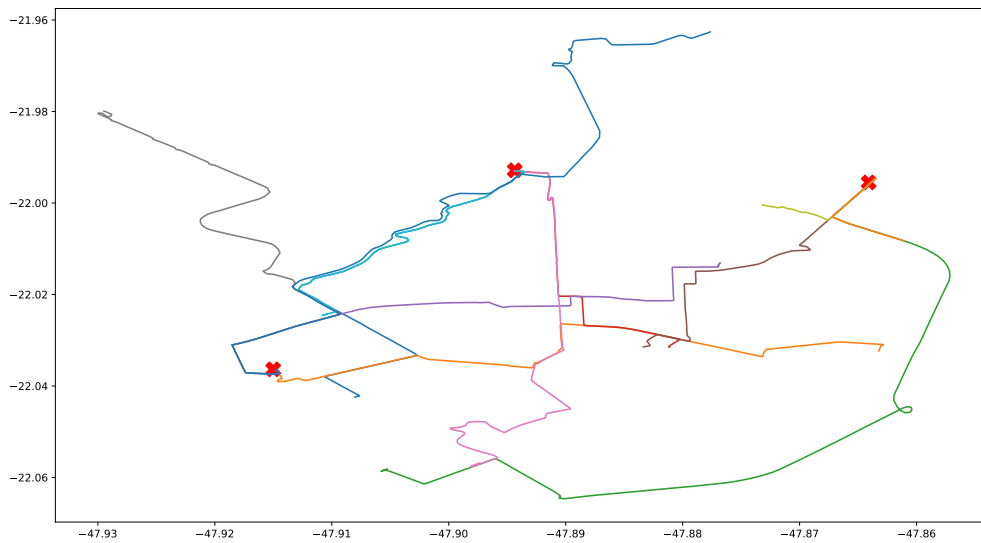


Figura 15 – Movimentação dos veículos direcionados aos ecopontos

nados à simulação, porém sem um redirecionamento por parte do controlador, portanto houve um desequilíbrio no número de veículos controlados em comparação com os movimentados aleatoriamente. Como forma de gerar mais dados de veículos que chegam no ecoponto o número de veículos controlados passou de 12 para 50. Observa-se também que a cada execução uma nova semente de aleatoriedade foi utilizada.

Ao total foram realizadas simulações equivalentes a mais de cinco horas de monitoramento de tráfego no mundo real. Então, foi realizada uma rotulação nos dados obtidos, de forma que as coordenadas geográficas (latitude e longitude) e velocidade, uma tupla de três valores, seriam empilhadas no primeiro eixo, ou seja, seriam montados vetores de 15 dimensões (3 variáveis x 5 passos).

Quanto à rotulação dos exemplos, para os veículo que não chegaram ao ecoponto (se moveram aleatoriamente), foram atribuídos rótulo 0 e para os veículos controlados, rótulo 1. Desta forma, experimentos foram conduzidos com o treinamento de modelos estatísticos tradicionais de Aprendizado de Máquina e alguns modelos de redes neurais de Aprendizado Profundo.

É válido mencionar que os dados foram analisados e constatou-se que seria necessário normalizar as latitudes e longitudes. O próprio simulador fornece os valores máximos e mínimos das coordenadas do mapa em análise. Portanto, foi utilizado um simples escalamento por mínimo e máximo:

$$valor_{escalado} = (valor - valor_{min}) / (valor_{max} - valor_{min})$$

Para os modelos de Aprendizado de Máquina tradicionais foram considerados os modelos *K-NN*, *SVM*, *Naive Bayes*, Florestas Aleatórias e Reforço de Gradiente.

Como forma de avaliação do modelo treinado, foi considerada a técnica de validação cruzada, com uma pequena modificação, em que, a cada fatia selecionada para treino e teste, o montante total não seria embaralhado, desta forma, garantindo que todos os veículos seriam avaliados uma única vez.

Ainda sobre a forma de avaliação, a métrica considerada foi a matriz de confusão que é bastante informativa e não possui viés no caso de bases de dados desbalanceadas. Já que pode-se observar quantidade de predições para cada classe sendo a predição correta ou errada.

Seguindo a referência do trabalho de [Duca, Bacciu e Marchetti \(2017\)](#), o primeiro modelo testado foi o modelo *K-NN* utilizando 5 vizinhos como parâmetro "K" do modelo. O resultado do teste pode ser observado na tabela 2. A última linha da tabela refere-se ao somatório de acertos e erros das matrizes de confusão de cada fatia.

