

Identificación de nubes de ceniza volcánica mediante redes neuronales en imágenes MODIS

Ivan Edmundo de la Rosa-Montero¹,
José Carlos Jimenez-Escalona¹,
Hind Taud¹, José Luis Poom-Medina²

¹ Instituto Politécnico Nacional,
Escuela Superior de Ingeniería Mecánica y Eléctrica Ticomán,
Sección de Estudios de Posgrado e Investigación,
México

² Universidad de Sonora,
División de Ciencias Exactas y Naturales,
México

ivan.edmundo@hotmail.com,
{jjimeneze, htaud}@ipn.mx

Resumen. La identificación de las nubes de ceniza volcánica representa un problema clave para la seguridad de la aviación debido a sus efectos negativos sobre las aeronaves. En este trabajo se han utilizado redes neuronales para identificar nubes de ceniza volcánicas a través de mediciones multiespectrales del Moderate Resolution Imaging Spectroradiometer (MODIS). Con el fin de identificar la presencia de nubes de ceniza volcánica después de un evento eruptivo, se ha entrenado una red neuronal perceptrón multicapa utilizando un conjunto de 14 imágenes MODIS, del volcán Popocatepetl, con presencia de ceniza obtenidas a partir del método de diferencia de temperatura de brillo. Además, se utilizaron métodos de balanceo de datos (undersampling, oversampling, SMOTE) para mejorar el rendimiento de la red. Se han comparado los resultados obtenidos por la red neuronal aplicando los métodos de balanceo de datos: a) Sin balanceo de datos, b) undersampling, c) oversampling y d) SMOTE. Los resultados muestran que el enfoque de red neuronal entrenado con el conjunto de datos no equilibrado presenta en sus gráficas de exactitud un sobreajuste y no es capaz de predecir la presencia de nubes de ceniza volcánica en las nuevas imágenes, esto puede ser debido a que hay un número mucho mayor de píxeles clasificados como "sin ceniza" que los clasificados como "ceniza". Por otro lado, cuando se entrena la red con el conjunto de datos equilibrado, ésta obtiene un 93.11 % de exactitud y mejora a un 31 % el puntaje F1 en la predicción de la presencia de nubes de ceniza volcánica en las nuevas imágenes.

Palabras clave: Redes neuronales, perceptrón multicapa, ceniza volcánica, MODIS, undersampling, oversampling, SMOTE.

Identification of Volcanic Ash Clouds Using Neural Networks in MODIS Imagery

Abstract. The identification of volcanic ash clouds represents a key problem for aviation safety due to their negative effects on aircraft. In this work, neural networks have been used to identify volcanic ash clouds through multispectral measurements from the Moderate Resolution Imaging Spectroradiometer (MODIS). In order to identify the presence of volcanic ash clouds after an eruptive event, a multilayer perceptron neural network has been trained using a set of 14 MODIS images of Popocatepetl volcano with the presence of ash obtained from the brightness temperature difference method. In addition, data balancing methods (undersampling, oversampling, SMOTE) were used to improve the performance of the network. The results obtained by the neural network applying the data balancing methods: a) No data balancing, b) undersampling, c) oversampling and d) SMOTE have been compared. The results show that the neural network approach trained with the unbalanced data set presents in its accuracy plots an overfitting and is not able to predict the presence of volcanic ash clouds in the new images, this may be because there is a much higher number of pixels classified as "no ash" than those classified as "ash". On the other hand, when the network is trained with the balanced dataset, it obtains 93.11% accuracy and improves to a 31% F1 score in predicting the presence of volcanic ash clouds in the new images.

Keywords: Neural networks, Multilayer perceptron, volcanic ash, MODIS, undersampling, oversampling, SMOTE.

