

Francis de Melo Marconcini

**Um sistema de vigilância inteligente de baixo
custo aplicado ao rastreamento de placas
veiculares**

Vitória, ES

2022

Francis de Melo Marconcini

Um sistema de vigilância inteligente de baixo custo aplicado ao rastreamento de placas veiculares

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do Grau de Mestre em Engenharia Elétrica.

Universidade Federal do Espírito Santo – UFES

Centro Tecnológico

Programa de Pós-Graduação em Engenharia Elétrica

Orientador: Prof. Marcelo Eduardo Vieira Segatto

Coorientador: Prof. Evandro Ottoni Teatini Salles

Vitória, ES

2022

Ficha catalográfica disponibilizada pelo Sistema Integrado de Bibliotecas - SIBI/UFES e elaborada pelo autor

M321s Marconcini, Francis de Melo, 1988-
Um sistema de vigilância inteligente de baixo custo aplicado ao rastreamento de placas veiculares / Francis de Melo Marconcini. - 2022.
58 f. : il.

Orientador: Marcelo Eduardo Vieira Segatto.
Coorientador: Evandro Ottoni Teatini Salles.
Dissertação (Mestrado em Engenharia Elétrica) -
Universidade Federal do Espírito Santo, Centro Tecnológico.

1. Internet das coisas. I. Segatto, Marcelo Eduardo Vieira.
II. Salles, Evandro Ottoni Teatini. III. Universidade Federal do Espírito Santo. Centro Tecnológico. IV. Título.

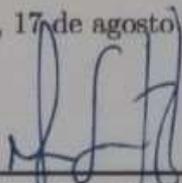
CDU: 621.3

Francis de Melo Marconcini

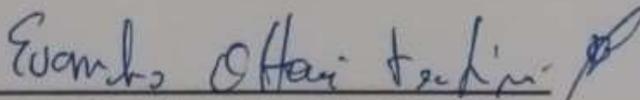
Um sistema de vigilância inteligente de baixo custo aplicado ao rastreamento de placas veiculares

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do Grau de Mestre em Engenharia Elétrica.

Trabalho aprovado. Vitória, ES, 17 de agosto de 2022:



Prof. Marcelo Eduardo Vieira Segatto
Orientador



Prof. Evandro Ottoni Teatini Salles
Coorientador



Camilo Arturo Rodríguez Díaz
Examinador Interno - UFES



Maxwell Eduardo Monteiro
Examinador Externo - IFES

Vitória, ES

2022

Dedico este trabalho a todos os acadêmicos que estão neste momento produzindo seus trabalhos científicos. Sei que não é tarefa fácil administrar a produção de um bom trabalho juntamente com todos os desafios que a vida nos lança. Torço por todos para que possam produzir seus trabalhos e fazer do mundo um lugar melhor.

Agradecimentos

Agradeço aos familiares pelo apoio, aos meus orientadores, Marcelo e Evandro por toda a força e incentivo durante o curso e a Deus.

Resumo

O crescimento dos centros urbanos tem um grande impacto nas nossas vidas e na nossa sociedade, um dos quais é o aumento da frota de veículos, que por sua vez é um dos principais responsáveis pelo aumento do congestionamento rodoviário, poluição, acidentes, furto de veículos, entre outros. Com o foco na minimização de problemas como furto de veículos em ambiente urbano, este trabalho propõe um sistema de Internet das Coisas para vigilância inteligente de baixo custo. O elemento central do sistema é acoplado a um veículo que trafega em um ambiente urbano fazendo o Reconhecimento Automático de Placas de Veículos à sua frente. As informações coletadas são encaminhadas para um serviço de nuvem responsável por monitorar placas de veículos com restrição de circulação para visualização de posicionamento, hora, data e estatísticas relacionadas às placas dos mesmos. O baixo custo de implantação do sistema permite que ele seja dimensionado para uma frota de veículos, possibilitando a construção de uma rede móvel de vigilância inteligente, ampliando a capacidade de monitoramento de uma área urbana. Os experimentos realizados em percursos de teste em um ambiente urbano, não controlado, mostram resultados promissores.

Palavras-chaves: Internet das Coisas, Vigilância Inteligente, Reconhecimento Automático de Placas

Abstract

The growth of urban centers has a major impact on our lives and on our society, one of which is the increase in the vehicle fleet, which in turns is a major offender in increasing road congestion, pollution, accidents, theft of vehicles, among others. With a focus on minimizing problems with theft of vehicles in an urban environment this dissertation proposes a low cost Internet of Things for smart surveillance system. The central element of the system is attached to a vehicle that travels in an urban environment making Automatic License Plate Recognition of the vehicles license plates in front of it. The information collected is forwarded to a cloud service that is responsible for monitoring restricted vehicle license plates to view positioning, time, date and statistics related to restricted vehicle license plates. The low cost of implementing the system allows it to be scaled to a fleet of vehicles, making it possible to build a mobile intelligent surveillance network, amplifying the monitoring capacity of an urban area. Experimental results obtained in test paths in an uncontrolled urban environment show promising results.

Keywords: Internet of Things, Smart Surveillance, Automatic License Plate Recognition

Lista de ilustrações

Figura 1 – Arquitetura IoT, 5G e IA compartilhada.	11
Figura 2 – Estágios do ALPR.	14
Figura 3 – Diagrama do contexto de aplicação do sistema.	18
Figura 4 – Arquitetura do nó de computação	19
Figura 5 – Conexão dos elementos de hardware.	21
Figura 6 – Fluxo de software.	22
Figura 7 – Novo modelo de placa brasileira (INFRAESTRUTURA, 2020b).	23
Figura 8 – Modelo antigo de placa brasileira (INFRAESTRUTURA, 2020a).	24
Figura 9 – Fluxograma de transmissão de arquivos.	24
Figura 10 – Hardware de computação central.	25
Figura 11 – Vista do hardware conectado à visão traseira do veículo de teste.	26
Figura 12 – Ângulo de visão do hardware para captura de imagem.	26
Figura 13 – Caminho de teste (caminho azul).	27
Figura 14 – Velocidades do veículo monitor durante a captura de imagens das placas veiculares reconhecidas pelo sistema.	28
Figura 15 – Histograma que representa a quantidade de placas capturadas em um intervalo de velocidade.	29
Figura 16 – Diferenças do posicionamento de caracteres dos padrões antigo e novo de placas veiculares brasileiro.	31
Figura 17 – Fluxo de envio de dados do Raspberry Pi para a nuvem.	32
Figura 18 – Estrutura do arquivo com informações de localização e tempo.	32
Figura 19 – Resultado da busca de placas no banco de dados.	33
Figura 20 – Imagem do veículo junto a placa obtida pelo sistema.	33

Lista de tabelas

Tabela 1 – Custo do elemento central.	21
Tabela 2 – Configuração ISO da câmera.	23
Tabela 3 – Faixa de velocidade em que as placas foram reconhecidas.	28
Tabela 4 – Taxa de sucesso no reconhecimento das placas veiculares.	30
Tabela 5 – Taxa de sucesso no reconhecimento das placas veiculares sem pós processamento.	31

Sumário

1	INTRODUÇÃO	1
1.1	Motivação	1
1.2	Objetivo Geral	3
1.3	Objetivos específicos	3
1.4	Contribuições	4
1.5	Organização da dissertação	4
2	REVISÃO DA LITERATURA	5
2.1	Arquiteturas Descentralizadas	6
2.2	Internet das Coisas	9
2.3	Reconhecimento Automático de Placas	13
3	PROPOSTA DO TRABALHO	17
3.1	Arquitetura do sistema	17
3.2	Implementação do sistema	20
3.2.1	Desenho do hardware	20
3.2.2	Software	21
4	TESTES E RESULTADOS	27
4.1	Testes Práticos	27
5	CONSIDERAÇÕES FINAIS	35
	REFERÊNCIAS	37

1 Introdução

1.1 Motivação

Nos últimos anos, no Brasil, houve uma queda no furto de veículos, com uso de violência em torno de 30 % e uma queda de 12 % sem uso de violência (PÚBLICA, 2021). Diversos fatores, como a economia do país e as políticas públicas, têm forte influência na redução da criminalidade no país e, se somada aos avanços tecnológicos aplicados à segurança, essa redução pode ser ainda mais significativa (VITÓRIA, 2022).

Os sistemas de vigilância legados, mais voltados para a área de segurança patrimonial, são tradicionalmente compostos por câmeras de Circuito Fechado de Televisão (*closed circuit tv* - CCTV), que captam imagens para serem supervisionadas por pessoas encarregadas de funções de monitoramento de segurança, as quais devem estar muito atentas aos eventos que ocorrem em cada uma das telas dos locais monitorados. Atualmente, o desenvolvimento tecnológico de dispositivos eletrônicos como os sensores sem fio (SWARNALATHA et al., 2020) aliado aos avanços da visão computacional e do processamento digital de imagens permitiram que a Internet das Coisas (*Internet of Things* - IoT) assumisse um papel fundamental na área de vigilância, criando o novo conceito de vigilância inteligente. Não menos importante que o monitoramento patrimonial e fiscalização de indústrias, destaca-se o monitoramento de veículos em vias urbanas, o qual possibilita aos órgãos de segurança rastrear veículos com restrições de circulação.

Os sistemas em operação na maioria das cidades com monitoramento de veículos restritos atualmente são compostos de câmeras fixas nos principais pontos da cidade considerados pelos órgãos de segurança pública como locais estratégicos. Para que esses locais possam ser equipados com unidades de monitoramento fixas, muitas vezes é necessário que sejam realizadas obras de adequação da infraestrutura da rodovia. Os equipamentos fixados devem ser adequados para obter imagens com precisão e suportar as condições climáticas e eventuais distúrbios que possam ocorrer na rodovia. Geralmente equipamentos com essa característica possuem custo elevado. Além da infraestrutura local, será necessária uma rede de transporte para que possa trafegar toda a informação obtida pelos equipamentos de captura de imagens até um centro especializado de processamento destes dados. Este centro especializado de dados deve ser equipado com um computador central capaz de processar as informações obtidas de todas as câmeras da cidade e efetuar com precisão a notificação da captura da imagem de uma placa pertencente a um veículo restrito às autoridades responsáveis.

Em sistemas de tempo real, os quais sua resposta é percebida por seres humanos como instantânea, aplicações de reconhecimento de placas veiculares devem ser robustas o suficiente em termos de hardware e software, de forma que sejam capazes de executar as etapas de aquisição da imagem, extração da placa do veículo e reconhecimento dos caracteres contidos na placa, as quais são básicas em um sistema de reconhecimento automático de placas (*Automatic License Plate Recognition* - ALPR) de acordo com (DU et al., 2012). Esta estrutura de hardware e software deve satisfazer os requisitos para aplicação dos algoritmos necessários em cada estágio e em cada quadro do *streaming* de vídeo capturado. Deve-se levar em consideração que quanto maior a resolução da imagem, maior a chance de extrair a placa e realizar o reconhecimento de seus caracteres, porém mais poder computacional é necessário para processar toda a matriz da imagem de alta resolução.

De modo a reduzir Custos com hardware de alto poder computacional para reconhecimento de placas veiculares, este trabalho propõe restringir a área de aplicação do sistema a um ambiente urbano, o que limita a velocidade dos veículos devido a muitos pontos de retenção como engarrafamentos, travessias de pedestres, semáforos de controle de tráfego, entre outros. As constantes desacelerações causadas por esses pontos de retenção fazem com que os veículos se desloquem em velocidades muito baixas ou parem em uma fileira e próximos uns dos outros, o que torna desnecessária a captura contínua de imagens de vídeo. Desta forma, o mesmo quadro de imagem seria capturado muitas vezes e a capacidade computacional seria desperdiçada ao executar as etapas de extração, segmentação e reconhecimento de caracteres da placa do veículo.

Com base nessas características, o sistema de IoT proposto adquire imagens de alta resolução a uma taxa de quadros por segundo adequada de modo a permitir que o hardware possa executar as rotinas do software de reconhecimento de placas veiculares e enviar os dados para o responsável pelo serviço de nuvem as informações de localidade (latitude, longitude), data, hora e identificação da placa veicular obtida. O sistema irá operar de forma online em que o tempo de resposta do mesmo fique entre 2 e 10 segundos pelo fato do hardware não ter poder computacional suficiente para resposta instantânea, e com baixo custo se comparado às plataformas ALPR de tempo real que processam vídeos de alta definição. A característica de processamento local do sistema faz com que a carga de processamento não se concentre na nuvem e que o tráfego de rede entre a fonte produtora de informação (veículo que captura as imagens) e o servidor na nuvem não seja alto, pois a informação já é encaminhada para o destino processada e conseqüentemente reduzida.

O sistema possui a característica de reprodutibilidade, pois o teste prático realizado neste trabalho através de somente um veículo, poderia ser facilmente realizado por uma frota de veículos em movimento pela cidade formando um cerco inteligente móvel e

monitorando muitas placas a cada segundo. Em automóveis mais antigos isso é possível equipando veículos monitores com o equipamento Raspberry Pi 3 com um cartão SD clonado a partir do protótipo principal utilizado neste trabalho, conexão com a internet (sem a necessidade de conexão contínua) e periféricos como câmera e GPS. Em automóveis atuais, hardwares que fazem parte de sua composição tem a capacidade de realizar as tarefas do sistema proposto, desta forma existe a possibilidade de montadoras oferecerem o sistema como um serviço através da integração do software desenvolvido neste trabalho em seu hardware. Desta forma, não seria necessário investimento em infraestrutura de câmeras e rede de dados espalhadas pela cidade, juntamente com todos os processos envolvidos para regularização de sua instalação e portanto o tempo de ingresso ao mercado seria muito mais rápido proporcionando as pessoas usufruírem do benefício de segurança de forma rápida.

Sistemas fixos de monitoramento de veículos geram para a gestão da segurança pública um custo elevado de implantação, operação e manutenção, além de um tempo considerável com toda a regularização para intervenção em áreas públicas.

1.2 Objetivo Geral

O objetivo geral desta dissertação é produzir um sistema de rastreamento de placas veiculares de baixo custo que possa ampliar o alcance dos sistemas fixos existentes proporcionando um serviço ainda mais eficiente para a segurança pública.