Nota-se na tabela 2 que o total de observações para a classe 1 é de 170, e que deste montante, somente 3 classificações estavam corretas. O que mostra um desempenho ruim.

Após realizar o mesmo teste com os outros modelos, notou-se que os modelos *K-NN*, *Naive Bayes* e *SVM* possuíram uma performance similar e os modelos de Florestas Aleatórias e Reforço de Gradiente mostraram um desempenho bem superior, o resultado do teste com o modelo de Florestas Aleatórias pode ser observado na tabela 3

Na tabela 3, nota-se um excelente desempenho onde 162 amostras de um total de 170, isto é 95,29% dos dados, foram classificados corretamente, considerando somente a classe com menor amostragem.

Finalmente, para os modelos de redes neurais foram consideradas duas arquiteturas simples. A primeira baseada somente em camadas totalmente conectadas, sendo 256 neurônios para a primeira camada, 128 para a segunda, 30 para a terceira e, um neurônio para a camada de saída. Para as camadas escondidas foram adotadas a função de ativação *relu* e para a camada de saída a ativação sigmoide.

A segunda arquitetura, baseada na camada *LSTM*, contava com 32 unidades na camada única escondida e como saída, um neurônio com ativação sigmoide. Vale mencionar que para este treinamento os dados foram re-alinhadas de forma que houvesse um eixo adicional referente à variação temporal, isto é, ao invés de um vetor de 15 dimensões, foram utilizadas matrizes 5x3 para cada dado de exemplo.

Para estes treinamentos, ambos os modelos utilizaram o otimizador *Adam* com taxa de aprendizado  $1e - 4$ , função de custo entropia cruzada binária e como métrica de treinamento, a

Fatias		0 verdadeiro	1 verdadeiro
1	0 predito	163	12
	1 predito	3	0
2	0 predito	165	10
	1 predito	3	0
3	0 predito	151	23
	1 predito	4	0
4	0 predito	162	11
	1 predito	4	1
5	0 predito	158	19
	1 predito	1	0
6	0 predito	153	19
	1 predito	5	1
7	0 predito	154	23
	1 predito	1	0
8	0 predito	168	9
	1 predito	0	0
9	0 predito	147	24
	1 predito	5	1
10	0 predito	159	17
	1 predito	1	0
Somatório	0 predito	1580	167
	1 predito	27	3

Tabela 2 – Validação cruzada do Modelo K-NN

acurácia binária (todos provenientes do tensorflow ([ABADI et al., 2015](#))).

Como os modelos de redes neurais possuíam como saída uma ativação sigmoideal foi necessário estabelecer um limiar para que as predições fossem consideradas pertencentes à uma classe ou outra. Ambos os modelos foram considerados com limiar de 0.2 e mostraram performance muito similar. O resultado do modelo LSTM podem ser observados na tabela 4.

A tabela 4 mostra que as técnicas baseadas em redes neurais apresentam um desempenho ligeiramente superior ao da tabela 2, já que mostrou uma taxa de acerto relativamente maior para a classe 1, a qual estava "penalizada" pelo desbalanceamento. No entanto, ainda não alcança o desempenho dos modelos de aprendizado de máquina baseados em conjuntos. Isto pode ser explicado devido à baixa quantidade de amostras geradas para cada classe que pode não ter sido



Fatias		0 verdadeiro	1 verdadeiro
1	0 predito	165	1
	1 predito	1	11
2	0 predito	168	0
	1 predito	0	10
3	0 predito	155	2
	1 predito	0	21
4	0 predito	165	1
	1 predito	1	11
5	0 predito	159	1
	1 predito	0	18
6	0 predito	158	0
	1 predito	0	20
7	0 predito	155	1
	1 predito	0	22
8	0 predito	168	1
	1 predito	0	8
9	0 predito	152	1
	1 predito	0	24
10	0 predito	160	0
	1 predito	0	17
Somatório	0 predito	1605	8
	1 predito	2	162

Tabela 3 – Validação cruzada do Modelo Florestas Aleatórias

suficiente para que os modelos baseados em redes neurais chegassem uma boa generalização.

Constatou-se, finalmente, que para este tipo de problema e a forma como foi concebido, os modelos tradicionais de Aprendizado de Máquina baseados em conjuntos de árvores de decisão, conseguem um desempenho melhor de classificação e generalização.

