

## 13º Congresso de Inovação, Ciência e Tecnologia do IFSP - 2022

### Análise comparativa de técnicas de aprendizagem de máquina para classificação de materiais descartáveis

MATHEUS A.M. SANTOS<sup>1</sup>, REGIVALDO S. FERREIRA<sup>2,5</sup>, IGOR C. ZADI<sup>3,5</sup>, FELIPE R. M.BASILE<sup>4,5</sup>

<sup>1</sup>Discente do IFSP, Câmpus Pirituba. matheus.mattias@aluno.ifsp.edu.br

<sup>2</sup>Docente do IFSP, Câmpus Pirituba, regivaldo.ferreira@ifsp.edu.br

<sup>3</sup>Docente do IFSP, Câmpus Pirituba, igor.zadi@ifsp.edu.br

<sup>4</sup>Docente do IFSP, Câmpus Pirituba, felipe.basile@ifsp.edu.br

<sup>5</sup>Grupo de Informática e Tecnologia em Educação e Sociedade, GITES

Área de conhecimento (Tabela CNPq): 1.03.02.02-6 Modelos Analíticos e de Simulação

**RESUMO:** No ano de 2020 o Sistema Nacional de Informação Sobre Saneamento (BRASIL, 2021) registrou a massa média *per capita* de resíduos sólidos domiciliares (RDO) e resíduos públicos (RPU) coletada diariamente de 0.97 kg por habitantes, em relação a população total do Brasil. Enquanto a massa coletada seletivamente, seja através da coleta porta a porta ou em postos especializados, foi de 15,3 kg/habitante/ano. São coletados aproximadamente 354 kg/habitante/ano e mesmo assim, menos de 5% desses resíduos passam por processo de separação e reciclagem. Faz-se necessário um auxílio computacional no processo de triagem desses materiais, na busca por melhorias na seleção. Diante deste problema, o objetivo deste trabalho é avaliar comparativamente técnicas de aprendizagem de máquina para classificar imagens de objetos como reciclável ou orgânico. Serão analisadas técnicas de aprendizagem de máquina capazes de identificar imagens e categorizar em duas classes. Com isso, será possível identificar a eficácia dos resultados considerando a melhor precisão nos resultados e a menor taxa de erro.

**PALAVRAS-CHAVE:** Aprendizagem de Máquina; algoritmos; Reciclável; Orgânico.

#### Comparative analysis of machine learning techniques for disposable materials classification

**ABSTRACT:** In 2020, the National Sanitation Information System (BRAZIL, 2021) recorded the average per capita mass of household solid waste (RDO) and public waste (RPU) collected daily of 0.97 kg per inhabitant, in relation to the total population of Brazil. While the mass collected selectively, either through door-to-door collection or at specialized posts, was 15.3 kg/inhabitant/year. Approximately 354 kg/inhabitant/year are collected and even so, less than 5% of this waste goes through a separation and recycling process. It is necessary a computational aid in the process of sorting these materials, in the search for improvements in the selection. Faced with this problem, the objective of this work is to comparatively evaluate machine learning techniques to classify images of objects as recyclable or organic. Machine learning techniques capable of identifying images and categorizing them into two classes will be analyzed. Therefore, it will be possible to identify the effectiveness of the results considering the best precision in the results and the lowest error rate.

**KEYWORDS:** Machine Learning; Algorithm; Recyclable; Organic.

#### INTRODUÇÃO

A necessidade de um gerenciamento apropriado para os resíduos sólidos tem engendrado um desafio em nossa sociedade devido aos diversos problemas ocasionados pelo descarte irregular. São produzidos valores acima de 78,3 milhões de toneladas de resíduos sólidos anualmente somente no Brasil a estimativa é de um valor aproximado a 5,7 bilhões de reais com o potencial retorno para a economia caso fossem reciclados esses materiais. (BOEHM, 2018).

Uma das maneiras de redução dos altíssimos índices de descarte incorreto é utilização de instrumentos legais para a responsabilização de quem descartar incorretamente um determinado resíduo

## 13º Congresso de Inovação, Ciência e Tecnologia do IFSP - 2022

sólido (PARRA; NASCIMENTO; FERREIRA, 2010). A preocupação legal, não dispensa a necessidade de outras ações a serem desenvolvidas e aplicadas para minimizar os efeitos deste problema.