1.3 Objetivos específicos

Os objetivos específicos da dissertação são alcançados através dos seguintes passos:

- Propor uma arquitetura de um sistema de vigilância inteligente de baixo custo para captura de placas veiculares
- Fazer aquisição do hardware necessário para infraestrutura do sistema
- Embarcar o software de reconhecimento automático de placas juntamente com suas dependências (bibliotecas necessárias para o funcionamento do software)
- Preparar rotinas automatizadas para capturas de imagens para serem fornecidas ao software de reconhecimento
- Preparar software de pós processamento dos valores de saída obtidos do software de reconhecimento
- Preparar as rotinas de software para transferência de arquivo para o servidor remoto responsável pelo recebimento das imagens

- Preparação do veículo de testes com a fixação do hardware e verificação do posicionamento ideal para capturas de imagens de placas veiculares
- Planejamento de rota e execução de testes práticos conforme premissas do sistema de monitoração em ambiente urbano
- Avaliação dos resultados após execução das rotinas do sistema.

1.4 Contribuições

O trabalho realizado para a dissertação, resultou na publicação *A low-cost Smart Surveillance System applied to vehicle license plate tracking* no periódico *Journal of Microwaves, Optoelectronics and Eletromagnetic Applications* (MARCONCINI; SEGATTO; SALLES, 2022).

1.5 Organização da dissertação

O trabalho está organizado da seguinte forma: O capítulo II descreve os trabalhos relacionados às tecnologias capacitadoras para o sistema implementado. Serão abordados os temas de arquiteturas descentralizadas, Internet das Coisas e reconhecimento automático de placas. A abordagem de arquiteturas descentralizadas se dá pelo fato do sistema implementado realizar rotinas de processamento de imagens localmente, tirando a carga de processamento do lado da nuvem e diminuindo o tráfego de informações através da rede. Em IoT trabalhos com ênfase no 5G, computação ubíqua e sistemas de transporte inteligente são abordados afim de facilitar a visão do sistema desenvolvido neste trabalho como uma aplicação para IoT. E através do tema de reconhecimento automático de placas, podem ser vistas as principais técnicas utilizadas na atualidade nas áreas de visão computacional e reconhecimento de padrões adotadas neste tipo de aplicação.

A arquitetura do sistema será descrita no capítulo III, destacando questões como topologia do sistema implementado, escolha do hardware e periféricos além das tecnologias de software que farão parte da composição. A implementação do sistema será descrita na capítulo IV, juntamente com os testes práticos, onde é possível avaliar a eficiência do sistema aplicado a um ambiente urbano. Finalmente, as conclusões são apresentadas no capítulo V.

2 Revisão da Literatura

Os sistemas de vigilância inteligente consistem no uso de tecnologias de análise automática de vídeo ([HAMPAPUR et al., 2003](#)), que se destinam a preencher as lacunas da atenção humana. Os sistemas de vigilância legados contam apenas com a captura de vídeo por sistemas de câmeras. Estas encontram-se espalhadas por locais estratégicos do ambiente monitorado, em que suas imagens são submetidas à análise humana para investigar incidentes ocorridos, além de sua supervisão servir para monitoramento de atitudes suspeitas no ambiente. A evolução da tecnologia da informação, associada aos avanços nas áreas de robótica, eletrônica, visão computacional e IoT, permitiu que os sistemas de vigilância evoluíssem para arquiteturas muito mais elaboradas, como a proposta em ([BRAICOV et al., 2018](#)).

Por exemplo, o uso de sensores vestíveis em forças policiais, microfones e câmeras espalhadas pela cidade, sensores acoplados a veículos policiais e drones, todos capturando dados para submeter a algoritmos de inteligência artificial capazes de cruzar informações para evitar incidentes ou até mesmo catástrofes. Conforme discutido em ([HAMPAPUR et al., 2003](#)), esta é a quebra de paradigma trazida pelos sistemas de vigilância inteligentes que mudaram de sistemas de investigação de incidentes para sistemas de prevenção de incidentes.

Como pode ser visto em ([TIAN et al., 2008](#)), nestes tipos de sistemas inteligentes, os eventos são registrados e rastreáveis, podendo ser revisados a qualquer momento através de consultas simples no banco de dados, não se limitando apenas a ambientes onde o monitoramento do patrimônio e o controle de acesso são necessários. Os sistemas de vigilância inteligentes também podem ser aplicados a ambientes mais dinâmicos, como vias de trânsito urbanas por onde os veículos trafegam.

Algumas cidades no Brasil já possuem sistemas de monitoramento inteligentes que formam um cerco de segurança, como Vitória no estado do Espírito Santo, Brasil ([VITÓRIA, 2021](#)). É um sistema com 86 câmeras fixas de alta resolução instaladas em 24 barreiras espalhadas pela cidade, na qual fotos das placas dos veículos são registradas e reconhecidas por um sistema ALPR. Portanto, caso haja alguma restrição quanto às placas dos veículos, a instituição responsável para segurança será acionada.

Arquiteturas descentralizadas, conforme propostas em ([SANTAMARIA et al., 2019](#)), podem trazer um ganho em otimização em sistemas de vigilância inteligentes. Tal otimização é alcançada pelo fato de reduzir o tempo de resposta do sistema, aumentar a escalabilidade do mesmo, além de poupar recursos de rede fazendo com que todo processamento de informação fique local e transportando para fora da rede a informação

já tratada e em menor volume.

2.1 Arquiteturas Descentralizadas

Os sistemas de monitoramento centralizados dependem de arquiteturas computacionais robustas, que precisam atender aos requisitos de tempo de resposta do sistema para as várias áreas monitoradas. A infraestrutura deve crescer proporcionalmente à medida que aumenta a área de cobertura do sistema. Considerando esses desafios, arquiteturas descentralizadas são propostas afim de satisfazer aos requisitos de tempo de resposta e escalabilidade conforme abordado em (SANTAMARIA et al., 2019). Edge Computing pode ser definido como um recurso de rede com poder computacional localizado no caminho entre o dispositivo de IoT e a nuvem (SHI; DUSTDAR, 2016).

Em (NIKOU EI et al., 2019) as arquiteturas para vigilância inteligente são baseadas em *Edge Computing* (AI; PENG; ZHANG, 2018), paradigma onde a computação complexa é realizada nos dispositivos de borda do sistema. Este novo paradigma é uma proposta para superar as deficiências da computação em nuvem (JR, 2012; BUSHHOUSEN, 2011). Desafios como escalabilidade, acesso ubíquo a dados sensoriais, sobrecarga de processamento de eventos, alto tráfego de rede e armazenamento massivo podem ser superados por meio de *Edge Computing*, que visa oferecer suporte à latência crítica de aplicativos de vigilância inteligente, promovendo a proximidade entre a computação em nuvem e os produtores de dados. Ele também elimina longos tempos de ida e volta introduzidos anteriormente pela infraestrutura em nuvem usada para análises, bem como economia de custos, economia de energia e consumo reduzido de largura de banda (NETO et al., 2018).

Atualmente, as arquiteturas de *Mobile crowdsensing* (MCS) (MARJANOVIĆ; ANTONIĆ; ŽARKO, 2018) tornaram-se viáveis por meio da descentralização e do uso de *Mobile Edge Computing* (MEC). A alta demanda por recursos de computação como conexões simultâneas no *backend* de serviços em execução na nuvem, poder de processamento em tempo real, bem como funções de gerenciamento de dispositivo (na qual o rastreamento de contexto é mantido no aplicativo), onde sua taxa de atualização é muito dinâmica, apenas uma arquitetura descentralizada baseada no MEC pode trazer melhor desempenho e evolução para a aplicação em questão. Caso contrário, ocorrerão problemas como aumento de cargas elevadas na rede móvel e *backhaul*, gerando efeitos colaterais indesejados, como gargalos e atrasos na comunicação.

O avanço nas comunicações móveis tornou inevitável a adoção de *Edge Computing*, principalmente no que se refere em controle de rede e armazenamento (network control and storage). Conforme citado por (MAO et al., 2017), os sistemas de comunicação das gerações 1 a 4 (1G a 4G) tinham como objetivo aumentar as velocidades sem fio para suportar a transição de tráfego centrado em voz para centrado em multimídia. A quinta

geração (5G) de comunicações móveis tem um propósito diferente das gerações anteriores. Esta geração deve suportar comunicação, computação, controle e entrega de conteúdo, em que os aplicativos requerem alta velocidade de acesso sem precedentes e baixa latência. Por esses requisitos, o essencial para os serviços desta nova era das comunicações é que sejam adotadas arquiteturas baseadas em *Edge Computing*. Trazendo a capacidade de armazenamento e computação para mais perto dos usuários e fazendo com que a nova tendência de comunicação em que o tráfego é consumido e produzido localmente seja atendida dentro de parâmetros especificados para uma rede 5G.

Antes de iniciar falando sobre arquiteturas descentralizadas não se pode deixar de mencionar sobre arquiteturas centralizadas. Não se trata de uma comparação apontando qual delas seja a melhor, mas sim em qual cenário cada uma é melhor aplicada e otimizada para as aplicações de usuário. Arquiteturas centralizadas baseadas em *Cloud Computing* foram as principais responsáveis para que aplicações como realidade virtual, cidades inteligentes, quinta geração de comunicações móveis (5G), entre outros, pudessem ser possíveis devido a alta disponibilidade de recursos computacionais e serviços. Porém arquiteturas centralizadas baseadas em *Cloud Computing* não foram idealizadas para atender aplicações críticas com requisitos de baixa latência, localização e mobilidade. Problemas como congestionamento de rede e alta latência na comunicação são alguns dos desafios a serem superados. A latência de rede é causada muitas vezes pelo fato de se usar os nós de computação na nuvem, ficando longe da aplicação de usuário que necessita de uma elaboração remota dos seus dados.

Conforme (SANTAMARIA et al., 2019), a latência de rede pode ser diminuída migrando-se módulos de processamento de dados da aplicação pra mais perto do usuário. Apesar de não apresentar uma alta capacidade de recursos computacionais compartilhados como a *Cloud Computing*, a *Edge Computing* tem a vantagem de estar próxima as camadas do usuário.

Afim de tentar alcançar um modelo com um bom custo benefício para aplicações de mobilidade e latência crítica, arquiteturas híbridas como a abordada em (REN et al., 2019) apresenta propostas de estratégias de colaboração entre *Edge Computing* e *Cloud Computing*, solucionando por exemplo problemas de latência e congestionamento de rede através de *Edge Computing* e de limitação de recursos através de *Cloud Computing*. Neste mesmo tipo de abordagem (MITROVIC et al., 2016) propõe uma arquitetura descentralizada que reduz a sobrecarga de comunicação na rede, levando em consideração que as informações sejam particionadas em subconjuntos e enviadas para os dispositivos de borda efetuarem o calculo somente para a região onde estão localizados.

É cada vez mais comum aplicações que trabalham com tráfego de veículos utilizarem arquiteturas descentralizadas. Com o avanço dos smartphones, que a cada dia tornam-se dispositivos com recursos computacionais mais abundantes, além de serem equipados

com os vários tipos de sensores como *Global positioning System* (GPS) e acelerômetro, o que facilita a manipulação de dados localmente e processamento para cálculos de rotas e tempos de viagem, as aplicações podem se beneficiar desta capacidade de processamento utilizando-se desses dispositivos como um nó de *Edge Computing*. Desta forma aliviando o tráfego na rede, tornando o mesmo local e mais seguro para o usuário. Apesar das vantagens citadas acima em se utilizar *Edge computing* ao invés de *Cloud Computing* para aplicações de mobilidade e latência crítica, tal tarefa não é simples. Em (GIANG et al., 2018) duas questões principais são levantadas com relação a migração de aplicações baseadas em *Cloud Computing* para *Edge Computing*:

- Como decompor uma aplicação para que a mesma seja facilmente distribuída da *Cloud* para a *Edge computing* ?
- Como suportar as características que são inerentemente relevantes na rede *Edge*, como grande escala, natureza dinâmica e natureza dependente do contexto da computação ?

Pensando em tais questões ao se planejar um sistema baseado em *Edge Computing*, um modelo híbrido pensando em melhor custo benefício pode ser idealizado para atender aos requisitos da aplicação, sempre avaliando a possibilidade de determinados módulos de processamento serem executados em *Cloud Computing*.

As literaturas abordam muito os benefícios do *Edge Computing* em relação aos recursos de rede poupados, porém existem mais fatores que beneficiam sistemas baseados neste tipo de arquitetura. Dispositivos de IoT geralmente trabalham com baterias e possuem restrições quanto ao consumo de energia. Por isso, os dispositivos não são capazes de transmitir altos volumes de dados para a *Cloud*, desta forma a estrutura de *Edge Computing* é mais eficiente no que se refere ao gasto energético do dispositivo. Trabalhos como o de (ASLANPOUR et al., 2022) visam melhorar ainda mais os desafios energéticos dos dispositivos de IoT e *Edge Computing*, buscando melhorar a eficiência energética através de um sistema de consciência de recursos energéticos.

Em termos de privacidade, os dados no *Edge computing* são distribuídos somente nos nós mais próximos, o que traz dificuldade em se atacar cada nó para roubar os dados (YU et al., 2017). O número de dispositivos de IoT no mundo já chegaram na marca do bilhão. A quantidade de dados produzidos por esses dispositivos não pode ser encaminhada e tratada pela estrutura convencional de *Cloud Computing*, por isso, devem ser consumidas pela *Edge* (KAUR et al., 2018).

Em *Edge Computing*, os dados gerados por dispositivos de IoT e sensores não precisam necessariamente ir para a *Cloud*. Em alguns casos o próprio dispositivo, ou até mesmo o dispositivo a frente (ainda dentro da infraestrutura do *Edge Computing*) são capazes de processar os dados e emitir uma resposta ao dispositivo que fez a requisição

de forma rápida. Tais tarefas que podem ser executadas em *Edge Computing* sem ter que recorrer aos serviços de *Cloud* e conectividade com a internet, tornam a resposta do sistema extremamente rápida.

2.2 Internet das Coisas

A IoT revolucionou a computação onipresente e está se expandindo muito rapidamente. Há alguns anos projetava-se que em 2020 teríamos cerca de 50 bilhões de dispositivos no mundo (ALBERTIN; ALBERTIN, 2017), o que não é possível saber ao certo hoje, mas percebe-se que ocorreu um crescimento exponencial. Dispositivos como etiquetas de identificação por rádio frequência (*radio frequency identification - RFID*), sensores, atuadores, telefones celulares, etc., estão cada vez mais presentes em nossas vidas, mudando a forma como interagimos com o mundo. Em (ATZORI; IERA; MORABITO, 2010), a redução em termos de tamanho, peso, consumo de energia e custo de dispositivos de rádio é apontada como um ponto crucial para a expansão do conceito de IoT. Tal fato permitiu que praticamente todos os objetos tivessem rádios integrados, possibilitando um simples objeto ter conectividade com pessoas e qualquer outra "coisa" que também tivesse capacidade de comunicação. Com o advento das redes de 5ª geração (redes 5G), a tecnologia IoT pode ter aprimorado os recursos de conectividade, além de segurança, confiabilidade, cobertura, baixa latência e atender a uma ampla gama de novas aplicações. De acordo com (STANLEY et al., 2018), as redes 5G garantirão à IoT a qualidade necessária por meio de seus recursos, como banda larga móvel aprimorada (*enhanced mobile broadband - eMBB*), comunicações massivas do tipo máquina (*massive machine type communication - mMTC*) e comunicações críticas (serviços com latência ultrabaixa).