Fatias		0 verdadeiro	1 verdadeiro
1	0 predito	150	7
	1 predito	16	5
2	0 predito	145	8
	1 predito	23	2
3	0 predito	144	15
	1 predito	11	8
4	0 predito	151	6
	1 predito	15	6
5	0 predito	138	12
	1 predito	21	7
6	0 predito	142	16
	1 predito	16	4
7	0 predito	144	21
	1 predito	11	2
8	0 predito	152	7
	1 predito	16	2
9	0 predito	134	21
	1 predito	18	4
10	0 predito	133	11
	1 predito	27	6
Somatório	0 predito	1433	124
	1 predito	174	46

Tabela 4 – Validação cruzada do Modelo LSTM

---

## DISCUSSÃO E TRABALHOS FUTUROS

---

Como ainda não foi implementado um primeiro protótipo do sistema completo, esta sessão listará os trabalhos pendentes para finalizar a elaboração de um protótipo funcional do sistema.

### 6.1 Célula de Carga

Para o primeiro protótipo, acredita-se que duas células de carga com capacidade de até 1000 Kg serão suficientes para atender a demanda. Ressalta-se que as células de carga aqui não necessitam de um peso exato, visto que o que se quer é a informação sobre o carregamento da caçamba, isto é, se está ou não carregada. Vale salientar que mais testes poderão ser conduzidos para desenvolver um protótipo menos custoso financeiramente, através da escolha de um célula de carga com menor precisão, por exemplo. A célula de carga é um componente relativamente caro e pode ser escolhida de acordo com a necessidade. Alguns cenários podem demandar células de carga com capacidades menores, o que pode baratear o custo final da solução, viabilizando, desta forma, a produção do sistema em escala e adequação ao mercado.

Além disto, seria interessante avaliar o desempenho das células de carga quando instaladas na parte traseira do veículo, onde atuarão de fato. Com isto será possível analisar pontos como a estabilidade da medida de peso, nível de oscilação do sinal e as adaptações necessárias a serem realizadas no veículo a fim de que operem conforme o desejado.

### 6.2 Antena e *tag* RFID

O conjunto de Antena e *tags* *RFID* se mostraram capazes de atender a demanda do projeto nas condições do ensaio realizado. No entanto, a antena não foi testada com o conjunto correto de *tags* e os mesmos não estavam anexados à superfícies metálicas.

Seria muito importante verificar o funcionamento da antena em conjunto com os *tags* corretos, isto é, *tags* específicos para serem anexados à superfícies metálicas. E os mesmos anexados às caçambas de entulho. Além de elaborar testes mais robustos para certificar que o componente funcionará adequadamente na aplicação.

### 6.3 Módulo *GPS/GSM*

O teste no módulo *GPS/GSM* consistiu na leitura de seus registros de localização através do padrão NMEA. No entanto, seria necessário testar a comunicação bilateral com o módulo, isto é, além de receber seus dados, também enviar instruções.

Este teste é importante para se averiguar que a comunicação via rede de telefonia é, de fato, possível, conforme afirmam os produtores do módulo, e investigar possíveis gargalos que o módulo pode, eventualmente, mostrar.

Assim que estabelecida a comunicação com o módulo, pode-se estimar com maior precisão o intervalo de tempo em que os dados serão enviados ao servidor, equilibrando custo e precisão das informações.

### 6.4 Raspberry Pi

A Raspberry Pi foi testada de maneira genérica, isto é, foram realizados alguns desenvolvimentos utilizando os pinos de propósito geral do *Single Board Computer* para comunicação com diversos sensores, porém, não foi realizada uma comunicação com os sensores e módulos contemplados neste projeto.

É necessário que, no futuro, sejam testadas as comunicações com os demais elementos deste projeto. Apesar deste ser o principal elemento que fará o gerenciamento de toda a aplicação, sua prioridade na realização de testes e ensaios não era tão alta, já que é um componente bastante didático e simples de se manipular, aceitando linguagens de programação de alto nível e possuindo um sistema operacional bastante completo.

Além da simples interação com os outros sensores, pode-se ainda monitorar sensores do próprio veículo, como por exemplo verificar se o caminhão foi desligado através de um sinal do alternador. Este dado (de desligamento do veículo) poderá ser utilizado para acionar uma rotina de envio dos dados armazenados (e remanescentes) para o servidor, e preparar-se para o desligamento do sistema, encerrando operações de leitura (de sensores) e escrita (de arquivos de dados), promovendo uma segurança no quesito de integridade dos dados. O objetivo desta rotina seria prevenir que a bateria do veículo não mantenha o sistema em funcionamento sem que haja movimentação, já que a bateria pode perder sua carga se o veículo ficar desligado por um longo período de tempo e o sistema continuar em funcionamento sem contribuir com novas informações relevantes.

