



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

CATEGORIA 3

Identificação e classificação de componentes e
Ações em Sistemas Ferroviários Baseado em
Deep Learning

INTRODUÇÃO

Nos últimos anos é notório o crescimento do setor ferroviário na sociedade, sendo impactado pela necessidade de melhorias no transporte de passageiros. Com essa crescente demanda e com o advento tecnológico, às ferrovias precisam acompanhar, renovar e inovar os processos de operação, manutenção e segurança.

Panorama do setor (2023-2024) - Portal Gov.br

Destaca-se a proposta de aplicação de visão computacional e aprendizado de máquina, sendo capaz de identificar objetos e componentes que compõem o sistema de via permanente em ferrovias, identificar invasão de pessoas em trechos ferroviários, bem como propor um sistema de detecção de velocidade por visão



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA **11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS**

computacional, em trechos de serviços de manutenção que exijam redução de velocidade de trens (Cautela).

Através do uso da visão computacional é possível melhorias no desempenho de processos do setor, frisando as áreas de manutenção de via permanente, segurança patrimonial e segurança do trabalho.

As aplicações práticas para um algoritmo de aprendizado profundo em uma ferrovia são inúmeras. Trabalhos realizados de análise por visão computacional e aprendizado de máquina como o de Brossard et al [1], que classificaram peças de vestuários, podem ser adaptados para classificar e identificar dormentes, trilhos, grampos de fixação de trilhos entre outros componentes contidos na ferrovia. Ainda com base no processamento de imagens é possível, verificar e identificar placas de sinalização de indicação de velocidades permitidas no trecho criando-se algum tipo de representação dessas velocidades para o condutor do veículo sobre trilhos podendo até o veículo em questão atuar de maneira autônoma, reduzindo ou aumentando a velocidade sem intervenção humana assim colaborando para a segurança no trabalho das equipes que estão em atividades sobre a via permanente.[19] Ferreira, Macilio da Silva

No que se refere a segurança patrimonial em trechos ferroviários, o trabalho visa demonstrar uma aplicação de um sistema de monitoramento por câmera instalado



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

em um determinado trecho onde este possa identificar qualquer tipo de intrusão de elementos que possam prejudicar de alguma forma o sistema.

Segundo o CEO da MRS Guilherme Segalla de Mello, relata em recente entrevista um alerta para manutenção e operação nas ferrovias, destacando a necessidade de adequações nos processos para seguir no mundo tecnológico. Para isso, sugere soluções que utilizam inteligência artificial, sensoriamento de ativos, Big Data, automações e outras ferramentas tecnológicas. [2].

TEORIA

O processamento de imagens digitais aplica métodos para , captar, analisar, manipular e processar imagens do mundo real para obter resultados úteis que possam ser aplicados em melhorias de processos[3]. As imagens digitais podem ser processadas a fim de se obter resultados que gerem soluções em processos na área de automação industrial e em outros diversos ramos de atividades [4].

A visão computacional é um ramo da ciência da computação que permeia por um campo desafiador, em busca de desvendar a complexidade da percepção visual humana através de processamento de sinais, algoritmos e técnicas matemáticas.

Um conjunto de cores juntamente com intensidades, representando um objeto que o olho humano pode ser capaz de interpretar pode dar uma definição inicial do que é imagem [4].



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

Uma imagem será digital, se esta for adequada para processamento computacional e para tal, ela precisa ser digitalizada no aspecto espacial e em sua amplitude.

Dentre os aspectos elementares que podem ser observados na digitalização e estão ligados ao processamento de sinais digitais há a amostragem, que que cria uma matriz para armazenar os dados de amplitude, digitalizando as coordenadas espaciais em intervalos regulares. A quantização é o processo de digitalização da amplitude, onde irá exprimir valores numéricos para cada elemento da matriz em níveis de cinza. O pixel, menor valor da divisão da imagem e níveis de intensidade de cinza, será expresso em potências binárias.

As imagens digitais, devido a sua representação numérica por meio de matrizes de valores, podem ser manipuladas utilizando técnicas algébricas como a convolução.

Na convolução o componente central é o núcleo da matriz, que pode ser referido por diversos termos como kernel, matriz convolucional, elemento estruturante ou máscara. No entanto, a definição mais precisa é que o núcleo é uma matriz de menor proporção.

O presente trabalho aborda a detecção de elementos mecânicos como (clips, sapatas, trilhos.) que por sua vez, apresentam anormalidades ou não além de outros elementos que possam ser identificados por análise de vídeo através de aprendizado



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

por IA. O sistema propõe alguns desafios na detecção, segmentação e avaliação de defeitos encontrados na via permanente. No trabalho de levantamento devemos propor também a localização do trecho defeituoso, que deve ser identificado, por metragem ou tempo.

A avaliação deve ser consolidada para trechos de A.M.V (aparelhos de mudança de via)ou em segmentos retilíneos.

A aplicação de um algoritmo não satisfaz, então para execução desta tarefa, lançamos mão do artifício Visão Computacional e de rede neural para execução da tarefa,

Com o desenvolvimento do trabalho verificamos necessidades mais graves e urgentes, a preservação da vida em situação de manutenção ou invasão.

O sistema pode ser usado para controle de velocidade de Trens, em situações de Manutenção de via, "cautela", ou por invasão da via permanente, por elementos ou pessoas que obstruam a passagem dos veículos ferroviários, o trabalho visa a apresentação de uma alternativa, para minimizar acontecimentos mais graves.

O projeto nesta fase trocará o aprendizado da rede neural de elementos de manutenção (trilhos, rodas, presilhas...etc.), e placas de velocidade e de alertas, como também elementos: como pessoas, animais, ou seja, qualquer fator, que possa afetar o tráfego e a segurança, do usuários e trabalhadores da Manutenção. Com o



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

aprendizado destes elementos, podemos através de um reconhecimento, de uma placa, ou da invasão de uma área delimitada, aplicar uma reação contrária. Essa reação irá variar, desde uma notificação de usuário na via, redução de velocidade e ou a parada total da composição.

Para isso lançaremos a logica Fuzzy que em seu contexto irá propor uma lógica de funcionamento do sistema.

Definição de logica Fuzzy: São aquelas que tomam decisões baseando em análises de informações estritamente qualitativas. Isto é feito de forma que a decisão de um sistema não se resume entre um 'sim' e um 'não' , mas também tenha decisões abstratas do tipo 'próximo de', 'em torno de', 'muito alto', 'bem baixo', etc. \cite{USP-SEL0364}.

Um conjunto Fuzzy X num universo U é caracterizado por uma função de pertinência que assume valores no intervalo [0,1] -Figura 1,2 e 3.

$$\mu_X(u) \in [0,1], \forall u \in U$$

Figura 1 *Formula de definição logica Fuzzy*

Essa lógica é baseada em algumas funções de pertinência como:



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

- Função trapezoidal, triangular, sino, gaussiana, sigmoide.

Podemos aplicar operações básicas nestas funções como:

Intersecção-Operação mínimo:

$$\mu A(x) \cap \mu B(x) = \text{mínimo}(\mu A(x), \mu B(x))$$

Figura 2 Intersecção-Operação mínimo:

União-Operação máximo:

$$\mu A(x) \cup \mu B(x) = \text{máximo}(\mu A(x), \mu B(x))$$

Figura 3 União-Operação máximo

Complemento:

$$\mu(x) = 1 - \mu(x)$$

Figura 4 Igualdade

Através dessas regras podemos associar a definições de lógica, como "Se, é,então"
conforme : **SE** Velocidade é Baixa **ENTÃO** Aceleração é Alta.

Podemos apresentar um esquema básico da logica Fuzzy-Figura 5

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

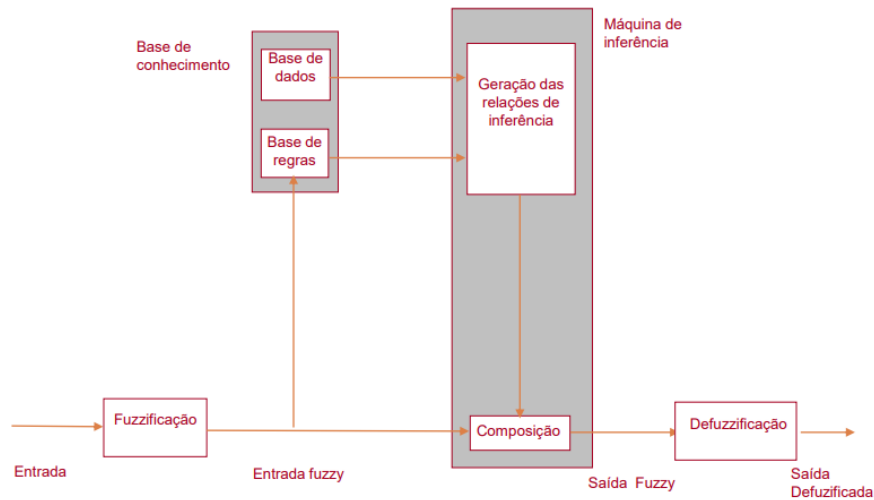


Figura 5 Fluxo básico da logica fuzzy - Fonte:USP-SEL0364

Vamos exemplificar para melhor entendimento:

Considere a variável linguística peso, constituída dos seguintes termos: $T(\text{peso}) = \{\text{baixo, médio, alto}\}$. A esses se faz corresponder conjuntos Fuzzy B, M e A, respectivamente, definidos por suas funções de pertinência Figura 6.

