Uso do algoritmo de classificação Support Vector Machine para a classificação de cultura-solo em nível de pixel: comparação dos diferentes parâmetros e desempenho dos dados RGB e HSL

Gustavo Camargo Alves - camargo.alves@aluno.ifsp.edu.br - IFSP Campus Registro Roberson Paulo Valencise - roberson.p@aluno.ifsp.edu.br - IFSP Campus Registro Sherfis Gibran Ruwer - sherfis@ifsp.edu.br - IFSP Campus Registro Michelle de Oliveira Parreira Ruwer - parreira.michelle@ifsp.edu.br - IFSP Campus Registro

INTRODUÇAO

A agricultura passou por diversas transformações tecnológicas nas últimas décadas e tais avanços a levaram a um nível de macrogerenciamento cada vez maior. Apesar dos benefícios trazidos por tal gerenciamento, diversos problemas surgiram em decorrência dele. O combate a plantas daninhas nas plantações da forma que é realizado atualmente (Figura 1) provoca sérios problemas ao meio ambiente e majora o custo de produção (ZHAI, 2020). No contexto da agricultura 4.0 novas tecnologias surgiram para mitigar tal maleficio.



Figura 1. Aplicação terrestre e aérea de agrotóxicos. Fotos: Henry Milleo/ Agência pública/Repórter Brasil e Edmarjr/Commons Wikimedia Como alternativa à tal aplicação surge a utilização de algoritmos de classificação com as tecnologias de visão computacional, em que por meio da identificação computacional da planta daninha em meio à plantação é possível a aplicação do herbicida de forma localizada ao invés da aplicação convencional como na Figura 2.

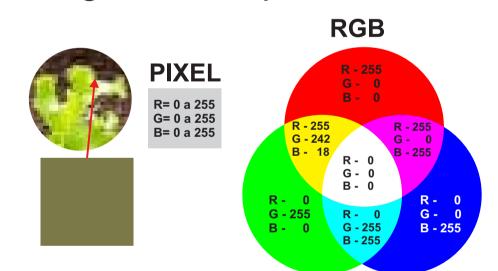


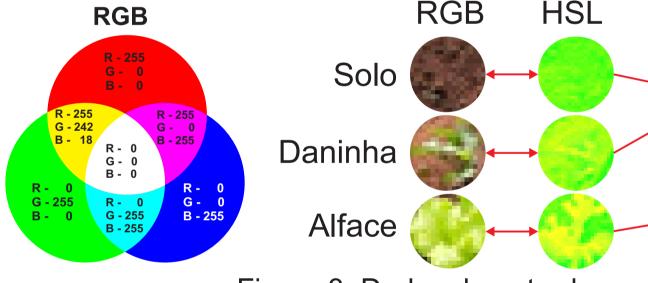


Figura 2. Robô Delta no campo e cultura de alface infestada por plantas daninhas. Fotos: Site stylourbano.com.br e R.P.Valencise A presente pesquisa tem o objetivo de, por meio da aplicação do algoritmo Support Vector Machine (SVM) com o uso do software WEKA (Waikato Enviroment for Knowledge Analysis), identificar o desempenho de classificação do algoritmo SVM com seus diferentes parâmetros nos valores RGB e HSL de um *pixel* na classificação dele como pertencente à classe solo ou classe cultura.

FUNDAMENTAÇÃO TEÓRICA

A imagem é composta por *pixels* que são vários pontos com informações RGB para composição da imagem. Cada *pixel* contém três valores que correspondem a uma cor específica (Figura 3).





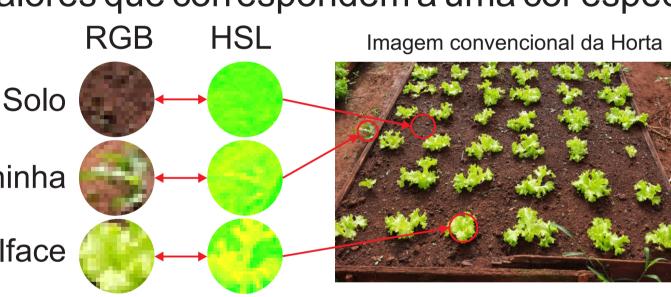
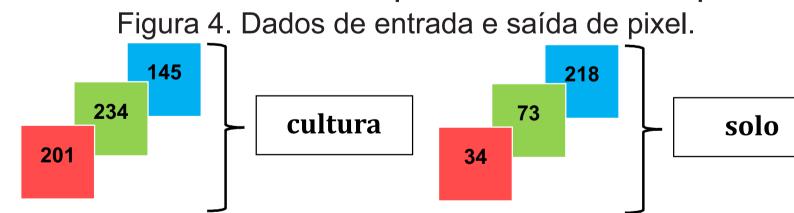


Figura 3. Dados de entrada e saída de pixel.

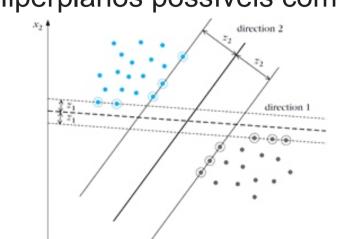
A Figura 4 demonstra, como exemplo a classificação de um pixel para demonstrar a relação entre os dados de entrada e saída de um sistema de aprendizado de máquina supervisionada.



Fonte: Autoria dos próprios autores (2021)

O algoritmo support vector machine é um algoritmo de classificação ou regressão em que se define o hiperplano que melhor separe linearmente os dados. A Figura 5 apresenta um conjunto de dados com dois possíveis hiperplanos.

