



Mapeamento de plantas daninhas

Uma comparação de análise clássica e moderna

Alecsander Gesser | pasqualli.alecs@gmail.com
Caio Blumer | caioblumer5@gmail.com

Agricultura de precisão é um novo campo de aplicação categorizado principalmente pelo uso de tecnologia para aumentar a produtividade e qualidade enquanto mantendo o uso das boas práticas e preservando o meio ambiente. Exemplos de agriculturas de precisão incluem: gerenciamento de dados de cultivo, drones (McBratney, A., 2005).

Um problema muito desafiador para a área é o mapeamento de plantas invasoras para otimização do uso de agentes químicos e por consequência otimização de diversos recursos para o agricultor. Neste, foram propostos métodos clássicos e modernos para mapeamento de uma cultura específica de planta invasora, sua família derivada das gramíneas (Cynodon Sp.) conhecida como Grama Seda.

1) Método Clássico

Para discriminação de classes:

- ☐ Classe 1 - Cultura+Solo
- ☐ Classe 2 - Cynodon Sp.

Primeiramente utilizou-se o método de distância de (Mahalanobis, P. C., 1936) para discriminação entre vegetação (cultura e planta invasora) e solo. Após, um breve tratamento de morfologia matemática para pequenos ruídos. Prosseguindo para a discriminação entre cultura e planta invasora, um descritor de características foi utilizado (histograma de gradientes), com 32 orientações e um tamanho de célula de 25. Para a final classificação dos dados, o método de *Support Vector Machine* foi usado com seus devidos parâmetros e pesos de classes para corrigir o desbalanceamento do dataset.