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS




Figura 6 – Função de Pertinência variável exemplo Fuzzy

Pela função temos

Pessoas de até 50 Kg apresentam grau de pertinência igual a 1 no conjunto B; o grau de pertinência nesse conjunto decresce à medida que o peso aumenta;

Uma pessoa de 75 Kg é totalmente pertencente ao conjunto M

Pessoas acima de 80 Kg (aproximadamente), apresentam grau de pertinência diferente de 0 em A

Pessoas acima de 100 Kg, definitivamente estão com o peso alto

Aplicamos essa mesma lógica em nosso projeto, mas com variáveis diferentes

DIAGNÓSTICO



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

- **Descrição Experimental**

Iniciamos o relato da proposta de identificação de componentes:

Fixações Elásticas, Dormentes (aspecto visual), Trilhos (Características de instalação), Juntas, JIC's , etc.

Os objetos acima, deverão inicialmente identificados no processo com seus problemas.

Nesse método, a IA (inteligência Artificial) é treinada, usando um conjunto de dados rotulado, que consiste em pares de entrada (imagens) e saída desejada (informação sobre os defeitos ou classificação desejada). O modelo aprende com esses exemplos e, uma vez treinado, pode identificar defeitos em novas imagens com base no que aprendeu durante o treinamento. Em alguns casos, a IA pode usar técnicas de aprendizado não supervisionado, onde não há rótulos específicos para as imagens de treinamento. Nesse caso, a IA pode aprender padrões ou características intrínsecas nas imagens sem depender de rótulos explícitos -Figura 7 e 8.

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS




Figura 7 Coleta dos dados iniciais-Fonte Arquivo Pessoal



*Figura 8 -Detalhe apresentando a resolução da coleta 1920 X 1080 ou Full HD
1080p, perfazendo total 2.073.600 pixels-30 fps. (frames por segundo).*

Fonte-Arquivo Pessoal

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

Com os dados iniciais aplicamos a etapa de preparação do treinamento da rede neural. A preparação de um modelo computacional de identificação conforme cronograma -Figura 9

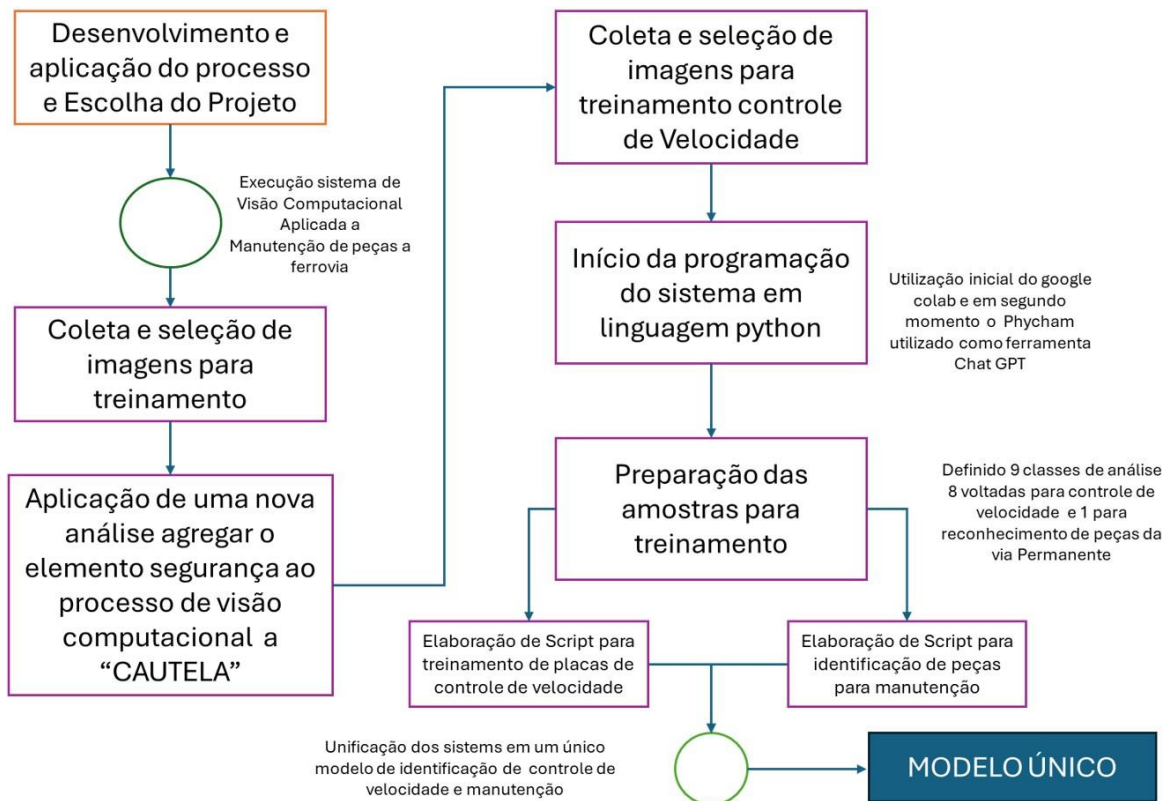


Figura 9 Cronograma básico de elaboração do modelo computacional



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

- **Processo de aprendizado de sistema para manutenção**

De acordo com informações da Wikipédia, 1080p (1920×1080), tecnicamente, é o nome abreviado de um tipo de resolução de imagem de telas ou monitores. O número 1080 representa 1080 linhas horizontais de resolução vertical,[1] enquanto a letra p denota uma varredura progressiva. É considerado um formato de HDTV. O uso do termo pressupõe geralmente um formato WideScreen 16:9, o que implica uma resolução horizontal de 1920 pixels e vertical de 1080 pixels, num quadro de 1920×1080 equivalendo a uma resolução com 2.073.600 pixels no total (2.1 MP). A frequência em hertz de quadros por segundo pode-se deduzir pelo contexto ou ser especificada a seguir à letra p, por exemplo, 1080p30, significando 30 hertz. Isso pode ser visto na Figura 8.

Com os vídeos; utilizamos o software "DaVinci Resolve 18 - (Blackmagic)", para separarmos a imagens em quadros, e convertemos as imagens, para imagens de diversos modelos , tamanhos e ângulos, além disso utilizamos de imagens disponíveis na internet para melhorar o aprendizado Figura 10 e 11.

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS



Figura 10 Fotos do pré-processamento de imagens- Fonte Acervo Pessoal



Figura 11 Fotos do pré processamento de imagens para etapa de controle de velocidade Fonte : Arquivo Pessoal

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

Para inicialização, o sistema transforma a imagem no tamanho de 32X32 pixels portanto 1024 células, e com atribuídos de valores 0...255 sendo 0 a ausência de informação ou preto e o 255 a cor branca ou máximo de intensidade.

Em nossa visão, reconhecemos diversas características que em processamento mental classificam os objetos, agora nas Redes Neurais Convolucionais (CNN), essa classificação ocorre a partir de filtros -Figura 12.




Figura 12 -Exemplo de processamento de imagem de forma matricial Fonte Ph.D. Steven W. Smith

Feito o pré-processamento, iniciamos o processo de PDS-Processamento de sinais digitais, neste item lançamos mão do processamento de convolução que consiste por definição:

"A convolução é uma operação matemática simples que é fundamental para muitos operadores comuns de processamento de imagem. A convolução proporciona uma forma de "multiplicar" duas matrizes de números, geralmente de tamanhos

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

diferentes, mas com a mesma dimensão, para produzir uma terceira matriz de números com a mesma dimensionalidade" afirma [1].

Podemos exemplificar; vamos supor que uma imagem que queremos aplicar a convolução, ela possui as dimensões de 9 X 9 (linhas e colunas), aplicamos um filtro que denominamos Kernels de 3 X 3, (Deixando claro que o modelo aplicado de Kernels é definido pelo algoritmo para melhor extração), ao executarmos a operação matemática, sucessivamente, e de forma como descrito na figura 13 obtermos uma matriz modelo, que por sua vez carrega as características da imagem que aplicamos a convolução Figura 14.

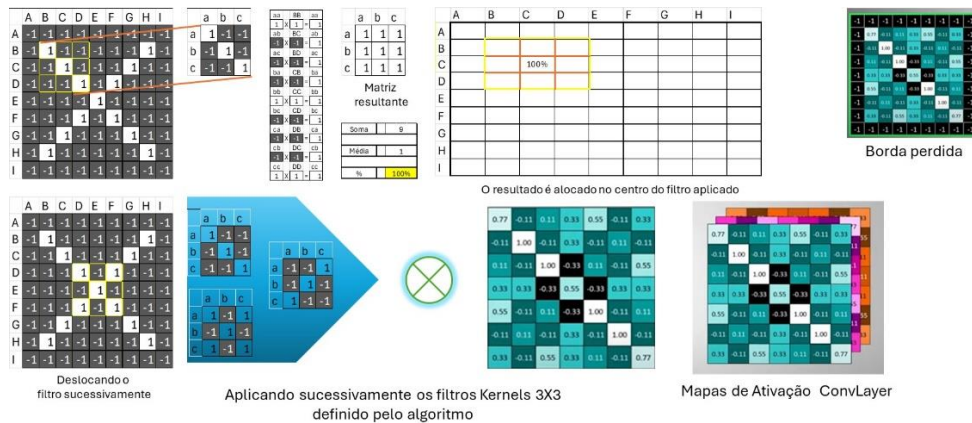


Figura 13-Exemplo de convolução para extração de Caraterísticas-Fonte Acervo pessoal

Em um exemplo visual temos uma imagem-figura 14 aplicando o filtro de Kernel




Figura 14- Exemplo de aplicação de filtro de Kernel Fonte: Loreane/ SERPRO.

A aplicação, de mais de uma convolução, vai depender se a acurácia no aprendizado pela rede neural, para que ela atinja valores entre 90 e 100 por cento, e é o que



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

perseguimos em nosso projeto. **Essa acurácia é definida pela relação entre a quantidade de previsões corretas pelo número total de previsões.**

Após execução, aplicamos outros modelos de filtros, para melhorar o treinamento da rede neural.

Para isso temos, algumas definições básicas a conhecer:

Mas o que é basicamente uma rede neural: Uma rede neural, é um mecanismo de aprendizado de máquina, (Machine Learning), muito poderoso, que imita basicamente como um cérebro humano aprende. Fonte Deep Learning Book.

