

**ANTT – Agência Nacional de Transportes Terrestres
RDT – Recurso de Desenvolvimento Tecnológico**

RELATÓRIO FINAL

PROJETO 13 - ANÁLISE DE VIABILIDADE DO USO DA TECNOLOGIA DE VISÃO COMPUTACIONAL NA RODOVIA BR-116 NO TRECHO SOB CONCESSÃO DA AUTOPISTA RÉGIS BITTENCOURT

Autopista Régis Bittencourt

13/04/2023

Sumário

1. DESCRIÇÃO DO PROJETO	4
1.1. Título:.....	4
1.2. Resumo:.....	4
1.3. Palavras-chave:.....	5
1.4. Justificativa:	5
1.5. Objetivos:	6
1.6. Organização do Trabalho:	7
1.7. Período de execução:.....	12
1.8. Cronograma de execução:	12
1.9. Local de execução:.....	13
1.10. Equipe executora:	13
2. MÉTODOS E TÉCNICAS UTILIZADAS.....	14
3. ETAPAS.....	15
3.1. ETAPA 0 – Adequação na Infraestrutura da rodovia	15
3.2. ETAPA 1 – Desenho da Solução e Preparação de Ambientes de Desenvolvimento e Infraestrutura Rodoviária.....	18
3.2.1. Atividade 1.1 - Setup de Ambientes de Desenvolvimento	18
3.2.2. Atividade 1.2 - Desenho de Solução	20
3.3. ETAPA 2 – Treinamento e Avaliação dos Modelos de Visão Computacional e Desenvolvimento de Algoritmos Auxiliares	21
3.3.1. Atividade 2.1 - Desenvolvimento Scripts Pré-Processamento	23
3.3.2. Atividade 2.2 - Integração Object Storage	23
3.3.3. Atividade 2.3 - Desenvolvimento Scripts Pós-Processamento.....	24
3.3.4. Atividade 2.4 - Iterações de Treinamento, Teste e Calibragem de Modelos.....	25
3.3.5. Atividade 2.5 - Desenvolvimento Dashboard Resultados	26
3.3.6. Atividade 2.6 - Validações e Testes de Integração.....	28
3.4. ETAPA 3 – UAT e Demonstração	28
3.4.1. Atividade 3.1 - Testes de Aceite e Demonstração.....	28
3.4.1.1. Período Diurno	28
3.4.1.2. Período Noturno	32
3.4.2. Atividade 3.2 - Estimativa Investimento da Implementação.....	38
3.5. ETAPA 4 – Análise de Viabilidade Técnica e Homologação Tecnológica.....	39
3.5.1. Atividade 4.1 - Preparação de Comparativo Técnico e Econômico entre as soluções.....	39
3.5.2. Atividade 4.2 - Requisitos Técnicos de integração CNSO.....	42
3.5.3. Atividade 4.3 - Estudos sobre impacto na Tarifa	43

3.5.4.Atividade 4.3 - Revisar Manuais/Procedimentos DNIT.....	43
3.6. ETAPA 5 – Relatório Final.....	43
3.6.1.Precisão de modelos e cálculos	43
4.CONCLUSÕES, CONSIDERAÇÕES E PRODUTOS GERADOS	45

1. DESCRIÇÃO DO PROJETO

1.1. Título:

Análise de viabilidade do uso da tecnologia de visão computacional na rodovia br-116 no trecho sob concessão da Autopista Régis Bittencourt.

1.2. Resumo:

O presente trabalho de pesquisa e desenvolvimento foi conduzido para descrever o planejamento, a solução desenhada, as atividades desempenhadas, os resultados e outras informações relevantes sobre a execução do PROJETO 13 - ANÁLISE DE VIABILIDADE DO USO DA TECNOLOGIA DE VISÃO COMPUTACIONAL NA RODOVIA BR-116 NO TRECHO SOB CONCESSÃO DA AUTOPISTA RÉGIS BITTENCOURT, no qual teve como seu principal objetivo a aplicação de tecnologias de inteligência artificial e analítica avançada em imagens de câmeras CFTV de monitoramento rodoviário a fim de analisar a viabilidade técnica do uso de tais tecnologias em substituição dos tradicionais contadores (SAT) baseados em sensores no pavimento da rodovia.

As equipes da Arteris Régis Bittencourt e IBM Brasil trabalharam entre os meses de dezembro de 2021 a fevereiro de 2022 na adequação da infraestrutura rodoviária e execução da solução proposta com imagens da câmera de CFTV instalada no KM 288 + 800 da rodovia Régis Bittencourt, trecho onde já existe um equipamento do tipo SAT instalado e que já coleta informações de volume e velocidade de veículos. No local também foi instalado um poste de iluminação artificial para facilitar a visualização e identificação dos veículos no turno da noite, para assim garantir a maior assertividade possível.

As imagens de tráfego obtidas nessa câmera foram compartilhadas e usadas para o treinamento de modelos de visão computacional para a identificação e categorização de veículos e subsequente aplicação de analítica avançada para a contagem de volume e medição de velocidade no trecho.

Os resultados dessas análises foram disponibilizados em um dashboard para consulta e comparação com os resultados obtidos no SAT instalado no mesmo trecho. Além do escopo pretendido, de maneira experimental, um modelo para a identificação de eixos de veículos comerciais foi treinado e testado a fim de analisar o caso de uso. As informações dessa experiência estão detalhadas na sessão 3.1 deste relatório e, quando aplicável, os resultados

serão evidenciados e discriminados entre o período diurno e noturno, para melhor explicação e entendimentos dos resultados obtidos.

1.3. Palavras-chave:

MVP (Mínimo Produto Viável), Inteligência Artificial, Deep Learning, Visão Computacional, Validação de Tecnologia.

1.4. Justificativa:

O setor de rodovias impulsionado pelas exigências e normativas da ANTT e buscando ganhos em segurança operacional, qualidade dos serviços e eficiência operacional, tem feito uso cada vez maior de novas tecnologias. Não obstante, observa-se a utilização ainda modesta de tecnologias digitais em processos mais tradicionais.

O projeto visa introduzir tecnologias digitais de “gerenciamento de tratativa de imagens” com uso de Inteligência Artificial e “Deep Learning” em processo rodoviários, neste primeiro momento mais especificamente no tocante a contagem de veículos por categoria e velocidade média, hoje realizados pelos sistemas SAT. O projeto não é apenas relevante para a engenharia rodoviária nacional, mas essencial para permitir maior agilidade, flexibilidade e controle para a ANTT e concessionárias para prover um serviço de melhor qualidade aos usuários.

A Autopista Régis Bittencourt opera um trecho da rodovia BR-116 com 402,6 quilômetros de extensão, entre São Paulo e Curitiba, desde 2008. Há, no trecho, 5 contadores de tráfego em operação, localizadas em trechos homogêneos da rodovia. Estes contadores hoje são todos baseados em sensoramento no solo, com a utilização de laços indutivos que sofrem muito desgaste assim como o próprio pavimento.

Os SATs, como são conhecidos esses contadores, possuem as seguintes funcionalidades: Contagem de veículos; Categorização do veículo, classificados em automóvel, moto ou comercial através da contagem de eixos; Captura do instante da passagem (data, hora, minutos, segundos); Comprimento total de cada veículo; Velocidade do veículo; Número da faixa da rodovia; Sentido da faixa (crescente ou decrescente em relação aos marcos quilométricos); Distanciamento entre eixos (tamanho total entre eixos, para definição de categoria); Número de Eixos (1 – moto/veículo passeio, 2 em diante comercial); Tipo da rodagem (simples, dupla ou tripla). Todas as informações acima, são agrupadas por faixa da rodovia e por bloco horário (15 minutos).

Considerando que o uso desta nova tecnologia visa interpretar imagens geradas por câmeras, sem nenhum requerimento óptico específico, permite que os pontos de monitoramento sejam mais facilmente implementados e mantidos, sem a interrupção do fluxo viário, pois não requer ações no pavimento; Com esta flexibilidade os pontos de monitoramento podem ser alterados com menor custo operacional; Futuramente, a função “pontos de monitoramento” pode ser implementada em outros pontos das rodovias em locais onde já existam câmeras, melhorando a análise e potencializando investimentos já realizados.

A análise digital por imagem permitirá um detalhamento maior do ponto de monitoramento, como contagem, tipo de veículo, velocidade viária. Considerando integrações e futuras expansões, a solução alavancará maior segurança para os usuários através da predição de velocidade a frente, por exemplo, e até mesmo integrar com empresas de uso frequente, como frotistas, provendo informações que possam ser de interesse da gestão destas empresas, ampliando o “ecossistema” de uma rodovia “digital e integrada”.

1.5. Objetivos:

Objetivo Geral

Analisar a viabilidade técnica e homologar com a Agência Nacional de Transportes Terrestres (ANTT) a utilização de solução baseada em tecnologias avançadas de Inteligência Artificial, Machine Learning, Deep Learning e Visão Computacional para substituição dos tradicionais contadores de tráfego (SAT), através do conceito de MVP (Mínimo Produto Viável) no qual se implementa uma solução com os requisitos mínimos para sustentar as análises de viabilidade técnica e impactos do uso de novas técnicas e tecnologias na operação de monitoramento de tráfego rodoviário. A identificação e validação será feita através da criação e identificação de *labels*. *Labels* são as caixas que o algoritmo forma em volta do veículo definindo em qual categoria ele se encontra.

Objetivos Específicos

São objetivos específicos desta pesquisa:

- Analisar a capacidade dos algoritmos de detecção de veículos na utilização de contagem de veículos, com intuito de capturar a volumetria de tráfego, a categoria dos veículos e demais requisitos mínimos de um contador de tráfego atualmente utilizado pela Autopista Régis Bittencourt.