1. Introducción

La erupción de un volcán puede ocasionar presencia de diferentes tipos de productos volcánicos en la atmósfera, como son ceniza volcánica y dióxido de azufre (SO₂) que pueden ser transportadas tanto verticalmente por efecto de erupción, como horizontalmente, por la acción de los vientos dominantes en la zona. En los casos en los que se tiene abundante emisión de ceniza y esta es transportada a zonas urbanas, esta se deposita en las calles, sobre casas, vehículos, etc.

En las zonas aeroportuarias la caída de ceniza representa una alerta que paraliza las operaciones aeronáuticas. Por otro lado, el tiempo de permanencia de estos materiales en la atmósfera representa un alto riesgo para la seguridad de las aeronaves que utilizan el espacio aéreo alrededor de volcanes activos, debido a los efectos negativos que se han identificado.

Actualmente el uso de imágenes satelitales para la detección de ceniza volcánica es de gran utilidad debido al amplio rango de visión que se tiene con estas. El uso de estas imágenes, a pesar de tener buenos resultados, aún presenta problemas al momento de identificar nubes de ceniza volcánica, por lo que algunos investigadores han optado por implementar herramientas del área de la inteligencia artificial para el estudio de las mismas [6, 4].

Tabla 1. Erupciones volcánicas.

Volcán	Fecha	Hora	Hora de erupción	Sensor
Popocatepetl	14/04/2012	05:10	04:37	Terra
Popocatepetl	14/04/2012	17:20	10:24	Terra
Popocatepetl	16/04/2012	20:11	19:46	Terra
Popocatepetl	18/04/2012	16:55	12:48	Terra
Popocatepetl	20/04/2012	16:45	14:10	Terra
Popocatepetl	25/04/2012	20:10	17:09	Terra
Popocatepetl	14/04/2012	07:55	04:37	Aqua
Popocatepetl	14/04/2012	20:30	10:24	Aqua
Popocatepetl	20/04/2012	19:50	19:09	Aqua
Popocatepetl	21/04/2012	08:05	06:57	Aqua
Popocatepetl	02/05/2012	17:10	16:14	Terra
Popocatepetl	03/05/2012	17:50	15:22	Terra
Popocatepetl	04/05/2012	04:45	04:34	Terra
Popocatepetl	04/05/2012	16:55	13:59	Terra

Debido a los efectos negativos que la parencia de ceniza volcánica puede ocasionar, se requiere la obtención de datos de una forma muy rápida, desafortunadamente los métodos actuales toman mucho tiempo debido a la enorme cantidad de información que se requiere analizar, por lo cual ha surgido la necesidad de desarrollar nuevos métodos para la detección de nubes, que sean capaces de arrojar la información en el menor tiempo posible.

Por otro lado, aunque el aprendizaje profundo se ha estudiado desde hace muchos años, los resultados más relevantes se han obtenido en los últimos años, incluso se ha superado la capacidad del ser humano en algunas tareas. Una de las razones de ello, es que en la actualidad se cuenta con potentes equipos de cómputo, capaces de llevar a cabo el procesamiento requerido por los algoritmos.

En este trabajo se propone el uso de redes neuronales y de métodos de balanceo, con el fin de detectar de una forma más rápida y precisa nubes de ceniza volcánica y que ayude a la construcción de mapas de prevención y mitigación de riesgo en caso de una erupción que emita productos volcánicos a la atmósfera en la zona de volcanes ubicados en el territorio mexicano.

2. Redes neuronal perceptron multicapa

Un Perceptron multicapa es una red de tipo "hacia delante" compuesta por varias capas de neuronas entre la entrada y la salida de la misma. Esta red permite establecer regiones de decisión mucho más complejas que las que permite la regresión logística.

