



SISTEMA PARA RECONHECIMENTO DE NÚVENS PARA SISTEMA FOTOVOLTAICO

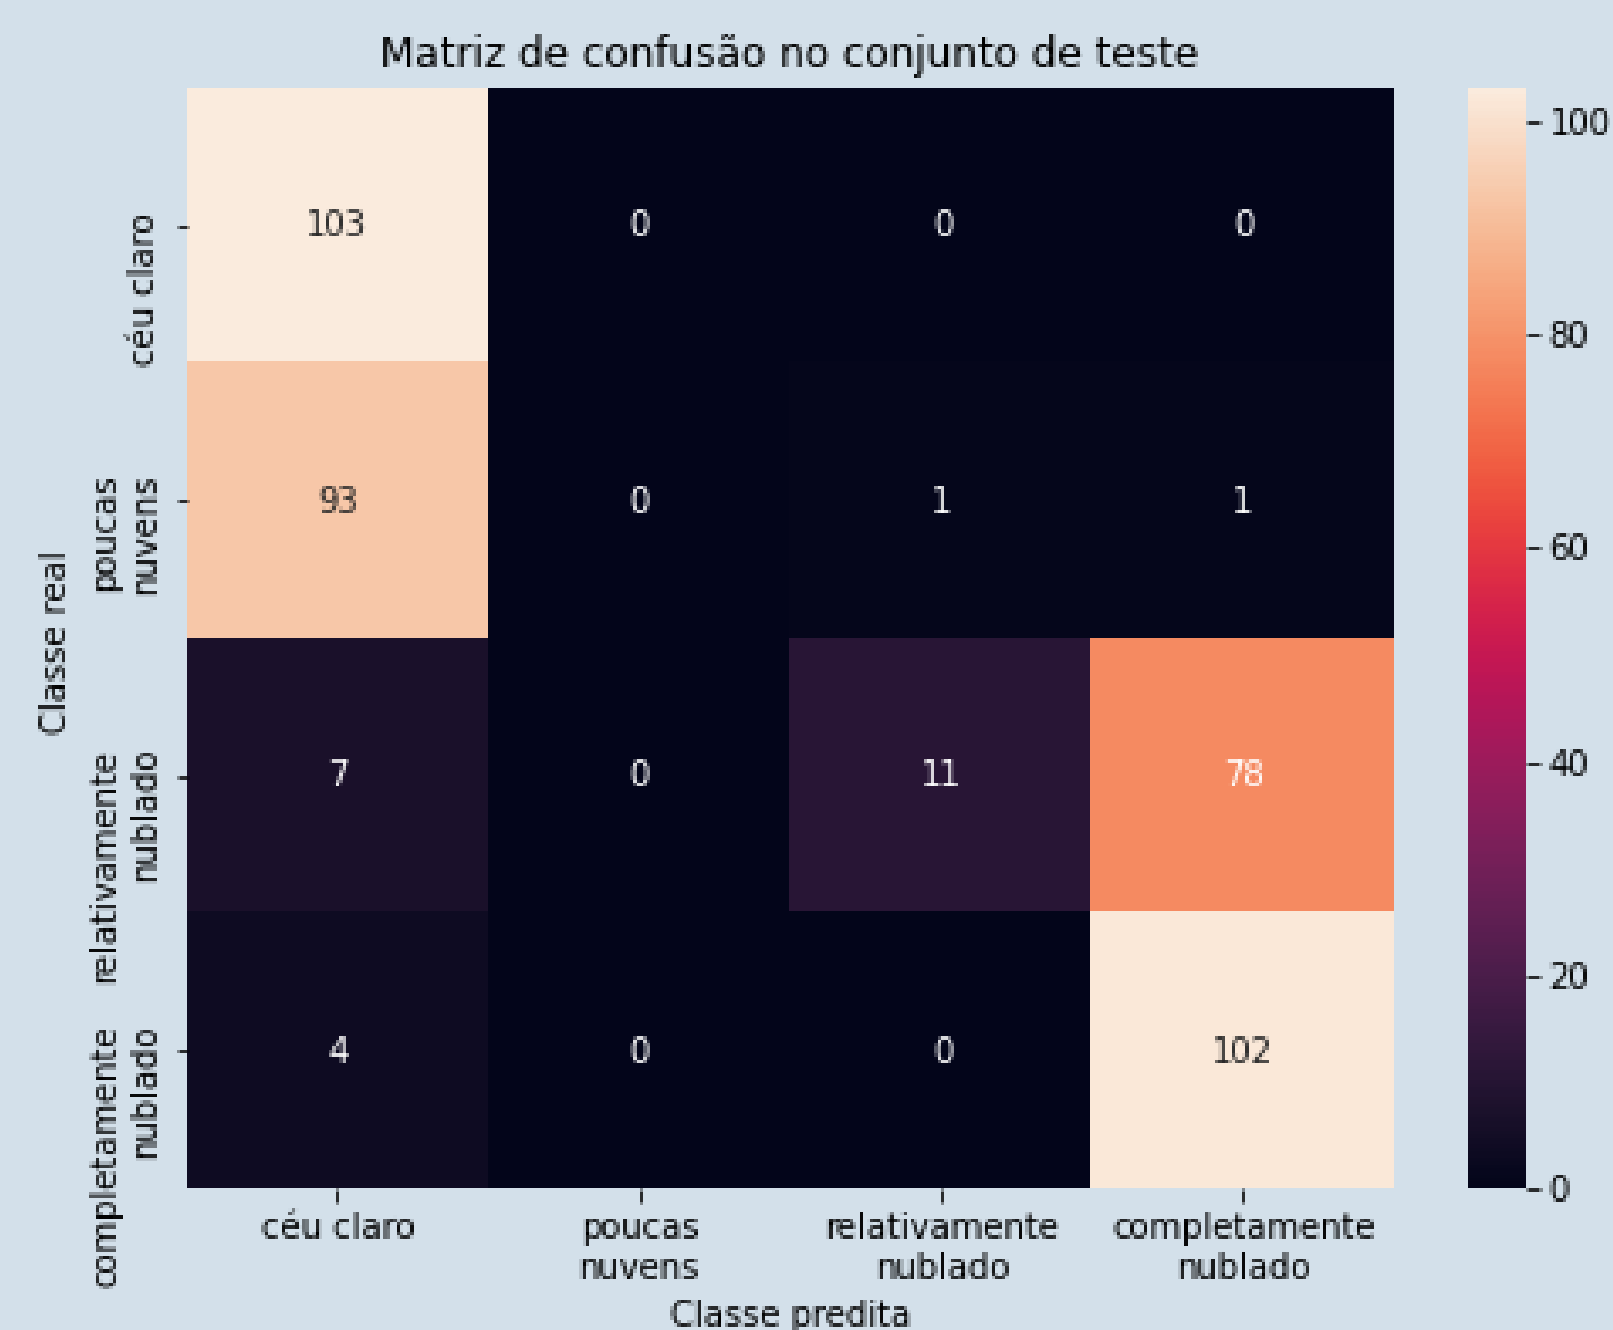
Marcos Moretto e Nicolas Moreira Branco

Objetivo e base de dados

A adoção das energias renováveis têm crescido consideravelmente nos últimos anos, seja devido a fatores técnicos ou sociais. O aumento de sua participação pode ser nocivo ao sistema energético, devido a serem intermitentes, caso não possam ser previstas com precisão. Sabe-se que o percentual de nuvens no céu é muito relevante para a previsão de geração fotovoltaica, portanto esse trabalho buscou comparar os resultados de um método clássico e outro com *machine learning* para essa tarefa. Foram utilizados dados de uma Sky Imager instalada na estação SONDA em Florianópolis. Os dados foram divididos em céu claro, poucas nuvens, relativamente nublado e completamente nublado. Os dados foram divididos sendo 1320 para treinamento, 400 para validação e 400 para teste. As imagens do banco têm resolução de 1600x1200x3.



Exemplo de imagem utilizada no estudo, classificada como relativamente nublado capturada pela SONDA de Florianópolis em 01 de março de 2018. Imagem recortada devido as bordas escuras.