- Realizar testes de utilização de tecnologia que possa contar os veículos que trafegam por determinada faixa da rodovia, categorizando-o como automóvel, moto ou comercial, determinar a velocidade e comprimento de cada veículo agrupando-os em blocos horários (15 minutos).
- Comparar os resultados obtidos com o uso da tecnologia de visão computacional contra os dados reais (SAT).
- Realizar estudo comparativo entre a nova tecnologia fruto desse plano de trabalho e a tecnologia utilizada atualmente na concessionária, trazendo na comparação desde o valor de investimento necessário para a aquisição do equipamento atual versus o investimento inicial para a montagem de um sistema completo baseado em visão computacional. Além disso, comparar os custos recorrentes gerados pela utilização de ambas as tecnologias (atual e nova abordagem) ao longo do tempo afim de avaliar o retorno de investimento e/ou redução de custos de operação. Uma vez identificados benefícios no emprego da nova tecnologia, calcular os impactos na tarifa da concessionária.
- Avaliar a interoperabilidade entre a nova tecnologia baseada em Visão Computacional com o CNSO da ANTT, identificando a forma ideal de se integrar o novo sistema com a demanda de coleta de informações da ANTT.

1.6. Organização do Trabalho:

Etapas

O projeto MVP será dividido em 5 etapas, que consideram:

0. Adequação da Infraestrutura Rodoviária
1. Desenho da Solução e Preparação de Ambientes de Desenvolvimento
2. Treinamento e Avaliação dos Modelos de Visão Computacional e Desenvolvimento de Algoritmos auxiliares
3. Testes de aceitação finais (UAT) e Demonstração
4. Análise de viabilidade de implantação de soluções de visão computacional nas concessões
5. Relatório Final

Todas as etapas serão descritas nos itens a seguir:

ETAPA 0 – Adequação na Infraestrutura da rodovia

A localidade escolhida para a realização dessa avaliação de tecnologia foi na Rodovia BR-116 (Régis Bittencourt), no Km 288+800, sentido Norte, onde atualmente está instalado o SAT 01 (ID 15 SIR ANTT) que monitora 2 faixas. A Autopista Régis Bittencourt instalou uma câmera dedicada para este fim (MVP) na mesma localização do SAT 01, de forma a simular o mesmo ponto de captura existente hoje e, também, não ter interferências na operação de uma câmera que hoje está destinada a monitorar outros eventos da rodovia. Além disso, marcações a cada 30 metros no pavimento do trecho de rodovia selecionado foram feitas para que fossem criados pontos de referência, a fim de auxiliar os cálculos de velocidade de veículo por imagens de vídeos. Toda esta preparação foi efetuada com recursos próprios da Autopista Régis Bittencourt, utilizando-se de material disponível na concessionária. Por se tratar de uma etapa preliminar ao projeto, não constará do cronograma físico-financeiro.

ETAPA 1 – Desenho da Solução e Preparação de Ambientes de Desenvolvimento e Infraestrutura Rodoviária

Previamente as equipes da Arteris e IBM já trabalharam em conjunto para desenvolver o desenho de solução do projeto MVP. Esse desenho foi definido para que a execução do projeto fosse efetuada de maneira rápida, dentro das características de um produto mínimo viável, sem complexidades de integração entre sistemas e utilizando um ambiente de execução 100% configurado em Cloud. Dessa maneira os dados de imagens de vídeos serão disponibilizados de maneira manual em um sistema compartilhamento de arquivos online (Box) e todo o ambiente de desenvolvimento do projeto estará no IBM Cloud, que contará com a plataforma para treinamento e execução de modelos de visão computacional e servidor para desenvolvimento de scripts auxiliares e integração de aplicações internas. Na primeira etapa, foi realizado um refinamento do desenho da solução previamente proposto, levando em consideração tanto as possíveis variáveis físicas (posicionamento de câmera, luminosidade, marcações na pista, bloqueios de visão etc.) como as possíveis variáveis lógicas (resolução de imagens, performance de servidores etc.) que possam influenciar a execução do projeto e seus resultados.

ETAPA 2 –Treinamento e Avaliação dos Modelos de Visão Computacional e Desenvolvimento de Algoritmos Auxiliares

A acurácia dos modelos de visão computacional para identificar, localizar e classificar objetos em imagens de vídeos é peça fundamental para o sucesso da execução do projeto e futura implantação da solução proposta. Desta maneira propôs-se a utilização da plataforma IBM Maximo Visual Inspection e suas capacidades para realizar o treinamento e refinamento destes modelos. Conforme mencionado anteriormente neste plano de trabalho, o treinamento de modelos poderá ser feito por usuários experientes, a exemplo de cientistas de dados que têm conhecimento sólido no ramo de aprendizado de máquinas, ou mesmo usuários que ainda não possuem prévio conhecimento nesse ramo tecnológico, mas que saibam e possam indicar o evento a ser treinado, como por exemplo, identificar quais tipos de veículos estão presentes nas imagens.

O treinamento de modelos de visão computacional é executado de maneira automática na plataforma e o usuário irá somente carregar o conjunto de imagens, rotulá-las (indicar com rótulos onde e qual objeto está presente no conteúdo da imagem) e selecionar o tipo de treinamento que melhor se adequa à situação, seja para classificação de imagens, identificação de objetos em imagens ou detecção de ações em vídeos. Ao final do treinamento, um modelo de visão computacional customizado estará disponível para ser implementado e executado na plataforma IBM Maximo Visual Inspection ou em qualquer outra plataforma aberta de processamento de imagens. Essa característica se dá ao fato de os modelos utilizarem algoritmos open source para seu treinamento, evitando assim um possível aprisionamento tecnológico (vendor lock-in). A execução das atividades de treinamento e refinamento dos modelos durante a etapa 2 do projeto se deu em distintas iterações, baseadas na metodologia Ágil e na prática de DevOps, onde trechos das imagens de vídeos da câmera da rodovia pré-selecionada foram utilizados para treinar, validar, otimizar, retreinar e validar novamente os modelos, até que estes chegassem na acurácia de identificação de elementos desejada. A função desses modelos de identificação de objetos em imagens dentro da solução foi de:

- Identificar e classificar qual o tipo de veículo, entre veículos de passeio, motocicletas, caminhões e ônibus, estão presentes nas imagens de vídeos;
- Identificar e localizar quais são as faixas da rodovia presentes na imagem (por exemplo em uma rodovia de 3 faixas: Faixa 1, faixa 2 e faixa 3 ou faixa da direita, faixa do meio e faixa da esquerda);
- Identificar os pontos de entrada e saída de determinado veículo na imagem de vídeo (utilizado para auxiliar os cálculos de velocidade média por imagem).

A fim de garantir uma maior fidelidade às métricas atualmente utilizadas nas concessões, foram utilizadas as gravações de imagens de vídeos para realizar o treinamento e execução dos modelos de visão computacional. Estas imagens foram compartilhadas pela equipe da Arteris via serviço de compartilhamento e extraídas e consumidas pela equipe IBM de maneira não integrada aos sistemas de armazenamento de vídeos atuais da Arteris. Por ser tratar de uma solução cujo objetivo é obter dados de volumetria de tráfego e velocidade média agregada de veículos através de imagens de vídeo, e não somente a pura identificação de objetos em imagens, será necessário, ainda dentro da etapa 2, o desenvolvimento de algoritmos complementares para que estes dados sejam disponibilizados e analisados no relatório final do projeto. Estes algoritmos, comumente chamados de scripts de pós-processamento, tiveram como objetivo:

- Contar o número de veículos por categoria em determinada faixa;
- Calcular a velocidade do veículo em determinada faixa;
- Agregar os dados analisados e gerar a contagem final de veículos por categoria, faixa e espaço de tempo e gerar a velocidade média geral por faixa e espaço de tempo.

Outras atividades fundamentais como o desenvolvimento de operações de pré-processamento para a integração e preparação dos dados para treinamento e inferência dos modelos no servidor da plataforma IBM Maximo Visual Inspection e o desenvolvimento de scripts para a integração e customização do Dashboard de Resultados. O Dashboard de Resultados, produto final deste projeto e essencial na condução das análises de viabilidade técnica da solução, apresenta um agregado das informações identificadas pelos modelos de visão computacional e complementados pelos algoritmos de cálculos matemáticos, onde os usuários poderão visualizar de forma fácil os resultados finais das análises das imagens de vídeos da rodovia.

Com estes dados em mãos, pode-se comparar os dados coletados pela nova tecnologia com os dados reais do SAT 01. Durante a etapa 2 do projeto MVP foi analisada a viabilidade de integração da solução proposta com a plataforma CNSO, verificando assim como será desenvolvida a interoperabilidade entre plataformas uma vez que seja feito uma possível implementação da solução. Seguindo o desenho de arquitetura do projeto MVP, os dados

contendo os resultados das análises inteligente de vídeo são disponibilizados no formato JSON em um banco de dados não relacional dentro do Cloud IBM.

ETAPA 3 – UAT e Demonstração

Após as iterações de desenvolvimento e validação dos modelos e algoritmos, esta etapa previu a realização de testes de aceitação e demonstrações internas dos resultados da aplicação da solução em gravações de vídeos do trecho de rodovia pré-selecionado para a equipe da Arteris. Além disso, essa etapa foi utilizada para realizar ajustes finais, na interface do Dashboard dos resultados. Todos os modelos treinados e algoritmos desenvolvidos durante o projeto de MVP, assim como os resultados do processamento de imagens, foram disponibilizados para a Arteris como parte do produto final do projeto MVP. Nela também foi desenvolvida uma estimativa preliminar do investimento necessário para a implementação da Solução na Rodovia selecionada para o MVP, desenvolvida em conjunto pela IBM e Arteris.

Este plano de trabalho previu a entrega de um Mínimo Produto Viável, que após homologação e validação pela ANTT possa virar um produto completo a ser implantado em toda a concessionária Autopista Régis Bittencourt e se tornar um padrão para o segmento de concessões no Brasil. Diante da aprovação do MVP, pode-se iniciar uma fase 2 onde se pode trabalhar com alguns cenários:

- Implantação completa do novo modelo computacional, baseado na experiência do MVP para a concessionária Autopista Régis Bittencourt, para todos os pontos de SAT hoje existentes.
- Estudo de novas abordagens de visão computacional, como por exemplo, detecção automática de eventos e automação dos processos de acionamento para apoio da operação do Centro de Controle Operacional da concessionária.