Buscando alicerçar os benefícios providos pela visão computacional, no objetivo de alcançar uma alternativa auxiliar na reciclagem, este trabalho propõe a avaliação 4 diferentes algoritmos de aprendizagem de máquina para classificar imagens de objetos sendo categorizados em recicláveis ou orgânicos, a fim de propor uma alternativa computacional de melhoria ambiental e econômica.

### MATERIAL E MÉTODOS

No desenvolvimento do proposto, foi utilizado o *software* Orange, contendo diversas ferramentas para visualização e mineração de dados, de código aberto, contendo 10849 imagens classificadas em duas categorias sendo elas: orgânicas e recicláveis. As imagens foram carregadas como um vetor e analisadas utilizando a arquitetura Inception V3 e avaliadas localmente sendo computadas as representações vetoriais. Essa arquitetura, Inception V3 utiliza a rede neural profunda da Google utilizada para o reconhecimento de imagens (XIAOLING XIA; CUI XU; BING NAN, 2017). As imagens embarcadas foram treinadas passando por 4 algoritmos diferentes para posteriormente serem avaliadas quanto ao objetivo de identificação das imagens como orgânicas ou recicláveis.

Os algoritmos analisados neste trabalho são: I) *Gradiente boosting*, fazendo uso de técnicas de regressão e classificação e para fornecer a previsão (NATEKIN E KNOLL, 2013), consideramos as configurações da biblioteca *Scikit Learning*. II) *Random Forest*, por sua vez, construindo uma série de árvores aleatoriamente para classificar as imagens (CUTLER; CUTLER; STEVENS, 2012). Neste algoritmo foram utilizadas 10 árvores com 20 de profundidade. Não foram considerados subconjuntos menores que 5 para essa avaliação. III) o SVM, (*Support Vector Machine*), mapeando pontos considerados para treinamento, levando em conta um determinado intervalo de pontos entre as duas categorias (CHAUHAN; DAHIYA; SHARMA, 2019). A tolerância numérica para esta análise foi considerada 0,0010 em um limite de 100 iterações. IV) Perceptron multicamada (RAMCHOUN, et al., 2016) com retropropagação, em sua função de ativação foi escolhida a função de unidade linear retificada, como solucionador de pesos foi escolhido o otimizador baseado em gradiente estocástico.

A avaliação contará com apoio da elaboração da matriz de confusão com os resultados de cada algoritmo e de uma ferramenta de pontuação e testes, contendo detalhes sobre os resultados encontrados. Nesta abordagem consideramos fatores como curva característica do operador receptor (ROC), capaz de avaliar a taxa entre verdadeiros positivos e falsos positivos.

A análise desse parâmetro mostra o quão são fiéis os resultados encontrados no classificador em relação aos dados obtidos no teste por meio de uma média harmônica entre precisão e *Recall*. Para completar os parâmetros de análises, teremos o *recall*, também descrito como sensibilidade, e a precisão sendo os fatores avaliativos da matriz de confusão contemplados, respectivamente, pelas equações 1 e 2 onde:

VP corresponde aos Verdadeiros positivos;

VN verdadeiros negativos;

FP equivalente aos falsos positivos;

FN falsos negativos.

$$\text{Sensibilidade} = \frac{VP}{VP+FN} \quad (1) \quad \text{Precisão} = \frac{VP}{VP+FP} \quad (2)$$

### RESULTADOS E DISCUSSÃO

Encontrado os primeiros resultados, fez-se necessário elaborar uma tabela dos testes avaliativos dos algoritmos.

TABELA 1. Pontuação de cada algoritmo testado.

## 13º Congresso de Inovação, Ciência e Tecnologia do IFSP - 2022

1.	Algoritmos	Precisão	Sensibilidade	F1	AUC
	<i>Neural Network</i>	0.971	0.971	0.971	0.995
	SVM	0.835	0.797	0.796	0.900
	<i>Gradiente Boosting</i>	0.952	0.952	0.952	0.990
	<i>Random Forest</i>	0.926	0.926	0.926	0.975

Em análise da tabela 1, nota-se em um primeiro momento, um comportamento melhor adequado para a situação atual, a utilização do *Neural Network* considerando além de sua precisão ser acima dos outros testados, o melhor valor em relação a sensibilidade.

Vale salientar também sobre os algoritmos, em uma análise geral, uma leve similaridade abrindo precedentes para outros fatores a serem abordados futuramente por não fazerem parte do escopo deste trabalho, tais como desempenho de *hardware* e possibilidades de paralelismo.