Sea K el número de neuronas de la primera capa oculta recibe como entrada un vector de características $\bar{x} = (x_1, x_2, \dots, x_n)$ y genera como salida un valor calculado en la ecuación 3.4:

$$q_k^{(1)} = w_{0k}^{(1)} + \sum_{i=1}^n w_{ik}^{(1)} x_i \quad \forall k \in \{1, 2, \dots, K\}, \quad (1)$$




Fig. 1. (A) Respuesta espectral de la bandas MODIS 28,29,30,31 y 32;(B) Transmisión espectral de la ceniza; (C) Transmisión espectral hielo.

donde $q_k^{(1)}$ es la salida de la k -ésima neurona de la primera capa, $w_{ik}^{(1)}$ es el peso que conecta la i -ésima componente del vector de características con la k -ésima neurona en la primera capa y $w_{0k}^{(1)}$ es el peso asociado a lo que se conoce como sesgo o "bias" de la red.

A esta salida se le suele aplicar lo que se conoce como una función de activación, la cual se encarga de transformar la salida $q_k^{(1)}$ a un valor acotado acorde a la aplicación. Este proceso puede repetirse para una siguiente capa oculta, utilizando las salidas de las neuronas de la capa anterior como entradas de las neuronas de la siguiente capa, en la cual se repite el proceso. Una red que posee múltiples capas ocultas se denomina red neuronal profunda (Deep Neural Network, DNN).

3. Desequilibrio de clases, consecuencias y métodos de solución

Un problema común al que se enfrenta la minería de datos es el desequilibrio de clases. Se dice que un conjunto de datos está desequilibrado si una clase supera ampliamente a la otra. El problema del desequilibrio de clases se produce cuando la clase que es superada en número es la clase de interés. Una complicación obvia que surge con este problemas es la efectividad de la exactitud para determinar el rendimiento de un clasificador.

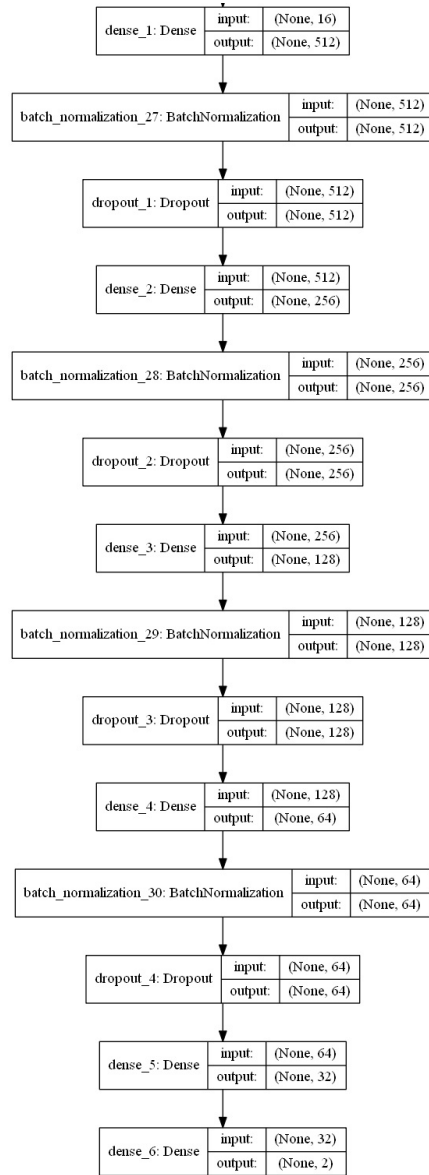


Fig. 2. Arquitectura perceptron multicapa.

Una consecuencia de esta limitación puede observarse en el rendimiento de la mayoría de los clasificadores tradicionales. Esto se debe al hecho de que la mayoría de los clasificadores optimizan la precisión. En consecuencia, se han desarrollado numerosos métodos que tratan de resolver el problema del desequilibrio de clases. Los métodos de muestreo (por ejemplo, sobremuestreo aleatorio y submuestreo aleatorio) se han convertido en enfoques estándar para mejorar el rendimiento de la clasificación [3].

Tabla 2. Matriz de confusión dos clases.

		Clasificador	
		Ceniza	No ceniza
Valor real	Ceniza	TP	FN
	No ceniza	FP	TN

En los métodos de muestreo, el conjunto de capacitación se modifica de manera que se cree una distribución de clases más equilibrada. El conjunto de datos muestreados resultante es entonces más susceptible a los algoritmos tradicionales de extracción de datos, que pueden utilizarse para clasificar los datos.