Ainda sobre a questão do desligamento do veículo e sistema, seria importante adicionar a informação de data e hora em que ocorreu o desligamento para que seja possível uma eventual busca por provável tentativa de burlar o monitoramento.

Também seria possível adicionar mais uma camada de segurança com relação ao cartão de memória a ser instalado na Raspberry Pi, contendo algum tipo de chave única que deveria ser validada somente por aquele dispositivo.

## 6.5 Inteligência Artificial

Tendo em mãos informações acerca do descarte de resíduos sólidos em locais inadequados, propõe-se realizar uma análise para estimar uma relação de causalidade (se existente) entre este despejo inadequado e eventos relacionados ao meio ambiente.

Por exemplo, analisar se o fato de ocorrer muitos despejos inadequados na rua A, bairro B, na cidade C está relacionada diretamente com a ocorrência frequente de enchentes. Ou, então, se o aumento de ocorrência de despejos em determinada região pode ser um fator alarmante para um possível surgimento de enchente. Será que o fato da região A possuir um número muito elevado de ocorrência de despejos inadequados possui correlação com a sua desvalorização imobiliária?

Diversos estudos podem ser conduzidos a partir do momento em que o sistema for implantado. É inegável que este tipo de informação já exista, no entanto, devido ao processo manual de coleta de informações, este pode estar muito enviesado e sujeito a falhas humanas, estando inclusive suscetível a corrupção. A proposta deste projeto reduz este tipo de viés e confiabilidade nos dados, já que tudo é realizado de forma automatizada.

Os ensaios realizados com a modelagem estatística ocorreram com base na geração de novas localizações a cada cinco segundos, porém, a elaboração geral do sistema, propõe a coleta de dados com intervalo de 30s. Seria importante fazer a avaliação do modelo estatístico considerando esta largura de tempo maior e verificar se possuirá uma performance similar.

Vale também alinhar este intervalo de tempo com os custos estimados de envios de requisições. Espera-se que quanto maior a quantidade de dados, maior será a precisão da inferência, entretanto, o custo será maior. É necessário balancear os pontos positivos e negativos desta mecânica.

Quanto ao modelo estatístico preditor que foi detalhado, seria possível realizar outros tipos de abordagens, por exemplo, ao invés de classificar se o próximo passo do veículo resultará em sua chegada ao ecoponto, considerar N passos seguintes. Ou seja, baseado nos experimentos descritos, dados 25 segundos de movimentação, quer-se descobrir se no 30º segundo o veículo teria chegado no ecoponto, seria possível modelar de forma que ao invés de classificar o 30º segundo, classificar o 60º, por exemplo.

Este tipo de abordagem com um espaço temporal maior pode ser de grande utilidade na tomada de decisões, ao passo que sua precisão pode diminuir, já que haverá maiores incertezas.

Existe também a possibilidade do veículo passar pelo ecoponto e não permanecer lá para fazer o despejo do conteúdo de sua caçamba. Este cenário merece uma atenção especial já que não está contemplado no estado atual da solução.

## 6.6 Servidor

O servidor *web* é a base para concentrar todos os dados obtidos. Deve-se estudar e escolher qual a melhor maneira de se armazenar os dados dos veículos.

Assim que os dados estiverem disponíveis na rede, é possível criar uma interface do tipo *dashboard* para monitoramento em tempo real das caçambas.

---

## CONCLUSÃO

---

Este trabalho descreve um sistema de monitoramento de descarte de resíduos sólidos. Através dos ensaios e testes realizados com cada componente, concluiu-se que a escolha dos mesmos estaria atendendo as exigências da aplicação final. Ainda são necessários alguns testes em laboratório e instalações nas plataformas alvo (veículos) para se observar o comportamento dos elementos na prática.

No entanto, fica como contribuição para a sociedade a descrição de um sistema automatizado para realizar uma tarefa que vem sendo feito de forma manual e bastante suscetível à falhas e fraudes. Além disto, foram exploradas técnicas de Inteligência Artificial juntamente com análise quantitativa e qualitativa de dados gerados através de simulador.