A partir de então será necessário avaliar a precisão do classificador abordando o resultado por meio da elaboração da matriz de confusão referente a aplicação de cada algoritmo.

		Redes Neurais		SVM	
		Classes Previstas			
		Orgânico	Reciclável	Orgânico	Reciclável
Classe Esperada	Orgânico	5785	200	4034	1951
	Reciclável	117	4747	247	4917
		Random Forest		Gradiente Boosting	
		Classes Previstas			
		Orgânico	Reciclável	Orgânico	Reciclável
Classe Esperada	Orgânico	5665	320	5710	275
	Reciclável	482	4382	250	4614
				Verdadeiros positivos	
				Falsos Positivos	

FIGURA 1: Matriz de confusão gerada a partir dos resultados em cada algoritmo.

As matrizes de confusão da figura 1 apresentam de forma numérica os valores acertados e errados considerando cada algoritmo. No indicador classe esperada temos a informação real sobre a imagem avaliada e no indicador classe prevista temos o comportamento de cada algoritmo. A taxa de erro na predição de objetos recicláveis chega a ser metade do segundo melhor colocado nessa avaliação.

Na primeira matriz de confusão, elaborada sobre as redes neurais, é possível encontrar o melhor resultado sendo 98% a taxa de acerto na predição de imagens de objetos orgânicos e 96% a taxa de acerto na predição de imagens de objetos recicláveis. Foi observado sobre o SVM, quando aplicado, a obtenção de 94.2% de taxa de acerto na predição de imagens para objetos orgânicos, todavia, quando necessário prever, imagens de objetos recicláveis, foram alcançados os piores resultados em comparação aos outros, errando 29,7%. Mesmo assim, vale considerar como bons resultados se formos visualizar outros aspectos de aplicação. Ao aplicar o modelo *Random forest*, foi encontrado uma peculiaridade por ter sido o único modelo capaz de prever melhores resultados para objetos recicláveis em comparação a aplicação do mesmo algoritmo para objetos orgânicos alcançando 93,2% para recicláveis e 92.2% para imagens de objetos orgânicos.

## 13º Congresso de Inovação, Ciência e Tecnologia do IFSP - 2022

A partir de então é possível notar os melhores resultados obtidos por meio da utilização de redes neurais, pois, além de apresentar a melhor taxa de acerto para objetos orgânicos, também apresentou melhor taxa de acerto para recicláveis em comparação a todos os outros modelos testados.

Com isso, nosso próximo passo será analisar o comportamento individual dos algoritmos tanto para orgânico quanto para reciclável visando compreender com profundidade as características de acerto e erro.

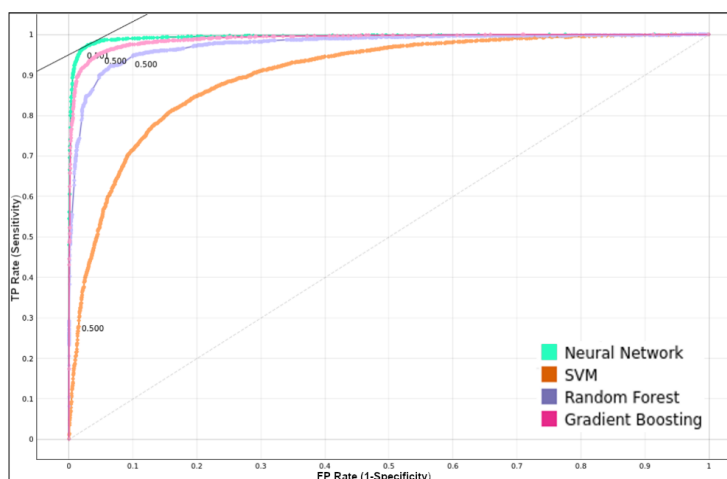


FIGURA 2: Resultado da Curva ROC nas imagens de objetos Orgânicos

O gráfico apresentado na figura 2 exemplifica o comportamento dos algoritmos quando utilizado para treino de imagens de objetos orgânicos. O esperado por essa análise gráfica é um percurso que se aproxime o máximo possível da lateral esquerda e do canto superior do gráfico. Essa aproximação corrobora com o quanto cada algoritmo é capaz de identificar corretamente os resultados.