3.1. Métodos de muestreo

El muestreo es una de las metodologías más populares utilizada para afrontar el desequilibrio de clases. El objetivo de los métodos de muestreo es crear una base de datos que tenga relativamente una distribución balanceada de sus clases, así los clasificadores tradicionales tendrán un mejor rendimiento.

Debido a que los métodos de muestreo son utilizados con el fin de realizar una correcta clasificación de clase minoría, el conjunto de datos resultante debe aproximarse al conjunto original. Específicamente, el conjunto resultante debe contener solamente instancias que son similares a las del conjunto original.

Submuestreo aleatorio. En el submuestreo aleatorio, las instancias de la clase mayoritaria se descartan aleatoriamente hasta que se alcanza una distribución de datos más equilibrada. Considérese, por ejemplo, un conjunto de datos compuesto por 10 instancias de clases minoritarias y 100 instancias de clases mayoritarias.

En el submuestreo aleatorio, se podría intentar crear una distribución de clases equilibrada seleccionando 90 instancias de clases mayoritarias al azar para ser eliminadas. El conjunto de datos resultante constará entonces de 20 instancias: 10 instancias de clase mayoritaria (que permanecen aleatoriamente) y 10 instancias de clase minoritaria (las originales).

Sobremuestreo aleatorio. En el sobremuestreo aleatorio, las instancias de las clases minoritarias se copian y se repiten en el conjunto de datos hasta que se alcanza una distribución más equilibrada. Así, si hay dos instancias de clases minoritarias y 100 de clases mayoritarias, el sobremuestreo tradicional copiaría las dos instancias de clases minoritarias 49 veces cada una.

El conjunto de datos resultante consistiría entonces en 200 instancias: las 100 instancias de la clase mayoritaria y las 100 instancias de la clase minoritaria (es decir, 50 copias de cada una de las dos instancias de la clase minoritaria).

SMOTE. Mientras que el submuestreo aleatorio sufre la pérdida de información potencialmente útil, el sobremuestreo aleatorio sufre el problema de overfitting. Específicamente, al replicar aleatoriamente instancias en el conjunto de datos, el modelo aprendido podría ajustar los datos de entrenamiento demasiado cerca y, como resultado, no generalizar bien a los casos no vistos.

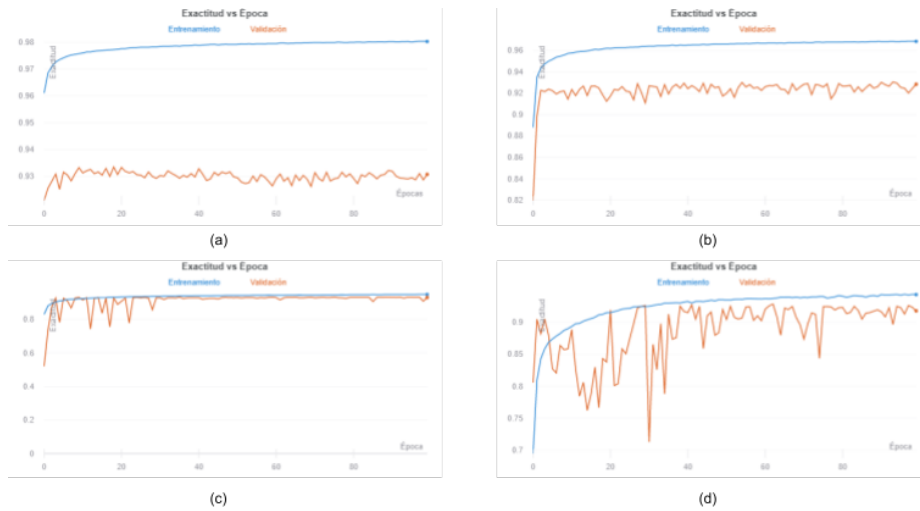


Fig.3. Gráfica de exactitud vs época con el conjunto de datos. (a) Sin balancear; (b) Oversampling; (c) SMOTE y (d) Undersampling.