ETAPA 4 – Análise de Viabilidade Técnica e Homologação Tecnológica

Nessa fase é onde se prevê que a Autopista Régis possua os insumos necessários para comparar os custos de implantação e de manutenção da nova tecnologia em relação à tecnologia em uso atualmente para a contagem de veículos. Com o levantamento comparativo em mãos, foi possível avaliar possíveis impactos na tarifa da concessionária. Além da validação técnica e econômica, uma vez evidenciado a aplicabilidade da nova solução, avaliar a revisão de manuais e procedimentos do DNIT em relação ao uso de tecnologia computacional na contagem de veículos. Com base nas análises dos resultados da execução dos modelos de visão

computacional e algoritmos complementares e nas observações realizadas durante o desenvolvimento do projeto, foi possível validar e discutir a implementação de uma solução baseada na tecnologia de visão computacional no trecho pré-selecionado, considerando variáveis como:

- Acurácia dos resultados obtidos através da solução de Vídeo Analytics versus os resultados obtidos pelo sistema atual (SAT);
- Discussão sobre o uso de tecnologias passivas que podem substituir tecnologias intrusivas e que afetam o dia a dia das operações rodoviárias;
- Viabilidade de implementação da solução em outros trechos da concessão escolhida e em demais concessões administradas pela Arteris. Esta última etapa de projeto tem como objeto principal apresentar os resultados da execução do projeto MVP no trecho de rodovia elegido e buscar a homologação para o uso da tecnologia proposta junto a ANTT.

ETAPA 5 – Relatório Final

Desenvolvimento e relatório final do contendo todos os elementos, análises, desafios e lições aprendidas durante o desenvolvimento do projeto MVP.

1.7. Período de execução:

O período de execução do presente projeto de pesquisa e desenvolvimento foi de 15 de novembro de 2021 a 17 de Fevereiro de 2022. Inicialmente a data de início do projeto estava prevista para a primeira semana de Novembro, o que fez com que o projeto terminasse duas semanas após o programado inicialmente.

1.8. Cronograma de execução:

O cronograma de execução do presente projeto está apresentado na Tabela 01.

Etap a	Atividade	Período de execução - Meses													
		nov/21				dez/21				jan/22				fev/22	
		1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	ETAPA 1: Desenho da Solução e Preparação de Ambientes de Desenvolvimento e Infraestrutura Rodoviária			X	X										
2	ETAPA 2: Treinamento e Avaliação dos Modelos de Visão				X	X	X	X	X	X					

	Computacional e Desenvolvimento de Algoritmos Auxiliares																
3	ETAPA 3: UAT e Demonstração									X	X						
4	ETAPA 4: Análise de Viabilidade Técnica e Homologação Tecnológica											X	X	X			
5	ETAPA 5: Relatório Final																X

Tabela 1 - Cronograma de atividades no desenvolvimento do projeto

1.9. Local de execução:

O trabalho foi desenvolvido nos escritórios da IBM no Brasil e na Índia, com supervisão e apoio da equipe da Arteris S.A. e Autopista Régis Bittencourt. Com aplicação em Loco no KM 288 + 800 da rodovia Régis Bittencourt.

1.10. Equipe executora:

Identificação da Equipe Executora da IBM

Nome	Área de Atuação	Categoria/Função	CPF/ID	Empresa
Caio Augusto Ribas Padula	Consultoria de Transformação Digital e I4.0	Consultor Especial / Líder Técnico	351.223.098-92	IBM
Raghu Ramaswamy	Consultoria de Transformação Digital e I4.0	Consultor Especial / Arquiteto de Solução	912079744	IBM
Gurumoorthy Krishnasamy	Desenvolvimento de Aplicações Inteligentes (AI)	Consultor Especial / Líder de Desenvolvimento e Testes	000A5I744	IBM
Hiran K Hari	Desenvolvimento de Aplicações Inteligentes (AI)	Consultor Especial / Desenvolvedor de Aplicação	04268H744	IBM
Mradula Singh	Desenvolvimento de Aplicações Inteligentes (AI)	Consultor Especial / Desenvolvedor de Integrações	01927X744	IBM
Manasi Dhekane	Suporte a Sistemas Cognitivos	Consultor Especial / Especialista Visão Computacional	0296B7744	IBM

Leandro Consentino Ruiz	Suporte a Sistemas Cognitivos	Consultor Especial – Cientista de Dados	310.512.568-01	IBM
-------------------------	-------------------------------	---	----------------	-----

Identificação da equipe responsável pelos Vídeos de Monitoramento de Tráfego

Nome	Área de Atuação	Função	Empresa
José Acácio Delmonego Júnior	Operações	Gerente	Arteris Autopista Régis Bittencourt

Identificação da equipe de supervisão da Autopista Régis Bittencourt e Arteris S.A

Nome	Área de Atuação	Função	Empresa
Doracy Augusto da Costa	Sistemas /Manutenção	Coord. Regional de Implantação	Arteris Autopista Régis Bittencourt
Márcio Rogério de Lima	Tecnologia	Gerente Projetos e Sustentação de Aplicações	Arteris

Obtenção das Informações sobre Requisitos de Interoperabilidade com a CNSO:

Nome	Área de Atuação	Função	Empresa
Doracy Augusto da Costa	Sistemas/ Manutenção	Coord. Regional de Implantação	Arteris Autopista Régis Bittencourt
Márcio Rogério de Lima	Tecnologia	Gerente Projetos e Sustentação de Aplicações	Arteris

2. MÉTODOS E TÉCNICAS UTILIZADAS

Métodos e Técnicas Utilizadas

- Área experimental escolhida no KM 288 + 800 da rodovia Régis Bittencourt, trecho onde já existe um equipamento do tipo SAT instalado e que já coleta informações de volume e velocidade de veículos.
- Desenvolvimento de script para a extração, armazenamento e transferência das imagens de vídeos compartilhadas a plataforma IBM Maximo Visual Inspection;
- Desenvolvimento de script para “quebra” das imagens de vídeos em distintos trechos;
- Desenvolvimento de script para o consumo, via API, dos trechos de vídeos e inferência dos modelos de visão computacional treinados.
- Desenvolvimento de algoritmo para tracking de objetos por frame de vídeo;

- Desenvolvimento de algoritmo com fórmulas matemáticas para a contagem de objetos identificados em imagens, cálculos de velocidade de objetos e agregação de cálculos;
- Desenvolvimento de script para o armazenamento e envio de resultados;
- Imagens de vídeos serão consumidas para a realização do treinamento e para a execução dos modelos de visão computacional;
- Elaboração de Dashboard Analítico, com contagem de veículos por categoria e faixa da concessão em um determinado espaço de tempo e a velocidade média agregada dos veículos por faixa de concessão em um determinado espaço de tempo.

3. ETAPAS

3.1. ETAPA 0 – Adequação na Infraestrutura da rodovia

Conforme mencionado no item 1.6, a câmera disponibilizada pela Arteris na rodovia Régis Bittencourt KM288+800 estava na posição lateral e muito próxima de um equipamento SAT no mesmo trecho. A câmera foi estrategicamente instalada neste ponto, junto aos sensores do SAT, a fim de utilizar os dados do equipamento atual em comparação aos resultados apresentados pela aplicação de vídeo analítica para contabilizar e medir a velocidade dos veículos na rodovia.

O projeto foi realizado com a câmera instalado na posição lateral devido rapidez da instalação e conexão do equipamento sem afetar os usuários da rodovia, mesmo entendendo que uma câmera posicionada no eixo da rodovia pudesse trazer mais assertividade nas contagens, esse se mostrou eficiente e retornou um alto índice de acertos, bem como ampliando as possibilidades para contagem de eixos, e provavelmente uma melhor acuracidade no cálculo e velocidade, conforme veremos mais adiante neste relatório.



Figura 1 – Posicionamento da câmera de monitoramento

Para que seja possível calcular a velocidade de veículos através de imagens de vídeos é sempre necessário ter pontos de referência nas imagens para que os objetos sejam identificados e rastreados durante a passagem no ponto de interesse. Essas referências podem ser digitais ou físicas onde a última é sempre indicada devido a maior precisão no cálculo final. Por esse motivo foi necessário que a equipe de operações da Arteris demarcasse o pavimento com faixas de 10cm, com um espaçamento de 30cm em um trecho de 20 metros, cobrindo a área das duas faixas da rodovia.

Com as faixas desenhadas no solo foi possível estabelecer a zona de interesse para cálculo de volume e velocidade de veículos por faixa.

Cabe reforçar, que não se viu a necessidade de revisão de normas ou manuais do DNIT vigentes, visto a pouca interferência na via quanto aos dispositivos necessários para efetuar as classificações.



Figura 2 - Linhas desenhadas no solo do KM288+800




Figura 3 - Linhas digitais desenhadas sob linhas físicas

3.2. ETAPA 1 – Desenho da Solução e Preparação de Ambientes de Desenvolvimento e Infraestrutura Rodoviária

3.2.1. Atividade 1.1 - Setup de Ambientes de Desenvolvimento

A arquitetura de solução do projeto piloto foi desenhada levando em consideração um cenário de desenvolvimento de um produto mínimo viável (MVP) cujo seu principal objetivo foi de realizar uma prova de viabilidade técnica do uso da visão computacional aplicada a um cenário real de monitoramento de tráfego e comparar seus resultados aos da atual tecnologia em uso. Desta maneira, a arquitetura proposta foi simplificada contendo apenas elementos chave para a execução ágil do projeto piloto, excluindo integrações com sistemas ou bases de dados da Arteris Régis Bittencourt ou de terceiros.