Portanto, quando o cérebro humano é solicitado, (estímulo), processa, e gera uma informação em forma de resultado, quanto mais difícil a tarefa, mais neurônios o cérebro humano vai precisar, para gerenciar essa tarefa, transformando em uma rede, que compartilha as informações, a fim de gerar um resultado. Na rede neural, o comportamento é semelhante. Ne rede neural cada neurônio possui um peso, além de uma função de ativação, que nada mais é uma transformação não linear, ela executa o seguinte procedimento:

A informação se move da camada de entrada, para as camadas ocultas. As camadas ocultas, fazem o processamento, e enviam a saída final, para a camada de saída. Este é o movimento direto da informação, conhecido como propagação direta.

Mas, se o resultado gerado estiver longe do valor esperado?

Em uma rede neural, atualizaríamos os pesos e bias, (o peso fornecido para um cálculo no algoritmo de treinamento dentro de uma rede neural artificial (RNA)), dos neurônios com base no erro. Este processo é conhecido como backpropagation. Uma vez que todos os dados passaram por este processo, os pesos e bias finais são usados para previsões. Fonte: Deep Learning Book.

Para entender melhor vamos exemplificar, tomemos como base um pixel de uma imagem escrita à mão, e queremos que ao apresentarmos esse dado para rede, exista um processo de aprendizado, regulando pesos para que exista a classificação correta

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

do elemento, faremos uma pequena mudança de peso, gere uma pequena alteração na saída da rede. Isso gerará um aprendizado - Figura 15

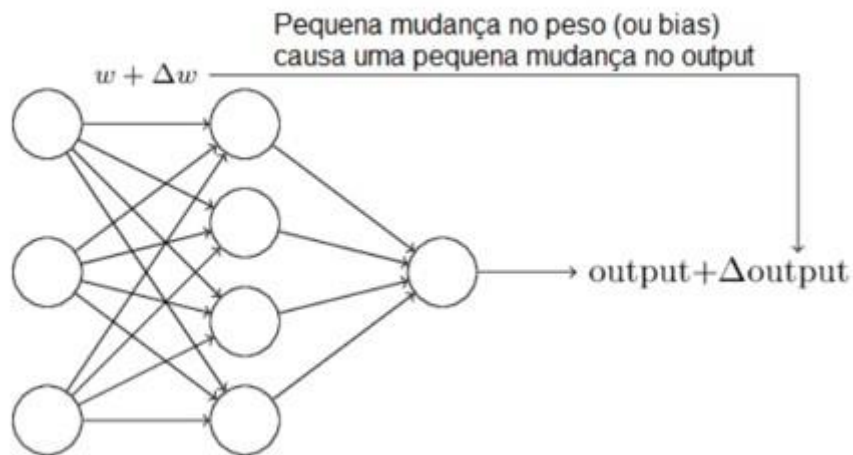


Figura 15 - exemplo de aprendizado rede neural- Fonte :Deep - Learning Book

. Então se executarmos pequenas variações na entrada, chegaremos ao resultado esperado, isso é o aprendizado da rede.

Mas quando mudamos a imagem isso pode gerar novas conexões portanto para que esse aprendizado seja possível aplicamos a função de ativação

Uma das funções de ativação que estamos aplicando em nosso projeto, é a função Sigmoid, cuja definição é:

$$f(x) = \frac{1}{1 + e^{-x}}$$

Esta é uma função suave, e é continuamente diferenciável. A maior vantagem sobre a função de etapa e a função linear é que não é linear Fonte: Deep Learning Book.

Essa função tem como característica mapear a entrada "x", para qualquer valor de X para o intervalo 0 até 1. Quando a função é positiva, ela assume valores próximos de

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

1, enquanto quando esta função apresenta valores negativos, ela se aproxima do 0, o fato é que quando a função tem valor 0, ela tem valor exato 0.5.

A função essencialmente tenta empurrar os valores de Y para os extremos. Esta é uma qualidade muito desejável quando tentamos classificar os valores para uma classe específica.

O resultado, é que a função sigmoide apresenta um aprendizado rápido, mas possui um inconveniente. Quando ela é aplicada sucessivamente, ela acaba ocasionando a perda de aprendizado. Esse fenômeno é chamado de "Vanishing Gradient", que no procedimento de reaplicação do algoritmo derivativo, acaba retornando valores pequenos ou zero dificultando o aprendizado.

Em nosso projeto, tivemos esse problema, onde não conseguíamos alcançar valores de aprendizado satisfatórios, conforme gráfico, Figura-16

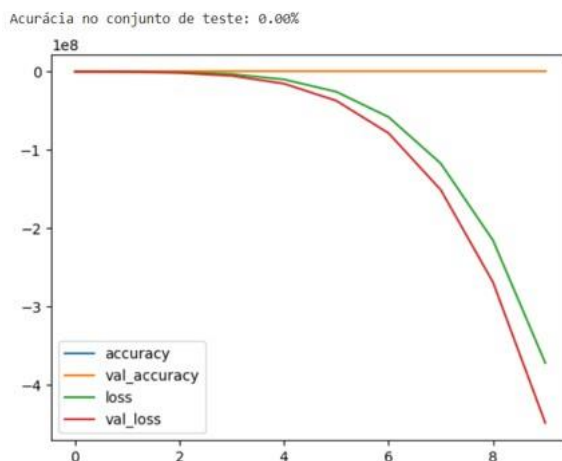


Figura 16 - Aplicação no aprendizado do projeto com aplicação de muitas camadas da função sigmoide - Fonte Arquivo Pessoal

Devido a limitação da camada da camada de ativação sigmoide, lançamos mão de outros modelos de ativação.

Adicionamos ao aprendizado a camada "ReLU".

ReLU-"Rectified Linear Unit" (Unidade Linear Retificada, em tradução livre),ela definida por:

$$f(x) = \max(0, x)$$

Esse modelo de ativação, é muito utilizado para aprimoramento da uma rede neural, ou seja, de seu aprendizado, é uma camada não linear, ou seja, significa que podemos

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

facilmente copiar os erros para trás, e ter várias camadas de neurônios ativados pela função ReLU. Uma das vantagens dessa camada é a seletividade, ela não ativa todos os neurônios ao mesmo tempo. Explicado melhor, ao ser apresentado para camada Relu, um número negativo, ele será convertido em zero, portanto o neurônio envolvido não apresentará ativação, tornando a rede neural, com dados com intervalos, "espaçamentos" facilitando o seu processamento, figura 17




Figura 17 - Gráfico apresentando a função RELU- Fonte DenseNet-DC

O próximo passo é aplicar então, o pooling Layer ou efeito downsampling, essa camada processa o sinal de 3(três)formas o max. pooling, min. pooling ou avg. pooling, em nosso projeto aplicamos o max, pooling que consiste: A camada é considerada, como uma camada de agrupamento são aplicadas normalmente após a convolução, justamente para diminuir a amostra apresentada. Podemos exemplificar o funcionamento desta camada, imaginemos uma matriz de uma imagem 4 X 4, o algoritmo escolhe um filtro 2 X 2, essa grade será posicionada no canto superior esquerdo da célula 4X4, e o algoritmo selecionará a célula de maior entre as 4

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

possíveis, valor maior será selecionado, e o primeiro algoritmo de uma célula 2 X 2 será criado na primeira célula do lado esquerdo superior - Figura 18

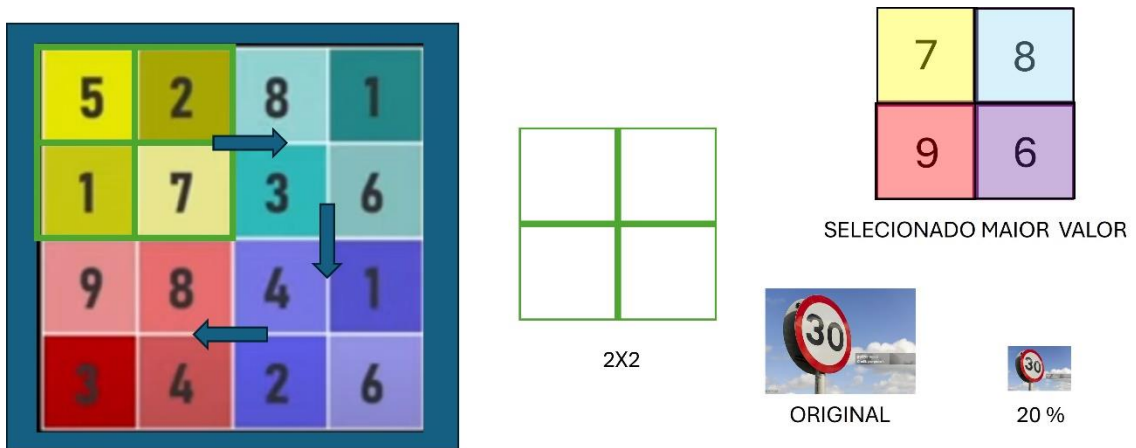


Figura 18-Exemplo de POOLING-Fonte:Canal Sandeco

Seguindo as etapas temos o Flattening, basicamente é manipulação do sistema extraído em forma de 1 vetor por n linhas para assim poder entrar na camada densa da rede, então temos demonstrado na Figura 19

