



Avaliação da classificação automática de imagens hiperespectrais após a redução da dimensionalidade usando algoritmos de *Manifold Learning*

Rafael V. da SILVA¹; Diego SAQUI²

RESUMO

Imagens hiperespectrais (IHs) possuem centenas de bandas e devido a isso maior capacidade de discriminação, o que beneficia na precisão de diversas aplicações de classificação. Entretanto, a alta resolução espectral e alta correlação de bandas das IHs podem provocar a ocorrência da maldição da dimensionalidade. Dessa forma, o estudo de métodos de redução de dimensionalidade (RD) como a Análise de Componentes Principais (PCA) e métodos de *manifold learning*, (como *t-distributed Stochastic Neighbor Embedding* [t-SNE]) são relevantes nessas imagens. Nesse cenário, o objetivo do presente trabalho é analisar a classificação final de pixels de IHs fazendo uso dos classificadores *K-Nearest Neighbors* (KNN) e *Support Vector Machines* (SVM) após o processo de RD usando os procedimentos previamente citados, na qual o redutor t-SNE com o classificador SVM obteve acurácia de 70,81%, enquanto o PCA com KNN teve cerca de 57,32% de acurácia.

Palavras-chave: extração de característica, *manifold learning*, redução de dimensionalidade, imagens hiperespectrais.

1. INTRODUÇÃO

Sensoriamento Remoto (SR) envolve a obtenção de informação sem o contato físico ao objeto ou cena (DE MORAES, 2002), à qual é possível porque diferentes objetos refletem, absorvem e emitem radiação eletromagnética (REM) de forma única. Baseando-se na textura e composição molecular por meio da REM, esta chega a um sensor que é usado para identificar um objeto de interesse, podendo caracterizar precisamente a composição química e discriminar materiais espectralmente similares (GHAMISI et al., 2017). O resultado final desse processo pode ser convertido nas chamadas imagens hiperespectrais (IHs), que fornecem uma ampla gama de informações que podem ser usadas para resolver uma variedade de problemas como análise de safras, mapeamento geológico, exploração mineral, etc.

Em aprendizado de máquina, os algoritmos de classificação como o *K-Nearest Neighbors* (KNN) e *Support Vector Machines* (SVM) visam treinar um modelo usando os dados rotulados existentes, que podem ser utilizados posteriormente para a tomada de decisão em dados desconhecidos. Esses procedimentos são comumente utilizados em conjunto com imagens hiperespectrais (IHs) para possibilitar as diferentes aplicações citadas.

Ainda sobre os classificadores, na maioria dos problemas, cada item de dados é representado por um número maior de dimensões (atributos), na qual pode-se ocorrer a Maldição da Dimensionalidade (HUGHES, 1968). A eficiência da técnica de classificação depende da

¹Rafael Vicente da Silva, IFSULDEMINAS – Campus Muzambinho. E-mail: 12151002569@muz.ifsuldeminas.edu.br.

²Diego Saqui, IFSULDEMINAS – Campus Muzambinho. E-mail: diego.saqui@muz.ifsuldeminas.edu.br.

quantidade de dados de treinamento e da quantidade de dimensões. Se a dimensão dos dados de treinamento for alta e o número de amostras baixo, o modelo pode ficar superdimensionado, o que leva a uma baixa generalização. Portanto, em diversas aplicações, em especial, as que utilizam IHS, muitas vezes necessitam de métodos de redução da dimensionalidade (RD) para lidar com esse problema. Algumas técnicas populares de RD incluem Análise de Componentes Principais (PCA) e o *t-distributed Stochastic Neighbor Embedding* (t-SNE). O t-SNE é um método desenvolvido por Laurens Van Der Maaten et al. (2008), ao qual usa a distribuição *t* de Student para representar os dados em baixas dimensões. PCA utiliza uma transformação ortogonal para converter um conjunto de observações de variáveis possivelmente correlacionadas num conjunto de valores de variáveis linearmente não correlacionadas chamadas de componentes principais (PEARSON, 1901).