Como tecnologia em destaque atualmente, IoT tem atraído muitos investimentos e vem sendo a grande aposta das empresas para novas oportunidades de negócio. Através deste novo conceito, o objetivo é trazer crescimento econômico para sociedade, inovação na urbanização e infraestrutura, novos empregos, inovação na área da saúde e serviços diversos. De acordo com (SHAFIQUE et al., 2020 apud LEE; LEE, 2015), o IoT transforma o mundo em um mundo inteligente, não só trazendo novas oportunidades de negócio, mas também tem a oportunidade de melhorar processos e sistemas através de pesquisas eficientes, combinando diversas áreas como negócios, engenharia e ciências humanas. Através deste propósito, o objetivo do IoT se torna cada vez mais concreto no qual visa melhorar os padrões de vida das pessoas. Segundo (SHAFIQUE et al., 2020 apud LEE; LEE, 2015) no geral as empresas tem feito investimentos imediatos, mais para casos em que se realiza a atualização de sistemas legados e/ou sistemas em que não existe qualquer tipo de automação.

Para novas oportunidades de negócio, para soluções de IoT ainda não amadurecidos

no mercado, prefere-se utilizar a abordagem de investimento "espere e veja" (*wait-and-see*), em que o investimento é feito de maneira controlada sem muitos riscos através de soluções abertas e mais baratas. Ao explorar as atuais tecnologias *wireless* utilizadas para conectar dispositivos IoT a rede, percebe-se que as gerações móveis 1G, 2G, 3G, 3.5G e 4G, além das tecnologias *bluetooth* e *Wi-Fi*, não são adequadas em sua totalidade aos requisitos de IoT. Como abordado anteriormente, a nova geração 5G, recém chegada ao mercado de Telecomunicações, possui proposta de atender a todos os requisitos de IoT, para os mais variados modelos de negócio vislumbrados para esta tecnologia. Começando pelo espectro de frequência do 5G, que vai do mais baixo (abaixo de 2GHz) até o mais alto (ondas milimétricas - 24 GHz, 28 GHz, 37 GHz, 39 GHz e 47 GHz). (SHAFIQUE et al., 2020 apud LEE; LEE, 2015) apresenta os seguintes casos de uso para cada uma delas:

- Baixas frequências - Adequadas para mMTC e aplicações *indoor*. Possui cobertura extensa e facilita mobilidade. Possui canais e mobilidade mais amplos;
- médias frequências - Compreendem uma faixa aproximada entre 3.55GHz e 7.125GHz. Adequada para áreas abertas e urbanas. Possui curto alcance com baixa latência.
- Altas frequências - Adequadas para eMBB e aplicações urbanas. Possuem alcance curto com baixa latência e alta capacidade devido a canalização ampla;

Na rede 5G, inovações foram incorporadas à arquitetura para que a mesma pudesse atender aos inúmeros novos cenários recém chegados. A arquitetura de rede das gerações anteriores, baseadas em hardware, não atende a novas demandas. O tráfego exponencial, novos nós de rede, infraestrutura de transporte e flexibilidade de expansão eficientes são alguns dos novos desafios a serem gerenciados pela nova geração de comunicação móvel. Para que estes desafios sejam alcançados e um suporte adequado ao IoT sobre o 5G, as seguintes tecnologias são fundamentais:

- Redes de Sensores *wireless* definidas por *software* (*software defined wireless sensor network* - SDWSN) - Através deste novo paradigma de rede, será possível controlar toda a infraestrutura de encaminhamento de informações, atribuindo a um elemento externo a função de controle e programabilidade da rede. Tal elemento descentralizará as funções de controle dos dispositivos de rede como um *switch* por exemplo. Segundo (AKPAKWU et al., 2017) a necessidade de introduzir o SDWSN no 5G se dá em simplificar toda a infraestrutura de rede, gerenciar e controlar todos os requisitos do sistema e manter a heterogeneidade dos ambientes de rede para permitir futuros casos de uso de IoT;
- Virtualização de funções de rede (*Network Function Virtualization* - NFV) - Esta tecnologia tem como vantagem o ganho de flexibilidade e escalabilidade diante da diversidade de dispositivos de IoT (mMTC) que irão se conectar à rede. Além da

diminuição de gastos com investimentos e operações de rede (CAPEX e OPEX), bem como consumo de energia eficiente e um tempo de resposta rápido ao mercado para os novos casos de usos de IoT;

- Rádios Cognitivos - A otimização do uso de recursos de rádio é o objetivo desta tecnologia. Esta otimização é necessária devida a conectividade massiva que chega junto com os novos serviços de IoT. Técnicas dinâmicas de acesso ao espectro proporcionam aos rádios cognitivos operar no melhor canal disponível.

Diante de tantas melhorias de rede com o advento do 5G, a inteligência artificial (IA) não poderia ficar de fora. Esta que se torna um alvo dos mais sofisticados casos de uso de IoT. As altas taxas de dados alcançadas pelo 5G tornam possível o uso de sofisticados algoritmos de IA como *Deep Learning* e Redes Neurais aplicados a dados em tempo real para tomadas de decisão, tradução de fala, classificação de vídeos, entre outras. Abre-se então um leque de oportunidades e novos casos de uso de IoT. A Fig. 1 representa uma arquitetura onde o 5G, IoT e IA compartilham suas aplicações, servindo como recursos compartilhados entre si.

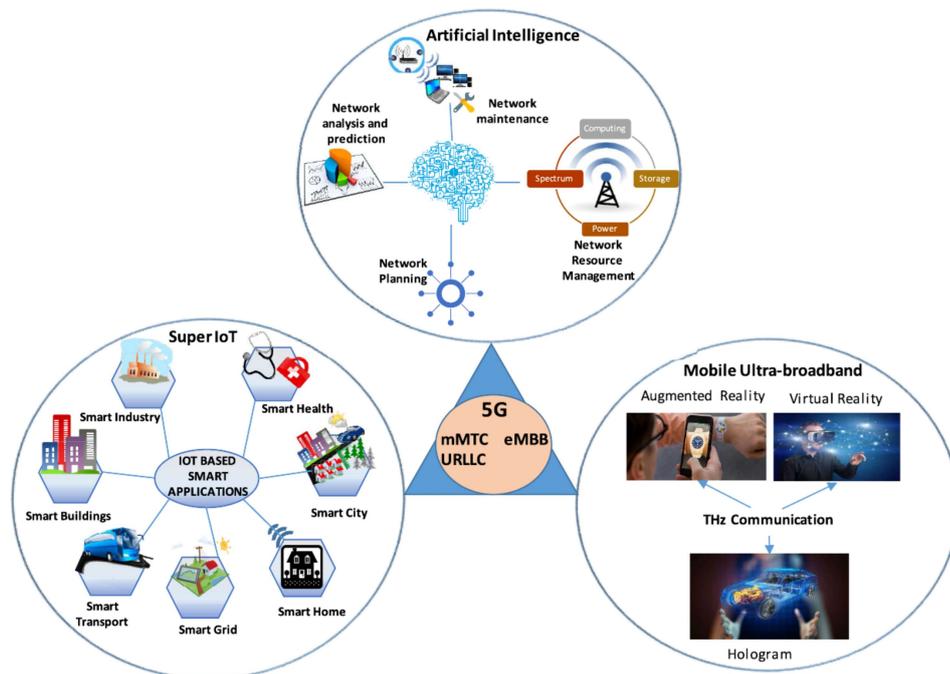


Figura 1 – Arquitetura IoT, 5G e IA compartilhada.

Fonte: (SHAFIQUE et al., 2020).

Todos os ganhos de velocidade, latência e capacidade trazidos ao IoT pelo 5G vem acompanhados de inúmeros desafios a serem superados. Abaixo são citados alguns destes:

- Segurança - Levando em consideração a conectividade massiva necessária a rede para as demandas de IoT e que necessitam ter uma certa facilidade de conectividade dos

novos nós, visto que muitos tratam-se de sensores com formas simples de conexão a rede. É possível fazer isso de forma segura a ponto de resguardar a informação trocada nessas inúmeras conexões? Para proteger os dados e as conexões feitas entre esses dispositivos de IoT serão necessários esforços tanto dos fabricantes de dispositivos, como também por parte das operadoras de rede, de forma a garantir a comunicação segura entre os nós de IoT. Abre-se uma oportunidade neste ponto de aplicar a inteligência oriunda com os avanços de IA aplicados as redes 5G.

- Flexibilidade de rede - A flexibilidade de rede torna-se um desafio pelo fato da heterogeneidade que os dispositivos de IoT irão incorporar a rede. Os tipos de tráfego de IoT são dos mais variados, gerados por dispositivos simples que comunicam-se através de mensagens curtas, dispersas no tempo, em sua maioria utilizam mais tráfego de *uplink* tudo isso sob a condição de recursos de energia e computação limitados. Tal fato torna complexa a condição da rede de se adequar da melhor forma para atender aos requisitos deste tipo de dispositivos. Mais uma vez vislumbra-se soluções baseadas em IA para que seja reconhecido o perfil do dispositivo IoT na rede e seja feita uma reconfiguração dinâmica nos seus parâmetros afim de adequar o tipo de comunicação que atenderá ao dispositivo de forma otimizada. Tudo isso através de soluções baseadas em IA e também de NFV, a qual está relacionada a alocação dinâmica de recursos de rede associados aos dispositivos de IoT.
- Alta demanda de dispositivos conectados - Para atender ao alto número de dispositivos conectados, o 5G possui a *Narrow Band IoT* (NB-IoT) para atender a comunicação de baixo consumo dos dispositivos, de modo a que características de cobertura não drenem totalmente a bateria dos dispositivos. O NB-IoT também visa atender ao tráfego de altos volumes de dados de forma a garantir mínima latência e confiabilidade.

Como uma tecnologia revolucionária, a IoT não poderia ficar de fora da quarta revolução industrial, conhecida como Indústria 4.0. Essa tecnologia é baseada em Sistemas Ciberfísicos (*cyber physical systems* - CPS) (ADEBAYO; CHAUBEY; NUMBU, 2019), uma disciplina que envolve a engenharia da computação e sistemas de comunicação que fazem interface com o mundo físico. Esse conceito de CPS torna essa tecnologia intimamente ligada à IoT, que de certa forma também envolve a engenharia da computação e os sistemas de comunicação interagindo com o mundo físico. Em (SHI et al., 2011) o autor trata o conceito de CPS de forma mais completa, deixando a visão de IoT com uma das tecnologias que a integram.

2.3 Reconhecimento Automático de Placas

Sistemas de monitoramento de placas veiculares estão sendo cada vez mais solicitados por órgãos de segurança pública e fiscalização de trânsito para monitorar veículos com restrições de tráfego, fiscalizar impostos atrasados e para controle de tráfego. Se sistemas de monitoramento dependerem somente de recursos humanos para monitoramento, isso trará problemas como alto custo de manutenção e baixa eficiência. O grande desafio do reconhecimento automático de placas é extrair da imagem os caracteres que representam a identificação da placa veicular. Inúmeros obstáculos aumentam o grau de dificuldade do desafio de reconhecimento das placas. Em um cenário de tráfego real na qual se aplica um sistema de monitoramento inteligente de placas veiculares, podemos ter inúmeros obstáculos a serem superados para que se obtenha sucesso no reconhecimento. Alguns deles são:

- Condições de tempo - chuva, neve, neblina e até o dia e a noite (condições de iluminação);
- Condições de captura da imagem da placa veicular – Tipo de câmera utilizada (câmera de mão, câmera fixa) na qual podem gerar imagens sem foco, trêmulas, com reflexão, com inclinação do ângulo de captura, resolução ruim, obstrução dos caracteres da placa e fundo complexo de imagem.

Todo o desafio para se realizar um reconhecimento de sucesso depende de uma extração de característica que possa superar tais fatores.

No que se refere a condições de captura da imagem de placas veiculares, trabalhos como o de (DONG et al., 2017) utilizam redes neurais convolucionais para extrair a região de interesse de imagens de fundo complexo e com algum ângulo de inclinação através de redes *Region Proposal Network* - *RPN* de uma imagem reduzida. Ao extrair as regiões de interesse (possíveis localizações das placas veiculares) as mesmas são entregues a uma *Region based Convolutional Neural Network* – *R-CNN*, a qual retorna as possíveis placas veiculares juntamente com as coordenadas dos pontos de canto. Dada esta etapa bem sucedida, a etapa de reconhecimento que ocorre a seguir, faz o alinhamento dos caracteres, retirando o ângulo em que foi capturada a imagem e então realizando o reconhecimento dos caracteres da placa. Em (RAO; MUTHU, 2017) problemas com imagens sem foco são tratados através de métodos de estimação de kernel para então através de uma deconvolução, possa se chegar a imagem com melhor foco. Bem como em (SUN et al., 2015), a estimação de funções de distribuição de probabilidade é realizada via CNN para tratamento de imagens com desfoque de movimento não uniforme.

Em (RIO-ALVAREZ et al., 2019) o reconhecimento automático de placas é avaliado em relação as condições meteorológicas e de iluminação das imagens utilizadas para treinar

algoritmos de aprendizado e produz interessantes conclusões. A primeira é que imagens de placas com chuva, neve ou neblina, situações que tornam as imagens ruidosas, diminuem a eficiência de reconhecimento do sistema quando inseridas no conjunto de treinamento utilizado por algoritmos de aprendizado. Ao contrário, imagens com condições de iluminação diversas são bem vindas ao se efetuar o treinamento do sistema de reconhecimento de placas veiculares, visto que em testes práticos a eficiência de reconhecimento aumenta. Diante disso, a remoção dos ruídos causados por condições meteorológicas na imagem, dentro das possibilidades de filtros e tempos de resposta (maioria das aplicações são em tempo real), deve ser aplicada anterior ao treinamento dos algoritmos de aprendizado para reconhecimento automático de placas veiculares.

