

Clasificación de Granos de Polen con Deep Learning y SVM

Matías Roodschild
G.I.T.I.A.
U.T.N. – F.R.T.
Tucumán, Rivadavia 1055
mroodschild@gitia.org

Jorge Gotay Sardiñas
G.I.T.I.A.
U.T.N. – F.R.T.
Tucumán, Rivadavia 1055
jgotay57@gmail.com

Adrián Will
G.I.T.I.A.
U.T.N. – F.R.T.
Tucumán, Rivadavia 1055
adrian.will.01@gmail.com

Abstract

A lo largo de la historia, muchos algoritmos fueron utilizados para los problemas de clasificación, entre ellos los SVM, actualmente los autoencoders son el estado del arte, por su facilidad para obtener características del problema mediante el entrenamiento no supervisado en base a ejemplos, tal como lo haría un ser humano. Entre sus aplicaciones más destacadas, podemos mencionar el reconocimiento de voz, sistemas de seguridad, aplicaciones medicinales, conducción autónoma de vehículos, agricultura de precisión, entre otros. Muchos campos de investigación, poseen una gran variedad de información y presentan determinadas características propias de su naturaleza que dificultan el aprendizaje, entre ellos, podemos mencionar el solapamiento y el desbalance de las clases. En la presente publicación, mostraremos las principales ventajas de incorporar deep learning con autoencoders a los clasificadores SVM y como mejoran el rendimiento.

1. Introduction

A lo largo de la historia, muchos algoritmos fueron utilizados para los problemas de clasificación, entre ellos: Árboles de Decisión[1], Análisis Discriminante[2], Naive Bayes[3], Nearest Neighbors[4], Redes Neuronales[5], SVM[6], entre otros, actualmente los autoencoders, por su facilidad para extraer características de los datos mediante el entrenamiento no supervisado[7], se han convertido en el estado del arte, al constituir el elemento principal de las redes profundas[8]. Muchos campos de investigación, poseen una gran variedad de información, desde datos numéricos hasta imágenes, y en los problemas de clasificación, es de interés diferenciar los datos, sobre todo, mirar los límites que existen entre unos y otros. Estos límites, muchas veces no son claros, ni puede determinarse fácilmente, es por eso, que la selección de la heurística o la combinación de más de una, determinará el éxito para

resolver el problema. Entre las diferentes heurísticas de clasificación mencionadas, los SVM siempre tratan de brindar la mejor frontera de separación[9]. Los autoencoders son el corazón de funcionamiento de las redes profundas, caracterizándose por la extracción de características de los datos, reflejando de esta manera, una mejora considerable en los algoritmos de clasificación. Es por eso, que proponemos la combinación de ambos métodos, para así aprovechar, las virtudes que estos tienen. Los datos que analizaremos en este artículo, serán bases de datos reconocidas para deep learning: la **Iris Data Set** y **MNIST**, y una base de datos real de **Imágenes de Granos de Polen**. La primera base de datos, posee la particularidad de tener 3 conjuntos de datos, dos de ellos están solapados y el tercero es linealmente separable de los otros dos, la segunda base de datos, es una recolección de números escritos a mano y la tercera base de datos, corresponde a la clasificación de granos de polen pertenecientes a 4 especies de 4 familias de plantas localizadas en el Noroeste Argentino. Estas bases de datos fueron seleccionadas por poseer uno de los problemas más serios en la clasificación, que es **el solapamiento de los datos**.

En la sección 2, haremos una pequeña introducción a los algoritmos SVM y las Redes Neuronales. En la Sección 3, hablaremos de la lógica de funcionamiento de los autoencoders. En la sección 4, mostraremos lo que es el deep learning y como puede ser aprovechado por los SVM. En la sección 5, hablaremos de los ensayos y los resultados obtenidos. Y en la sección 6, hablaremos de las conclusiones.