Nos últimos anos, devido à presença de um grande número de bandas (características) nos dados, a RD tornou-se mais proeminente para melhorar a precisão da classificação de pixels, e estudos que buscam a extração de características para RD em IHS têm sido realizados. Curiosamente, é mostrado que “Nenhuma técnica de RD única é adequada para atender a todas as aplicações” (DAMODARAN et. al, 2014). Portanto, há uma necessidade de mais investigação para encontrar novas ou melhorar as técnicas de RD existentes. Com isto, o objetivo deste trabalho é avaliar a RD dos dados a partir do uso de algoritmos de *manifold learning*, com o enfoque no melhoramento da classificação de regiões em IHS.

2. MATERIAL E MÉTODOS

A metodologia foi conduzida conforme as etapas de: Pré-processamento, Transformação, Mineração de dados, Avaliação e Interpretação (Fig. 1).

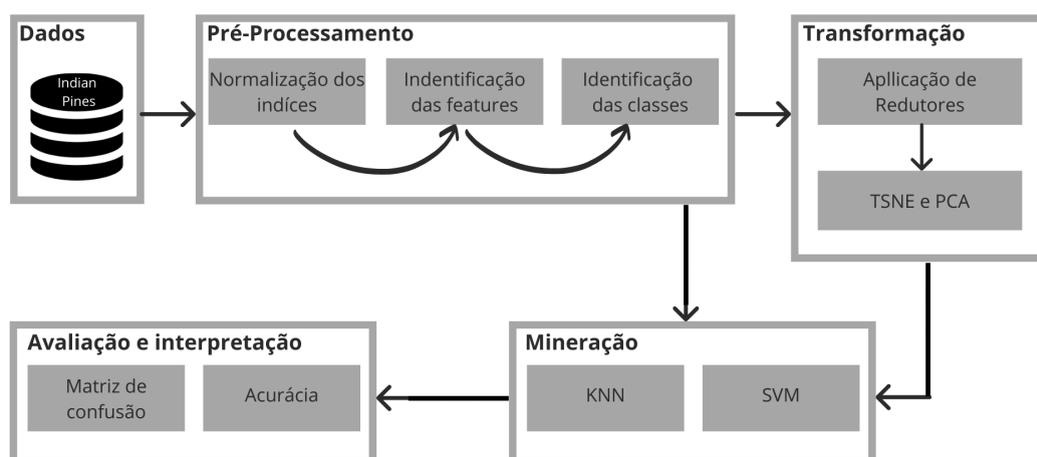


Figura 1. Fluxograma descrevendo as etapas de Análise e Descoberta de Conhecimento (do inglês *knowledge-discovery in databases - KDD*) para as bases de dados Indian Pines.

Os **dados** foram coletados em Junho de 1992 pelo sensor AVIRIS na região noroeste do estado de Indiana, EUA, a cena identificada como Indian Pines é composta de 145×145 pixels, 200

bandas de refletância com comprimento de onda no intervalo de 0,4 a 2,5 μm e 16 classes que representam diferentes culturas, árvores ou estruturas (construções).

O **pré-processamento** foi a parte responsável pelo tratamento e identificação dos dados a serem analisados na imagem (pixels) para posteriormente identificar as classes, o próximo passo já foi realizar a **mineração** da imagem, classificando sem antes reduzir a dimensionalidade, para assim realizar comparativos com os dados dimensionalmente reduzidos, para isto fez-se uso do KNN, analisando os pixels vizinhos de um intervalo de 100 à 1000, e obtendo a acurácia pela média da iteração, e já o SVM operou com uma taxa de regularização de 3500, utilizando um kernel radial, com coeficiente de kernel escalar. A **transformação** pautou-se em reduzir a dimensionalidade com o PCA para 10 componentes (dimensões) e a redução utilizando o t-SNE foi feita reduzindo de 200 dimensões para apenas 2, com 10 de perplexidade em 1200 iterações. A **avaliação e interpretação** foi realizada através de geração de matriz de confusão análise da acurácia obtida.