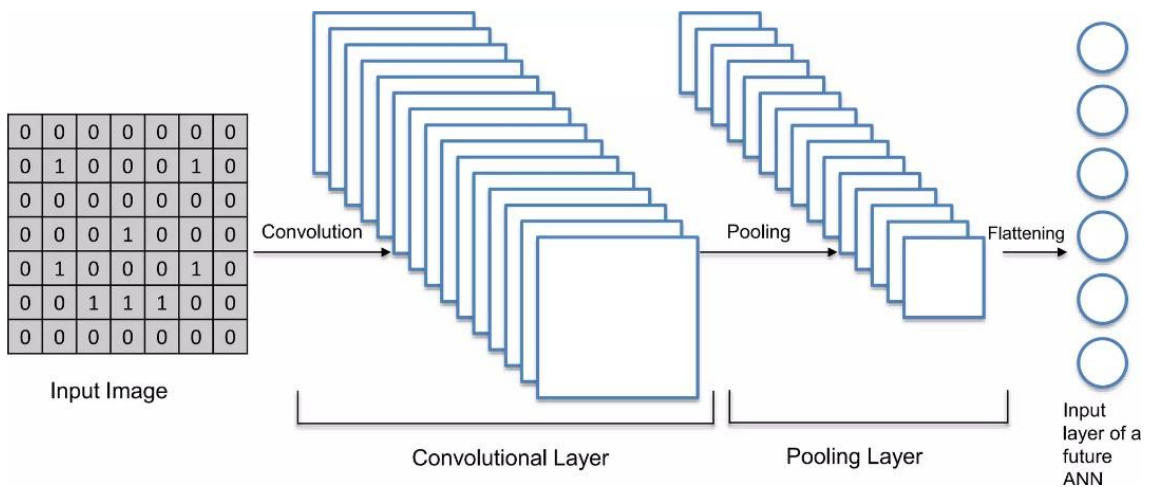


Figura 18-Exemplo de Flatening - Fonte : Kirill Eremenko



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA **11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS**

Assim podemos iniciar o Deep Learnig ou aprendizagem profunda, é a etapa onde é implementado algoritmos, que imitam o sistema de processamento do cérebro humano .Deep Learning usa camadas de neurônios matemáticos para processar dados, compreender a fala humana e reconhecer objetos visualmente. A informação é passada através de cada camada, com a saída da camada anterior fornecendo entrada para a próxima camada. A primeira camada em uma rede é chamada de camada de entrada, enquanto a última é chamada de camada de saída. Todas as camadas entre as duas são referidas como camadas ocultas. Cada camada é tipicamente um algoritmo simples e uniforme contendo um tipo de função de ativação Fonte :Deep Learning Book.

Em nosso projeto, utilizamos o YoloV8 que quer dizer "You Only Look Once", ou "Só se olha uma vez.

No projeto aplica-se o Yolo, que tem como característica, a aplicação de complementação da camada densa, por camada de convolução global Fonte Ultralytics.

Descriminando temos que O YOLOv8, usa uma arquitetura de rede neural profunda, que é dividida em duas partes principais:



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

A backbone é responsável por extrair características da imagem. Ela é composta por uma série de camadas convolucionais que aprendem a identificar padrões visuais cada vez mais complexos.

A head é responsável por classificar as caixas delimitadoras e regredir suas coordenadas. Ela é composta por uma série de camadas convolucionais e uma camada densa fina Fonte :Ultralytics.

ANÁLISE DOS RESULTADOS

Em nossa experimentação prática, executamos os dois tipos de processamento, treinamento para denotar qual seria mais eficiente para aplicação.

Na primeira aplicação executamos um processo de que definimos como tradicional, utilizando bibliotecas computacionais tradicionais, seguindo o script em python v3.12.

Tentamos utilizar o modelo, (ver dados na figura 20), gerado para as classes de placas e para as peças de via permanente



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

Model: "sequential"

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 28, 28, 32)	832
max_pooling2d (MaxPooling2D)	(None, 14, 14, 32)	0
conv2d_1 (Conv2D)	(None, 10, 10, 64)	51,264
max_pooling2d_1 (MaxPooling2D)	(None, 5, 5, 64)	0
dropout (Dropout)	(None, 5, 5, 64)	0
flatten (Flatten)	(None, 1600)	0
dense (Dense)	(None, 128)	204,928
dense_1 (Dense)	(None, 10)	1,290

Total params: 258,314 (1009.04 KB)
Trainable params: 258,314 (1009.04 KB)
Non-trainable params: 0 (0.00 B)

Figura 20 – Perfil Modelo calculado para aprendizado rede Neural

A aplicação do modelo foi feita em diversas épocas, mas o melhor resultado obtido foram 120 épocas de treinamento. Obtivemos o seguinte resultado de treinamento da Rede Neural: Teste SCORE: 0,087 Teste de Acurácia :0,97 Podemos ver os Gráficos de Acurácia e dados perdidos Figuras 21 e 22

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

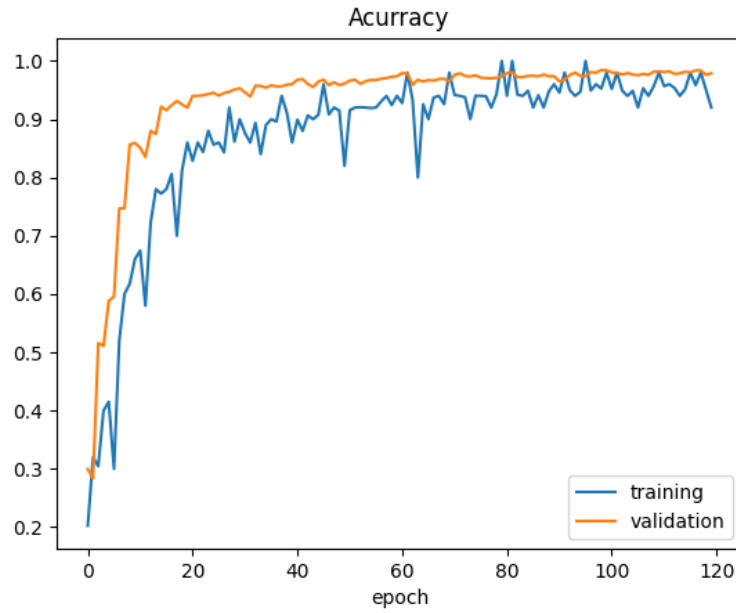


Figura 21-Gráfico de Acurácia do treinamento rede neural

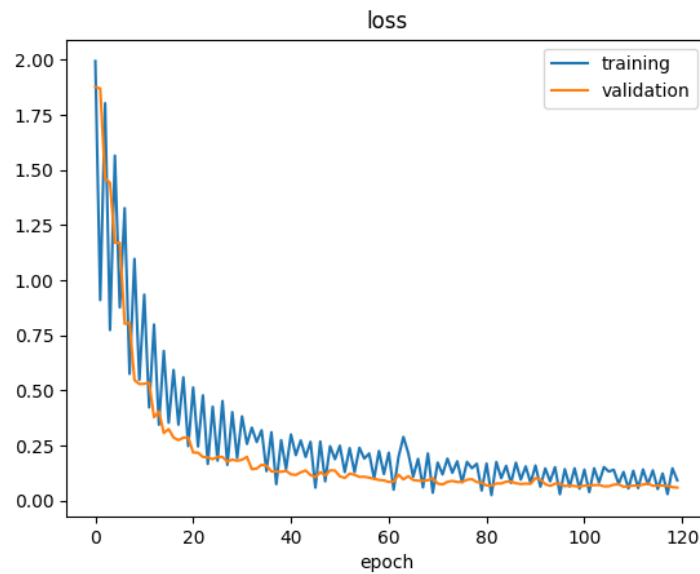


Figura 22- Gráfico de Dados perdidos do treinamento rede neural

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

Os resultados foram satisfatórios, com relação ao reconhecimento de placas, mas para reconhecimento das peças de via permanente, **o reconhecimento foi negativo**. Então executamos o treinamento do modelo, somente com essas peças, e verificamos que o treinamento não tinha sido eficaz, conforme gráfico-figura 23 devido a complexidade do elemento:

Acurácia no conjunto de teste: 0.00%




Figura 23- Gráfico demonstrando o não aprendizado

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

Com o resultado, positivo quanto ao reconhecimento de placas podemos, iniciar, procedimento de controle com lógica Fuzzy. Verificando a eficácia do modelo Treinado.

Então após pesquisa, executamos algoritmo de treinamento recomendado pela Ultralytics desenvolvedora do YoloV8 o Roboflow e verificamos os resultados Figura 24 e 25 e na foto 28 mostramos o reconhecimento de placas de velocidade pré treinadas .