2. Support Vector Machine SVM.

Los SVM son una heurística matemática, y es una de las técnicas clásicas en machine learning para los problemas binarios de clasificación. Este algoritmo, es matemáticamente complejo, y ha sido considerado el “estado del arte” hasta hace poco tiempo [10], cuando nació el deep learning, las redes neuronales tuvieron un

nuevo florecer en la comunidad científica, para los problemas de clasificación, porque solucionaron el difícil

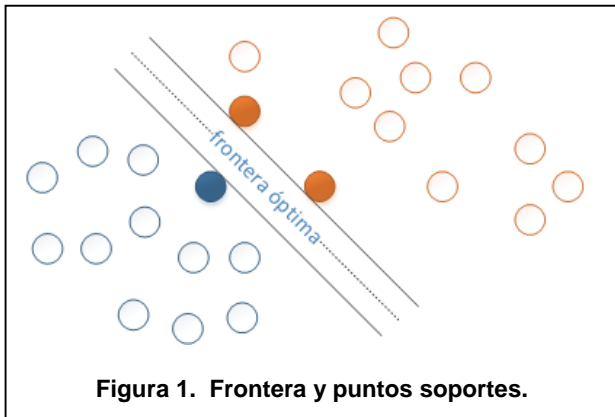


Figura 1. Frontera y puntos soportes.

problema de entrenar redes de arquitecturas profundas de manera eficiente[11]. La principal virtud de los SVM, es que fueron concebidos con el objetivo de encontrar la mejor frontera, o hiperplano de separación entre dos clases. [9]

Siendo conscientes de la limitación binaria que poseen los SVM, usaremos la técnica de todos-contra-todos para la clasificación de más de dos clases, y la competencia determinará el resultado final.

Otra heurística muy conocida para la clasificación, son las redes neuronales artificiales, que están inspiradas en las neuronas biológicas, y estas también tienen muy buenos resultados a la hora de realizar una clasificación. Las redes neuronales, puede ser entrenadas por diversos algoritmos, entre ellos, el más conocido es el backpropagation.

Si bien esta otra técnica, es actualmente la principal heurística en deep learning, a diferencia de los SVM, no fue concebida con el objetivo de buscar las mejores fronteras.

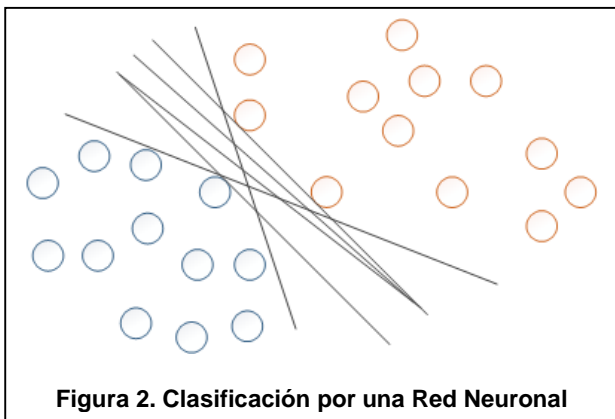


Figura 2. Clasificación por una Red Neuronal

Como podemos observar en la figura 2, todas estas fronteras son válidas, y resuelven muy bien los datos de

entrenamiento, pero no garantizan la mejor generalización.

3. Autoencoders

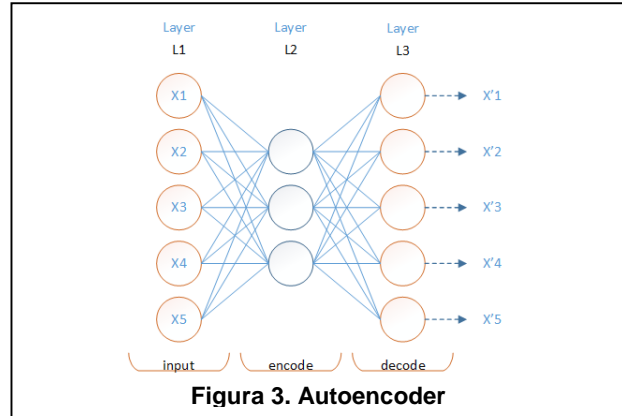


Figura 3. Autoencoder

Un autoencoder, es una red neuronal del tipo feedforward, con la particularidad de que posee solo 3 capas, una de entrada, una oculta y una de salida. Durante el entrenamiento de un autoencoder, este será entrenado con el objetivo de poder reproducir en la salida, la misma información que ingresa por la capa de entrada. Más formalmente, podemos decir que, durante el entrenamiento, se aprenderá una aproximación de la función identidad, por lo que, el x' de salida es similar al x de entrada.