Visão computacional clássica

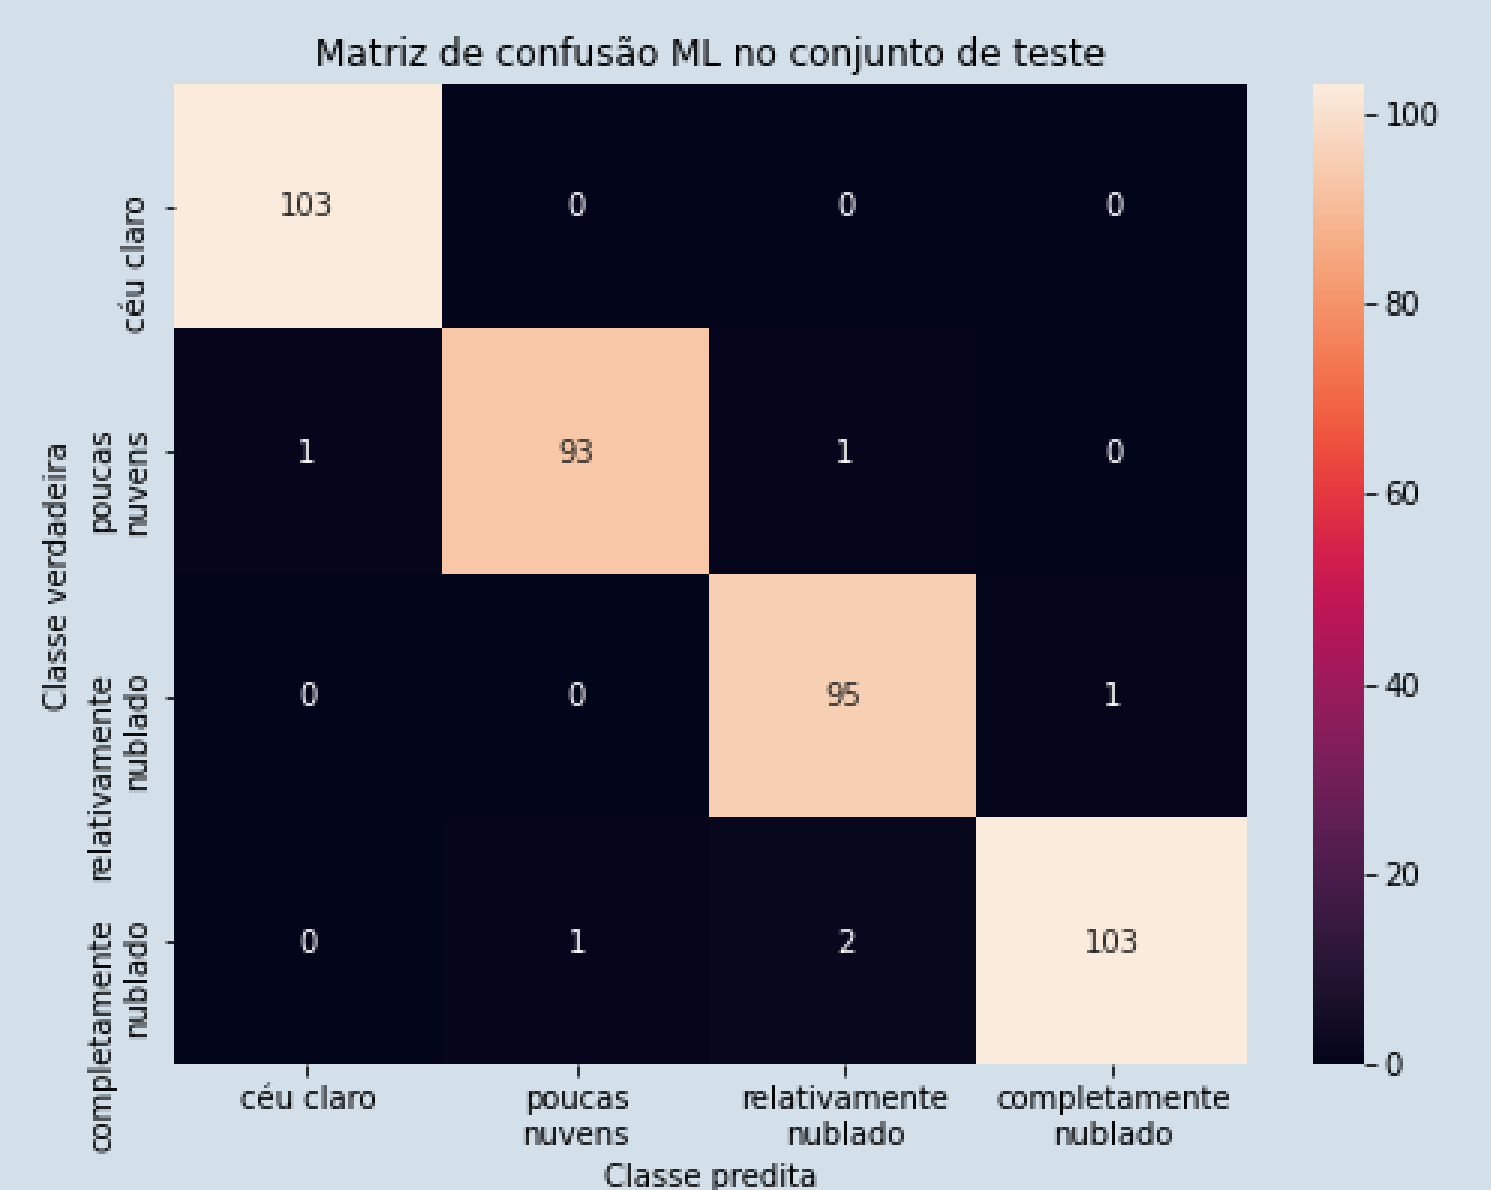
A imagem foi utilizada com a resolução original, sobre as quais foi aplicado um threshold colorido utilizando o `inRange((121, 0, 0),(255, 255, 130))`, a partir disso calculou-se a presença de pixels brancos que representam o céu, e então estimou-se a classificação, nesta estimativa observou-se que as classificações pouco-nublado ou parcialmente nublado acabavam sendo confundidas com céu claro e nublado respectivamente. Portanto conclui-se que o `inRange` pode ser melhorado para criar uma diferença maior entre as classes que foram entendidas como outras classes, o que melhoraria o modelo utilizando visão computacional clássica. Também é importante observar as imagens e identificar a separação das classes pela contagem de pixels brancos.