Figura 24- Gráfico demonstrando treinamento usando ferramentas profissionais

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

Training Graphs

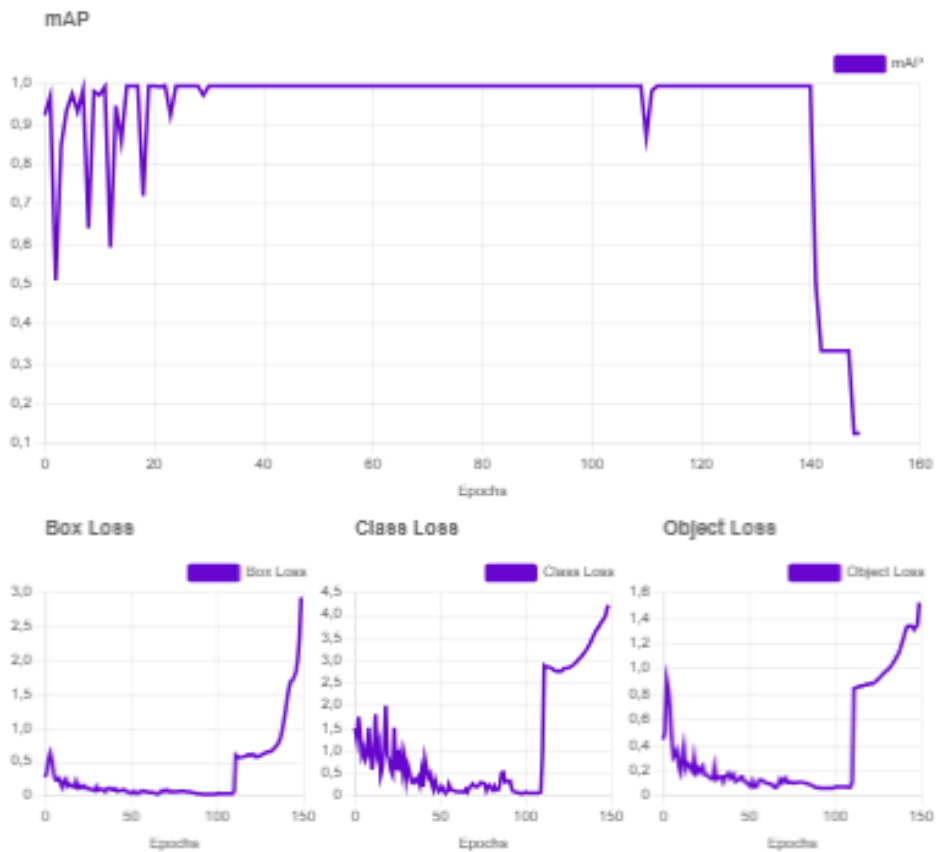


Figura 25- Gráfico demonstrando detalhes do treinamento

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS



Foto 26 demonstrando a aplicação do modelo treinado na identificação de placas -

Fonte: Acervo Pessoal

Resultados de 99,5 por cento de acurácia e 100 por cento de precisão. Notamos devido a quantidade de imagens treinadas, cerca de 10668 imagens dividas em 9027 imagens para treinamento, 1057 imagens para validação e 584 para teste-Figura 24 e 25.

- Aplicação dos modelos de placas e peças

Na figura 26 podemos ver o o funcionamento, do modelo para identificação de placas aplicando o modelo construído e treinado pelo algoritmo em Python.

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

Na sequência com os resultados positivos, executamos etapa de detecção pelo Yolov8, na foto 27 podemos ver a aplicação do modelo Yolo-v8 de detecção de peças.

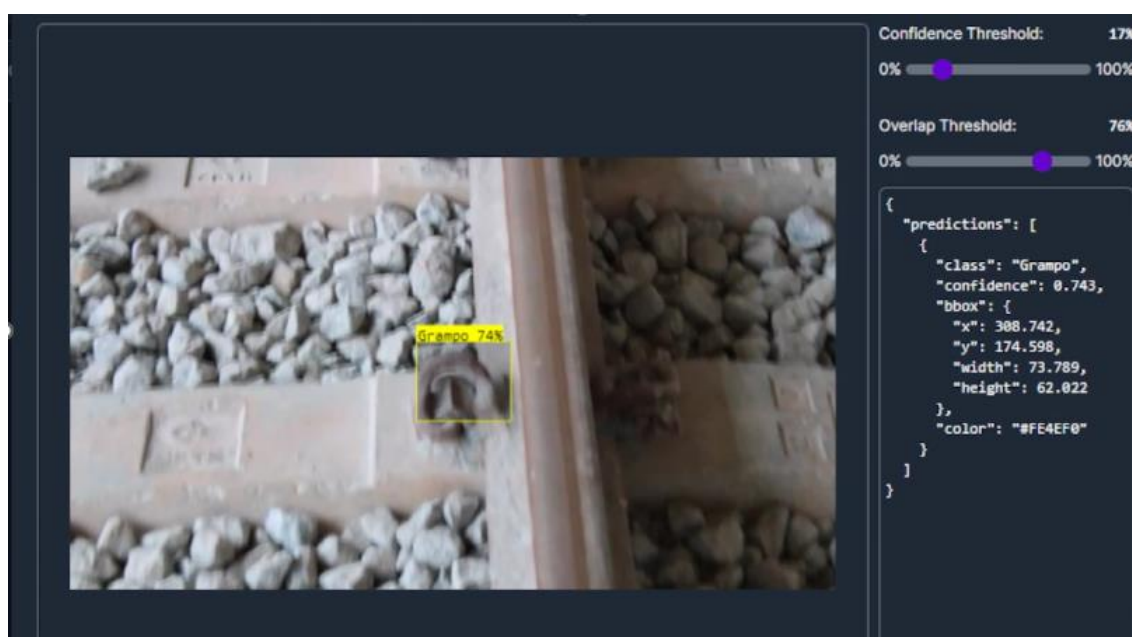


Foto 27 Aplicação do modelo de treinamento Roboflow na identificação de peças

Passamos então para o terceiro processo de identificação para focar na invasão de trechos da ferrovia, ou para trabalho ou ainda para evitar vandalismo. Utilizamos modelo já treinado, mas para pessoas.

Esse trabalho foi aplicado, com algoritmo de treinamento de detecção de invasão de área com a possível identificação do invasor, e alarme de monitoramento Figura 28.

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS



Figura 28 - Aplicação do modelo de treinamento python na identificação de pessoas

Com esse teste, voltamos a o desenvolvimento de dois sistemas de tratamento de sinais, o primeiro visa o envio de um sinal PWM modulado com uma música, e em uma frequência de 30 KHz e com amplitude muito baixa (não audível a princípio), a fim de proceder um alarme, a ser transmitido por sistema de som ambiente ou telefone, como alternativa de notificação de alarme, assim podendo o áudio ser filtrado, e o sinal PWM utilizado para disparo de um aviso ou sistema de notificação de forma remota, sem uso de internet. Na figura 29 e 30.

Podemos ver a simulação no Simulink do sistema de teste de manipulação do sinal PWM.

**30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS**

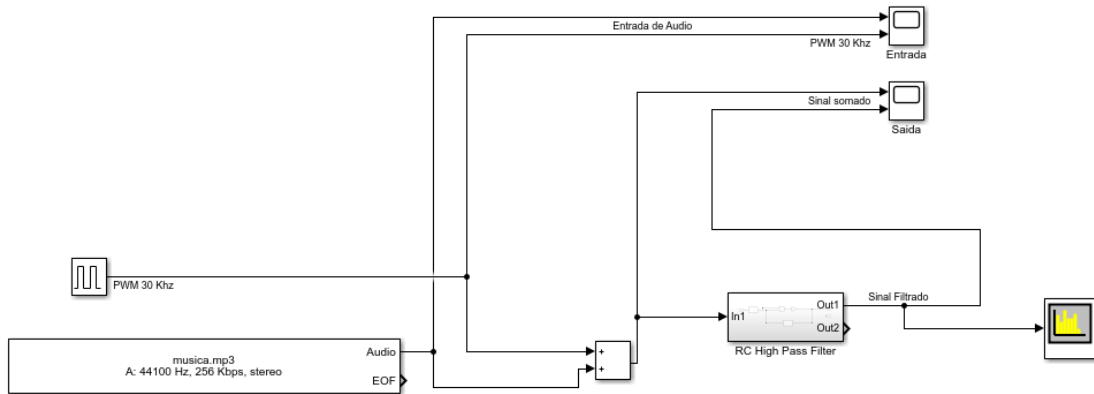


Figura 29 Circuito de estudo de proposta de alarme alternativo Matlab/Simulink -

Fonte Arquivo Pessoal

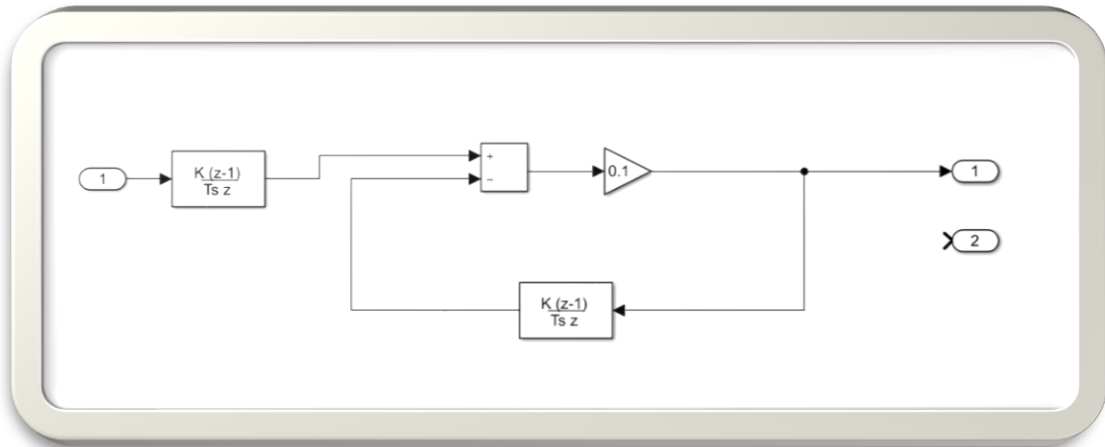


Figura 30 Detalhe do filtro passa alta aplicado a simulação para estudo-

Matlab/Simulink -Fonte Arquivo Pessoal

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

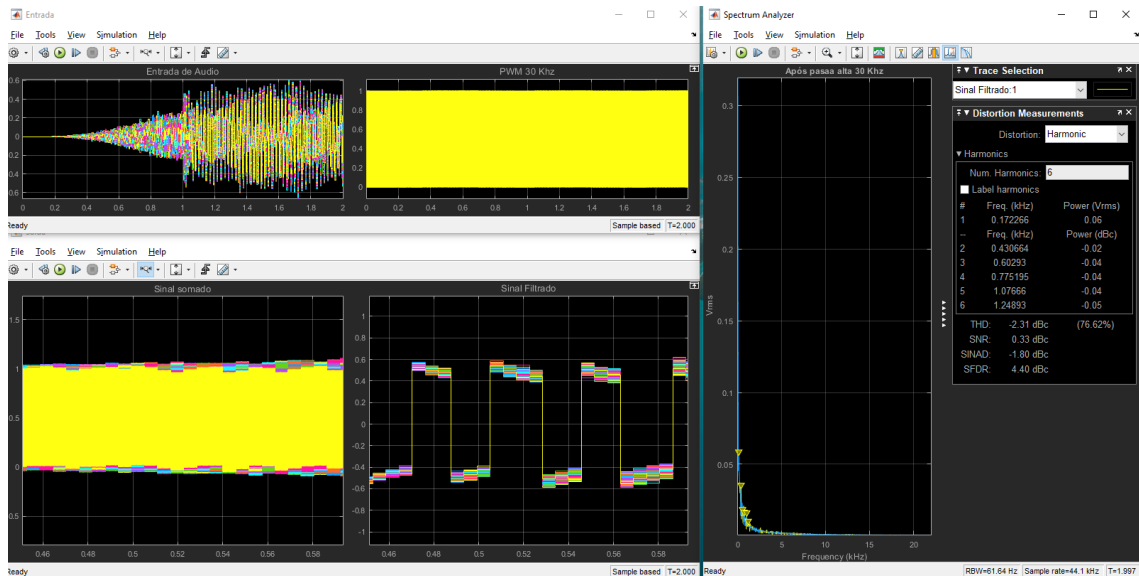


Figura 31 Simulação na aplicação de sistema de alarme alternativo afim de desenvolver a manipulação do sinal PWM-Matlab/Simulink