De acordo com (DU et al., 2012), um sistema ALPR consiste em quatro etapas:

- Aquisição de imagem: Aquisição imagem propriamente dita, englobando todo o veículo.
- Extração de Placas: Identificação da placa veicular através de um pré-processamento de imagem para que se possa realizar sua detecção e extração da região de interesse.
- Segmentação de Caracteres: A partir da placa extraída, ela é segmentada para extrair os caracteres a serem reconhecidos.
- Reconhecimento de Caracteres: A partir dos caracteres segmentados, eles são reconhecidos para obter o resultado final, que é a identificação da placa.

Na Fig. 2, (SHASHIRANGANA et al., 2020) apresenta de forma gráfica os estágios que compõe um reconhecimento automático de placas veiculares.

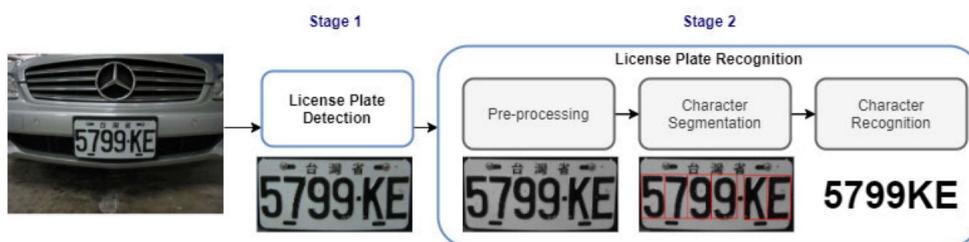


Figura 2 – Estágios do ALPR.

Fonte: (SHASHIRANGANA et al., 2020).

Cada etapa deve ser realizada com sucesso para que um resultado de qualidade satisfatória possa fornecer informações precisas para a próxima etapa. Neste trabalho, o ALPR será realizada através do OpenALPR (SYSTEMS, 2020), que é baseado nas bibliotecas OpenCV (TEAM, 2021), responsável por toda a manipulação de imagens, e Tesseract (AL., 2021), que é baseado em redes neurais de memórias de longo e curto prazo (*Long Short Term Memory - LSTM*) (HOCHREITER; SCHMIDHUBER, 1997). Estas, por

sua vez, imitam o sistema humano de memória de longo e curto prazo e têm a vantagem de superar os problemas de retro propagação de erros (HOCHREITER; SCHMIDHUBER, 1997) encontrados nas redes de retro propagação através do tempo (HOCHREITER; SCHMIDHUBER, 1997; HAYKIN, 1994). Sistemas ALPR como o implementado em (HOCHREITER; SCHMIDHUBER, 1997) usam redes LSTM para localizar os caracteres na placa do veículo, bem como extrair características dos caracteres. Atualmente, redes amplamente utilizadas para reconhecimento de imagens e conseqüentemente em ALPR são as Redes Neurais Convolucionais (CNN). Os autores de (DORBE et al., 2018) e (ZOU et al., 2020) usam essas redes em conjunto com os LSTMs para realizar extração de características, localizar os caracteres na placa e reconhecê-los. Técnicas avançadas de reconhecimento de imagem enriquecem muito o ALPR, porém, utilizando-as com o ajuste dos parâmetros do sistema definidos conforme discutido em (HSU; CHEN; CHUNG, 2012) voltado para a aplicação, é possível chegar a um estado da arte.

3 Proposta do Trabalho

3.1 Arquitetura do sistema

A arquitetura do sistema proposto oferece um modelo de sistema de vigilância inteligente descentralizado baseado em IoT. Utilizando um *Single Board Computer* (SBC), o Raspberry Pi 3 Modelo B, com câmera integrada e GPS, será realizado o OCR (*Optical Character Recognition*) na placa veicular, a qual terá suas imagens capturadas juntamente com suas coordenadas GPS e posteriormente enviadas para um banco de dados remoto. Este sistema funcionará como um *Edge Computing*, cuidando de todo o processamento de imagem necessário para o reconhecimento da placa do veículo e enviará para o destino (servidor remoto com banco de dados na nuvem) somente as informações úteis.

Com a redução em termos de tamanho, custo e aumento no poder computacional dos computadores, os dispositivos IoT têm contribuído fortemente para a evolução das arquiteturas IoT baseadas em *Edge Computing*. Tarefas com operações mais complexas podem ser resolvidas diretamente nesses dispositivos de borda, desde que não existam restrições de energia. Em (NAIR et al., 2018) o *Single Board Computer* (SBC), pode ser usado como uma alternativa mais barata e compatível com softwares de visão computacional existentes em comparação com o uso de *Field Programmable Gate Array* (FPGA) e hardware embarcado de uso geral.

Nesta categoria de SBC, destaca-se o *Raspberry Pi* (PI, 2020), dispositivo que cabe na palma da mão, mas com alta capacidade computacional, capaz de realizar tarefas de visão computacional, sendo uma alternativa aos sistemas descentralizados baseados em computação de ponta. Com base nas características de sistemas baseados em *Cloud* e em *Edge computing*, o sistema de rastreamento de placas veiculares proposto neste trabalho foi idealizado para não depender de um servidor centralizado para reconhecimento das placas veiculares, pois por se tratar de um sistema de rastreamento móvel, tal característica faz com que exista a probabilidade do veículo rastreador estar em uma área de sombra (sem cobertura de rede celular) e não possa executar o trabalho de visão computacional para reconhecimento da placa em um serviço em *Cloud*. Com um processamento local da etapa de visão computacional, o sistema poderá efetuar o reconhecimento da placa, e não será perdida localização pelo fato da mesma ser obtida via sensor GPS. Assim, as informações serão armazenadas localmente no dispositivo, e postas em uma fila para transmissão ao servidor de banco de dados remoto. Quando a rede celular estiver disponível novamente, os arquivos serão transferidos pelo dispositivo. Mesmo por um longo período sem disponibilidade de rede, o sistema continuará fazendo leitura de placas veiculares e obtendo sua localização juntamente com o tempo em que ocorreram (até o limite de

armazenamento do dispositivo, no caso o que foi utilizado no sistema proposto, este possui um cartão de 64 Gigabytes).

A seguir estão listadas vantagens de se usar uma *Raspberry Pi* como nó de computação no trabalho proposto:

- Um dispositivo flexível que suporta vários sistemas operacionais (entre eles, várias distribuições Linux e Windows)
- Uma capacidade de expansão de memória de armazenamento superior a 64 GB (dependendo do cartão SD usado)
- Processador Broadcom BCM2837, que inclui 4 processadores de 64 bits ARM Cortex-A53 operando a 1,53 GHz
- GPU Videocore IV, com clock de 400 MHz
- Quatro portas USB, 40 pinos GPIO para interface
- Suporte para linguagens de programação C / C ++, Python e Java
- fonte de alimentação 5V, o que também facilita a conexão a células solares ou baterias
- Pode ser executado em modo de servidor, como um servidor web, lidando com inúmeras solicitações.

O objetivo do sistema é que apenas instituições de segurança pública autorizadas tenham acesso à visualização das placas reconhecidas pelo sistema. Os dados coletados serão transmitidos criptografados sentido à nuvem para armazenamento e análise. Uma abordagem focada em segurança e privacidade de dados não será o foco deste trabalho. A Fig. 3 apresenta um diagrama do contexto de aplicação do sistema.

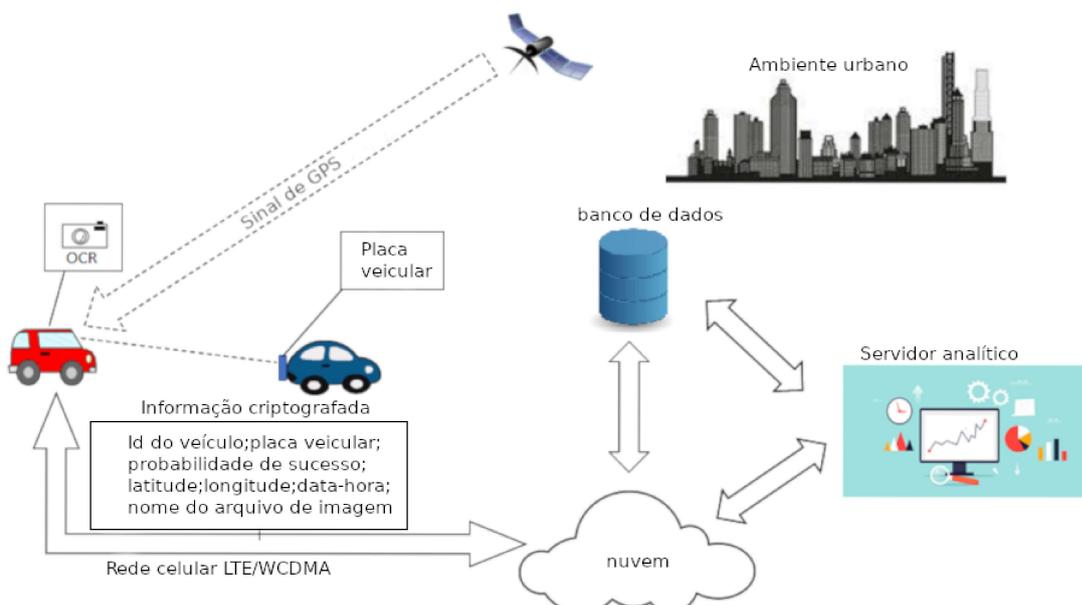


Figura 3 – Diagrama do contexto de aplicação do sistema.

O elemento central do sistema é um Raspberry Pi 3 Modelo B, sob o qual o sistema operacional Raspbian OS é executado. Este será o elemento central do sistema, sendo responsável por executar as rotinas de software relacionadas a localização, visão computacional e transmissão de dados. A Fig. 4 mostra a arquitetura implementada no elemento central do sistema.

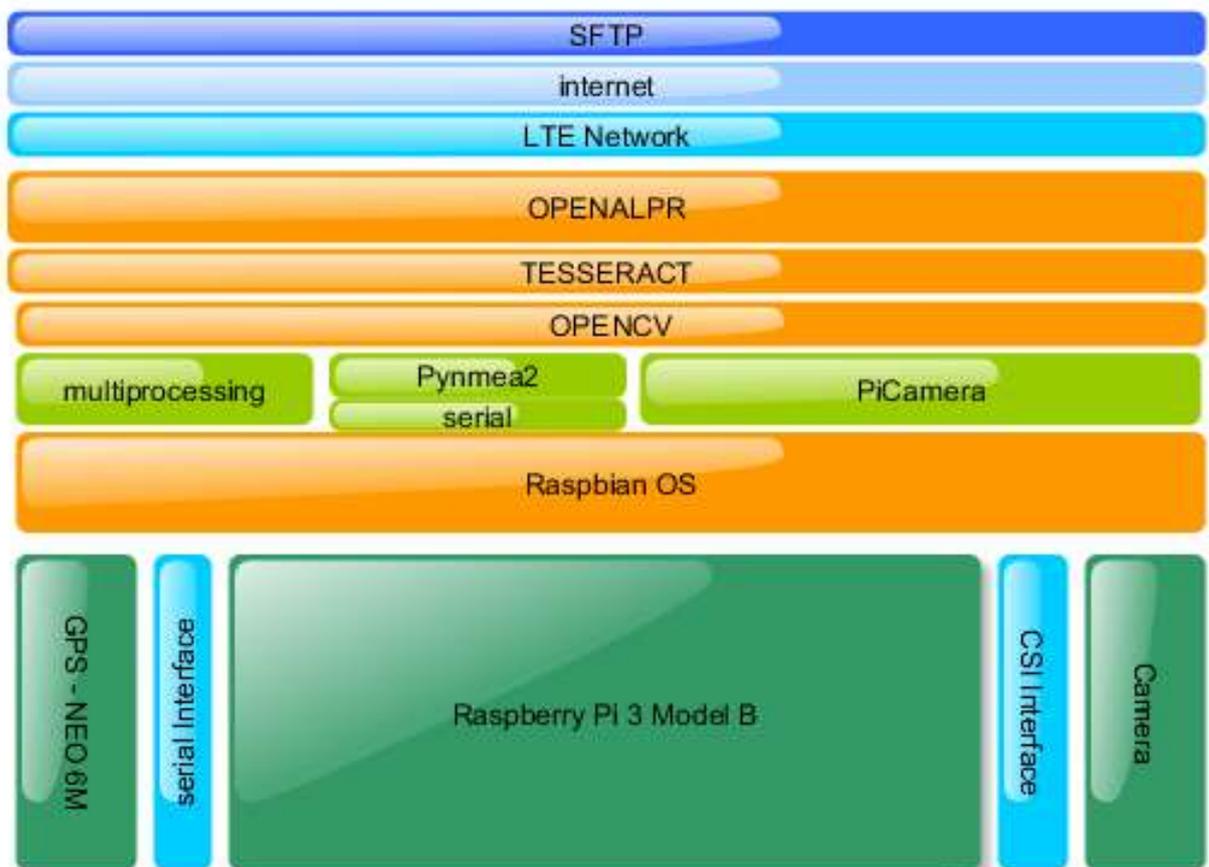


Figura 4 – Arquitetura do nó de computação

Os elementos que compõem o hardware são os seguintes:

- Raspberry Pi 3 Modelo B: Um Hardware SBC responsável por fornecer os recursos computacionais necessários para o OCR e transmissão para a nuvem.
- GPS - NEO 6M: Hardware responsável pela comunicação GPS. Ele é conectado ao Raspberry Pi 3 através de uma interface Serial e a aquisição de dados de GPS é feita através da biblioteca Python Pynmea2.
- Câmera: Hardware para aquisição de imagens. Ela está conectada ao Raspberry Pi 3 por meio de uma interface CSI. As imagens obtidas pela câmera são gerenciadas através da biblioteca Python PiCamera.
- Multiprocessamento: Uma biblioteca Python com suporte a multiprocessamento foi utilizada para controlar o processo de reconhecimento das placas veiculares.

- OpenCV: uma biblioteca Open Source com centenas de algoritmos de visão computacional. A qual foi utilizada pelo OpenALPR nas tarefas de visão computacional.
- Tesseract: Uma biblioteca que realiza o OCR.
- OpenALPR: Uma biblioteca de código aberto para reconhecimento automático de placas de veículos escrita em C++ com API's para C#, Java, Node.js, GO e Python. Esta biblioteca analisa imagens e vídeos e identifica placas veiculares. Como resultado da análise, tem-se a representação em texto dos caracteres da placa veicular. O OpenALPR tem como base o OpenCV e o Tesseract.
- Internet: A internet será acessada pelo sistema através de uma rede celular LTE, através de um smartphone com função de roteador habilitada.
- SFTP: Protocolo de Transferência de Arquivos SSH. Ele fornecerá um canal seguro para transmissão de arquivos contendo informações de placas de veículos para o banco de dados na nuvem.