Figura 4 - Arquitetura de Solução Projeto Piloto

Para o projeto piloto os seguintes componentes de solução e arquitetura foram utilizados:

- Câmera IP de vigilância - Fabricante Intelbras modelo VIP 1130B – Resolução 1 megapixels (720p). Sensor de imagem 1/2.7” 1 megapixels
 - Progressive CMOS
 - Obturador eletrônico Automático
 - Manual: 1/3s ~ 1/100.000s
 - Pixels efetivos 1280 (H) × 720 (V)
 - Iluminação mínima 0,1 lux/F2.0 (Colorido, 1/3s, 30IRE)
 - 0 lux/F2.0 (IR ligado)
 - Relação sinal-ruído >50 dB

- Controle de ganho Automático/Manual
- Balanço do branco Auto / Natural / Externo Automático / Exterior / Manual / Personalizado
- Compensação de luz de fundo BLC/ HLC/ DWDR (60dB)
- Perfil Dia & Noite Automático (ICR) /Colorido/ Preto e Branco
- Instância da solução Box para compartilhamento de arquivos entre Arteris e IBM, incluindo trechos de gravações de monitoramento de tráfego rodoviário;
- Banco de dados IBM Cloud Object Storage 1TB: Armazenamento dos vídeos de monitoramento de tráfego compartilhados pela equipe Arteris via BOX (file sharing).
- Servidor IBM Maximo Visual Inspection no IBM Cloud versão 8.3 com 10 GPUs para executar o treinamento e inferência de modelos de visão computacional (identificação de tipos de veículos e faixas na pista)
- Máquina Virtual no IBM Cloud configurada com 16 vCPUS, 32GB RAM, 100GB com Ubuntu versão 18.04 para a execução de tarefas de pré-processamento (conversão de vídeos em frames para inferência de modelos), tarefas de pós-processamento (processamento de resultados da inferência, cálculos de volume e velocidade e gravação no banco de dados), filewatcher e integração com dashboard.
- Instância do dashboard de analytics Grafana (open source) para a visualização dos resultados da inferência de analítica avançada.




Figura 5 - Arquitetura de Solução Projeto Piloto – Visão Funcional

3.2.2. Atividade 1.2 - Desenho de Solução

Conforme mencionado anteriormente, o desenho de arquitetura foi elaborado para acelerar a execução do projeto MVP, minimizando a complexidade para o acesso aos dados disponibilizados. Desta maneira o fluxo de dados acontece da seguinte forma:

1. Câmera de vídeo posicionado no KM 288+800 da rodovia BR-116 grava o tráfego rodoviário e armazena no banco de dados da solução Digifort.
2. Equipe Arteris acessa a solução Digifort e extrai trechos dos vídeos armazenados e os disponibiliza a IBM, de maneira manual, via solução de compartilhamento de vídeo BOX.
3. Através de um File Watcher os vídeos são identificados, extraídos e armazenados no banco de dados Object Storage da IBM.
4. Em um primeiro momento os vídeos armazenados são utilizados para o treinamento e refinamento dos modelos de visão computacional para a identificação da categoria de veículos e identificação das faixas da rodovia. Essa etapa somente é executada no início do projeto ou quando existe uma demanda para refinamento (re-treinamento) de um modelo já existente ou um novo modelo para identificação de novos objetos nas imagens de vídeos.
5. Uma vez que o modelo de identificação de veículos está treinado e com precisão desejada, os trechos de vídeos descarregados na pasta de compartilhamento serão convertidos em imagens (frames).
6. O modelo treinado para a identificação de veículos será inferido em cada imagem (frame) do vídeo compartilhado.
7. Os resultados da inferência do modelo serão enviados ao servidor para a aplicação dos scripts de análise avançada para que seja feito o tracking, contagem e medição de veículos por faixa.
8. Finalmente os resultados da aplicação dos scripts de análise avançada são agregados e disponibilizados para consulta via dashboard.




Figura 6 - Arquitetura de Solução Projeto Piloto – Fluxo de Dados visão High-level

3.3. ETAPA 2 –Treinamento e Avaliação dos Modelos de Visão Computacional e Desenvolvimento de Algoritmos Auxiliares

No projeto enviado originalmente a Arteris propôs a utilização de imagens de 25 dias de tráfego rodoviário que entregariam aproximadamente 600 horas para realizar o treinamento. No decorrer do projeto foi feita uma análise de assertividade do projeto e descobriu-se que o algoritmo alcançava um alto índice de assertividade com 10 horas de treinamento, chegando próximo de 100% de acertos. O gráfico abaixo trás essa informação:




Figura 7 – Gráfico mAP 1

O indicador “mAP” (*Mean Average Precision*) retorna a % de uma classe conseguir ser identificada corretamente nos frames e o “Avg Loss” (*Average Loss*) são os erros que o modelo comete durante as detecções e, para fins de desenvolvimento tecnológico, o projeto é aceitável quando o *Average Loss* é inferior a 2%. Como observado no gráfico o algoritmo atinge índices bem elevados, chegando e permanecendo estável após 7.200 interações. Essas interações são o algoritmo aprendendo a diferenciar as categorias entre si (carros, motos e caminhões). Portanto com esse número alcançado após o treinamento, podemos afirmar que sempre que o algoritmo detectar um objeto ele irá acertar sua categoria aproximadamente 99,5% das vezes.

Outro motivo para não se usar esse alto número proposto anteriormente foi o princípio de *Overlearning/Overtraining*, que ocorre quando uma inteligência artificial é treinada muitas vezes no mesmo ambiente. Neste caso, por exemplo, ao identificar veículos de dia e de noite, ela tende a “viciar” nesse cenário e quando aplicada em um outro tipo ambiente, na neve por exemplo onde os carros podem ter seu formato alterado devido acúmulo de neve e a visibilidade também é alterada, o algoritmo estará tão “preso” ao formato que aprendeu que terá dificuldade de se adaptar e reconhecer.

A importância de se atentar ao princípio citado acima é evidenciada no gráfico abaixo, onde a inteligência foi testada com vídeos no período do entardecer (entre 17h e 18h) onde está começando a escurecer, mas ainda há luz.




Figura 7 – Gráfico mAP 2

Na “Figura 6 – Gráfico mAP 1” a inteligência foi treinada com vídeos do entardecer e amanhecer, mas ao inserirmos novos cenários, como de noite, o algoritmo rapidamente aprende e volta aos seus altos padrões de eficiência, coisa que não aconteceria caso ele continuasse sendo treinado de forma exaustiva com um só cenário.

3.3.1. Atividade 2.1 - Desenvolvimento Scripts Pré-Processamento

Para o projeto piloto foi utilizada a plataforma Maximo Visual Inspection para treinar e executar um modelo de identificação de veículos de acordo com as categorias estabelecidas: Carros, motos e veículos comerciais. Para isso foi utilizado o algoritmo YOLO para demarcar os objetos.

Para o treinamento diurno deste modelo foram coletadas 7503 imagens base. O modelo final obteve uma acuracidade de 95% e um IoU, importante métrica onde é medida a área de intersecção entre o objeto demarcado (ground truth) e o objeto previsto pelo modelo, de 77%.

Já para o treinamento noturno foram coletadas 15.056 imagens onde 12.154 foram utilizadas como treinamento e 2.902 para a validação do programa. De todas as imagens coletadas 48,4% são veículos de passeio, 43,7% são veículos comerciais, 7,9% são motos e do universo total 12,9% das observações foram feitas durante a chuva. Nesse período se obteve uma acuracidade de 98% e um IoU de 79,39%.

Além disso vale destacar o alto valor atingido em outras métricas importantes para a validação de modelos visão computacional como Precisão e Recall, respectivamente valoradas em 96% e 97% para o período diurno e 98% e 99% para o período noturno. Diferentemente da métrica de acuracidade, onde é medida a capacidade de performance do modelo sobre toda a amostragem, a métrica de Precisão calcula a capacidade do modelo em classificar uma amostra como positiva, calculando quantos verdadeiros positivos são encontrados em amostras positivas, sejam elas verdadeiras ou falsas. Já a métrica de Recall calcula a capacidade do modelo de encontrar uma amostra positiva, calculando quantas amostras verdadeiras positivas foram encontradas em verdadeiras positivas e falsos negativos.

3.3.2. Atividade 2.2 - Integração Object Storage

No projeto, foi feita a utilização de um Object Store IBM, onde este efetuou todo o armazenamento dos dados, imagens, vídeos e metadados utilizados no projeto. A sua arquitetura no processo consta na Figura abaixo.




Figura 8 - Arquitetura de Solução Projeto Piloto – Fluxo de orquestração de dados detalhado

3.3.3. Atividade 2.3 - Desenvolvimento Scripts Pós-Processamento

Para a futura implementação em produção em média/larga escala do caso de uso desenvolvimento neste projeto e também para a implementação de outros casos de uso que utilizarão uma solução de visão computacional e analítica avançada similar, foi desenhado uma arquitetura de referência levando em conta um cenário de infraestrutura híbrido, onde o treinamento de modelos e desenvolvimento de algoritmos é realizado em um ambiente corporativo em um Cloud privado e a execução destes modelos e algoritmos é realizado próximo onde o dado é gerado, nos servidores dos centros de operações da Arteris.

Para o projeto piloto foi utilizado dois servidores hospedados no IBM Cloud. Um servidor com 1 GPU e contendo uma instância do software de Visão Computacional da IBM, Máximo Visual Inspection, foi utilizado para treinar e executar (inferir) modelos de identificação de objetos (veículos e faixas). Outro servidor foi utilizado para a execução da analítica avançada e integrações com o software Maximo Visual Inspection, bases de dados e solução de dashboard. Inicialmente esse servidor foi configurado com 4 vCPUs (detalhes da configuração completa na seção 2.2 deste relatório) porém devido ao longo tempo de execução foi decidido aumentar a capacidade do servidor para 16vCPUs.

Para o experimento de modelos de identificação de eixos de veículos foram utilizados os mesmos trechos de vídeos disponibilizados para o restante do projeto, isto é, vídeos com a câmera no mesmo ponto da rodovia, mesma posição, ângulo e trechos diurnos.

Para o treinamento deste modelo foram coletadas 50 imagens base, utilizando o algoritmo de identificação de objetos YOLO para demarcar rodas simples de veículos (traseiras e dianteiras)

como eixos. Com a técnica de aumento automático de dados o número de imagens saltou para 768 (com um total de 3408 eixos identificados), melhorando ainda mais a precisão dos modelos.