Podemos notar na Figura 31, os gráficos, na parte superior, o primeiro mostra a música, o segundo a direita, o sinal PWM de 30 KHz, já na parte inferior, mais dois gráficos, o primeiro a esquerda inferior, o sinal PWM somado a música, o segundo a direita inferior o sinal PWM recuperado após a passagem do filtro passa alta, possibilitando a manipulação do sinal PWM para acionamentos em outros processos de acionamento usando PWM.

Ao lado dos 4 gráficos, podemos ver o Espectrômetro, mostrando, a existência majoritária de uma frequência de 30 KHz.



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

Paralelo a essa função, iniciamos o modelo de lógica Fuzzy que será utilizada para controle do inversor de frequência.

Definimos então as características de controle- Tabela 1

Velocidade	Frenagem	Potência
Devagar	Leve	Baixa
Moderada	Leve	Média
Alta	Pesada	Alta
Moderada	Baixa	Média

Então após definimos e colocamos valores para as variáveis:

- Entradas:

Qual nível de velocidade que o Trem Está em uma escala 0 a 5

Velocidade Devagar, Velocidade moderada, Velocidade rápida

Qual nível de frenagem que deve ser aplicada em uma escala 0 a 5

Frenagem baixa, Frenagem moderada, Frenagem Rápida

- Saídas:

Conseqüentemente-(Saídas)

Qual a potência do “motor” da Locomotiva 0 a 10%

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

Baixa , média , alta

Iniciamos a aplicação da Lógica e traçamos os gráficos de pertinência

De velocidade - Figura 32:

<matplotlib.legend.Legend at 0x7c75b590b340>

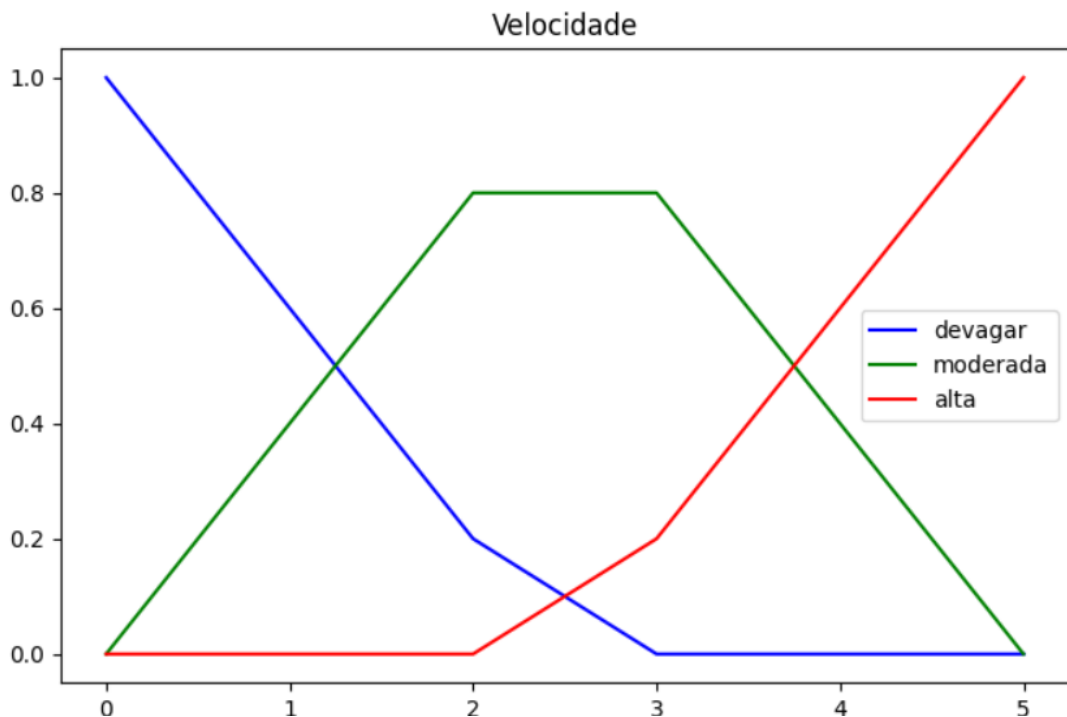


Figura 32-Função de pertinência de Velocidade

De Frenagem - Figura 33:

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

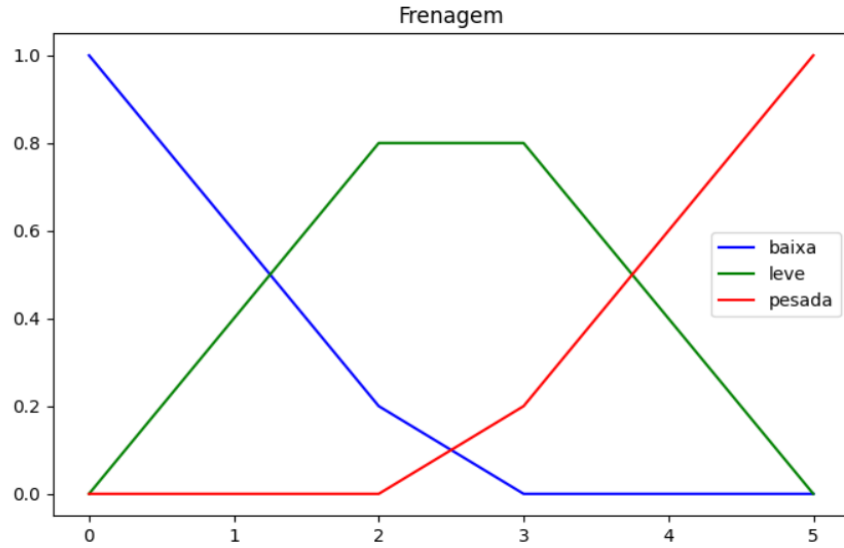


Figura 33-Função de pertinência de Frenagem

Consequentemente-(Saídas)

De Potência - Figura 34:




Figura 34-Função de pertinência de Potência

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

Aplicando a lógica Fuzzy no projeto temos o gráfico de saída das atividades interligadas obedecendo as 4 regras apresentadas na tabela 1 -Figura 35

Text(0.5, 1.0, 'Saída das atividades interligadas')

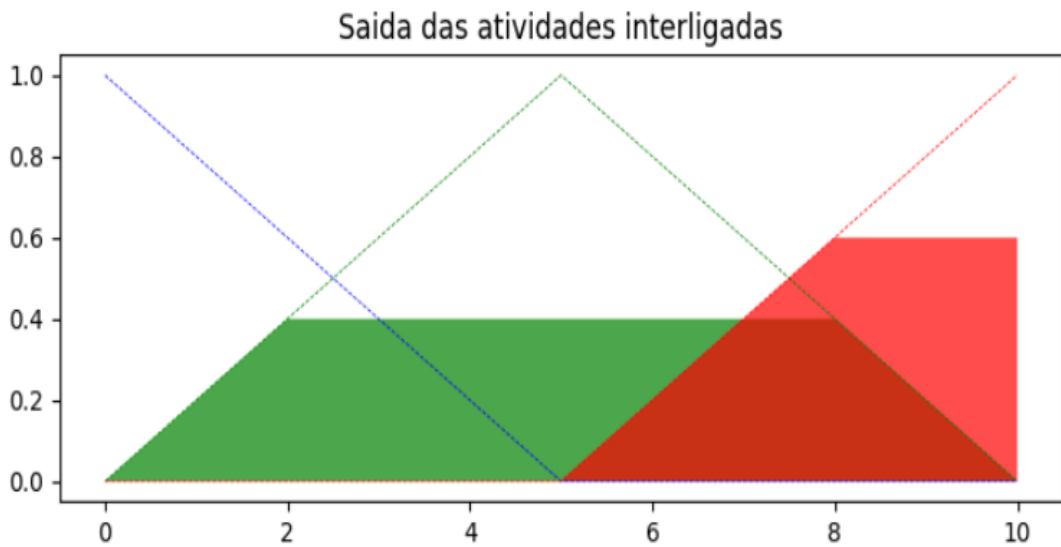


Figura 35- Saída das atividades interligadas

Finalizando a condição inicial se coletarmos as variáveis

Velocidade como sendo [0,0.4,0.6] sendo a atribuição de valores 0 para variável devagar 0.4 para variável moderada e 0.6 para nível alto para Frenagem [0,0.8,0.2] tendo a mesma ordem que a velocidade baixa . leve, alta. E aplicarmos a logica Fuzzy teremos um resultado de 5,87 por cento de potência conforme gráfico de defuzzyficação Figura 36