As análises e experimentos mostraram que é possível utilizar um modelo classificador para inferir se um determinado veículo chegará em um ponto especificado previamente (neste caso, os ecopontos da cidade), no próximo passo de tempo. Os resultados mostraram que os modelos baseados em conjuntos de modelos (Florestas aleatórias e Reforço de Gradiente) atingem um desempenho bastante satisfatório: acima de 90% de acerto na classe com menos observações.

Resumindo, os ensaios realizados mostram que:

- A célula de carga é funcional e já possui implementação para utilização;
- A Antena e *tags* adquiridos possuem um funcionamento mínimo;
- O módulo GPS/GSM consegue capturar as informações de geolocalização;
- A modelagem estatística atinge resultados satisfatórios;

Portanto, este projeto se conclui com a descrição de um sistema inteiramente inédito e protegido legalmente através do depósito de patente. Confirma-se de funcionamento básico

de vários componentes utilizados para compô-lo além de explorar abordagens baseadas em inteligência artificial que podem ser imensamente expandidas em trabalhos futuros. Contribui-se, também, com a proposta de um sistema que fará a coleta de diversos dados que, através dos quais, seria possível extrair diversos tipos de informações que poderão contribuir para a sociedade no escopo do meio ambiente.



## REFERÊNCIAS

---

---

ABADI, M.; AGARWAL, A.; BARHAM, P.; BREVDO, E.; CHEN, Z.; CITRO, C.; CORRADO, G. S.; DAVIS, A.; DEAN, J.; DEVIN, M.; GHEMAWAT, S.; GOODFELLOW, I.; HARP, A.; IRVING, G.; ISARD, M.; JIA, Y.; JOZEFOWICZ, R.; KAISER, L.; KUDLUR, M.; LEVENBERG, J.; MANÉ, D.; MONGA, R.; MOORE, S.; MURRAY, D.; OLAH, C.; SCHUSTER, M.; SHLENS, J.; STEINER, B.; SUTSKEVER, I.; TALWAR, K.; TUCKER, P.; VANHOUCHE, V.; VASUDEVAN, V.; VIÉGAS, F.; VINYALS, O.; WARDEN, P.; WATTENBERG, M.; WICKE, M.; YU, Y.; ZHENG, X. **TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems**. 2015. Software available from [tensorflow.org](https://www.tensorflow.org). Disponível em: [<https://www.tensorflow.org/>](https://www.tensorflow.org/). Citado nas páginas 28 e 62.

AGORA, S. C. Sistema de monitoramento de cacambas ja esta funcionando em sao carlos. <https://www.saocarlosagora.com.br>, Nov 2013. Disponível em: [<https://www.saocarlosagora.com.br/cidade/sistema-de-monitoramento-de-cacambas-ja-esta-funcionando-em-sao-carlos/48925/>](https://www.saocarlosagora.com.br/cidade/sistema-de-monitoramento-de-cacambas-ja-esta-funcionando-em-sao-carlos/48925/). Citado na página 25.

BARR, M. **Programming embedded systems in C and C++**. [S.l.]: "O'Reilly Media, Inc.", 1999. Citado na página 27.

BESSE, P. C.; GUILLOUET, B.; LOUBES, J.-M.; ROYER, F. Destination prediction by trajectory distribution-based model. **IEEE Transactions on Intelligent Transportation Systems**, IEEE, v. 19, n. 8, p. 2470–2481, 2017. Citado nas páginas 33 e 34.

BROWNLEE, J. **Machine learning algorithms from scratch with python**. [S.l.]: Machine Learning Mastery, 2016. Citado na página 28.

CARRUTHERS, D.; ROLLO, E. D. **Vehicle load sensing system**. U.S. Patent US20140000969A1, Jan. 2014. Citado na página 37.

DUCA, A. L.; BACCIU, C.; MARCHETTI, A. A k-nearest neighbor classifier for ship route prediction. In: **OCEANS 2017 - Aberdeen**. [S.l.: s.n.], 2017. p. 1–6. Citado nas páginas 34, 59 e 61.

DURBIN, M. J. **System for remote management of a network of waste containers**. U.S. Patent US006360186B1, Mar. 2002. Citado nas páginas 39 e 40.

EKELOF, S. The genesis of the wheatstone bridge. **Engineering Science & Education Journal**, IET, v. 10, n. 1, p. 37–40, 2001. Citado na página 51.

FLOOD, C. M.; FISHER, M. S. **Method and apparatus for monitoring waste removal and administration**. U.S. Patent US20170121107A1, May 2017. Citado na página 36.