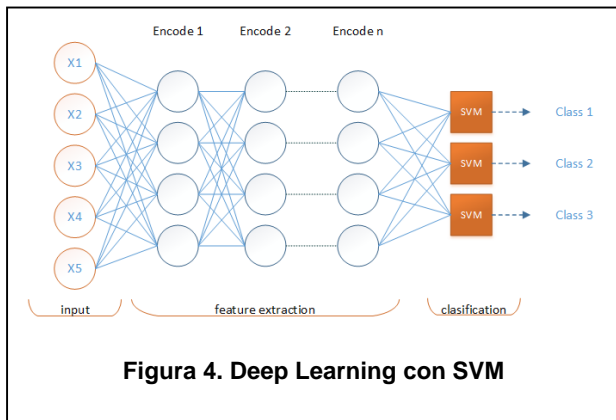
$$h_{W,b}(x) \approx x$$

A simple vista parece trivial el aprendizaje; pero si se introducen ciertas restricciones en a las neuronas de la capa oculta, se pueden descubrir estructuras interesantes en los datos. Por ejemplo, si tenemos una imagen con una entrada de 10x10 píxeles, entonces el vector de entrada pertenece al espacio \mathbb{R}^{100} , si en la capa oculta se consideran 50 neuronas, entonces mediante un proceso de codificación, estaríamos forzando a que un vector de \mathbb{R}^{50} represente al vector original en una versión comprimida. Cuando la cantidad de neuronas en la capa oculta, es igual e incluso superior a la de la entrada, una restricción de Sparsity, es decir, cuando cada neurona se activa un porcentaje muy pequeño durante el lote completo del conjunto de entrenamiento, también resultan interesantes las estructuras que se descubren en los datos[12].

En el proceso de aprendizaje, la capa oculta logrará capturar las características y relaciones que existen en los datos de entrada, a este proceso, se lo conoce como codificación. En la codificación, los datos de entrada son representados por las neuronas de la capa oculta, y luego

en la capa de salida serán decodificados y así reproducir los datos aprendidos.

4. Deep Learning con SVM



Cuando se habla de deeplearning, suele hacerse referencia a una red neuronal del tipo feedforward, con más de una capa oculta, donde el pre entrenamiento de los pesos suele obtenerse mediante los autoencoders.

El entrenamiento de estos autoencoders, será obtenidos individualmente, con las salidas de la capa anterior, y pidiendo que reproduzca como salida, la entrada al mismo, esto logrará un filtro capa a capa, que visualizará distintos aspectos de los datos, esto lo hace ideal en los problemas de clasificación de imágenes, ya que, de manera sencilla, puede ser utilizado para realizar un pre procesamiento de la información[12].

Una vez entrenados los autoencoders, como última etapa, suele agregarse un clasificador supervisado, este podrá ser una red neuronal de una capa, donde la función de salida es la softmax, y será la encargada de decidir a qué instancia pertenece la entrada de la red. Pero como mencionamos anteriormente, estas técnicas de clasificación son efectivas, pero no buscan la mejor frontera de clasificación, es por eso, que al final del deeplearning se propuso un SVM como clasificador final[8].

5. Ensayos

Iris Data Set, Es una base de datos de flores, con tres variedades de la misma planta: setosa, versicolor y virginica. Al igual que la base de datos de MNIST, es muy utilizada como benchmark, consta con un total de 150 datos, conformados por 50 muestras por especie, de los cuales uno es linealmente separable de los otros dos, y las dos últimas clases no son linealmente separables. Para este ensayo, no tomaremos datos de testeo, solo queremos visualizar si logran identificar todas las clases.

Table 1. Resultados Iris Data Set.

SVM	Deep Learning + SVM
98.7%	100%

MNIST es un conjunto de datos estándar de números escritos a mano, y son fuertemente utilizados como benchmark en deeplearning. Es un problema de clasificación con 10 clases, con 60.000 datos de entrenamiento y 10.000 datos de testeo. En el primer ensayo corrimos un SVM, y en el segundo un SVM con deeplearning en el preprocesamiento, para esta red neuronal, pusimos 100 neuronas en el primer autoencoder, y en el segundo autoencoder utilizamos 50 neuronas.

Table2. Resultados MNIST.

SVM	Deep Learning + SVM
95.1%	97.3%

Base de datos de imágenes de granos de polen:

Los granos de polen fueron observados para la descripción morfológica en un microscopio Carl Zeiss Primo StarMod. 415500 equipado con cámara fotográfica Canon PowerShot G10. Una base de datos de 200 imágenes de 128 x 128 píxeles conformada por 50 imágenes correspondientes a 4 especies de 4 familias de plantas localizadas en el Noroeste Argentino, las cuales son muy visitadas por las abejas sin aguijón. En la tabla 3 se muestra la información acerca de la familia y especie.

