

# Detecção de Ervas Daninhas Utilizando um Modelo Generalizado da Transformada de Hough

Lucas de Arruda Campos Simões, Guilherme Wachs Lopes  
Departamento de Ciência da Computação, FEI  
l.arrudacs@gmail.com e gwachs@fei.edu.br

**Resumo:** Esse trabalho apresenta um modelo para detecção de imagens de ervas daninhas. É utilizada a transformada de Hough generalizada para representação das formas das ervas daninhas. Essa técnica permite mais controle do que os métodos convencionais, utilizando redes neurais para aprendizagem da ferramenta, o que também facilita a análise do seu treinamento. Os resultados apresentaram, em média, 76% de detecção das ervas daninhas contidas nas imagens com 17% de desvio padrão.

## 1. Introdução

A área de visão computacional tem passado por uma grande mudança nos últimos anos. A popularização de frameworks e inteligência artificial tem facilitado muitos pesquisadores a inovarem na área, principalmente quando se trata de Redes Neurais artificiais.

Contudo, a área de Redes Neurais, quando aplicada à Visão Computacional, tem obtido algumas críticas por parte dos pesquisadores. A principal delas é que uma Rede Neural aprende através da manutenção dos pesos utilizando uma técnica de otimização. Isso significa que são os pesos da rede que a torna capaz de efetuar uma tarefa de reconhecimento. A questão colocada pelos pesquisadores é que não se pode medir o que de fato a rede aprendeu ou, até mesmo, entender o que ela aprendeu. Assim, apenas técnicas de validação podem ser utilizadas para quantificar a aprendizagem.

Outras técnicas, mais específicas, como a Transformada de Hough[2], oferecem uma maneira direta para detecção de formas específicas em cena. Contudo, ela não oferece uma abstração tal como as Redes Neurais fazem. Essa técnica também é ineficiente para formas complexas por conta da quantidade de parâmetros envolvidos e o funcionamento dessa ferramenta ser baseado na força-bruta.

Sendo assim, temos duas técnicas antagônicas que podem ser aplicadas a tarefas semelhantes. Uma é altamente abstrata a ponto de não se entender de fato o que foi aprendido e outra específica demais a ponto de encontrar parâmetros exatos que descrevem uma forma em uma cena.

O contexto dessa aplicação foi inspirado na realização do diferenciamento das hortaliças a partir das informações presentes na topologia da forma[4], nesse caso no seu contorno. O objetivo desse trabalho é unir ambas as técnicas – redes neurais e transformada de Hough – para detecção de formas e cenas aplicando no domínio de detecção de ervas daninhas.

## 2. Metodologia

Essa seção conta com os passos para alcançar a detecção de ervas daninhas e os procedimentos para alcançá-la, que pode ser acompanhado a partir da figura 2. Inicialmente é feita leitura das imagens (etapa 1), o que implica em tratamentos para separar apenas as imagens de ervas daninhas para treinar o modelo (etapa 2), as quais serão recortadas em figuras menores antes de serem utilizadas no treino (etapa 3). O treinamento desse modelo envolve a criação de uma R-Table (etapa 4), que se trata de uma matriz de pontos em um espaço de coordenadas polares. Os pedaços das imagens utilizados na sua construção tem seus pontos comparados e tem suas convergências replicadas a uma matriz acumuladora (*Match Table*), a qual é utilizada para verificar a detecção das imagens inseridas no modelo.

A partir da criação dessa base (etapa 5), o modelo está pronto para receber imagens para que a identificação de ervas daninhas ocorra (etapas 6 e 7).

As etapas 8.1 e 8.2 são referentes aos testes realizados com o cálculo da entropia resultante das imagens treinadas, os quais seriam utilizados para ensinar uma rede neural a correlacioná-los com a presença de ervas daninhas. No momento da criação da R-Table, para cada imagem, foi criado um fator normalizante para modificar a sua convergência. Esse fator é utilizado no momento da inserção da imagem no *Match Table*, o qual retorna um resultado com uma entropia menor para um fator mais próximo ao qual a R-Table da imagem foi criada. Isso permite que a transformada generalizada fique também invariante à escala da imagem, o que não é sua característica original[2]. A técnica proposta utilizou a entropia como função capaz de quantificar o quanto uma escala é correta, ou seja com menos estados[5]. Isso pode ser visualizado na figura abaixo, onde a escala correta centraliza as votações dispersas na imagem em um único ponto.

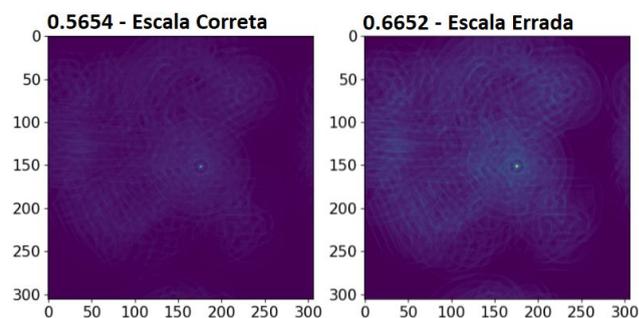


Figura 1 – Escala de Entropia

A partir da comparação dos pontos das figuras alimentadas ao modelo treinado, comparando com a matriz acumuladora (etapa 8.3), o modelo irá retornar o resultado da convergência da imagem (etapa 9).