3. RESULTADOS E DISCUSSÕES

O trabalho apresentou os redutores de dimensionalidade, t-SNE e PCA, com os classificadores KNN e SVM aplicados à IH *Indian Pines*. Abaixo Tabela 1 apresenta a média da acurácia e tempo em segundos da classificação de *Indian Pines*, utilizando os classificadores KNN e SVM, com e sem os redutores de dimensionalidade, PCA e t-SNE.

	Algoritmo	Acurácia	Tempo (s)
Sem redutor	KNN	69,61%	3,12
	SVM	83,11%	44,63
Com redutor	PCA + KNN	57,32%	1,34
	PCA + SVM	62,50%	128,70
	t-SNE + KNN	59,21%	0,91
	t-SNE + SVM	70,81%	6,08

Tabela 1: Média da acurácia e tempo da classificação de Indian Pines

O classificador SVM obteve um resultado mais satisfatório do que em relação aos demais, porém necessitou de otimização dos parâmetros para o caso, o que já não ocorre ao KNN, pois o mesmo leva em conta apenas a distância de seus vizinhos para a classificação, que no estudo fora estimado da média seus 1000 vizinhos, tendo carência na precisão nos resultados colhidos em questão da RD. Contudo, ao analisarmos o tempo de execução da classificação do SVM com o redutor t-SNE, consegue um tempo de praticamente 7 vezes menor do que o mesmo sem o redutor da classe de *manifold learning*, o com o classificador KNN, e quando aplicado o t-SNE com KNN,

consegue-se um melhor resultado em se tratando de precisão e tempo, obtendo 59,21% de acurácia com um tempo médio de 0,91 segundos por iteração. Portanto, a partir dos resultados obtidos evidencia o fato do uso de RD para o caso de Indian Pines em específico, de modo a obter uma classificação mais rápida e medianamente precisa, e para a otimização da classificação é explícito que o uso do algoritmo de *manifold learning*, t-SNE melhora a acurácia e ainda consegue ser mais rápido na classificação.

4. CONCLUSÕES

O presente estudo introduziu o problema de RD e sua importância na análise de IHS. Uma técnica da classe de métodos de *Manifold Learning* é aplicada, o t-SNE e estudos experimentais são conduzidos à IH, *Indian Pines*. Para o estudo da RD foram usados os redutores PCA e t-SNE juntamente com os classificadores KNN e SVM, os resultados são comparados com técnicas convencionais de RD, como é o caso do PCA, em conjunto ao método t-SNE. Os resultados empíricos mostram que t-SNE possui um bom desempenho em comparação com o PCA, tanto em acurácia, quanto em tempo de execução, projetando dados em duas dimensões e o PCA em 10, provendo uma melhor acurácia, e com a utilização do redutor de dimensionalidade t-SNE com o classificador SVM obtendo uma acurácia de 70,81% , enquanto o PCA com KNN tendo cerca de 57,32% de acurácia.

REFERÊNCIAS

- DAMODARAN, Bharath Bhushan; NIDAMANURI, Rama Rao. **Assessment of the impact of dimensionality reduction methods on information classes and classifiers for hyperspectral image classification by multiple classifier system.** *Advances in Space Research*, v. 53, n. 12, p. 1720-1734, 2014.
- DE MORAES, Elisabete Caria. **Capítulo 1 Fundamentos de sensoriamento remoto.** 2002.
- GHAMISI, Pedram et al. **Advances in hyperspectral image and signal processing: A comprehensive overview of the state of the art.** *IEEE Geoscience and Remote Sensing Magazine*, v. 5, n. 4, p. 37-78, 2017.
- HUGHES, Gordon. **On the mean accuracy of statistical pattern recognizers.** *IEEE transactions on information theory*, v. 14, n. 1, p. 55-63, 1968.
- PEARSON, Karl. LIII. **On lines and planes of closest fit to systems of points in space.** *The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science*, v. 2, n. 11, p. 559-572, 1901.
- VAN DER MAATEN, Laurens; GEOFFREY, Hinton. **"Visualizing data using t-SNE."** *Journal of machine learning research* 9.11 (2008).