Na classificação de imagens de objetos orgânicos, o *Neural Network* obteve a melhor taxa de acerto estando aproximado do *Gradient Boosting* e do *Random Forest*. Para esta análise o SVM apresentou a maior distância do resultado desejado.

A partir de então vamos avaliar a curva ROC gerada para classificação de imagens de objetos recicláveis.




FIGURA 3: Resultado da Curva ROC nas imagens de objetos Orgânicos

O gráfico apresentado na Figura 3 exibe a representação de como cada modelo treinado é capaz de separar corretamente os resultados descritos na matriz de confusão, De acordo com a legenda, pode-se observar novamente as Redes Neurais obtendo menor taxa de erro, se aproximando do formato ideal

## 13º Congresso de Inovação, Ciência e Tecnologia do IFSP - 2022

tanto para reciclável quanto para orgânico. Já o SVM, apresentou menor qualidade em classificar em comparação aos outros modelos testados.

Vale salientar ser insuficiente para os resultados, um modelo cujos os acertos estão concentrados em somente uma das classes, pois isso ocasionaria problemas relacionados a sobreajustes.

### CONCLUSÕES

Neste trabalho foi possível apresentar brevemente os resultados da avaliação de algoritmos de aprendizagem de máquina para a identificação de imagens de objetos classificados como orgânicos ou recicláveis. Levou-se em consideração os resultados obtidos a partir da geração de uma matriz de confusão, e os resultados da curva ROC, produzida de cada modelo evidenciando às redes neurais por possuírem o melhor comportamento para o estudo proposto.

A avaliação da curva ROC é uma alternativa de visualização clara sobre a comparação dos resultados de classificação dos modelos considerando suas taxas de erro.

Este trabalho abre portas para futuros estudos por considerar a possibilidade de implantação de redes neurais para identificar por meio de imagens de objetos.

Vale ressaltar, sobre os algoritmos testados, os resultados não tão distantes dos valores obtidos com as redes neurais o mantendo aberta a possibilidade de novas análises com alteração de parâmetros.

### REFERÊNCIAS

BOEHM, Camila; Brasil perde R\$ 5,7 bilhões por ano ao não reciclar resíduos plásticos; **Agência Brasil**, ago. 2018. Disponível em: <https://agenciabrasil.ebc.com.br/geral/noticia/2018-06/brasil-perde-r-57-bilhoes-por-ano-ao-nao-reciclar-residuos-plasticos>. Acesso em 25 ago. 2022.

BRASIL. Ministério do Desenvolvimento Regional. Secretaria Nacional de Saneamento. **Diagnóstico Temático Manejo de Resíduos Sólidos Urbanos - Visão Geral ano de referência 2020**, de 15 de dezembro de 2021. Brasília, 2021.

CHAUHAN, Vinod Kumar; DAHIYA, Kalpana; SHARMA, Anuj. **Problem formulations and solvers in linear SVM: a review**. Artificial Intelligence Review, v. 52, n. 2, p. 803-855, 2019.

CUTLER, Adele; CUTLER, D. Richard; STEVENS, John R. Random forests. In: **Ensemble machine learning**. Springer, Boston, MA, 2012. p. 157-175.

NATEKIN, Alexey; KNOLL, Alois. Gradient boosting machines, a tutorial. **Frontiers in neurorobotics**, v. 7, p. 21, 2013.

PARRA, Cristina Vilela; NASCIMENTO, Ana Paula Branco do; FERREIRA, Mauricio Lamano. **Reutilização e reciclagem de pneus, e os problemas causados por sua destinação incorreta**. XIV ENCONTRO LATINO AMERICANO DE INICIAÇÃO CIENTÍFICA EX ENCONTRO LATINO AMERICANO DE PÓS-GRADUAÇÃO–Universidade do Vale do Paraíba, 2010.

RAMCHOUN, Hassan et al. **Multilayer perceptron: Architecture optimization and training**. 2016.

XIAOLING XIA; CUI XU; BING NAN. **Inception-v3 for flower classification**. 2017 2nd International Conference on Image, Vision and Computing (ICIVC). **Anais...** Em: 2017 2ND INTERNATIONAL CONFERENCE ON IMAGE, VISION AND COMPUTING (ICIVC). Chengdu, China: IEEE, jun. 2017. Disponível em: <http://ieeexplore.ieee.org/document/7984661/>. Acesso em: 14 set. 2022