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

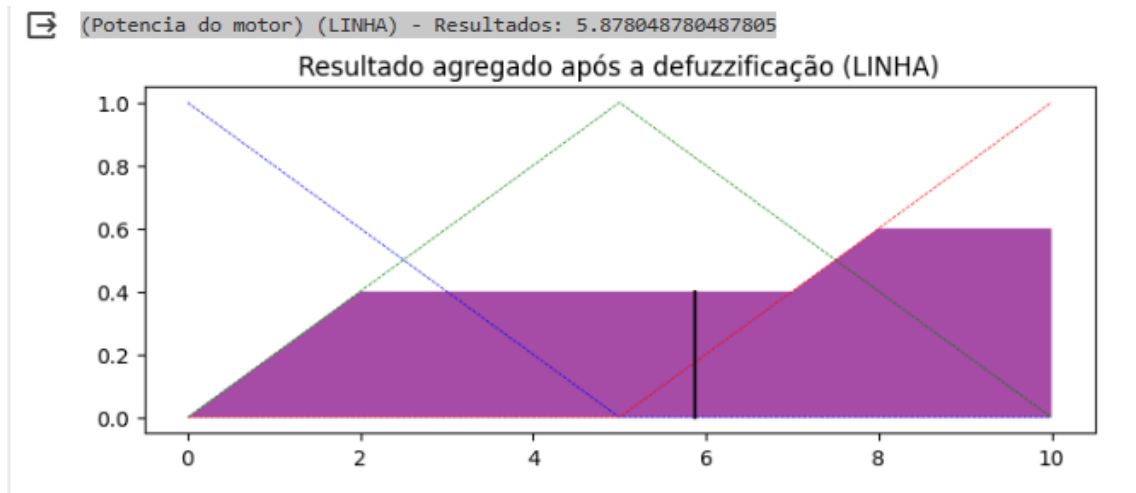


Figura 35- Saída das atividades interligadas resultado

Com esses resultados podemos aplicar a lógica proporcional em um sinal PWM para controle de inversor de frequência regulado a sua velocidade proporcionalmente.

Nesta etapa resolvemos aplicar os resultados em uma simulação no Matlab/Simulink (2018), podemos ver o diagrama no Simulink Figura 37

2018 Fonte: Acervo Pessoal

Esse diagrama, de blocos simula um controlador, que gera um sinal trifásico, de por sua vez passa por um bloco gerador PWM. Esse bloco PWM gera um sinal controlado e alimenta o bloco de diodos IGPT-Universal Bridge, caracterizando a arquitetura de um inversor de frequência de 6 pulsos.

Os demais blocos, são blocos para proceder a medição de parâmetros como velocidade, torque, corrente e potência.

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

Temos que dar ênfase ao controlador, que foi idealizado em sua arquitetura fuzzy. Vale a pena salientar que as regras propostas não são as aplicadas em grande escala, mas o efeito é verificar o funcionamento do sistema e o PSD (processamento de sinais digitais), para aplicação de grande por devemos rever as regras e se a mesma atende os requisitos de segurança internacional de transporte.

Abaixo o diagrama do controlador com lógica Fuzzy figura 38

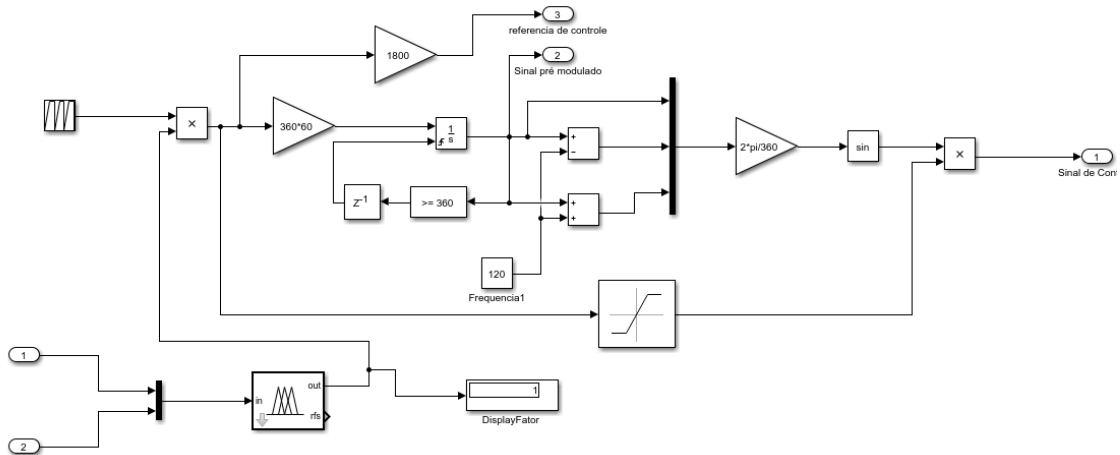


Figura 38 - imagem-Diagrama de simulação Simulink Matlab 2018 Fonte: Acervo Pessoal

Ao executar a simulação obtivemos os resultados gráficos:

**30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS**




Figura 39 imagem-Sinal pré modulado e modulado para controle Simulink Matlab 2018

Fonte: Acervo Pessoal

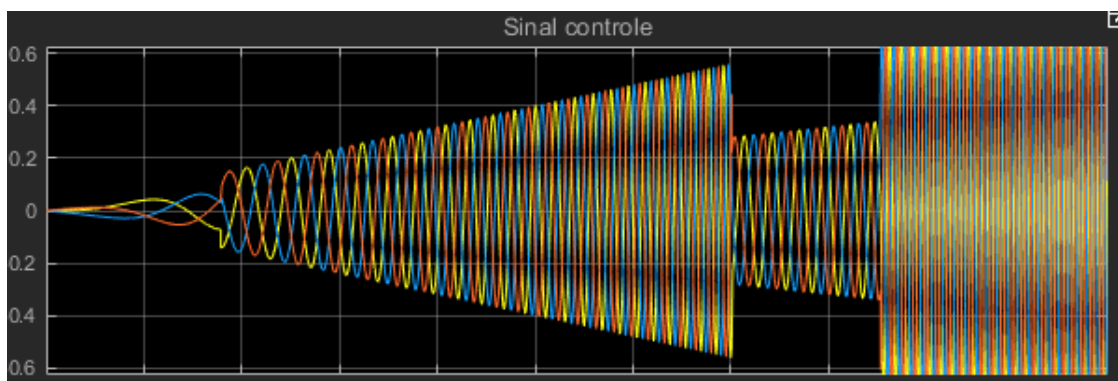


Figura 40- imagem-Sinal controle oscilando após aplicação da lógica Fuzzy Simulink

Matlab 2018 Fonte: Acervo Pessoal

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS




Figura 41- imagem-Velocidade (acima), Torque(central) e Sinal de controle (inferior)

aplicação da lógica Fuzzy Simulink Matlab 2018 Fonte: Acervo Pessoal

- Podemos avaliar na figura 41, que a variação de velocidade foi similar ao sinal de controle, demonstrando o grau de funcionamento do sistema proposto, verificou-se que o torque sofreu oscilação, mas em curto espaço de tempo, menor que 0.5 segundo, voltou a linearidade.

▪

E finalmente a avaliação da corrente e potência, varando proporcionalmente na partida, figura 42, e na oscilação da aplicação da lógica fuzzy demonstrando que o controlador é eficiente. Figura 41 terceiro gráfico

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS




Figura 42-imagem-Corrente e Potência com vimos a variação proporcional com aplicação da lógica fuzzy Simulink Matlab 2018 Fonte: Acervo Pessoal

Para completar executamos o resultado da logica fuzzy ao sistema de visão computacional alterando os graus de frenagem e velocidade conforme identificação de placas

A aplicação física (previsão):

O que é ESP32 - ESP32: Internet of Things

Desenvolvido pela empresa "Esparsais", o "ESP32" apresenta-se como um meio inovador no desenvolvimento de projetos automatizados. Possui WiFi, apresenta um sistema com processador Dual Core, Bluetooth híbrido e múltiplos sensores embutidos, tornando a construção de sistema como internet das coisas (IoT) muito mais simples e compacto.

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

Para captação de imagens devemos utilizar um microcontrolador ESP32 CAM que ficaria responsável pela captação de imagens e envio para processamento para um Raspberry Pi para análise e comparação da imagem detectada com o modelo previamente treinado.

A transmissão de imagem pode ser feita via Wifi ou cabo USB

Podemos ver uma foto ESP32 CAM - Figura 43 e 44 e seu sistema de pinagem




Figura 43- imagem-ESP32 CAM Fonte: Acervo Pessoal




Figura 44 imagem-ESP32 CAM-Pinagem Fonte: Acervo Pessoal

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

Para controle de velocidade e potência devemos utilizar a ESP32-30 pinos, optamos a solução de 2 microcontroladores, pois, normalmente o trabalho com imagem pode exigir uma capacidade de processamento relevante portanto essa utilização.

Podemos ver em detalhes uma foto-Figura 45 e 46 do ESP32 30 pinos com seu sistema de pinagem.



Figura 4 imagem-ESP32 – 30 pinos- Fonte: Acervo Pessoal




Figura 46 imagem-ESP32 CAM-Pinagem Fonte: Acervo Pessoal

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

Devemos proceder a conexão do ESP32 30 pinos ao inversor de frequência, essa comunicação deverá ser feita no formato RS485, nos pinos RX e TX do microcontrolador, temos então o pino 27 é utilizado para comunicação TX (transmissão dos sinais) e RX recepção (recepção dos sinais) pino 26.