Finalmente o modelo final obteve uma acuracidade de 100% e um IoU, importante métrica onde é medida a área de intersecção entre o objeto demarcado (*ground truth*) e o objeto previsto pelo modelo, de 89%.

Outras métricas importantes a destacar no modelo treinado como Precisão e Recall tiveram resultados perfeitos com 100% de exatidão.




Figura 9 - Métricas do modelo identificação de eixos

3.3.4. Atividade 2.4 - Iterações de Treinamento, Teste e Calibragem de Modelos

Durante o projeto piloto foram analisados trechos de 15 minutos de vídeo, opção escolhida devido aos relatórios do SAT estarem divididos dessa mesma maneira e assim facilitar o estado comparativo de resultados de ambas as tecnologias.

Conforme mencionado acima, inicialmente foi utilizado um servidor de inferência com 1 GPU para inferir o modelo de visão computacional para a identificação de veículos e um servidor com 4 vCPUs para executar o rastreamento e calcular os volumes e velocidades. Com essa

configuração, em um cenário onde foram analisados 20 frames de vídeo por segundo onde a inferência por frame leva 2 segundos, o tempo médio de análise de um trecho de vídeo de 15 minutos levou aproximadamente 2 horas.

Para melhorar esse tempo, a configuração do servidor foi aumentada para uma capacidade de 16 vCPUs onde, mantendo o cenário de análise de 20 frames de vídeo por segundo em um trecho de 15 minutos, o tempo médio para análise foi reduzido para 35 minutos.

É importante ressaltar que dois fatores contribuem para o aumento e diminuição no tempo médio de execução: o número de frames por segundo e o número de CPUs disponíveis para executar processos paralelos.

O cálculo para se estimar um tempo médio de processamento está descrito na figura abaixo.

Tempo total de inferência e calculo

- Taxa de Frames por segundo = 20 fps
- Sampling factor = 1/(2.5) Hz
- Tempo de inferência de cada imagem = ~2 segundos
- Numero de processos paralelos (N)

$$\frac{15 \text{ minutos}}{\text{video}} \times \frac{60 \text{ segundos}}{\text{minuto}} \times \frac{20 \text{ frames}}{\text{segundo}} \times \frac{1 \text{ Hz}}{2.5} \times \frac{\sim 2 \text{ segundos}}{\text{frame}} \times \frac{16}{F(N)} = \frac{\sim 36,000 \text{ segundos}}{\text{video clip}} = \frac{\sim 37.5 \text{ minuto}}{\text{video clip}}$$

Figura 10 - Cálculo de estimativa de tempo de execução

Uma vez que o modelo foi treinado e sua precisão provada, isso é, a capacidade do modelo em identificar distintos tipos de veículos nas imagens, foram aplicados cálculos de análise avançada para fazer o rastreamento de cada veículo por faixa de rodovia e ponto de interesse. Além disso foi também aplicado cálculo para medição de velocidade por veículo e finalmente um cálculo com resultados agregados de volume e velocidade de veículos por faixa e em todo o trecho da rodovia.

3.3.5. Atividade 2.5 - Desenvolvimento Dashboard Resultados

Foi efetuado o desenvolvimento de Dashboards Analíticos, com contagem de veículos por categoria e faixa da concessão em um determinado espaço de tempo e a velocidade média agregada dos veículos por faixa de concessão em um determinado espaço de tempo. um agregado das informações identificadas pelos modelos de visão computacional e

complementados pelos algoritmos de cálculos matemáticos, onde os usuários poderão visualizar de forma fácil os resultados das análises das imagens de vídeos da rodovia. Com estes dados em mãos, o objetivo será comparar os dados coletados pela nova tecnologia com os dados reais do SAT 01.



Figura 81 - Dashboard de Resultados




Figura 92 - Dashboard número de veículos VA x SAT

3.3.6. Atividade 2.6 - Validações e Testes de Integração

Os resultados apresentados neste projeto piloto foram satisfatórios indicando o uso promissor de novas tecnologias como Visão Computacional, Analítica avançada e Edge Computing para substituir os sistemas de monitoramento de tráfego atuais e melhorar os custos e eficiência das operações nas rodovias.

Vale ressaltar que os resultados apresentados nessa seção foram obtidos em análises de imagens de trechos diurnos e em condições de clima ideais, sem chuva ou neblina, através de uma câmera instalada na lateral da rodovia Régis Bittencourt próxima ao SAT do KM 288+800.

3.4. ETAPA 3 – UAT e Demonstração

3.4.1. Atividade 3.1 - Testes de Aceite e Demonstração

3.4.1.1. Período Diurno

Todos os resultados foram obtidos através do processamento de trechos de 15 minutos de vídeos diurnos e comparados com os mesmos trechos de 15 minutos e resultados disponibilizados nos relatórios do SAT.

Como exemplo de resultados e comparação utilizamos o trecho de vídeo do dia 18/01/2022 onde os seguintes resultados foram apresentados:

NP1 (Faixa Rápida) SAT

TOTAL VOLUME	VELOCIDADE MÉDIA	VOLUME CARROS	VELOCIDADE CARROS	VOLUME COMERCIAIS	VELOCIDADE COMERCIAIS	VOLUME MOTOS	VELOCIDADE MOTOS
109	98 km/h	81	101 km/h	24	89 km/h	4	97 km/h

NP1 (Faixa Rápida) VIDEO ANALYTICS

TOTAL VOLUME	VELOCIDADE MÉDIA	VOLUME CARROS	VELOCIDADE CARROS	VOLUME COMERCIAIS	VELOCIDADE COMERCIAIS	VOLUME MOTOS	VELOCIDADE MOTOS
96	109 km/h	74	113 km/h	18	98 km/h	4	101 km/h

Para obter um valor real de volumes foi feita uma contagem manual de veículos no mesmo trecho de 15 minutos:

NP1 (Faixa Rápida) CONTAGEM MANUAL

TOTAL VOLUME	VELOCIDADE MÉDIA	VOLUME CARROS	VELOCIDADE CARROS	VOLUME COMERCIAIS	VELOCIDADE COMERCIAIS	VOLUME MOTOS	VELOCIDADE MOTOS
99	-	79	-	17	-	3	-

Os resultados acima mostram as seguintes precisões:

- Volume Manual Vs. Volume Video Analytics = aprox. 97%
- Volume Manual Vs. Volume SAT = aprox. 90%
- Velocidade SAT Vs. Velocidade Video Analytics = aprox. 92%

Os resultados apresentaram uma precisão maior da aplicação do video analytics na contagem de volume se comparado ao SAT. O SAT por se utilizar de sensores no solo, sofre influência de vários fatores que contribuem com “saltos” na contagem – esse é um dos motivadores para o uso de uma tecnologia livre de interferência do pavimento e qualidade do sensor.

Algumas variações no volume e velocidade medidos com o video analytics podem ser explicadas pelo posicionamento da câmera onde em alguns casos um veículo pode obstruir o outro e esse veículo obstruído não ser contabilizado no cálculo final. Além disso alguns tipos de veículos foram identificados em categorias incorretas devido ao pouco tempo de treinamento. Para mitigar esses impactos é importante mencionar o posicionamento ideal da câmera no meio da rodovia e sempre refinar o modelo para que os objetos sempre sejam identificados em suas devidas categorias e evitar que objetos estranhos (como sombras, arvores, postes etc.) sejam identificados como veículos.




Figura 13 - Veículo amarelo identificado erroneamente como comercial devido a sua cor

Devido a inconsistência dos números apresentados pelo SAT durante o projeto e a fim de obter uma referência real de velocidade e fazer um comparativo com a solução de video analytics, utilizamos um carro de operações no trecho de rodovia e que trafegou em quatro velocidades nas duas faixas da rodovia. A figura abaixo mostra as velocidades reais que o veículo de operações trafegou e o resultado da análise do video analytics.

Video Name	Given Car Speed	Analyzed Car Speed
07.01.24-80KmNP1	80	76
07.08.48-90kmNP2	90	82
07.16.41-90KmNP1	90	86
10.09.08-70KmNP2	70	66
10.17.05-100KmNP1	100	96

Figura 1014 - Comparação velocidade real e velocidade obtida pelo video analytics

Em comparação com o valor real, a velocidade medida pela solução teve uma precisão aproximada de 95%. Esses cálculos podem ser melhorados com um fator de 3-4% que chegaria em uma precisão de 99%.

Como ponto positivo do uso da solução de Vídeo analytics ressaltamos sua implementação simplificada onde câmeras podem ser instaladas sem obstruir o tráfego rodoviário, baixa necessidade de calibragem dos modelos uma vez que um modelo esteja bem treinado e testado vai funcionar sempre e principalmente o custo de implementação e manutenção em comparação com os equipamentos SAT.

A aplicação do modelo teve resultados satisfatórios levando em conta um futuro caso de uso para identificar e contabilizar eixos em determinado trecho de rodovia. O caso pode ser explorado de melhor maneira com um treinamento mais completo seja com mais tipos de eixos e identificando os eixos em todos os veículos trafegando pela rodovia. Alguns pontos relevantes nos resultados da aplicação do modelo:

- Com apenas uma câmera em posição lateral monitorando uma pista dupla ou com mais faixas de tráfego, possivelmente haverá interferências quando veículos trafegarem ao mesmo tempo, lado a lado, nas faixas. Caso a rodovia tenha muitas faixas o ideal será posicionar múltiplas câmeras para que não haja obstrução de objetos (eixos).

- O modelo teve mais precisão na identificação de eixos quando os veículos estavam mais próximos a câmera.
- Apesar de não ter sido utilizado veículos de passeio no treinamento do modelo, em alguns momentos foram identificados eixos em veículos pequenos. Isso se deu pela similaridade dos objetos anotados (pneus e rodas com mesmo formato e cores).
- Nos testes realizados, todos os caminhões e ônibus tiveram os eixos identificados. Alguns veículos de passeio também tiveram os eixos identificados.