GTECH, S. A. **Problemas causados pelo descarte inadequado de resíduos**. 2018. Disponível em: [<https://gtechsolucoes.com.br/descarte-inadequado-de-residuos/>](https://gtechsolucoes.com.br/descarte-inadequado-de-residuos/). Citado nas páginas 23 e 25.

KALMAN, R. E. A new approach to linear filtering and prediction problems. **Transactions of the ASME–Journal of Basic Engineering**, v. 82, n. Series D, p. 35–45, 1960. Citado na página 52.

LOPEZ, P. A.; BEHRISCH, M.; BIEKER-WALZ, L.; ERDMANN, J.; FLÖTTERÖD, Y.-P.; HILBRICH, R.; LÜCKEN, L.; RUMMEL, J.; WAGNER, P.; WIESSNER, E. Microscopic traffic simulation using sumo. In: **The 21st IEEE International Conference on Intelligent Transportation Systems**. IEEE, 2018. Disponível em: <<https://elib.dlr.de/124092/>>. Citado na página 56.

MARUCA, D.; LEONE, J.; CRONIN, N. E. **Systems and methods for identifying banned waste in a municipal solid waste environment**. U.S. Patent US20070262878A1, Nov. 2007. Citado na página 35.

MEYERS, G.; MARTÍNEZ-GARCÍA, M.; ZHANG, Y.; ZHANG, Y. Reliable real-time destination prediction. In: IEEE. **2021 IEEE 19th International Conference on Industrial Informatics (INDIN)**. [S.l.], 2021. p. 1–6. Citado nas páginas 33 e 34.

MONTGOMERY, P. **Diferença entre antena RFID E Leitor**. DifferBetween, NA. Disponível em: <[https://pt.differbetween.com/article/difference\\_between\\_rfid\\_antenna\\_and\\_reader](https://pt.differbetween.com/article/difference_between_rfid_antenna_and_reader)>. Citado na página 47.

NACIONAL, J. Descarte de entulho é feito de forma incorreta em 80% dos municípios. <http://g1.globo.com/>, Jan 2018. Disponível em: <<http://g1.globo.com/jornal-nacional/noticia/2018/01/descarte-de-entulho-e-feito-de-forma-incorreta-em-80-dos-municipios.html>>. Citado na página 24.

NIELSEN, M. A. **Neural networks and deep learning**. [S.l.]: Determination press San Francisco, CA, USA, 2015. v. 25. Citado na página 30.

PEDREGOSA, F.; VAROQUAUX, G.; GRAMFORT, A.; MICHEL, V.; THIRION, B.; GRISEL, O.; BLONDEL, M.; PRETTENHOFER, P.; WEISS, R.; DUBOURG, V.; VANDERPLAS, J.; PASSOS, A.; COURNAPEAU, D.; BRUCHER, M.; PERROT, M.; DUCHESNAY, E. Scikit-learn: Machine learning in Python. **Journal of Machine Learning Research**, v. 12, p. 2825–2830, 2011. Citado na página 28.

PI, R. 2009. Disponível em: <<https://www.raspberrypi.com/>>. Citado na página 49.

POTTEBAUM, J. R.; INALSINGH, A. **Vehicle load weighing system and load cells for such systems**. U.S. Patent US20040226755A1, Nov. 2004. Citado na página 38.

SHEPHERD, A. J. Multi-layer perceptron training. In: **Second-Order Methods for Neural Networks**. [S.l.]: Springer, 1997. p. 1–22. Citado na página 30.

SINGLA, L.; BHATIA, P. Gps based bus tracking system. In: IEEE. **2015 International Conference on Computer, Communication and Control (IC4)**. [S.l.], 2015. p. 1–6. Citado na página 34.

U-BLOX. **Sara G-350 development kit**. U-blox, 2020. Disponível em: <<https://www.u-blox.com/en/product/c16>>. Citado na página 55.

USP, R. Jornal da. **Descarte inadequado de lixo e entulho compromete Aquífero Guarani**. 2016. Disponível em: <<https://jornal.usp.br/ciencias/ciencias-ambientais/descarte-inadequado-de-lixo-e-entulho-compromete-aquifero-guarani/>>. Citado na página 24.

WAITE, F.; SIGMUND, D.; HATFIELD, M.; PERRY, M. **Waste container with weight-measurement system**. U.S. Patent US20170211969A1, July 2017. Citado nas páginas 38 e 39.

ZARGAR, S. A. Introduction to sequence learning models: Rnn, lstm, gru. **no. April**, 2021. Citado na página 31.