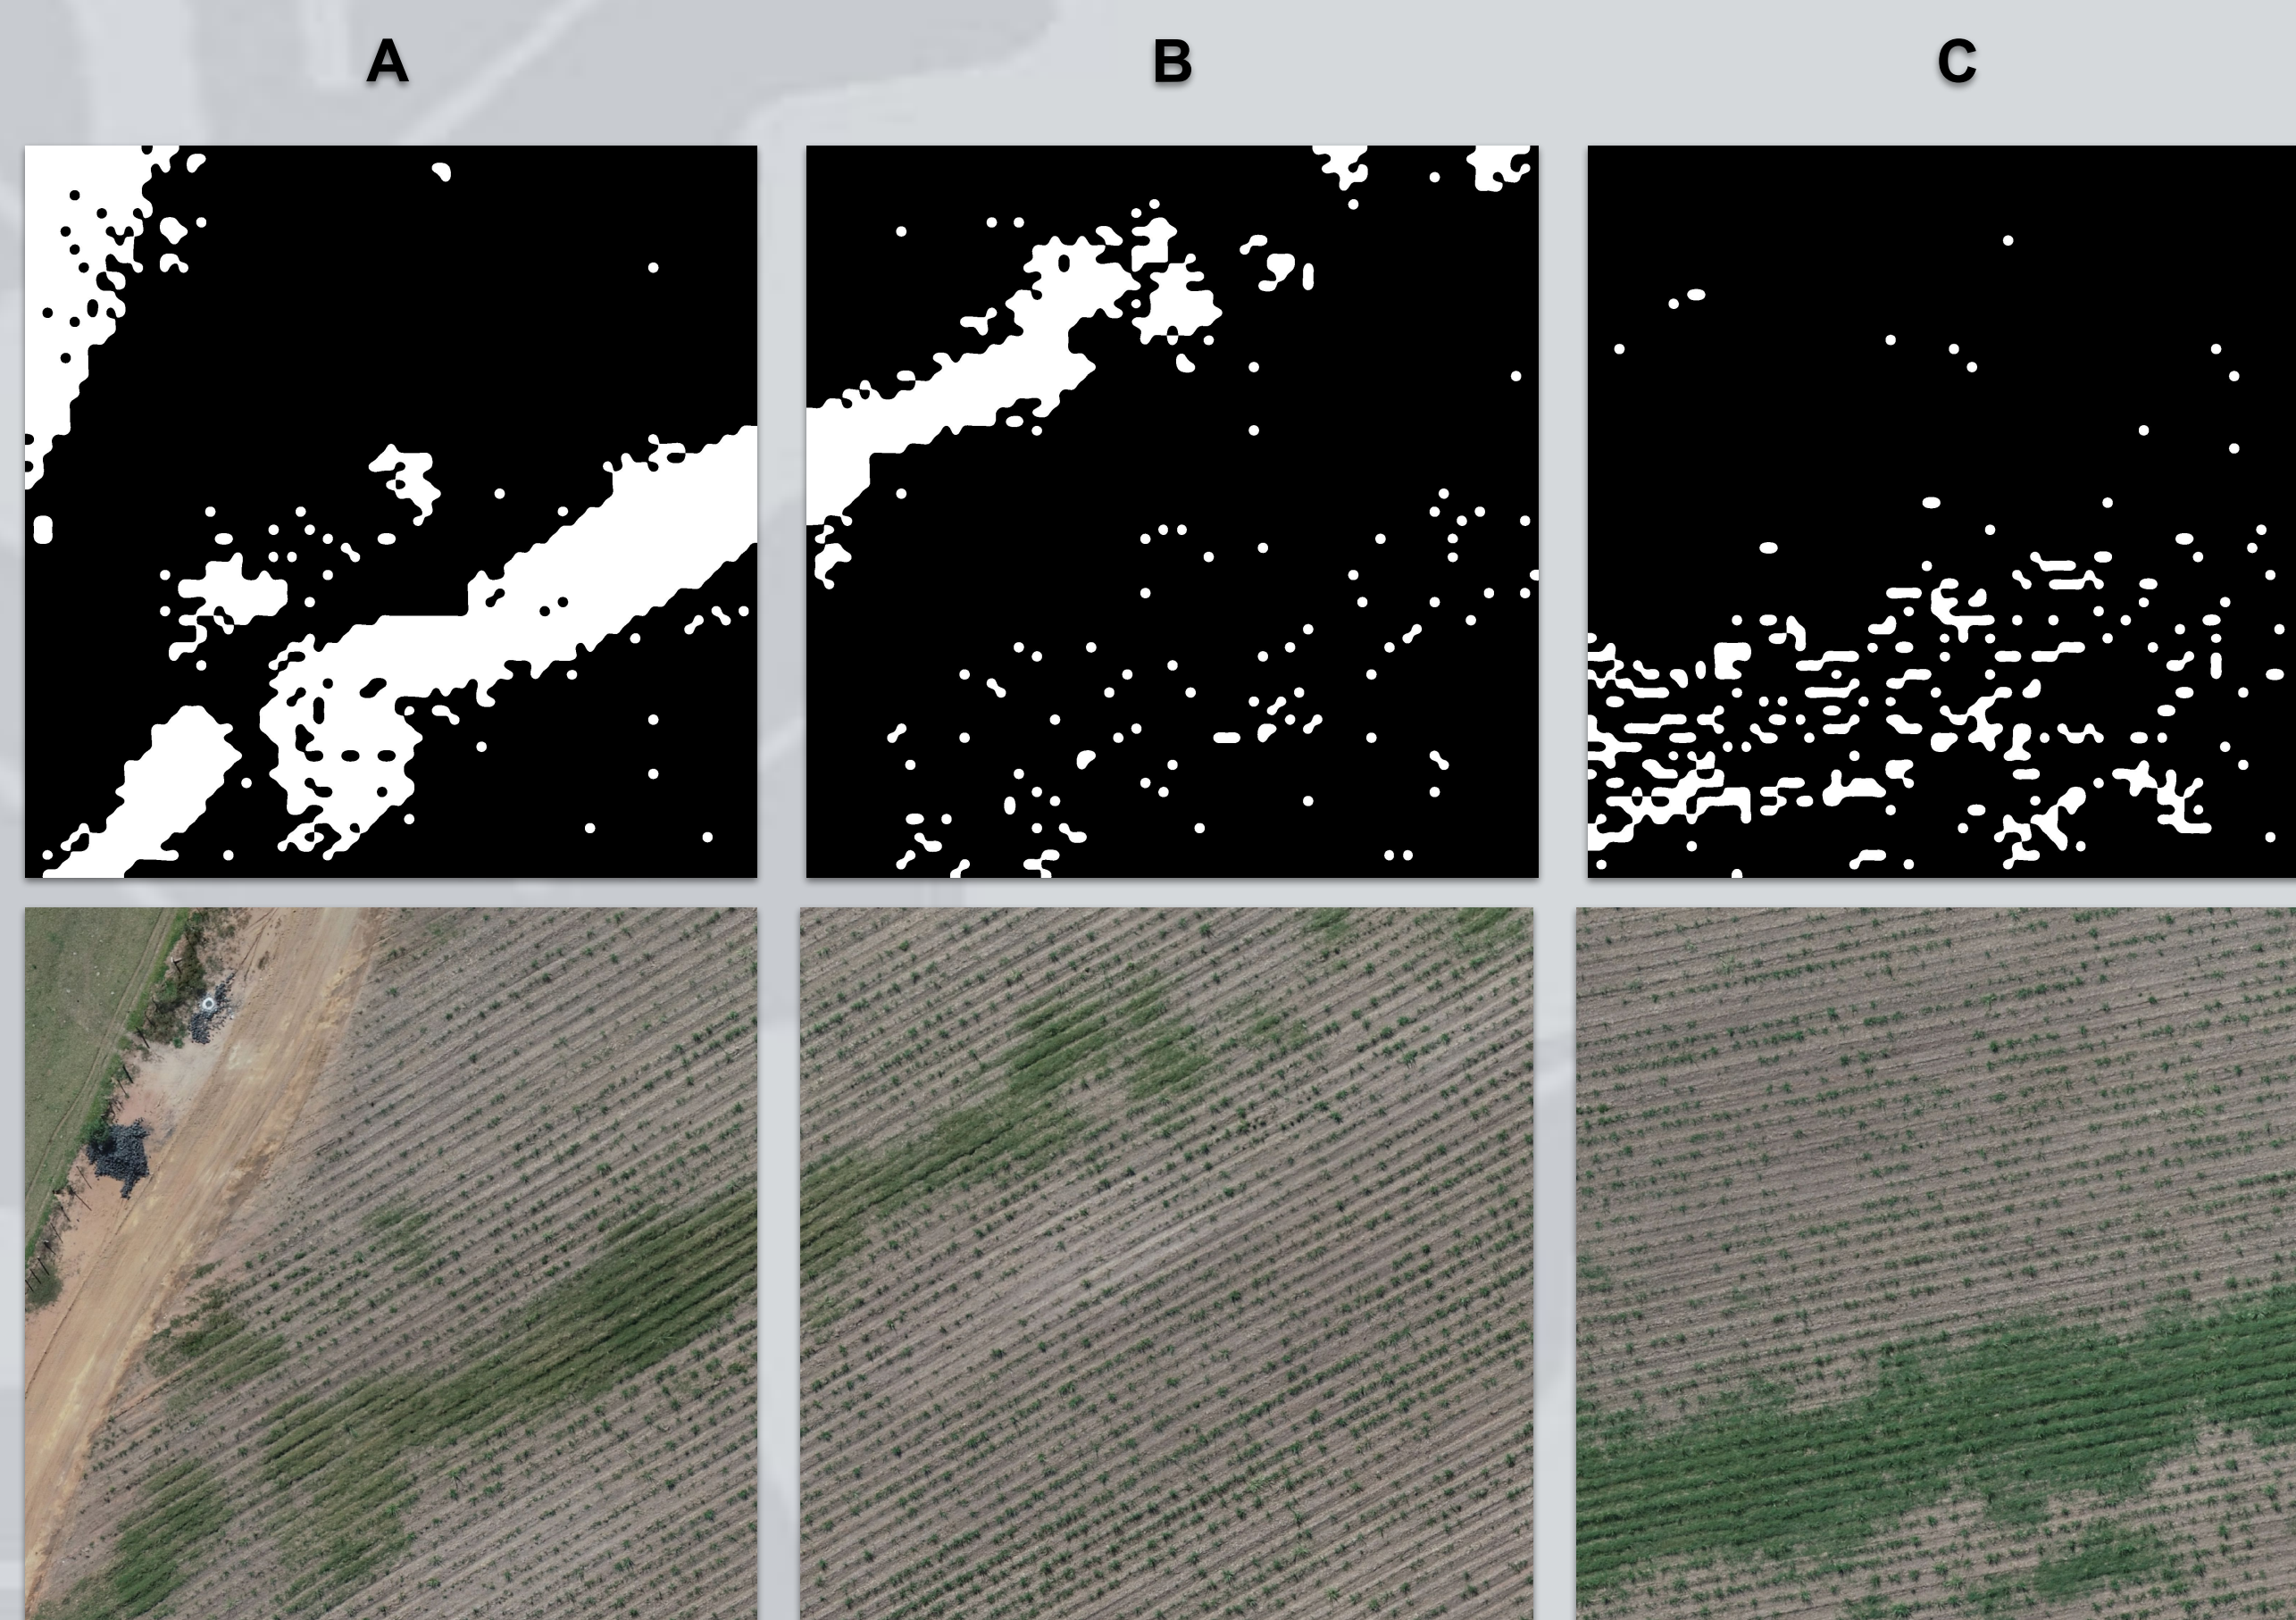


Fig. 1 - Resultados método clássico

Tile	F1 Score	Precision	Accuracy
A	0.7252	0.5880	0.8767
B	0.3434	0.4043	0.7709
C	0.7089	0.5466	0.9396

2) Método Moderno

Nesta abordagem, fizemos o uso da arquitetura SegNet, resultados preliminares se mostraram muito promissores chegando a valores de *Accuracy de 0.9*. Com dados de treinamentos abrangendo 618,1294 ha, com uma resolução de 3 cm/pixel, nosso *ground truth* é definido por dados geoespaciais vetorizados gerados por expert da área. Para o treinamento transformamos o vetor geoespacial para imagem e assim prosseguir ao treinamento padrão da ferramenta.



Fig. 2 Resultados Método CNN

3) Considerações finais

Como planos futuros, técnicas de data augmentation seriam muito benéficas para o método de redes neurais, pois observamos que pequenas diferenças de brilho levaram a rede a ter um comportamento não esperado. Outro ponto a se levar em consideração seriam o uso de FCNs já minimizando o problema entre bordas, e assim também otimizando ainda mais o tempo de processamento. Por fim, observa-se uma grande diferença a nível de generalização do método clássico ao moderno, testes realizados com amostras de outra plantação mostrou que o classificador clássico não é capaz de lidar com pequenas mudanças nas características. Por outro lado, observamos que ao utilizar redes neurais o classificador se tornou muito mais generalizável.