Figura 15 - Imagens resultados identificação de eixos

3.4.1.2. Período Noturno

Todos os resultados foram obtidos através do processamento de 4 trechos de 15 minutos de vídeos noturnos e comparados com os resultados disponibilizados nos relatórios do SAT. Como exemplo de resultados e comparação utilizamos o trecho de vídeo entre 04:00 horas até as 05:00 horas onde os seguintes resultados foram apresentados:

NP2 SAT

Total Volume	Velocidade Média	Volume Carros	Velocidade Carros	Volume Comerciais	Velocidade Comerciais	Volume Motos	Velocidade Motos
374	83.25	49	84.5	316	83.25	9	86

NP2 VIDEO ANALYTICS

Total Volume	Velocidade Média	Volume Carros	Velocidade Carros	Volume Comerciais	Velocidade Comerciais	Volume Motos	Velocidade Motos
374	90.6	48	96.5	306	92	20	78.3

NP2 CONTAGEM MANUAL

Total Volume	Velocidade Média	Volume Carros	Velocidade Carros	Volume Comerciais	Velocidade Comerciais	Volume Motos	Velocidade Motos
349	-	45	-	292	-	12	-

Embora os resultados tenham apresentado uma certa semelhança entre o video analytics na contagem de volume em relação ao SAT. Vale ressaltar que as variações entre os volumes por classes do vídeo analytics se assemelham bem mais a contagem manual do que as contagens realizadas pelo SAT.

A fim de obter uma referência real de velocidade e fazer um comparativo com a solução de video analytics, a Arteris disponibilizou horários de passagem e velocidade de veículos no trecho de rodovia, conforme tabela:

	Veículo Leve 0303 – 20h19 80km-h	Veículo Leve 0303 – 21h43 90km-h	Veículo Pesado 0403 – 02h42 70km-h	Veículo Pesado 0403 – 02h42 70km-h
Velocidade Real	80 km/h	90 km/h	70 km/h	80 km/h
Velocidade Prevista	85 km/h	81 km/h	86 km/h	115 km/h

Em comparação com o valor real, a velocidade medida pela solução teve uma precisão aproximada de 84%.

As observações realizadas no período diurno também se aplicam no noturno, mostrando que em todos os cenários a tecnologia utilizadas nas câmeras é mais eficiente e econômica do que o modelo SAT utilizado atualmente. No período noturno é importante salientar também que veículos com faróis altos podem acabar dificultando a detecção de veículos dentro da área

de contagem, porém, com base nos testes efetuados durante este projeto, os veículos continuam permanecendo sendo identificados e contabilizados de maneira correta quando passam na área mais próxima da câmera (onde esta não é tão afetada pelo farol alto) e, apesar de não possuir diferença significativa a ponto de afetar a eficiência final do projeto, há uma dificuldade em calcular a velocidade dos veículos. Além disso foi necessária a instalação de iluminação no local para garantir a alta assertividade.



Figura 16 – Veículo com farol alto

Durante o projeto foram identificados e discutidos outros casos de uso onde a tecnologia de visão computacional aliada às capacidades de análise avançada (dentre outras tecnologias complementares) podem auxiliar a concessionária a otimizar suas operações rodoviárias e assistir de maneira mais efetiva os usuários das rodovias sob sua concessão. Os casos de uso foram identificados e analisados levando em consideração os elementos que formam sua possível solução, integrações necessárias, dificuldade do acesso aos dados e complexidade de implementação.

Com as informações levantadas é possível que seja feita uma análise do esforço do desenvolvimento dos casos de uso versus o impacto operacional e financeiro da implementação, para que seja elaborado um planejamento no formato roadmap onde a Arteris poderá eleger a estratégia ideal para aplicar e estender o uso de tecnologias avançadas em suas operações.

ID	Nome	Descrição	Infraestrutura / Integrações	Complex.
1	Identificação e contagem de eixos na rodovia	Utilizar imagens de câmeras de segurança nas rodovias para identificar eixos e fazer a contagem. Ponto de Observação: Possível bloqueio de visão em rodovias com mais de 1 faixa de tráfego.	- Servidor de inferência de modelos - Servidor de execução de anallítica - Integração com sistema de operações/monitoramento	Baixa
2	Controle de eixos em pedágios	Utilizar imagens de câmeras em pedágios para identificar, contar e verificar eixos abaixados e suspensos, identificar o veículo através de um leitor de OCR e enviar dados ao sistema de controle que irá verificar a cobrança do pedágio.	- Servidor de inferencia de modelos - Servidor de execução de anallítica - Integração com OCR - Integração com sistema de operações/monitoramento - Integração com sistema de cobrança tag do pedágio	Alta
3	Identificação de animais/pessoas na pista	Identificar através das imagens de câmeras de segurança animais e pessoas próximas ou na pista para auxiliar na tomada rápida de ação do time de operações e resgate, prevenindo acidentes graves e auxiliando vítimas.	- Servidor de inferencia de modelos - Servidor de execução de anallítica - Integração com sistema de operações/monitoramento	Baixa/Média
4	Identificação de objetos na Pista	Identificar através das imagens de câmeras de segurança objetos na pista como restos de pneu, cargas, partes de veículos, etc, para auxiliar na tomada rápida de ação do time de operações e prevenir acidentes.	- Servidor de inferência de modelos - Servidor de execução de anallítica - Integração com sistema de operações/monitoramento	Baixa/Média
5	Identificação de danos na estrutura da pista	Utilizar imagens de câmeras de segurança nas rodovias ou instaladas no veículos de	- Servidor de inferência de modelos - Servidor de execução de analítica - Integração com sistema de manutenção	Média

ID	Nome	Descrição	Infraestrutura / Integrações	Complex.
		operações para o auxílio na identificação de danos estruturais na pista como desníveis, buracos, etc.		
6	Identificação de veículo parado no acostamento/SOS	Utilizar imagens de câmeras de segurança nas rodovias para identificar veículos parados no acostamento ou próximos aos setores de SOS para rápida reposta ao usuário com problemas na pista	- Servidor de inferência de modelos - Servidor de execução de analítica - Integração com sistema de operações/monitoramento	Média
7	Identificação de acidente	Utilizar imagens de câmeras de segurança para identificar acidentes e gerar alertas para uma tomada de ação mais rápida dos time de operações e resgate	- Servidor de inferência de modelos - Servidor de execução de analítica - Integração com sistema de operações/monitoramento	Média
8	Antecipação de eventos de risco	Utilizar imagens de câmeras de segurança para identificar e antecipar o auxílio em eventos de risco que possam gerar algum tipo de acidente como engavetamentos. Uma vez identificado um alto volume de carros em baixa velocidade, notificar equipe de operações para sinalizações na pista.	- Servidor de inferência de modelos - Servidor de execução de analítica - Integração com sistema de operações/monitoramento	Alta
9	Identificação de carga perigosa trafegando em túneis/rodovias restritas	Utilizar imagens de câmeras de segurança para identificar veículos que estão transportando cargas perigosas e monitorá-los, evitando que os veículos trafeguem	- Servidor de inferência de modelos - Servidor de execução de analítica - Integração com sistema de operações/monitoramento	Média

ID	Nome	Descrição	Infraestrutura / Integrações	Complex.
		em áreas proibidas como túneis. Os veículos são identificados previamente (alguns KMs antes do ponto proibido) e através de características únicas como tipo de caminhão ou sinalização no veículo e uma equipe é notificada para monitorar e atuar sobre a situação. Identificação utilizando placa da ONU de carga perigosa.		
10	Estimativa de filas no pedágio	Utilizar imagens de câmeras em pedágios para identificar, contar e mensurar filas em pedágio para auxiliar o time de operações sob a necessidade de sinalizações ou abertura de novos guichês para melhorar o fluxo de veículos. Alertar operação de maneira preditiva sobre ocupação para evitar filas longas e passar do limite permitido .	- Servidor de inferência de modelos - Servidor de execução de analítica - Integração com sistema de operações/monitoramento de pedágios	Média
11	Identificação de danos estruturais em pontes e viadutos	Utilizar imagens de câmeras de segurança, cameras instalada em veículos de operações ou mesmo drones para identificar danos estruturais em pontes e viadutos. Uma vez identificado, o sistema gerará uma notificação e uma ordem de manutenção ao time responsável.	- Servidor de inferencia de modelos - Servidor de execução de anallítica - Integração com sistema de manutenção	Média/Alta

ID	Nome	Descrição	Infraestrutura / Integrações	Complex.
12	Identificação de pontos de aquaplanagem	Utilizar imagens de cameras de segurança possíveis pontos de alagamento em dias chuvosos e alertar motoristas sobre possibilidade de aquaplanagem de veículos no ponto identificado	- Servidor de inferencia de modelos - Servidor de execução de anallítica - Integração com sistema de operações/monitoramento	Alta
13	Identificação prévia de veículos largos em aproximação de pedágio	Utilizar imagens de cameras de de segurança para identificar veículos largos que tenham que usar faixas especiais no pedágio. Ponto de atenção: O veículo pode ser identificado através de alguma sinalização visível ou que seja tomado suas medidas através de imagens. Para a segunda opção o ideal são imagens frontais do veículo para melhor precisão. Camera frontal e no topo do pórtico/marquise.	- Servidor de inferencia de modelos - Servidor de execução de anallítica - Integração com sistema de operações/monitoramento de pedágios	Média/Alta
14	Identificação de danos em sinalizações	Utilizar imagens de cameras de segurança nas rodovias ou instaladas no veículos de operações para o auxilio na identificação de danos na sinalizações da pista.	- Servidor de inferencia de modelos - Servidor de execução de anallítica - Integração com sistema de manutenção	Baixa
15	Uso de equipamento de segurança pela equipe de operação (EPs)	Identificar o uso de equipamentos de segurança pela equipe de operações.	IBM Worker Isights	Baixa / Média
16	Ciclo de Rotas de Viaturas Arteris	Identificar viaturas de inspeção pela rodovia em pontos pré-determinados para controle da	Identificar Viatura e horário que passou no ponto OCR para placa da Viatura	Baixa / Média

ID	Nome	Descrição	Infraestrutura / Integrações	Complex.
		ANTT. Hoje controlado por GPS porém tem pontos de falha.		
17	Comportamento de funcionários de operação	Identificação do cumprimento de comportamento de segurança dos funcionários da operação	IBM Worker Insights	Baixa / Média

3.4.2. Atividade 3.2 - Estimativa Investimento da Implementação

Conforme apresentado neste relatório, o resultado do uso da tecnologia implementada nesta primeira fase de estudo do projeto demonstrou grande capacidade de performance, apesar do curto espaço de tempo entre o seu desenvolvimento e testes e de algumas dificuldades que, apesar de não interferirem na alta eficiência final do projeto,

Para auxiliar a construção do caso de negócio em um cenário futuro em que a solução será implementada em todos os pontos onde estão atualmente instalados os equipamentos SAT na rodovia Arteris Régis Bittencourt, isto é, 5 pontos de câmeras, detalhamos abaixo uma estimativa aproximada do eventual custo de operação da solução.