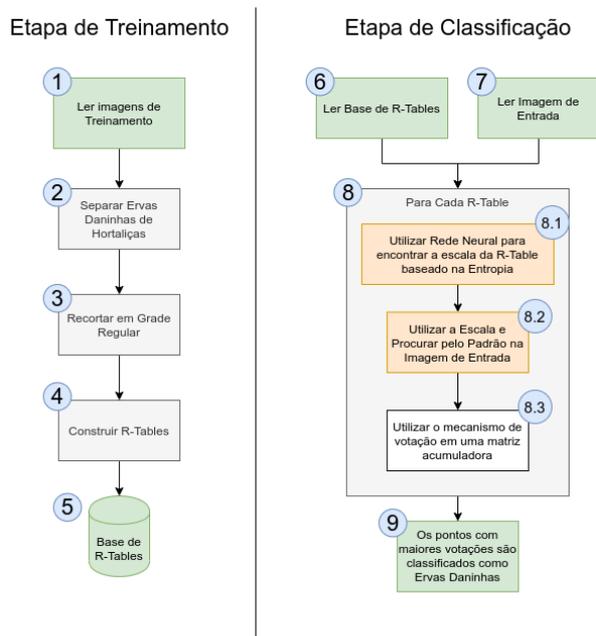


Figura 2 – Metodologia.

### 3. Resultados

Essa seção conta com os resultados dos testes de entropia e dos experimentos com a aplicação da ferramenta para detecção de ervas daninhas, respectivamente:

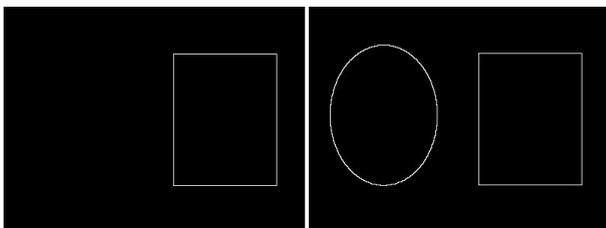


Figura 3 – Formas geométricas utilizadas na etapa 8.1.

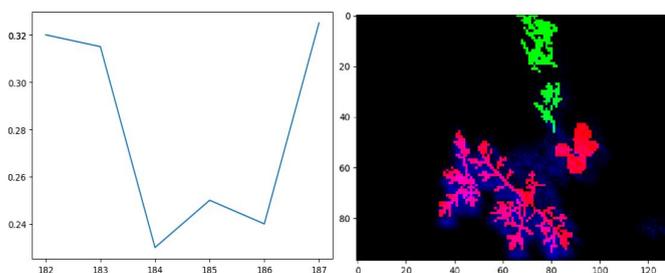


Figura 4 Esquerda – Refere-se ao gráfico de entropia (eixo horizontal: fator normalizante; eixo vertical: valor da entropia da imagem) - Direita - Resultado da Detecção de ervas daninhas.

As figuras 3 e 4 são referentes ao procedimento da identificação da imagem utilizando a variação da entropia a partir de um fator normalizante de escala. Os resultados indicaram que a entropia não é uma métrica

ideal para quantificar a qualidade da escala. A hipótese inicial deste trabalho é que, se a escala aplicada é a melhor, a transformada de Hough iria ter uma matriz acumuladora em um único ponto. Ao extrair a entropia dessa matriz, ela seria muito baixa, o que indica a convergência da transformada. Contudo, a transformada não apresenta esse comportamento tão pronunciado. Assim, esse trabalho não utilizou a invariância de escala para as formas aprendidas. Pode-se observar na figura 4 Direita que as formas preenchidas com a cor verde são hortaliças, enquanto as que foram preenchidas com a cor vermelha são ervas daninhas.

O sombreamento azul na figura 4 Direita configura a região onde a ferramenta identifica a presença de ervas daninhas.

Os resultados apresentaram, em média, 76% de detecção das ervas daninhas contidas nas imagens e 65% da presença de hortaliças. O desvio padrão desses valores foi de 17% na detecção de ervas daninhas e 26% das hortaliças.

### 4. Conclusões

A ferramenta desenvolvida neste trabalho, apesar de possuir um alto índice de detecção de ervas daninhas nas imagens treinadas, ainda apresenta um valor substancial de falsos positivos, superior ao de modelos com detecção de cor [3], o que impede a união desse modelo com o treinamento de uma rede neural. Esse resultado, no entanto, pode ser contornado com a utilização de um espaço amostral maior. Também é relevante notar que as imagens foram treinadas com a sua resolução reduzida no intuito de otimizar o tempo dos experimentos, o que também contribuiu para a acurácia dos resultados.

Contudo, a ferramenta não só possui potencial para detecção de imagens, mas também demonstra aptidão para enriquecer os resultados de outros modelos para detecção de imagens e outras pesquisas no mesmo campo por conta de permitir o manuseio dos parâmetros no processo de aprendizagem da ferramenta.

### 5. Referências

- [1] BALLARD, D.H. Generalizing the Hough Transform to Detect Arbitrary Shapes. v. 13, p. 111–122, dez.1987.
- [2] HOUGH, Paul.Method and Means for Recognizing Complex Patterns. [S.l.]: United States Patent Of-ice, dez. 1962. U.S. Patent 3.069.654.
- [3] El-Faki Mozib, Mohammed & Zhang, Naiqian & Peterson, D.. (2000). Weed Detection Using Color Machine Vision. Transactions of the ASAE. American Society of Agricultural Engineers. 43. 1969-1978.
- [4] ZHANG, Dengsheng; LU, Guojun. Review of shape representation and description techniques. PatternRecognition, v. 37, p. 1–19, 1 jan. 2004
- [5] SHANNON, Claude E. A mathematical theory of communication.Bell Syst. Tech. J., v. 27, n. 3, p. 379–423, 1948.

### Agradecimentos

À FEI e ao laboratório Intelligent Internet of Things pelo espaço e empréstimos de equipamentos.

Aluno de IC do Centro Universitário FEI (Bolsa FEI PBIC062/19). Projeto com vigência de 05/19 a 08/2020.