Table 3. Imágenes de Polen.

Especie	Nomenclatura	Imagen
<i>Sapiumhaematospermium</i>	E1	
<i>Crotonbonplandianus</i>	E2	
<i>Heteropterys glabra</i>	E3	
<i>Eucalyptussp.</i>	E4	

Las imágenes fueron llevadas al formato portable de escala de grises (.pgm) y presentada como un vector de 16384 componentes.

Se utilizó una validación cruzada de tipo k-fold, con k=5 de manera que el conjunto de entrenamiento, siempre contemplaba el 80% de los datos y conjunto de validación el 20% de los datos. Podemos destacar que la tasa de reconocimiento de éxitos fue del 85%, donde las especies E2 y E4 tuvieron el 100% de reconocimiento exitoso utilizando las SVM con deeplearning. El sistema de reconocimiento confundía la especie E3 con la especie E1.

Table 4. Resultados Granos de Polen.

SVM	Deep Learning + SVM
82%	85%

6. Conclusiones

En conclusión, pudimos ver el comportamiento en 3 bases de datos, dos de ellas como benchmark y una con datos reales.

Logró mejorar el rendimiento de los SVM, en un 2% a 3% en los casos probados, lo que confirma la mejora planteada por YichuanTang.

Como trabajo a futuro, debería probarse el rendimiento con múltiples clases, y si el rendimiento de las SVM se deteriora computacionalmente a medida que el número de clases crece.

Gran parte de los problemas de clasificación, suelen tener pocas clases a identificar, y los SVM con Deep Learning pueden ser una muy buena alternativa.

7. References

- [1] B. Pradhan, «A comparative study on the predictive ability of the decision tree, support vector machine and neuro-fuzzy models in landslide susceptibility mapping using GIS», *Comput. Geosci.*, vol. 51, pp. 350-365, feb. 2013.
- [2] J. L. Andrews y P. D. McNicholas, «Model-based clustering, classification, and discriminant analysis via mixtures of multivariate t-distributions: The tEIGEN family», *Stat. Comput.*, vol. 22, n.º 5, pp. 1021-1029, sep. 2012.
- [3] S. Mukherjee y N. Sharma, «Intrusion Detection using Naive Bayes Classifier with Feature Reduction», *Procedia Technol.*, vol. 4, pp. 119-128, 2012.
- [4] S. Garcia, J. Derrac, J. Cano, y F. Herrera, «Prototype Selection for Nearest Neighbor Classification: Taxonomy and Empirical Study», *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 34, n.º 3, pp. 417-435, mar. 2012.
- [5] D. Ciregan, U. Meier, y J. Schmidhuber, «Multi-column deep neural networks for image classification», en *2012 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2012, pp. 3642-3649.
- [6] O. Devos, G. Downey, y L. Duponchel, «Simultaneous data pre-processing and SVM

classification model selection based on a parallel genetic algorithm applied to spectroscopic data of olive oils», *Food Chem.*, vol. 148, pp. 124-130, abr. 2014.

[7] G. Farias, S. Dormido-Canto, J. Vega, G. Rattá, H. Vargas, G. Hermosilla, L. Alfaro, y A. Valencia, «Automatic feature extraction in large fusion databases by using deep learning approach», *Fusion Eng. Des.*, jun. 2016.

[8] Y. Tang, «Deep learning using linear support vector machines», *ArXiv Prepr. ArXiv13060239*, 2013.

[9] C. Cortes y V. Vapnik, «Support-vector networks», *Mach. Learn.*, vol. 20, n.º 3, pp. 273-297, 1995.

[10] E. Byvatov, U. Fechner, J. Sadowski, y G. Schneider, «Comparison of Support Vector Machine and Artificial Neural Network Systems for Drug/Nondrug Classification», *J. Chem. Inf. Comput. Sci.*, vol. 43, n.º 6, pp. 1882-1889, nov. 2003.

[11] Y. Bengio, «Learning Deep Architectures for AI», *Found. Trends® Mach. Learn.*, vol. 2, n.º 1, pp. 1-127, 2009.

[12] J. Xu, L. Xiang, Q. Liu, H. Gilmore, J. Wu, J. Tang, y A. Madabhushi, «Stacked Sparse Autoencoder (SSAE) for Nuclei Detection on Breast Cancer Histopathology Images», *IEEE Trans. Med. Imaging*, vol. 35, n.º 1, pp. 119-130, ene. 2016.