3.2 Implementação do sistema

O sistema foi criado para capturar imagens de placas de veículos em um ambiente urbano e transmiti-las para armazenamento em um servidor analítico na nuvem. Para isso, necessita de software dedicado para processamento de imagens, reconhecimento de caracteres e transmissão de informações com segurança. O sistema tem sua estrutura baseada na arquitetura mostrada na Fig. 4, que atuará no cenário apresentado pela Fig. 3.

3.2.1 Desenho do hardware

Como pode ser visto na Fig. 5, o nó central de processamento é um Raspberry Pi 3 Modelo B, que possui uma câmera olho de peixe de cinco megapixels, CCD: 1/4“ conectada via interface CSI e resolução máxima de 2592 x 1944 pixels.

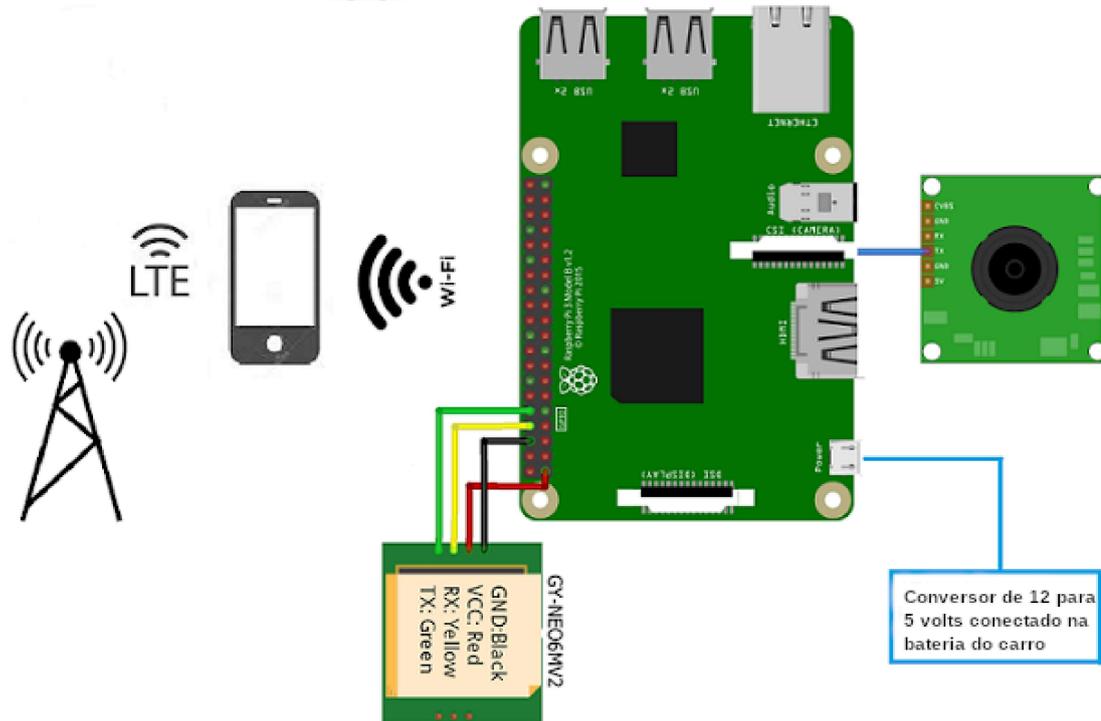


Figura 5 – Conexão dos elementos de hardware.

O custo do elemento central é mostrado na Tabela 1.

Tabela 1 – Custo do elemento central.

Item	Custo
Raspberry pi 3 Modelo B (1 GB de RAM)	\$ 80,00
Raspberry Pi Camera	\$ 19,00
Fonte de alimentação do carro 12V a 5v	\$ 12,00
GSP Module Neo-6M	\$ 12,00

3.2.2 Software

O principal componente de software do sistema é o OpenALPR, que realiza o OCR das placas dos veículos. Este é baseado nas bibliotecas OpenCV e Tesseract, rodando sob o sistema operacional Raspbian (FOUNDATION, 2020). Para a operação do OpenALPR, foram instaladas as seguintes dependências: OpenCV na versão 2.4.8 e Tesseract na versão 3.0.4. Abaixo está um diagrama do fluxo lógico executado pelo sistema representado na Fig 6.

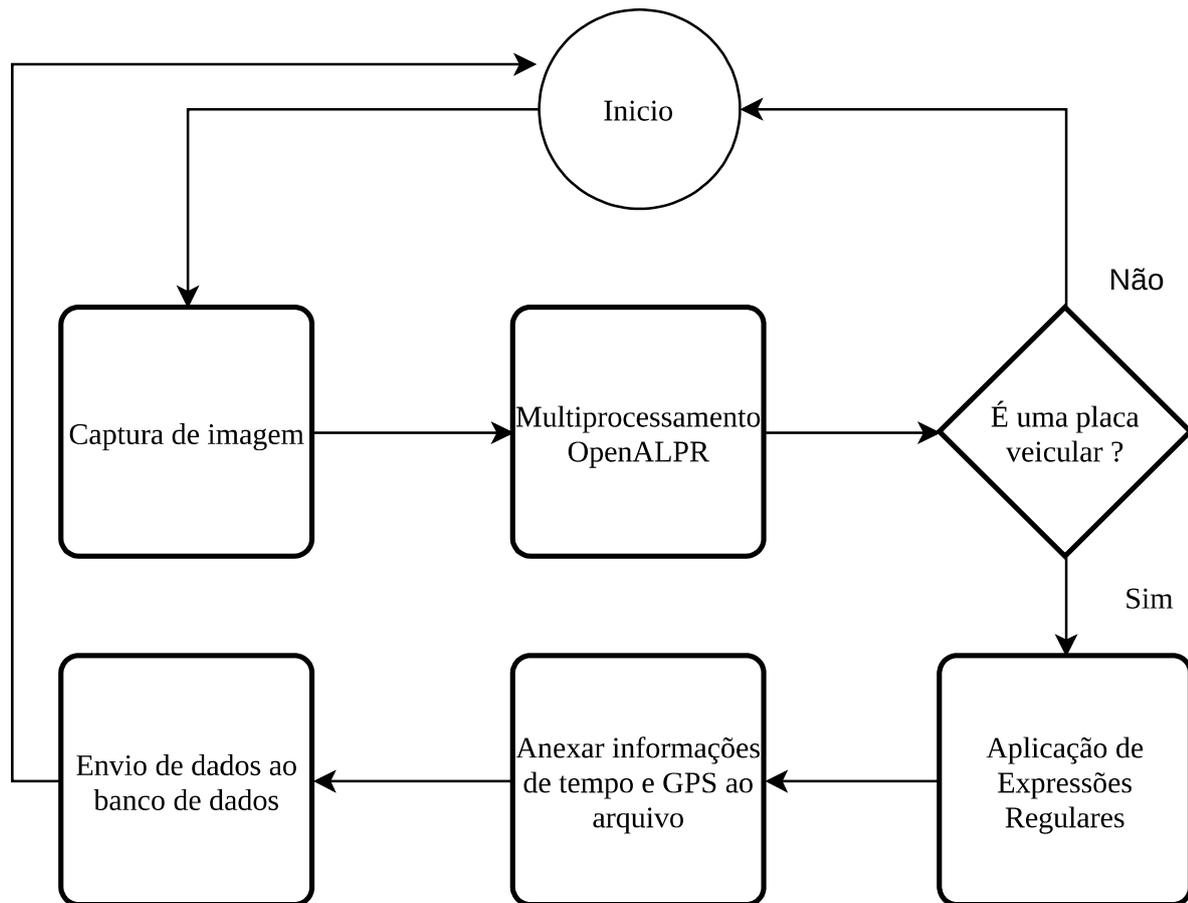


Figura 6 – Fluxo de software.

Quando o sistema é ligado, inicia-se um loop que captura quatro imagens em sequência, através da câmera acoplada ao Raspberry Pi. Estas imagens são submetidas a processos em paralelo rodando OpenALPR, através da biblioteca de multiprocessamento utilizada no software python que gerencia o fluxo da Fig. 6. A biblioteca de multiprocessamento possibilita processar as quatro imagens obtidas inicialmente em paralelo, fazendo uso dos quatro núcleos do processador ARM Cortex-A53 do Raspberry Pi para executar os processos OpenALPR. Durante o loop de captura da imagem, o parâmetro ISO da câmera, que controla a sensibilidade da câmera à luz, é configurado de acordo com o horário atual, conforme mostrado na Tabela 2. Valores ISO baixos implicam baixa sensibilidade, enquanto valores altos são usados para condições de baixa iluminação (JONES, 2021). Os valores adotados na Tabela 2 foram obtidos empiricamente durante testes práticos.

Outro parâmetro trabalhado no sistema é a velocidade do obturador da câmera. A velocidade do obturador é limitada pela taxa de quadros (frames por segundo - fps), na qual uma velocidade do obturador inferior a $1/\text{fps}$ não é possível. Uma velocidade lenta do obturador deixa os objetos alvo em movimento com uma aparência desfocada. Para evitar o desfoque, é ideal ter um tempo de captura do obturador inferior a 0,001 segundo para aplicações de tráfego livre (ANAGNOSTOPOULOS, 2014). Dessa forma, um tempo

de captura do obturador longo, a imagem fica borrada, enquanto, para uma velocidade de obturador rápida, a imagem fica mais congelada, trazendo clareza na presença de um objeto em movimento, porém os sensores captam menos luz, o que pode propiciar uma baixa relação sinal ruído. Assim, durante o período em que não há mais sol, o obturador é mantido aberto por mais tempo, para que seja possível capturar mais iluminação e visualizar as placas veiculares. Durante o dia, ele fica próximo ao inverso da taxa de quadros, pois há muita iluminação e os alvos estão quase sempre em movimento.

Após a captura das imagens, se alguma placa foi reconhecida, ou seja, segue o padrão alfanumérico das Placas no padrão brasileiro conforme mostrado na Fig. 7 e Fig. 8, as informações de data e hora (obtidas a partir do sistema) e GPS (obtidas a partir do hardware de GPS) são adicionadas às informações da placa veicular e então encaminhadas com segurança para o servidor remoto.

Tabela 2 – Configuração ISO da câmera.

	06:00 > Hora > 19:00	18:00 < Hora <= 19:00	18:00 >= Hora >= 06:00
ISO	400	300	60



Figura 7 – Novo modelo de placa brasileira (INFRAESTRUTURA, 2020b).



Figura 8 – Modelo antigo de placa brasileira (INFRAESTRUTURA, 2020a).

A informação é transmitida ao servidor remoto em formato de arquivo texto, protegido pelo protocolo SFTP. Este arquivo é mantido no Raspberry Pi até que a transmissão SFTP ocorra com sucesso, caso contrário, novas tentativas de envio são feitas em intervalos regulares até que sejam bem sucedidas conforme o diagrama da Fig. 9.

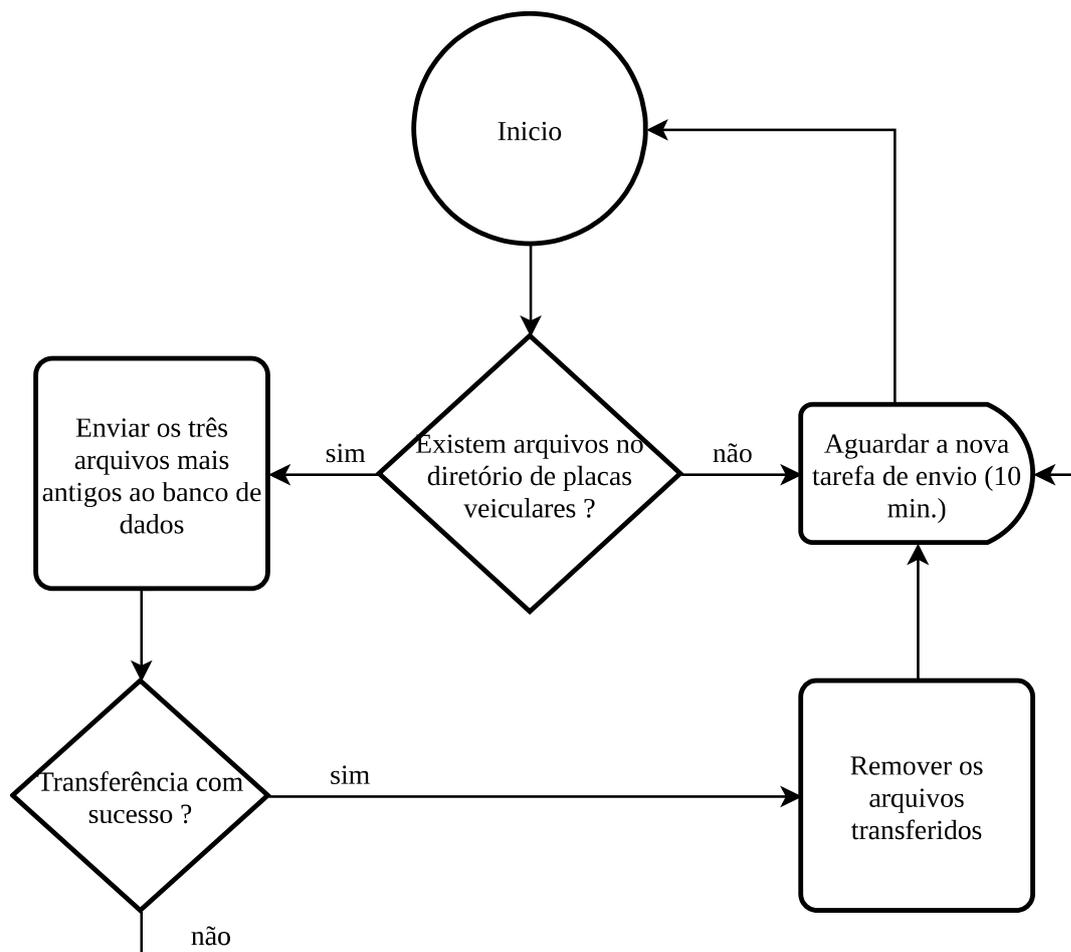


Figura 9 – Fluxograma de transmissão de arquivos.