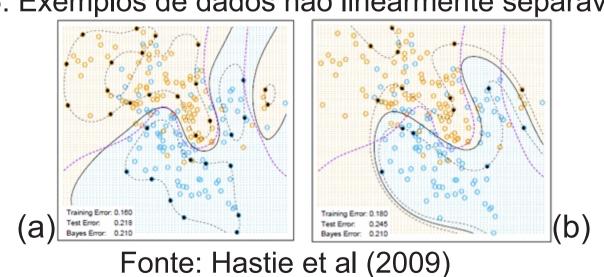
Figura 5. Hiperplanos possíveis com direções distintas



Fonte: Theodoridis (2009)

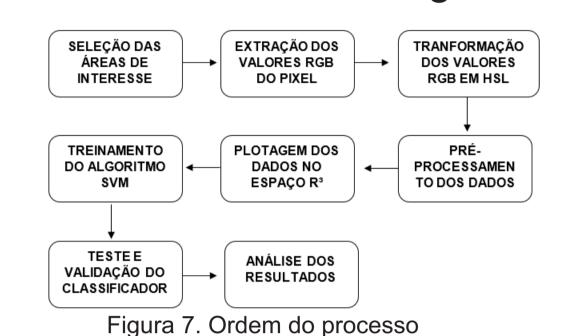
Nem sempre os dados se comportam de forma que seja possível separá-los linearmente, conforme a Figura 6 (a) e (b). Para que seja possível a plicação do SVM nesse caso, faz-se necessária a aplicação de funções kernel.

Figura 6. Exemplos de dados não linearmente separáveis



MATERIAL E MÉTODOS

A presente pesquisa realizou atividades a fim de obter os resultados úteis ao objetivo da pesquisa, seguindo a ordem constante no fluxograma da Figura 7.

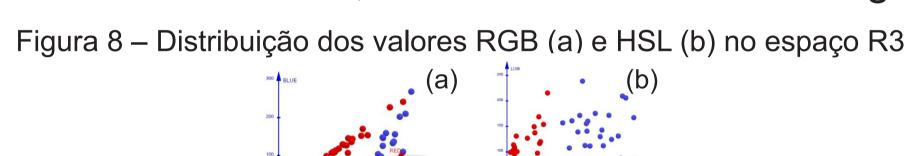


Foram selecionadas pequenas partições da imagem de forma que todos os *pixels* presentes nesta área de interesse tivessem sua classe conhecida. A Tabela 1 apresenta o número de instâncias utilizadas de cada classe.

Tabela 1 - Quantidade de instâncias por classe		
Classe	Instâncias (<i>Pixels</i>)	
Cultura	5.142	
Solo	6.468	
Total	11.610	
Fonte: Autoria dos próprios autores (2021		

RESULTADOS

Foram realizadas projeções no espaço R³ utilizando a ferramenta GeoGebra a fim de observar o comportamento dos dados, conforme observa-se na Figura 8.



Fonte: Autoria dos próprios autores (2021)

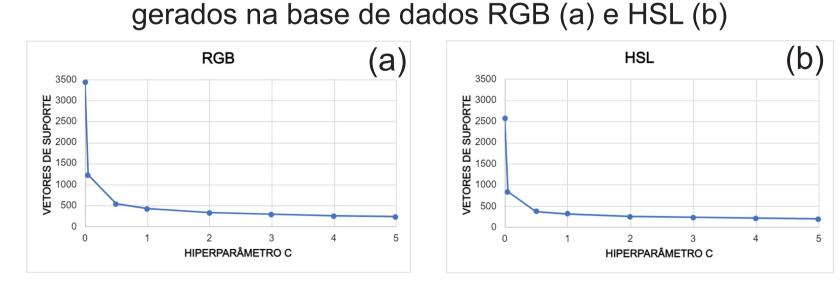
As primeiras aplicações foram realizadas utilizando o valor do parâmetro C de 1, conforme padrão do WEKA. As variações ocorreram na função kernel utilizada e valores utilizados do pixel (RGB ou HSL). A Tabela 2 detalha os resultados obtidos.

_	Tabela 2 - Resultados obtidos nas diferentes funções kernel e tipo de dado (RGB e HS					
	Dados	Kernel	Tempo de Processamento (S)	Acurácia (%)		
_	RGB	Polinomial Grau 2	6.7	99.56		
	HSL	Polinomial Grau 2	6.53	99.55		
	RGB	Linear	0.09	99.52		
	HSL	Polinomial Grau 3	6.56	99.45		
	RGB	Polinomial Grau 3	12.66	99.42		
	RGB	Polinomial Grau 4	16.77	99.29		
	HSL	Polinomial Grau 4	11,12	99.24		
	HSL	Linear	0.39	98.78		
	HSL	RBF	33.08	98.54		
	RGB	RBF	112.47	97.92		
_	Forston Antonio dos majorios sutemas (2004)					

Fonte: Autoria dos próprios autores (2021)

As Figuras 9(a) e 9(b) apresentam a correlação entre a variação do hiperparâmetro C e os vetores de suporte utilizados na definição do hiperplano de classificação utilizando kernel polinomial de grau 2.

Figura 9 – Correlação do valor do hiperparâmetro C e vetores de suporte



Fonte: Autoria dos próprios autores (2021)

CONCLUSÕES

Verifica-se a não necessidade de transformação dos dados RGB em HSL para a classificação cultura-solo. O kernel polinomial de grau 2 apresenta melhor desempenho na classificação.

REFÊRENCIAS:

ZHAI, Zhaoyu et al. Decision support systems for agriculture 4.0: Survey and challenges. Computers and Electronics in Agriculture, v. 170, p. 105256, 2020. Disponível em: https://doi.org/10.1016/j.compag.2020.105256. Acesso: 20 de setembro de 2021. STEINWART, Ingo and A. Christmann. Support Vector Machines, Information science and statistics. (2008).