Vale ressaltar que a estimativa apresentada abaixo fornecidos pela IBM, como referência, são apenas valores aproximados sugeridos em fevereiro de 2022 e não refletem e nem representam uma proposta oficial. Valores finais com incidência de impostos, variação cambial, descontos ou qualquer outro tipo de incidência, aditivo e/ou variação, devem ser apresentados oficialmente através de uma proposta comercial e contrato entre IBM Brasil e Arteris. Valores referentes aos serviços de consultoria da IBM não estão incluídos nessa estimativa e devem ser cotados através de um plano de trabalho formal.

Infraestrutura Lógica (Hardware e Software)	
Descrição	Valor Estimado Mensal
Servidor Virtual IBM Cloud 32vCPU 64GB 400GB Storage – OS Ubuntu 18.04	R\$ 5.736,78 ^a
Cluster Openshift IBM Cloud com 1 Worker Node 32 cores (2 GPUs) Tesla P100 NVIDIA)	R\$ 27.136,02 ^{a b c}
Banco de dados IBM Object Storage 4 TB (STaaS)	R\$ 916,41 ^a
PostgreSQL 100GB (PaaS)	R\$ 2043,36 ^a

IBM Container Registry 50GB (PaaS)	R\$ 12,79 ^a
Licença IBM Maximo Visual Inspection – Treinamento e Inferência de modelos em até 5 servidores Edge (assinatura 60 meses)	R\$ 50.000,00 ^{d e}
Grafana Dashboard (Open Source)	R\$ 00,00
Docker (Open Source)	R\$ 00,00
Python runtime (Open Source)	R\$ 00,00
NodeJS runtime (Open Source)	R\$ 00,00

^a preços convertidos com a cotação do dólar a R\$5,16 em 28/02/2022.

^b Cotação de 1 worker node. A IBM recomenda fortemente o uso de pelo menos 2 worker nodes por questão de alta disponibilidade de ambiente.

^c Cluster Openshift é somente necessário para realizar treinamento de modelos de visão computacional na plataforma IBM máximo Visual Inspection. Caso opte apenas pela inferência de modelos na borda (Edge), pode se usar uma máquina x86 padrão com GPUs NVIDIA. As GPUs NVIDIA suportadas pela plataforma podem ser encontradas através do link da documentação oficial do IBM Maximo Visual Inspection: <https://www.ibm.com/docs/en/maximo-vi/8.5.0?topic=edge-planning>

^d Cada servidor Edge tem a capacidade de conectar até 10 câmeras simultaneamente.

3.5. ETAPA 4 – Análise de Viabilidade Técnica e Homologação Tecnológica

3.5.1. Atividade 4.1. - Preparação de Comparativo Técnico e Econômico entre as soluções

Neste comparativo assumiu-se a premissa de 5 pontos de Visão Computacional em substituição aos 5 SATs em utilização na Arteris Régis Bittencourt. O primeiro cenário compara a aquisição e manutenção do ambiente de Visão Computacional totalmente em nuvem, com as soluções da IBM Cloud.

Investimentos - MVP Visão Computacional (5 pontos de contagem)			
Item	Vlr. Unit.	Qtde.	Vlr. Total
Câmera Intelbras Modelo VIP 1130 B + Instalação	R\$ 3.975,00	5	R\$ 19.875,00
Switch p/ conexão câmera	R\$ 6.280,00	5	R\$ 31.400,00
Implantação de defesa metálica	R\$ 40.000,00	5	R\$ 200.000,00
Iluminação - fornecimento e instalação	R\$ 21.400,00	5	R\$ 107.000,00
TOTAIS (A1)			R\$ 358.275,00

Valores Recorrentes Anuais - MVP Visão Computacional			
Item	Vlr. Unit. (*)	Qtde.	Vlr. Total
Servidor Virtual IBM Cloud 32vCPU 64GB 400GB Storage – OS Ubuntu 18.04	R\$ 1.147,36	5	R\$ 68.841,36
Banco de dados IBM Object Storage 4 TB (STaaS)	R\$ 183,28	5	R\$ 10.996,92
PostgreSQL 100GB (PaaS)	R\$ 408,67	5	R\$ -
IBM Container Registry 50GB (PaaS)	R\$ 12,79	1	R\$ 153,48

Licença IBM Maximo Visual Inspection	R\$ 1.000,00	5	R\$ 60.000,00
Grafana Dashboard (Open Source)	R\$ -	1	R\$ -
Docker (Open Source)	R\$ -	1	R\$ -
Python runtime (Open Source)	R\$ -	1	R\$ -
NodeJS runtime (Open Source)	R\$ -	1	R\$ -
TOTAIS (B1)			R\$ 139.991,76

(*) nesse cenário adotamos o valor de referência fornecido pela IBM e calculamos o custo por cada Câmera que substitui 1 SAT.

Valores Recorrentes Anuais - Recurso Computacional p/ treinamento e aprimoramento do modelo (Opcional)			
Item	Vlr. Unit	Qtde.	Vlr. Total
Cluster Openshift IBM Cloud com 1 Worker Node 32 cores (2 GPUs) Tesla P100 NVIDIA)	R\$ 27.136,02	1	R\$ 325.632,24
TOTAIS (C1)			R\$ 325.632,24

Investimentos - SAT tradicional			
Item	Vlr. Unit.	Qtde.	Vlr. Total
Equipamentos + Implantação	R\$ 111.097,00	5	R\$ 555.485,00
TOTAIS (A2)			R\$ 555.485,00

Valores Recorrentes Anuais - MVP Visão Computacional			
Item	Vlr. Unit. (*)	Qtde.	Vlr. Total
Manutenção Anual	R\$ 25.260,00	5	R\$ 126.300,00
TOTAIS (B2)			R\$ 126.300,00

Comparativo entre Soluções (Cenário 1A - sem ambiente de Treinamento na Nuvem)		
Item	Visão Comp.	SAT
Investimentos (A1 e A2)	R\$ 358.275,00	R\$ 555.485,00
Valores Recorrentes (B1 e B2)	R\$ 139.991,76	R\$ 126.300,00
TOTAIS	R\$ 498.266,76	R\$ 681.785,00
Comparativo entre Soluções (Cenário 1B - com ambiente de Treinamento na Nuvem)		
Item	Visão Comp.	SAT
Investimentos (A1 e A2)	R\$ 358.275,00	R\$ 555.485,00
Valores Recorrentes (B1 e B2)	R\$ 139.991,76	R\$ 126.300,00
Valores Recorrentes (C1)	R\$ 325.632,24	R\$ -
TOTAIS	R\$ 823.899,00	R\$ 681.785,00

Entre o Cenário 1A e o Cenário 1B, existe a opção no cenário 1B de se manter um ambiente na Nuvem para treinamento e aprimoramento dos algoritmos. Vale destacar que esse

ambiente poderia ser compartilhado com outras concessionárias da Arteris e esse valor seria rateado entre elas, dando escala ao projeto.

O segundo cenário compara a aquisição e manutenção do ambiente de Visão Computacional utilizando arquitetura Edge (local) para rodar tanto a inferência e treinamento locais na infraestrutura da concessionária.

Investimentos - MVP Visão Computacional			
Item	Vlr. Unit.	Qtde.	Vlr. Total
Câmera Intelbras Modelo VIP 1130 B + Instalação	R\$ 3.975,00	5	R\$ 19.875,00
Switch p/ conexão câmera	R\$ 6.280,00	5	R\$ 31.400,00
Implantação de defesa metálica	R\$ 40.000,00	5	R\$ 200.000,00
Iluminação - fornecimento e instalação	R\$ 21.400,00	5	R\$ 107.000,00
Servidor Edge Dell R750 32 Cores / 4 Gb RAM 2 GPUS Nvidia	R\$ 116.173,22	1	R\$ 116.173,22
TOTAIS (A1)			R\$ 474.448,22

0,			
Item	Vlr. Unit. (*)	Qtde.	Vlr. Total
Banco de dados IBM Object Storage 4 TB (STaaS)	R\$ 183,28	5	R\$ 10.996,92
PostgreSQL 100GB (PaaS)	R\$ 408,67	5	R\$ -
IBM Container Registry 50GB (PaaS)	R\$ 12,79	1	R\$ 153,48
Licença IBM Maximo Visual Inspection	R\$ 1.000,00	5	R\$ 60.000,00
Grafana Dashboard (Open Source)	R\$ -	1	R\$ -
Docker (Open Source)	R\$ -	1	R\$ -
Python runtime (Open Source)	R\$ -	1	R\$ -
NodeJS runtime (Open Source)	R\$ -	1	R\$ -
TOTAIS (B1)			R\$ 71.150,40

(*)valor de referência fornecido pela IBM e custo por cada Câmera que substitui 1 SAT.