O hardware proposto, que pode ser visualizado na Fig. 10, é acoplado ao retrovisor do veículo de testes. O veículo possui 1474 mm de altura e 3892 mm de comprimento. O hardware tem uma leve inclinação em direção ao solo, cerca de 18 graus, portanto a distância até o veículo da frente que fornece uma imagem com qualidade adequada fica entre 2 a 5 metros, como pode ser visto na Fig. 11 e Fig. 12. Um detalhe observado durante os testes foi de que os pinos da GPIO da Raspberry Pi, em presença de luz, produziam um brilho na imagem após a captura, o que causava diminuição na taxa de sucesso durante o reconhecimento da placa. Para contornar o problema os pinos foram revestidos com tecido preto fosco afin de retirar o brilho causador de ruído na imagem.

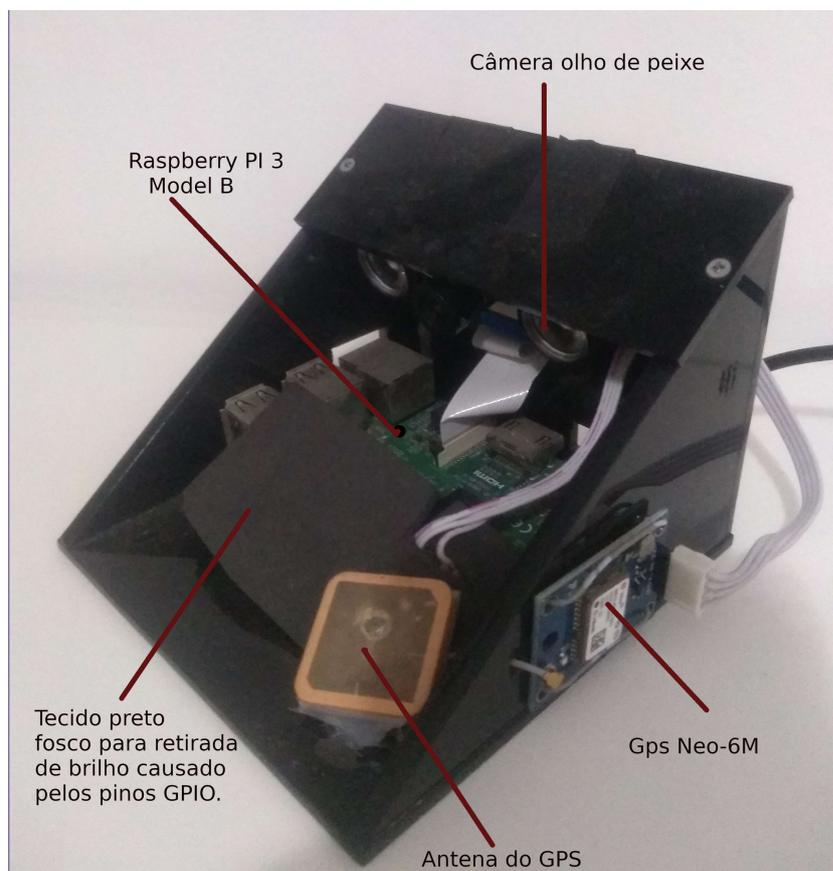


Figura 10 – Hardware de computação central.



Figura 11 – Vista do hardware conectado à visão traseira do veículo de teste.

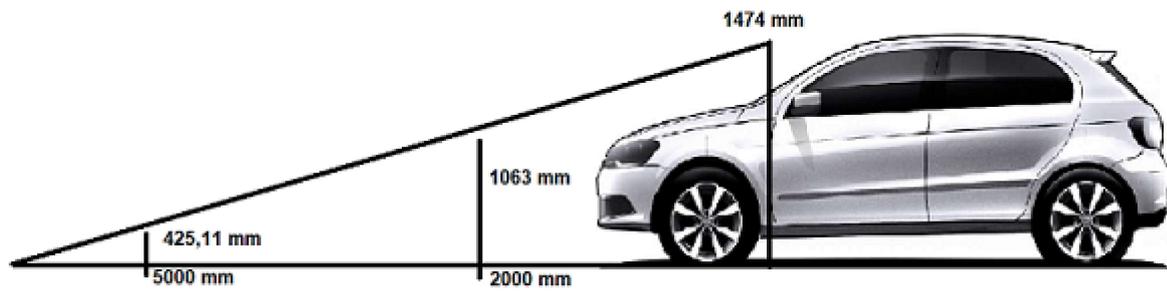


Figura 12 – Angulo de visão do hardware para captura de imagem.

4 Testes e Resultados

4.1 Testes Práticos

Para validar a implementação do sistema, o mesmo foi submetido a um percurso de teste em ambiente urbano. A rota escolhida foi entre as cidades de Serra e Vitória no estado do Espírito Santo, conforme mostrado na Fig. 13 destacando a rota em azul. O percurso foi realizado entre 07:30 e 08:30 da manhã, do dia 27 de fevereiro de 2022. Um horário com alto fluxo de veículos. O dia estava claro e com poucas nuvens.

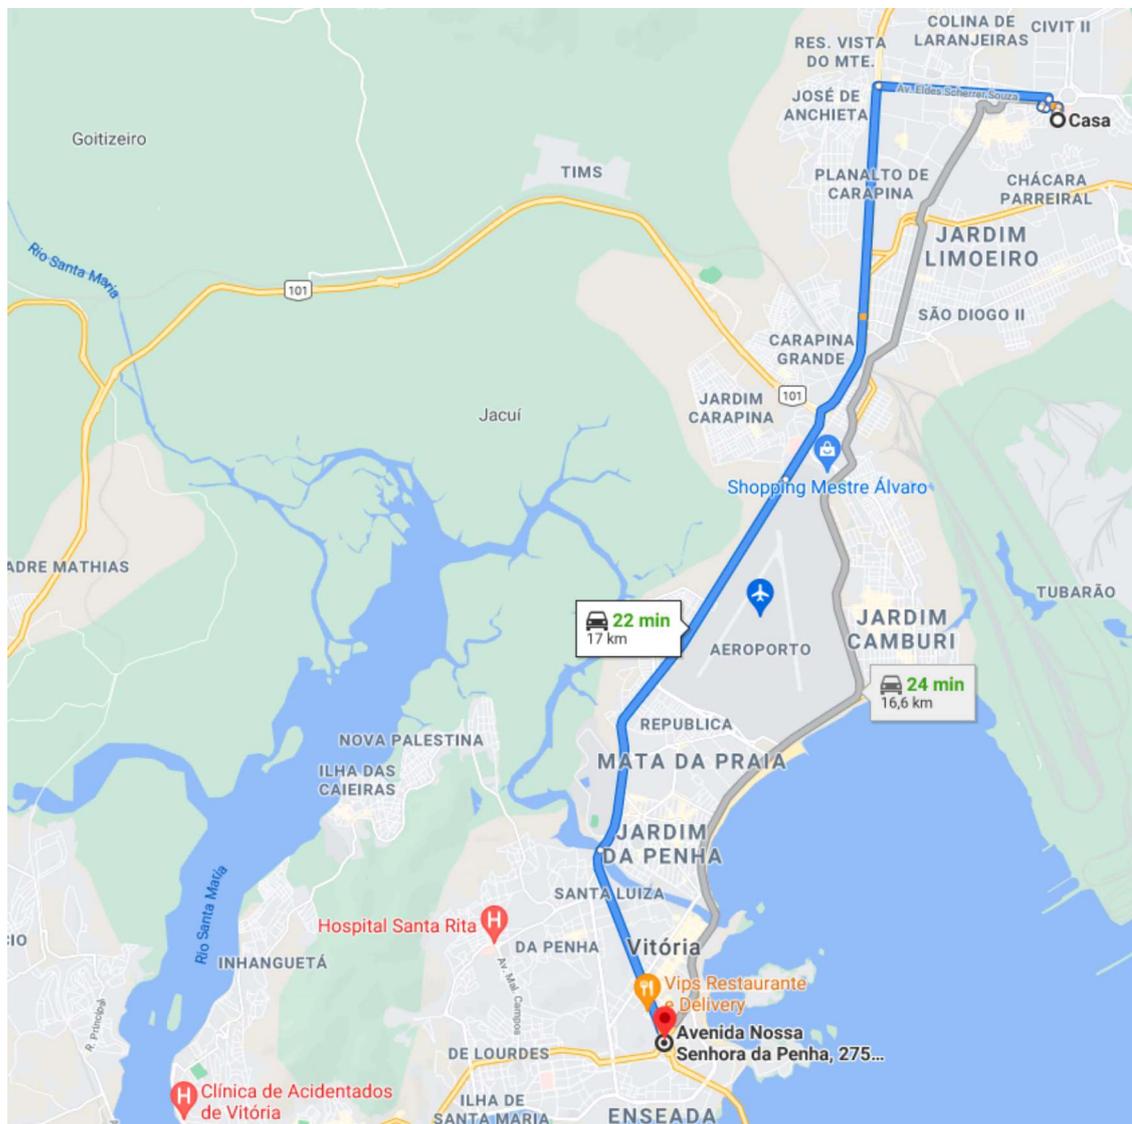


Figura 13 – Caminho de teste (caminho azul).

O percurso corresponde a 17,3 quilômetros entre as cidades de Serra e Vitória. Devido ao fluxo de veículos, o tempo gasto no trajeto foi de 32 minutos e 34 segundos.

Durante essa jornada, foram capturadas 280 imagens, das quais em 51 foi possível localizar e reconhecer uma placa veicular através do OpenALPR, ou seja, o fluxo de software mostrado na Fig. 6 ocorreu na condição de sucesso, chegando à etapa de aplicação da expressão regular aos caracteres retornados pelo software OpenALPR. As imagens às quais não tiveram sucesso no reconhecimento pelo OpenALPR, são descartadas pelo sistema para que seja liberado espaço de armazenamento para as novas imagens que chegarão. Por esse motivo, não foi feita uma avaliação humana se seria possível identificar mais de 51 imagens com conteúdo útil.

As imagens capturadas têm resolução de 1280 x 720 pixels com tamanho médio de 900KB. Na execução do teste, observou-se que o tempo necessário para o fluxo completo descrito na Fig. 6 varia de 4 a 7 segundos, ou seja, o intervalo de tempo entre capturas de, no máximo, 7 segundos. Lembrando que a cada execução são tiradas quatro imagens em sequência e então submetidas a quatro processos OpenALPR rodando em cada um dos núcleos da Raspberry Pi 3. A Tabela 3 mostra o número de placas reconhecidas com o respectivo intervalo de velocidade no momento da captura da imagem.

Tabela 3 – Faixa de velocidade em que as placas foram reconhecidas.

	0 a 20 km/h	20 a 40 km/h	40 a 60 km/h	Acima de 60 km/h
Quant. placas reconhecidas	46	4	1	0

O gráfico da Fig. 14 mostra os dados apresentados na Tabela 3 ao longo do tempo. É possível observar com que velocidade o veículo monitor capturou a imagem de uma placa que foi reconhecida pelo sistema.

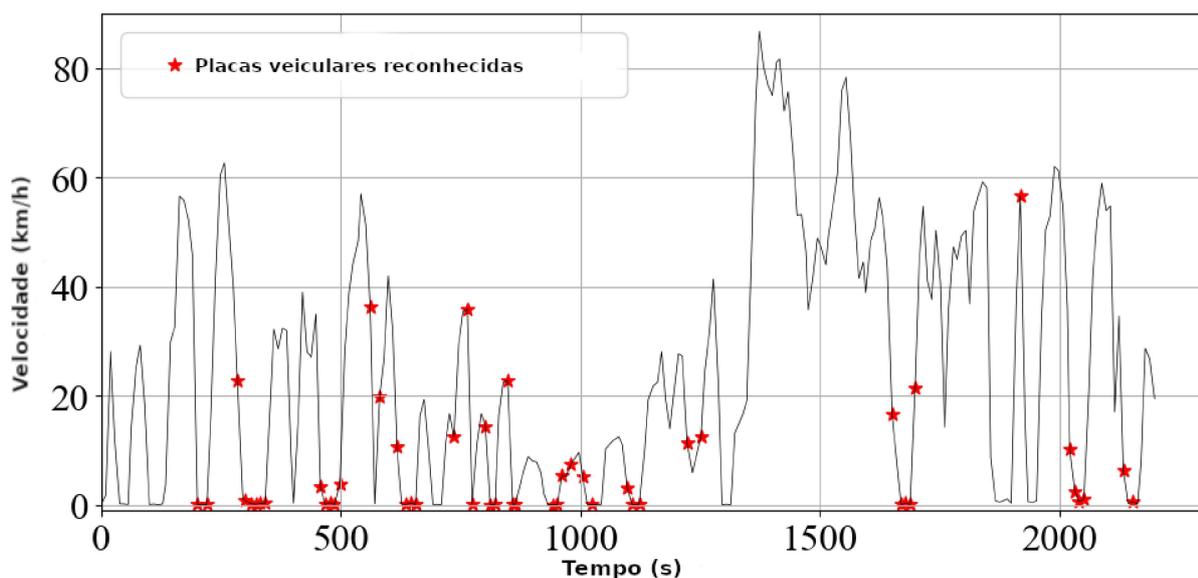


Figura 14 – Velocidades do veículo monitor durante a captura de imagens das placas veiculares reconhecidas pelo sistema.

De forma simplificada a Fig. 15 resume a Fig. 14. As figuras demonstram que a maior densidade de capturas de placas veiculares com seu respectivo reconhecimento ocorreu em baixas velocidades. A limitações da câmera e a velocidade de processamento do hardware são alguns dos fatores responsáveis por este cenário. A medida que a velocidade aumenta, menor o número de placas coletadas e reconhecidas com sucesso.

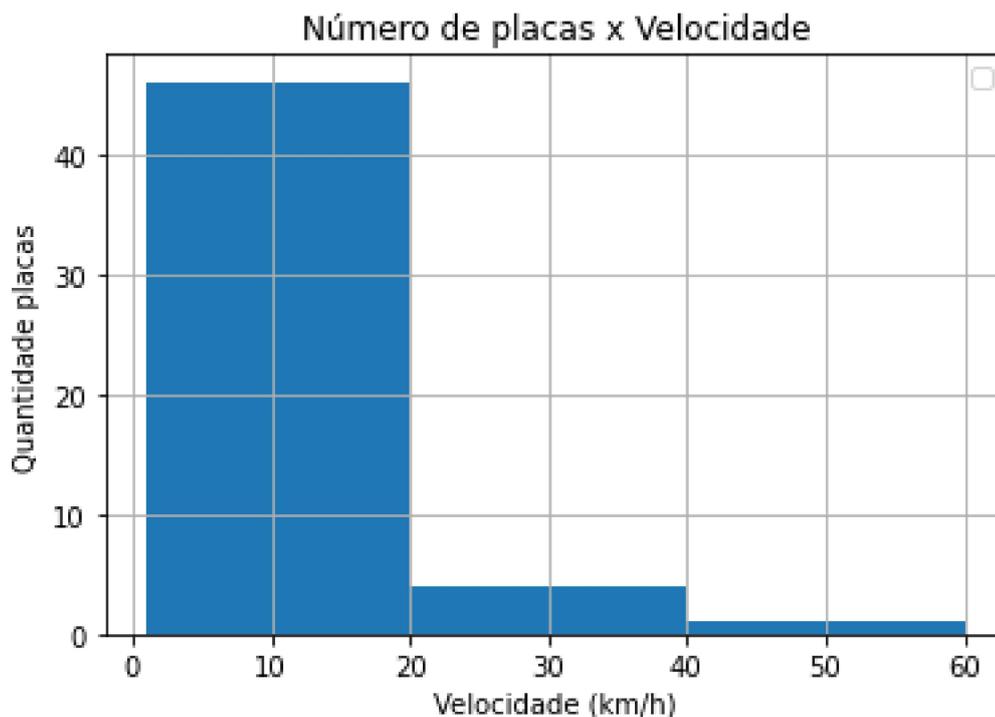


Figura 15 – Histograma que representa a quantidade de placas capturadas em um intervalo de velocidade.