Aprendizado de máquina

A imagem inicial foi recortada e teve sua resolução diminuída para 100x100x3. As limitações de processamento e de memória dos modelos de *machine learning* fazem esse processo necessário, que levou 56 segundos para ser processado. Esse conjunto de dados foi utilizado para treinar o seguinte modelo CNN, utilizando a otimização Adam, perda categórica esparsa, acurácia como métrica, 10 épocas de treinamento e taxa de aprendizado de 0,001.



Esse modelo obteve 98,8% de acurácia no conjunto de treinamento, 98,0% no conjunto de validação e 98,2% no conjunto de teste.



Matriz de confusão referente a previsão do modelo no conjunto de teste.

Resultados e Conclusões

Esse trabalho pode demonstrar alguns resultados interessantes da comparação de metodologias de visão computacional clássica e aprendizado de máquinas. No caso da clássica, dispensa-se a necessidade de recorte e redução de resolução das imagens, porém gasta-se uma boa quantidade de tempo do projetista selecionando todo o processo manualmente. Por outro lado, o *machine learning* facilita esse processo, automatizando boa parte do que era escolhido pelo usuário, porém aumenta a complexidade dos modelos e requer pré-processamentos das imagens de entrada. Sabendo dessas diferenças é interessante perceber que o modelo clássico tem resultados interessantes para algumas classes, porém ruim para outras, comparado aos resultados com aprendizado de máquinas. Também, o resultado obtido com a visão computacional clássica, pode ser melhorado trabalhando mais as separações das classes e refinando o `inRange` com mais imagens, e melhor trabalhando a separação de classes.

Próximos trabalhos: complementar modelos, diversificar, aumentar o conjunto de dados e aumentar a observação das classes geradas pelo modelo clássico e por aprendizado de máquina.