Investimentos - SAT tradicional			
Item	Vlr. Unit.	Qtde.	Vlr. Total
Equipamentos + Implantação	R\$ 111.097,00	5	R\$ 555.485,00
TOTAIS (A2)			R\$ 555.485,00

Valores Recorrentes Anuais - MVP Visão Computacional			
Item	Vlr. Unit. (*)	Qtde.	Vlr. Total
Manutenção Anual	R\$ 25.260,00	5	R\$ 126.300,00
TOTAIS (B2)			R\$ 126.300,00

Comparativo entre Soluções (Cenário 2 - ambiente Edge na concessionária)			
Item	Visão Comp.	SAT	
Investimentos (A1 e A2)	R\$ 474.448,22	R\$ 555.485,00	

Valores Recorrentes (B1 e B2)	R\$ 71.150,40	R\$ 126.300,00
TOTAIS	R\$ 545.598,62	R\$ 681.785,00

3.5.2. Atividade 4.2. - Requisitos Técnicos de integração CNSO

Além da integração com sistemas e bases de dados da Arteris, a arquitetura de referência proposta visa também a interoperabilidade da solução com a plataforma CNSO, integrando ambas as plataformas através de uma integração de baixa complexidade via micro serviços (APIs). Os resultados das análises avançadas serão disponibilizados no formato JSON visando a rapidez no tráfego da informação e baixo volume de armazenamento.

Arquitetura de Referência

Arquitetura High Level para referência de implementação




Figura 17 - Arquitetura de referência projetos Vídeo Analytics

A figura acima traz visualmente a separação entre as tecnologias envolvidas na operação. Do lado esquerdo está representado a parte física da operação, um servidor local onde rodará a aplicação em si, basicamente é onde passa a primeira informação que é capturada pela câmera e onde é feita toda a criação de *labels*, cálculo de velocidade etc. No lado direito está representada a aplicação em nuvem, aqui os dados já estão trabalhados e tratados. Essa parte é dedicada para análises futuras com os dados gerados, criação de novos relatórios, avaliação de parâmetros etc. Aqui também será o local de novos testes de inteligência artificial e, caso sejam eficientes e bem avaliados, eles são enviados para o lado esquerdo, onde ocorre de fato a aplicação da tecnologia.

Essa separação entre um servidor local, onde acontece o processamento de fato, e um espaço em nuvem, onde são feitas análises, é importante para redução de custos, já que espaço

em nuvem é mais caro que espaço local, e para facilitar a criação de conteúdos com os relatórios gerados, uma vez que estando em nuvem compartilhar documentos é mais fácil e rápido. O uso da tecnologia em nuvem é valioso também para criação e utilização de API's, que nada mais é que a aplicação de uma interface de programação, através dele é possível criar alertas enviados para WhatsApp, e-mail etc., a partir de regras definidas, como o envio de uma mensagem de alerta caso o fluxo de carros aumente em 15% dentro de um determinado período, por exemplo.

3.5.3. Atividade 4.3. - Estudos sobre impacto na Tarifa

Conforme exposto nas tabelas comparativas do item anterior, em um cenário preliminar, o impacto tarifário não seria significativo. A depender da solução a implantar, esta pode inclusive ser menos custosa que a implantação de um conjunto de SAT's convencionais.

Assim, uma análise mais aprofundada e pontual deverá ser efetuada com base na solução escolhida, considerando o tempo de vida dos equipamentos já implantados e o impacto das diferentes alternativas e possíveis incrementos de pontos para monitoração. Entretanto, a proporção custo/benefício se mostrou bastante satisfatória, indo de encontro às premissas dos novos Contratos de Concessão, que buscam a implementação de tecnologias em prol dos serviços prestados à baixos reflexos tarifários.

3.5.4. Atividade 4.4. - Revisar Manuais/Procedimentos DNIT

Como descrito no Capítulo 3, o sistema por Visão Computacional não requer quaisquer alterações de norma ou procedimento DNIT, pelo contrário, é uma ferramenta muito menos intrusiva, que não demanda sinalização dos dispositivos, tampouco interrupção de tráfego para manutenção/implantação de sensores em pavimento. Isto contribui inclusive para uma redução significativa de *downtime* do sistema. Ainda, por se tratar de dispositivo do tipo câmera, diagnósticos podem ser efetuados em tempo real e de maneira remota.

3.6. ETAPA 5 – Relatório Final

Durante a etapa de elaboração deste relatório e durante todo o processo do projeto, podemos citar alguns itens como experiências adquiridas e lições aprendidas:

3.6.1. Precisão de modelos e cálculos

Os modelos treinados e cálculos analíticos desenvolvidos tiveram resultados excelentes em comparação com as atuais tecnologias em uso, porém, como em todo projeto, sempre existe espaço para que melhorias sejam realizadas, mesmo que estas não afetem consideravelmente

os resultados já obtidos. Alguns pontos a serem levados em consideração para uma próxima fase de projeto, ou em uma aplicação efetiva:

1. Valores de referência com exatidão levando em consideração todos os tipos de veículos analisados;
2. Variação de posição, lentes e ângulo de câmera, para comparação entre os casos e obtenção do sistema mais aperfeiçoado.

Em relação ao posicionamento, foi observado que os resultados das análises da faixa rápida (NP1) foram minimamente impactados por veículos que deixaram de ser contabilizados e monitorados devido a visão lateralizada da câmera utilizada. Esse “ponto cego” da câmera, interferiu, mesmo que de maneira tímida, no estudo comparativo dos resultados da tecnologia de Video Analytics e os sensores SAT. Para que esse impacto seja minimizado, foi indicado que o posicionamento ideal da câmera em casos de uso como esse deve ser centralizado, em uma altura que seja possível observar e identificar todas as categorias de veículos a cerca de 60 a 80 metros de distância, em um ângulo aproximado de 45°. Como exemplo de posicionamento as câmeras podem estar instaladas em pórticos de sinalização rodoviária ou mesmo em viadutos e passarelas.

Para a realização do projeto foi utilizado a princípio um servidor virtual com 4 vCPUs (64 GB) para a execução da porção de analítica avançada do projeto, isto é, onde foi feito o monitoramento dos veículos identificados pelo modelo de visão computacional e calculadas as velocidades de cada veículo, velocidade agregada por faixa e velocidade geral. Em média, com essa configuração, o tempo análise de um trecho de vídeo de 15 minutos levou aproximadamente 2 horas para ser concluído. Visando melhorar esse tempo de execução o ambiente foi expandido para uma configuração com 16vCPUs, onde finalmente chegou-se a um tempo de execução de aproximadamente 30 minutos por trecho de 15 minutos de vídeo.

Vale ressaltar que esse tempo leva em consideração uma análise com vídeos com uma taxa de frequência de 20 frames por segundo, mas que podem ser diminuídas conforme a necessidade e análise da precisão dos modelos em configurações de taxas mais baixas.

Conforme já mencionado neste relatório a arquitetura desenhada para a solução foi simplificada por ser tratar de um “projeto estudo” onde o foco principal foi analisar a capacidade da tecnologia em uma situação real e compará-la as tecnologias implementadas hoje, e os testes forma muito bem-sucedidos.

Em um cenário futuro em que fatores como capacidade de rede e processamento são chaves para o sucesso da implementação da tecnologia de video analytics é proposto que seja usada uma arquitetura híbrida onde a execução dos modelos e analítica avançada sejam realizadas na borda (Edge), minimizando assim o consumo de tráfego pesado de imagens pela rede e interrupção do processamento em caso de falha da rede, e o treinamento de modelos seja realizado no Cloud.

4. CONCLUSÕES, CONSIDERAÇÕES E PRODUTOS GERADOS

Apesar do custo total levantado para a solução de Visão Computacional ainda ser maior que o do SAT tradicional, podemos dizer que a tecnologia é muito promissora e por ainda estar em fase de expansão, estes devem sofrer baixa com a adoção em massa pelo mercado. Outro ponto a se levar em consideração, é a adoção de parte da arquitetura em ambiente on-premise, utilizando recursos Edge para diminuir os custos recorrentes da nuvem, que em uma primeira análise parece ser competitivo em relação aos custos atuais do SAT, sem contar que o custo de manutenção do SAT que é algo recorrente, tornando-se assim no longo prazo uma tecnologia mais cara.

A ferramenta, mesmo desenvolvida a curto prazo, demonstra grande aplicabilidade e abre portas para a implementação de diversas soluções que podem ser avaliadas no âmbito de inteligência por Visão Computacional. Isto acaba por trazer expectativas de maior assertividade na prestação de serviço, atendimento e segurança ao usuário e às equipes da concessionária.

Apesar da alta eficiência nos reconhecimentos quando comparado ao SAT, chegando a ser até superior, pelo menor transtorno causado ao usuário da rodovia e de todos os outros pontos assinalados anteriormente, consideramos que é excelente para aplicação em concessões futuras e em locais onde o SAT vier a apresentar problemas que não são de fácil resolução, se tornando mais caro, ou de valor próximo, a implantação da tecnologia apresentada aqui nesse projeto no local em questão. Nesses casos o ideal é instalar as câmeras em pórticos para garantir melhor visualização pois, mesmo que já tenhamos uma alta taxa de acerto que chega a 97%, o processo de melhoria deve se manter contínuo. E, por todos esses motivos, estaremos juntos da ANTT futuramente para garantir a homologação dessa tecnologia.

Como trabalhos futuros, concluímos que pode ser válido uma próxima fase com maior detalhamento do projeto e maior escala na aplicação da tecnologia. Ainda, recomenda-se a

aplicação da Visão Computacional em outras soluções em prol de melhorias operacionais, conforme listadas.

Os produtos gerados neste projeto foram: Dashboard de resultados de aplicação da ferramenta vídeo analytics, Dashboard de velocidade, modelos treinados e algoritmos desenvolvidos durante o projeto MVP, Comparativo Técnico e Econômico entre a solução antiga (SAT atual) e a nova tecnologia proposta, e Requisitos técnicos para a integração com o CNSO ANTT.

Além disso alguns scripts gerados para esse estudo podem ser utilizados em futuros projetos como é o caso de:

- [resources_organization.py](#): organiza qualquer recurso, desde que tenha os frames e seus respectivos rótulos presentes;
- [classes_analytics.py](#): gera análises da quantidade real de rótulos extraídos por cada frame, assim como a quantidade total e % por classes;
- [generate_train.py](#): produz um arquivo .txt com uma lista de todas as imagens utilizadas para treinamento / validações juntamente com o caminho de todos os seus diretórios (brevemente já organizadas em um *dataset*);