Através da Fig. 14 é possível notar que os sucessos no reconhecimento das placas veiculares são alcançados em baixas velocidades. Em altas velocidades, ruídos como vibração (devido a irregularidades na rodovia e também devido a alta velocidade) e frequentes variações de iluminação causadas por sombras e reflexos de construções ao longo do percurso causam distorções da imagem onde piora a taxa de reconhecimento do sistema. Também em altas velocidades, adota-se uma distância maior que cinco metros do veículo da frente por questões de segurança, o que torna difícil o reconhecimento com sucesso da imagem da placa veicular. Ainda na Fig. 14 percebe-se que nos intervalos de velocidade superiores a 40 quilômetros por hora foi reconhecida somente uma placa. Tais trechos, onde essa velocidade foi alcançada e superada, caracterizam rodovias de trânsito rápido, o que não é o alvo deste trabalho. Por outro lado, percebe-se o sucesso de reconhecimento de placas veiculares onde a velocidade do veículo monitor encontrava-se abaixo de 20 quilômetros por hora, característica de ambientes urbanos onde o trânsito é concentrado além de inúmeros semáforos de controle de tráfego e faixas de pedestre (onde constantemente os carros param para dar preferência a passagem de pedestres). Este é o

cenário ideal no qual foi baseado o sistema. Como pode ser visto nos testes práticos, neste cenário a taxa de sucesso é maior.

Aprofundando ainda mais os resultados apresentados na Tabela 3 e Fig. 14, temos a Tabela 4.

Tabela 4 – Taxa de sucesso no reconhecimento das placas veiculares.

	Modelo novo de placa	Modelo antigo de placa
Placas coletadas	29 (56,86%)	22 (43,14%)
Placas reconhecidas corretamente	27 (93,10%)	20 (90,9%)
Caracteres reconhecidos corretamente	201 (99,01%)	152 (98,70%)
Caracteres reconhecidos incorretamente	2 (0,99%)	2 (1,3%)

Na Tabela 4, é possível avaliar o desempenho do OpenALPR em atividade no sistema, o qual já encontra-se treinado para o uso nesta dissertação. Esta tabela foi montada observando cada imagem de placa manualmente a fim de avaliar se trata-se do padrão novo ou do padrão antigo, comparando também os caracteres reconhecidos pelo OpenALPR com os obtidos por inspeção visual. Todas as placas coleta durante este trabalho foram utilizadas exclusivamente para testes e avaliação dos resultados alcançados. A Tabela 4 mostra que o sistema pode reconhecer tanto as placas do padrão antigo quanto o atual, mostrado na Fig. 7 e Fig. 8. Nota-se também um maior índice de acertos de caracteres em placas veiculares no novo padrão. Isso ocorre porque, no padrão antigo, os caracteres “I” e “1” são representados pelo mesmo símbolo, o que também ocorre entre os caracteres “O” e “0”. Para tratar estes casos, foi proposto um pós processamento do resultado obtido pelo OpenALPR com base em expressões regulares. Comparando Fig. 7 e Fig. 8 eles diferem no terceiro caractere da direita para a esquerda, em que na placa antiga, esse caractere é um número, enquanto na nova placa, esta é uma letra. Desta forma, qualquer “1” ou “0” que apareça nos três dígitos mais à esquerda será substituído por “I” ou “O” respectivamente e se os dígitos “I” ou “O” aparecerem nas quatro posições mais à direita, exceto a terceira posição (se as placas antigas e atuais coincidirem) é substituída por “1” ou “0”, respectivamente. A Fig. 16 mostra a diferença entre os caracteres dos padrões de placas trabalhados pelo sistema.

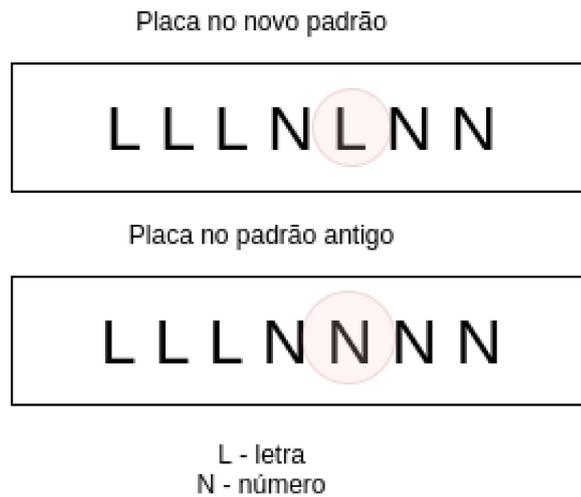


Figura 16 – Diferenças do posicionamento de caracteres dos padrões antigo e novo de placas veiculares brasileiro.

Caso as placas não passassem pelo pré-processamento para correção dos caracteres nas posições de números e letras conforme descrito acima, a Tabela 4 ficaria com os seguintes valores, conforme se observa na Tabela 5.

Tabela 5 – Taxa de sucesso no reconhecimento das placas veiculares sem pós processamento.

	Modelo novo de placa	Modelo antigo de placa
Placas coletadas	29 (56,86%)	22 (43,14%)
Placas reconhecidas corretamente	18 (62,07%)	20 (90,90%)
Caracteres reconhecidos corretamente	184 (90,64%)	150 (97,40%)
Caracteres reconhecidos incorretamente	19 (9,36%)	4 (2,60%)

Observando os dados da Tabela 5 percebe-se o ganho que foi obtido pelo sistema em aplicar o pós processamento ao comparar os dados com a Tabela 4.

Após a placa ser reconhecida, os dados a serem enviados ao servidor remoto são gravados em arquivo e armazenados localmente na Raspberry Pi 3. Atualmente, o sistema está configurado para enviar três arquivos de imagem (foto da placa), cada um com seu respectivo arquivo de texto contendo o texto da placa reconhecida, latitude, longitude, data, hora, identificação do veículo que capturou a placa e probabilidade de acerto do mesmo (OpenAlpr emite esta probabilidade ao reconhecer uma placa) a cada 10 minutos. Desta forma, a cada 10 minutos, seis arquivos no total serão transferidos para o servidor remoto. A Fig. 17 mostra o volume do fluxo de dados do percurso de teste nos 30 minutos iniciais.

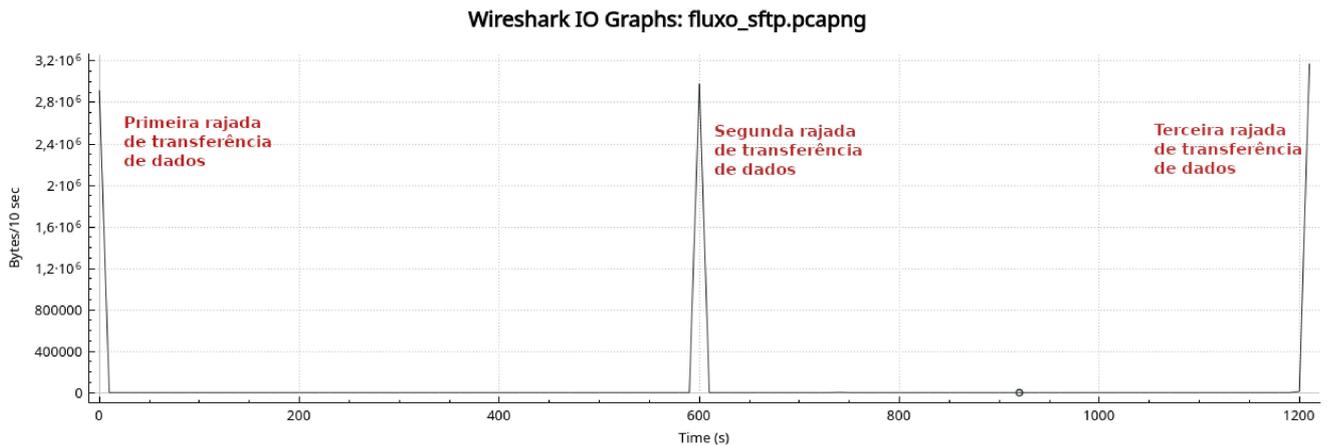


Figura 17 – Fluxo de envio de dados do Raspberry Pi para a nuvem.

Cada arquivo texto com, as informações de localização e tempo, possui em média 70 bytes e seu respectivo arquivo de imagem cerca de 900 Kilo Bytes. Na Fig. 18 é possível visualizar a estrutura do arquivo de texto que segue para a nuvem.



Figura 18 – Estrutura do arquivo com informações de localização e tempo.

Após transferir os arquivos para o servidor remoto e armazenar as informações em um banco de dados MYSQL, é possível, com credenciais autorizadas, realizar pesquisas de placas no servidor remoto, conforme mostrado na Fig. 19.

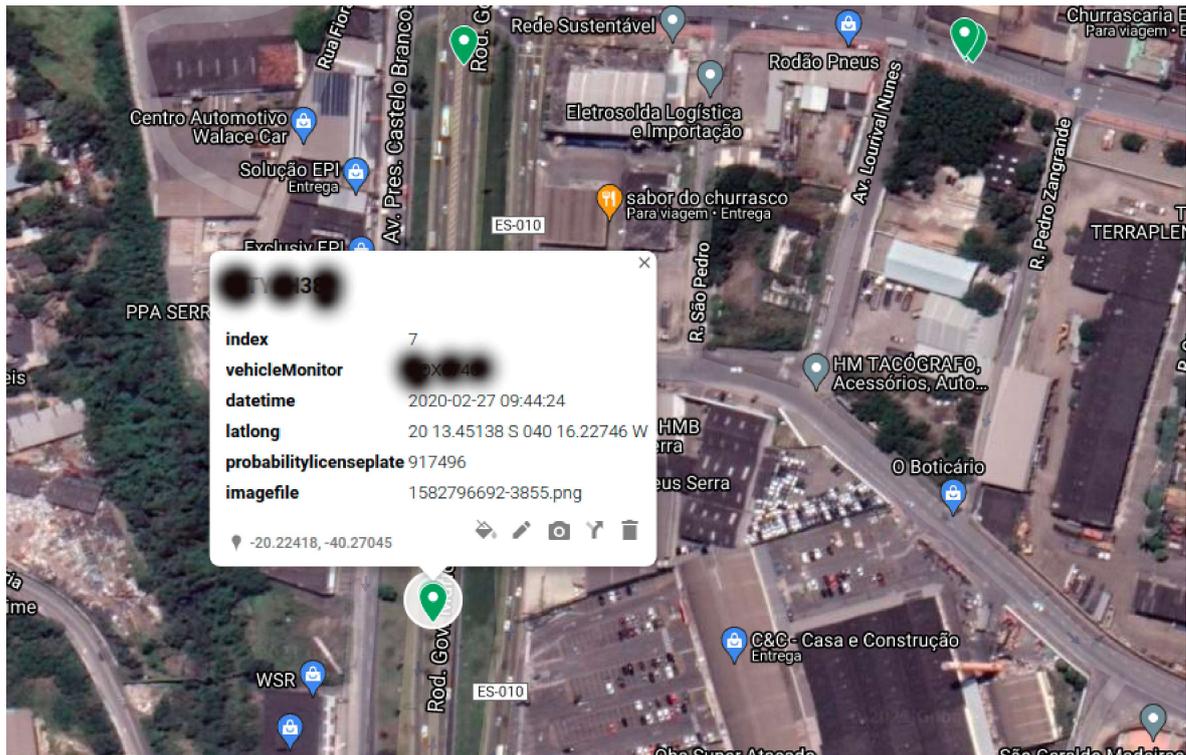


Figura 19 – Resultado da busca de placas no banco de dados.

As posições de latitude e longitude de onde foi obtida a imagem da placa marcam um ponto no mapa, que contém as informações de captura, juntamente com o nome do arquivo de imagem, caso seja necessária alguma consulta. Como exemplo, na Fig. 20, foi aberto o arquivo de imagem mostrado na Fig. 19, o que demonstra o reconhecimento correto do sistema (todos os caracteres foram reconhecidos corretamente, apenas omitidos para razões de privacidade).



Figura 20 – Imagem do veículo junto a placa obtida pelo sistema.

5 Considerações Finais

A implementação de um sistema IoT de baixo custo aplicado no contexto de vigilância inteligente foi apresentada nesta dissertação. Os resultados obtidos nos testes práticos demonstraram o potencial do sistema para realizar o monitoramento de placas de veículos em áreas urbanas, principalmente com a implementação da etapa de pós processamento, a qual permitiu um ganho de 31,03% na taxa de acerto de placas veiculares do novo padrão, garantindo assim maior confiabilidade ao sistema. Este sistema possui um custo relativamente baixo comparado aos sistemas com infraestrutura de câmeras fixas e estrutura computacional para análise e reconhecimento de placas centralizado existentes atualmente.

Através do sistema proposto, os órgãos responsáveis pela segurança pública poderiam obter uma rede de monitoramento por um valor bem abaixo das estruturas computacionais centralizadas que realizam todo o trabalho de processamento e reconhecimento de imagens atualmente, não tendo que se preocupar com custos de instalação de câmeras fixas de alta resolução em locais estratégicos da cidade. Em termos de tecnologia de reconhecimento de imagem, este sistema não é aprimorado como em [29], que faz uso de técnicas sofisticadas como redes neurais convolucionais e redes LSTM, além do uso de hardware de última geração (NVIDIA TITAN GPU com 12 GB de memória) do ponto de vista do processamento de imagens. Este sistema possui como vantagem, a característica de ser escalável, a ponto de ter tantos pontos de monitoramento móvel coletando imagens e realizando seu reconhecimento que superariam as deficiências de reconhecimento de imagens não vistas em sistemas sofisticados.