Devemos utilizar o pino 25 que é utilizado para controle de ativação da saída RS485, enquanto iremos gerar um sinal PWM afim de executar o controle do motor, por variação frequência. Devemos gerar um código que no pino 18 deverá ser gerado um sinal PWM, com uma frequência fixa de 10 KHZ, com resolução de 8 bits, podendo assim com uma resolução de 0 (zero) a 255 para controlar a velocidade do motor. Não esquecendo, que a geração desse código estará vinculada a lógica fuzzy, delimitando o sinal 0 a 255 já descritos anteriormente. Podemos simular a geração do sinal conforme gráfico. Figura 47 Para ilustrar simulamos a situação de controle PWM em um software de simulação chamado Wokwi Figura 46

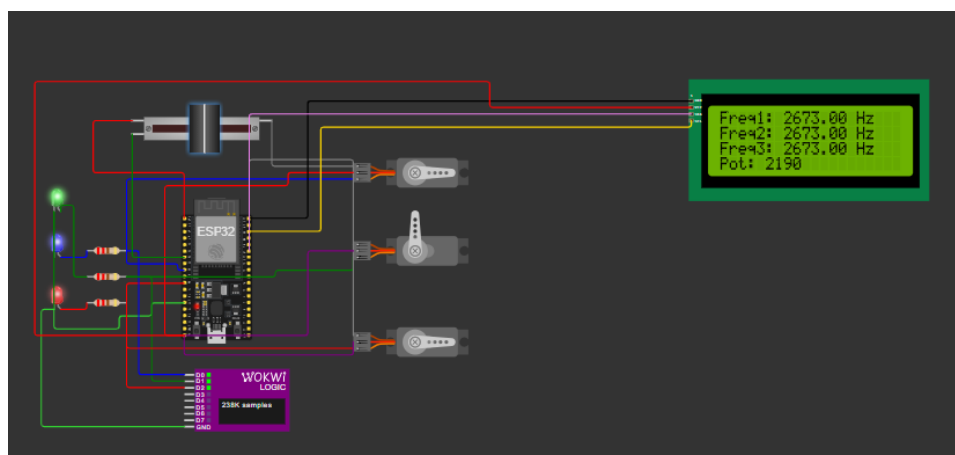


Figura 46 -Simulação do controle PWM para controle de motor trifásico

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS




Figura 47 - Simulação do controle PWM sinal gerado

- Para conectar o inversor ao ESP32, 30 pinos, precisaremos de alguns elementos que descreveremos a seguir:
- Filtro RC(passivo) - Esse filtro será necessário devido a possíveis interferências e ou ruídos.
- Ao escolher o tipo de inversor, poderemos nos deparar de uma necessidade de um sinal analógico, portando podemos ter que utilizar um DAC - Conversor analógico digital (caso necessário essa conversão deverá gerar mais interferências no sinal).



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

- Circuito de Isolamento: É necessário para isolar a entrada do ESP32, normalmente se usa um amplificador operacional na configuração de amplificador Buffer, que tem como propriedade manter o sinal e isolar as entradas pois o ganho deste modelo é 1. Isso dependerá de qual inversor a ser adotado ou aplicado no projeto.

CONCLUSÕES

aplicação de visão computacional tem sua viabilidade comprovada, para elementos mais variados, mas alguns tipos de cuidados devem ser observados. Notamos que o tratamento matemático dos elementos, é um dos pontos nevrálgicos para o reconhecimento e principalmente o treinamento de uma rede neural. Concluímos que a aplicação de convoluções e filtros e tipos de redes é experimental e necessita avaliação, dependendo do tipo de elemento detectável. Cada elemento deve ser treinado e avaliado, não se aplica a generalização. O modelo mesmo treinado pode não funcionar. Isso ficou claro em nosso projeto onde a aplicação convencional de elementos convolucionais e filtros se mostrou eficiente em figuras mais simples e com boa nitidez, mas para figuras complexas os padrões industriais e com mais elementos matemáticos se mostraram mais eficientes. O treinamento dos elementos no ambiente de aplicação, é fator determinante na autenticação do elemento e melhoria na detecção.



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

Na aplicação que chamamos de "convencional" o número de épocas é fator determinante no treinamento, mas ao mudar o tipo de elemento, ou número de amostras, para peças mais complexas isso não se reflete.

Concluimos que as o modelo de treinamento é chave da eficiência. E deve ser aplicado caso a caso, a generalização nem sempre é a melhor alternativa. Além disso podemos propor a aplicação do sistema para segurança patrimonial, visando a identificação de invasão de pessoas não autorizadas, esse sistema pode ser aplicado via câmera fixa, drone ou câmera fixada no próprio Trem. A nossa contribuição desde já deixa claro que a aplicação pode ser feita de forma simples e esse sistema pode ser usado em parceria com câmeras térmicas para complemento da análise.

Com relação ao controle de velocidade,

A aplicação da lógica Fuzzy, se mostrou em uma solução pertinente, para segurança do trabalho, visto que verificamos que somente controlando alguns parâmetros, obtivemos um bom resultado teórico nas simulações, mas na aplicação prática os resultados deverão ser avaliados, tomando os devidos ajustes de implantação, mas é solução aplicada a segurança, com a facilidade de simular as características humanas.

Esperamos que futuramente esse método de visão computacional e logica fuzzy seja adotado em larga escala, nas áreas de manutenção, segurança patrimonial e



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

segurança do trabalho em larga escala pelas Concessionárias locais e órgãos públicos de transporte.

Acreditamos que comprovaremos os resultados na aplicação física das simulações em protótipos a serem confeccionados.

REFERÊNCIAS BIBLIOGRÁFICAS

[1] Simon Perkins, Ashley Walker, Erik Wolfart e Robert Fisher. HYPERMEDIA IMAGE PROCESS-ING REFERENCE (aka HIPR). Disponível em: https://homepages.inf.ed.ac.uk/rbf/HIPR2/hipr_top.htm, 2000.

[2] José Alexandre and Fernandes Soares. Aplicação das matrizes no processamento de imagens usando o software Scilab. 2019.

[3] A enciclopédia livre. Origem: Wikipédia. 1080p. Disponível em: <https://pt.wikipedia.org/wiki/1080p>, 2023.

[4] Ph.D. Steven W. Smith. The Scientist and Engineer's Guide to Digital Signal Processing. Disponível em: <https://www.dspguide.com/>.

[5] Oge. Marques Filho and Hugo. Vieira Neto. Processamento digital de imagens. BRASPORT, 1999.

[6] Loreane Evelyn Nazareth Brandizzi. Visão computacional. SERPRO, Brasília-DF, 2020. Disponível em: <https://www.serpro.gov.br/menu/noticias/noticias-2020/o-que-eh-visao-computacional>.

[7] Esther Resendiz, John M. Hart e Narendra Ahuja. Automated visual inspection of railroad tracks. IEEE Transactions on Intelligent Transportation Systems, vol. 14, no. 2, pp. 751-760, 2013.

[8] Simon Perkins, Ashley Walker e Erik Wolfart. HYPERMEDIA IMAGE PROCESSING REFERENCE (aka HIPR). Digital, 2000.

[9] Kirill Eremenko. Convolutional Neural Networks (CNN):



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

[1] “L. bossard, (2013). apparel classification with style. accv 2012, volume 7727, pages 321–335. springer berlin heidelberg.”

[2] Revista Ferroviária RF edição maio/junho de 2023. Disponível em:
<https://revistaferroviaria.com.br/2023/06/ferrovia-e-sustentabilidade/>

[3] J. A. nalon, Introdução ao processamento Digital de Sinais, LTC, Ed., 2013.

[4] Y. Sá, Desenvolvimento de aplicações IA: robótica, imagem e visão computacional, Saraiva, Ed., 2021.

Step 3 - Flattening. SuperDataScience, 2018. Disponível em:
<https://www.superdatascience.com>.

[10] Data Science Academy. Deep Learning Book. Disponível em:
<https://www.deeplearningbook.com.br/>, 2023.

[11] Andre Tavares da Silva e Cristiano Roberto Siebert. DenseNet-DC: Optimizing DenseNet Parameters Through Feature Map Generation Control. Revista de Informática Teórica e Aplicada, vol. 27, no. 3, pp. 25-39, 2020.

[12] Canal sandeco. Convolução. Disponível em:
<https://www.youtube.com/@canalsandeco>, 2022.

[13] Equipe Ultralytics. Home - Ultralytics YOLOv8 Docs. Criado em 2023-11-12, atualizado em 2024-03-13.

[14] Dr(a) Mariangela Amendola Msc Anderson Luiz de Souza Laécio Carvalho Barros, P. (n.d.). Manual do uso da teoria dos conjuntos Fuzzy no MATLAB 6.5.



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

Retrieved April 5, 2024, from <http://celiomoliterno.eng.br/Arquivos/Mfuzzy.pdf>
<http://celiomoliterno.eng.br/>. Criado em maio-2005.

[15] Gabriel,D.,Rignel,S.,Chenci,G. P.,e Lucas,C.A.(n.d.). UMA INTRODUÇÃO A LÓGICA FUZZY. [www.facef.br/resiget- Vol1-NR1](http://www.facef.br/resiget-Vol1-NR1) <http://www.facef.br/resiget/> criado em 2011

[16] SEL0364 - Controle não linear aplicado 17 Abril 2013. (n.d.). INTRODUÇÃO À LÓGICA FUZZY Controle não linear aplicado SEL0364. Retrieved April 5, 2024, from <https://edisciplinas.usp.br/pluginfile.php/5126797/course/section/5937666/L>

[17] Guia de pinagem do ESP32CAM AI Thinker. (2024, March 13). 2012-2024 Suadica.Com; <https://suadica.com/dica.php?d=442&t=guia-de-pinagem-do-esp32-cam-ai-thinker>.

[18] Kevin M. Passino Stephen Yurkovich1998 13

[19] Ferreira, Macilio da Silva. Aplicação de técnicas de aprendizado profundo para a detecção e diagnóstico do estado de operacionalidade de sistemas: um estudo de caso em AMVS ferroviários. 2021. Dissertação de Mestrado – Escola Politécnica, Engenharia de Computação, Universidade de São Paulo, São Paulo, 2021. Orientador: Paulo Sergio Cugnasca. DOI: <https://doi.org/10.11606/D.3.2021.tde-20122021-170624>.