Outra característica relevante do ponto de vista da IoT é a de processamento local de dados, que otimiza o uso dos recursos da rede diminuindo, assim, a sobrecarga do servidor remoto no caso de um sistema centralizado. Esse recurso torna o sistema capaz de operar em redes de baixa taxa de dados sem sobrecarregá-lo. Este sistema, aliado a sistemas fixos legados para monitoramento inteligente, pode trazer capilaridade para a estrutura, proporcionando o monitoramento de áreas isoladas não alcançadas por sistemas de câmeras fixas. Assim, veículos restritos limitados a essas áreas poderiam ser alcançados.

Como proposta para trabalhos futuros, o uso de hardware que possibilite uma transferência da matriz de imagem obtida da câmera para o SBC mais rápida, além da possibilidade de uso de GPU para acelerar nas tarefas de processamento. Tais evoluções possibilitariam um ganho no tempo de resposta do sistema tornando a aplicação ainda mais eficiente. Uma alternativa para este propósito seria o NVIDIA Jetson ([CORPORATION., 2022](#)), porém trata-se de um investimento muito maior que uma Raspberry Pi 3 utilizada

nesta dissertação. A exploração de novos meios de comunicação de rede como dispositivos LoRa (*long range*) seria uma nova possibilidade para o sistema. Redes LoRa vem ganhando destaque atualmente com finalidade de suportar dispositivos de IoT com restrições de energia (dispositivos LoRa consegue transmitir e receber dados com um consumo muito baixo de energia). O uso desta tecnologia seria uma alternativa à rede celular, ou mesmo uma rede redundante. A medida que as cidades inteligentes forem se tornando uma realidade, gateways LoRa estarão disponíveis e espalhados por toda a área urbana permitindo o transporte de dados de IoT como o praticado nesta dissertação com a rede celular. O uso de uma câmera mais apropriada, com alta definição e mecanismos de correção de estabilidade, proporcionariam ao sistema maior sucesso durante as capturas de imagens. O aumento de velocidade deixaria de ser um obstáculo para o sistema ao proporcionar baixa taxa de reconhecimento de placas, trazendo robustez ao sistema e expandir sua capacidade de monitoramento também a rodovias de velocidades elevadas e não somente a ambientes urbanos cheios de pontos de retenção de tráfego.

Em termos de software, algoritmos mais evoluídos como redes neurais convolucionais poderiam ser uma opção para substituição do openALPR com o OCR utilizado nesta dissertação, e para isso, deve-se ter um suporte de hardware à altura como o NVIDIA Jetson (CORPORATION., 2022). Na etapa de testes de campo, uma parceria com uma empresa que possua uma frota de veículos seria de grande valor, pois o sistema realmente seria avaliado como uma rede móvel composta por vários elementos rastreadores.

Referências

- ADEBAYO, A. O.; CHAUBEY, M. S.; NUMBU, L. P. Industry 4.0: The fourth industrial revolution and how it relates to the application of internet of things (iot). *Journal of Multidisciplinary Engineering Science Studies (JMESS)*, v. 5, n. 2, 2019. Citado na página 12.
- AI, Y.; PENG, M.; ZHANG, K. Edge computing technologies for internet of things: a primer. *Digital Communications and Networks*, Elsevier, v. 4, n. 2, p. 77–86, 2018. Citado na página 6.
- AKPAKWU, G. A. et al. A survey on 5g networks for the internet of things: Communication technologies and challenges. *IEEE access*, IEEE, v. 6, p. 3619–3647, 2017. Citado na página 10.
- AL., R. S. et. *Tesseract-OCR*. 2021. (Acessed Apr. 11, 2021). Disponível em: <<https://www.opencv.org>>. Citado na página 14.
- ALBERTIN, A. L.; ALBERTIN, R. M. de M. A internet das coisas irá muito além as coisas. *GV EXECUTIVO*, v. 16, n. 2, p. 12–17, 2017. Citado na página 9.
- ANAGNOSTOPOULOS, C.-N. E. License plate recognition: A brief tutorial. *IEEE Intelligent transportation systems magazine*, IEEE, v. 6, n. 1, p. 59–67, 2014. Citado na página 22.
- ASLANPOUR, M. S. et al. Energy-aware resource scheduling for serverless edge computing. In: . [S.l.: s.n.], 2022. Citado na página 8.
- ATZORI, L.; IERA, A.; MORABITO, G. The internet of things: A survey. *Computer networks*, Elsevier, v. 54, n. 15, p. 2787–2805, 2010. Citado na página 9.
- BRAICOV, A. et al. Smart surveillance systems and their applications. In: SPRINGER. *EAI International Conference on Smart Cities within SmartCity360° Summit*. [S.l.], 2018. p. 179–187. Citado na página 5.
- BUSHOUSEN, E. Cloud computing. *Journal of Hospital Librarianship*, Taylor & Francis, v. 11, n. 4, p. 388–392, 2011. Citado na página 6.
- CORPORATION., N. *Jetson*. 2022. (Acessed Jul. 16 , 2022). Disponível em: <<https://www.nvidia.com/pt-br/autonomous-machines/embedded-systems/>>. Citado 2 vezes nas páginas 35 e 36.
- DONG, M. et al. A cnn-based approach for automatic license plate recognition in the wild. In: *BMVC*. [S.l.: s.n.], 2017. Citado na página 13.
- DORBE, N. et al. Fcn and lstm based computer vision system for recognition of vehicle type, license plate number, and registration country. *Automatic Control and Computer Sciences*, Springer, v. 52, n. 2, p. 146–154, 2018. Citado na página 15.
- DU, S. et al. Automatic license plate recognition (alpr): A state-of-the-art review. *IEEE*

Transactions on circuits and systems for video technology, IEEE, v. 23, n. 2, p. 311–325, 2012. Citado 2 vezes nas páginas 2 e 14.

FOUNDATION, R. P. *Raspbian*. 2020. (Acessed Dez. 03, 2020). Disponível em: <<https://www.raspberrypi.org>>. Citado na página 21.

GIANG, N. K. et al. Fog at the edge: Experiences building an edge computing platform. In: IEEE. *2018 IEEE International Conference on Edge Computing (EDGE)*. [S.l.], 2018. p. 9–16. Citado na página 8.

HAMPAPUR, A. et al. Smart surveillance: applications, technologies and implications. In: IEEE. *Fourth International Conference on Information, Communications and Signal Processing, 2003 and the Fourth Pacific Rim Conference on Multimedia. Proceedings of the 2003 Joint*. [S.l.], 2003. v. 2, p. 1133–1138. Citado na página 5.

HAYKIN, S. *Neural networks: a comprehensive foundation*. [S.l.]: Prentice-Hall, Inc., 1994. ISBN 0023527617, 9780023527616. Citado na página 15.

HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. *Neural computation*, MIT Press, v. 9, n. 8, p. 1735–1780, 1997. Citado 2 vezes nas páginas 14 e 15.

HSU, G.-S.; CHEN, J.-C.; CHUNG, Y.-Z. Application-oriented license plate recognition. *IEEE transactions on vehicular technology*, IEEE, v. 62, n. 2, p. 552–561, 2012. Citado na página 15.

INFRAESTRUTURA, M. da. *Resolução nº 241, de 22 de junho de 2007*. 2020. (Acessed Dec. 04, 2020). Disponível em: <https://www.gov.br/infraestrutura/pt-br/assuntos/transito/conteudo-contran/resolucoes/resolucao_contran_241.pdf>. Citado 2 vezes nas páginas 11 e 24.

INFRAESTRUTURA, M. da. *Resolução nº 729, de 06 de março de 2018*. 2020. (Acessed Dec. 04, 2020). Disponível em: <<https://www.gov.br/infraestrutura/pt-br/assuntos/transito/conteudo-contran/resolucoes/resolucao7292018consolidada.pdf/view>>. Citado 2 vezes nas páginas 11 e 23.

JONES, D. *API picamera*. 2021. (Acessed Dez. 03, 2021). Disponível em: <https://www.picamera.readthedocs.io/en/release-1.10/api__camera.html>. Citado na página 22.

JR, H. B. D. Cloud computing. *Judges J.*, HeinOnline, v. 51, p. 36, 2012. Citado na página 6.

KAUR, K. et al. Edge computing in the industrial internet of things environment: Software-defined-networks-based edge-cloud interplay. *IEEE communications magazine*, IEEE, v. 56, n. 2, p. 44–51, 2018. Citado na página 8.

LEE, I.; LEE, K. The internet of things (iot): Applications, investments, and challenges for enterprises. *Business horizons*, Elsevier, v. 58, n. 4, p. 431–440, 2015. Citado 2 vezes nas páginas 9 e 10.

MAO, Y. et al. A survey on mobile edge computing: The communication perspective. *IEEE Communications Surveys & Tutorials*, IEEE, v. 19, n. 4, p. 2322–2358, 2017. Citado na página 6.

- MARCONCINI, F. d. M.; SEGATTO, M. E. V.; SALLES, E. O. T. A low-cost smart surveillance system applied to vehicle license plate tracking. *Journal of Microwaves, Optoelectronics and Electromagnetic Applications*, SciELO Brasil, v. 21, p. 141–156, 2022. Citado na página 4.
- MARJANOVIĆ, M.; ANTONIĆ, A.; ŽARKO, I. P. Edge computing architecture for mobile crowdsensing. *Ieee access*, IEEE, v. 6, p. 10662–10674, 2018. Citado na página 6.
- MITROVIC, N. et al. On centralized and decentralized architectures for traffic applications. *IEEE Transactions on Intelligent Transportation Systems*, IEEE, v. 17, n. 7, p. 1988–1997, 2016. Citado na página 7.
- NAIR, S. et al. Image processing units on ultra-low-cost embedded hardware: Algorithmic optimizations for real-time performance. *Journal of Signal Processing Systems*, Springer, v. 90, n. 6, p. 913–929, 2018. Citado na página 17.
- NETO, A. J. et al. Fog-based crime-assistance in smart iot transportation system. *IEEE access*, IEEE, v. 6, p. 11101–11111, 2018. Citado na página 6.
- NIKOU EI, S. Y. et al. Decentralized smart surveillance through microservices platform. In: INTERNATIONAL SOCIETY FOR OPTICS AND PHOTONICS. *Sensors and Systems for Space Applications XII*. [S.l.], 2019. v. 11017, p. 110170K. Citado na página 6.
- PI, R. *Raspberry pi 3 model b*. 2020. (Acessed Dez. 03, 2020). Disponível em: <<https://www.raspberrypi.org>>. Citado na página 17.
- PÚBLICA, M. da Justiça e S. *Criminalidade Cai no País em 2019*. 2021. (Acessed Mar. 14, 2021). Disponível em: <<https://www.justica.gov.br/news/collective-nitf-content-1563293956.35>>. Citado na página 1.
- RAO, P. P.; MUTHU, R. K. A new de-blurring technique for license plate images with robust length estimation. In: IEEE. *2017 International Conference on Intelligent Computing and Control (I2C2)*. [S.l.], 2017. p. 1–6. Citado na página 13.
- REN, J. et al. Collaborative cloud and edge computing for latency minimization. *IEEE Transactions on Vehicular Technology*, IEEE, v. 68, n. 5, p. 5031–5044, 2019. Citado na página 7.
- RIO-ALVAREZ, A. et al. Effects of challenging weather and illumination on learning-based license plate detection in noncontrolled environments. *Scientific Programming*, Hindawi, v. 2019, 2019. Citado na página 13.
- SANTAMARIA, A. F. et al. An iot surveillance system based on a decentralised architecture. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 19, n. 6, p. 1469, 2019. Citado 3 vezes nas páginas 5, 6 e 7.
- SHAFIQUE, K. et al. Internet of things (iot) for next-generation smart systems: A review of current challenges, future trends and prospects for emerging 5g-iot scenarios. *Ieee Access*, IEEE, v. 8, p. 23022–23040, 2020. Citado 3 vezes nas páginas 9, 10 e 11.
- SHASHIRANGANA, J. et al. Automated license plate recognition: a survey on methods and techniques. *IEEE Access*, IEEE, v. 9, p. 11203–11225, 2020. Citado na página 14.

- SHI, J. et al. A survey of cyber-physical systems. In: IEEE. *2011 international conference on wireless communications and signal processing (WCSP)*. [S.l.], 2011. p. 1–6. Citado na página 12.
- SHI, W.; DUSTDAR, S. The promise of edge computing. *Computer*, IEEE, v. 49, n. 5, p. 78–81, 2016. Citado na página 6.
- STANLEY, U. et al. Iot and 5g: The interconnection. *development*, v. 1, p. 2, 2018. Citado na página 9.
- SUN, J. et al. Learning a convolutional neural network for non-uniform motion blur removal. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2015. p. 769–777. Citado na página 13.
- SWARNALATHA, P. et al. Smart sensing network for smart technologies. In: *Applications of Artificial Intelligence for Smart Technology*. [S.l.]: IGI Global, 2020. p. 177–191. Citado na página 1.
- SYSTEMS, I. R. *OpenALPR*. 2020. (Acessed Jan. 11, 2020). Disponível em: <<https://www.openalpr.com>>. Citado na página 14.
- TEAM, O. *OpenCV*. 2021. Disponível em: <<https://www.opencv.org>>. Citado na página 14.
- TIAN, Y.-l. et al. Ibm smart surveillance system (s3): event based video surveillance system with an open and extensible framework. *Machine Vision and Applications*, Springer, v. 19, n. 5-6, p. 315–327, 2008. Citado na página 5.
- VITÓRIA, P. *Cerco Inteligente Móvel de Vitória*. 2021. (Acessed Jan. 12, 2021). Disponível em: <<https://www.vitoria.es.gov.br/noticias/noticia-41646>>. Citado na página 5.
- VITÓRIA, P. M. de. *Cerco Inteligente ajuda a solucionar crimes e reduz roubo de veículos em Vitória*. 2022. (Acessed Jan. 04, 2022). Disponível em: <<https://m.vitoria.es.gov.br/noticia/cerco-inteligente-ajuda-a-solucionar-crimes-e-reduz-roubo-de-veiculos-em-vitoria-34771>>. Citado na página 1.
- YU, W. et al. A survey on the edge computing for the internet of things. *IEEE Access*, PP, p. 1–1, 11 2017. Citado na página 8.
- ZOU, Y. et al. A robust license plate recognition model based on bi-lstm. *IEEE Access*, IEEE, 2020. Citado na página 15.