Para superar este problema, Chawla et al [3] desarrollaron un método para crear instancias sintéticas en lugar de simplemente copiar las instancias existentes en el conjunto de datos. Esta técnica se conoce como la técnica de sobremuestreo de minoría sintética (SMOTE). Como se ha mencionado, en SMOTE, el conjunto de formación se altera añadiendo instancias de clase minoritarias generadas sintéticamente, lo que hace que la distribución de clases sea más equilibrada.

Decimos que las instancias creadas son sintéticas, ya que son, en general, nuevas instancias minoritarias que han sido extrapoladas y creadas a partir de las instancias de clases minoritarias existentes. Para crear las nuevas instancias de clases minoritarias sintéticas, SMOTE primero selecciona una instancia de clase minoritaria a al azar y encuentra a sus vecinos de clase minoritaria más cercanos k .

La instancia sintética se crea entonces eligiendo al azar uno de los k vecinos más cercanos de b y conectando a a y b para formar un segmento de línea en el espacio de características. Las instancias sintéticas se generan como una combinación convexa de las dos instancias elegidas a y b .

4. Metodología

Con el fin de determinar si es posible reconocer automáticamente patrones de ceniza volcánica en imágenes satélites ópticas que detectan en el infrarrojo Térmico, se estudiaron imágenes MODIS de distintos eventos eruptivos en México. La factibilidad del uso de una red neuronal para detectar cenizas volcánicas se exploró entrenando una red neuronal perceptrón multicapa, además del el uso de técnicas de balanceo de datos.

Tabla 3. Comparación de valores de exactitud.

Picchiani et al. [8]	Gray et al. [5]	MLP	Random Oversampling	Random Undersampling	SMOTE
97 %	93.2 %	93.05 %	93.15 %	93.09 %	93.11 %

4.1. Zona de estudio

En México existen amplias provincias volcánicas dentro de las cuales, según el Instituto de Geofísica de la UNAM, en la actualidad se cuenta con 12 volcanes activos. Un detalle importante es que en torno a varios de estos volcanes activos se encuentran localizadas importantes aglomeraciones urbanas y rurales, así como instalaciones aeronáuticas.

El Popocatepetl es uno de los volcanes más activos del país, con una elevación de 5,419.43 msnm, es la tercera cima más alta de México. Se encuentra localizado en la parte central del Cinturón Volcánico Transmexicano, en las coordenadas 19° 01' 23" N y 98° 37' 22" W. Los 25 millones de personas que habitan a menos de 100 km del cráter, lo convierten en uno de los volcanes más peligrosos del planeta.

Después de setenta años de inactividad, se notó un paulatino incremento en la actividad fumarólica del volcán, que reinició su actividad el 21 de diciembre de 1994 [5]. A partir de ese año ha tenido etapas efusivas y explosivas asociadas con el crecimiento y destrucción de domos de lava en el interior del cráter. Sus cenizas han alcanzado las ciudades de Puebla y de México y poblaciones incluso más distantes como Querétaro y Veracruz.

La emisión y dispersión de cenizas, uno de los fenómenos más frecuentes en la actividad de este volcán, ha afectado los estados mencionados, además de Tlaxcala y el Distrito Federal, convirtiéndose en una seria amenaza para la salud pública. Por otra parte, debido a la gran altitud del Popocatepetl (5,419 msnm), las emisiones de gas y ceniza volcánicas han afectado una región y espacio aéreo más amplios.

Una futura erupción del volcán puede poner en peligro la seguridad del tráfico aéreo y afectar varios de los principales aeropuertos de México y países vecinos [2]. Es por ello, que los efectos de la actividad volcánica pueden catalogarse como de índole de seguridad nacional. Para el desarrollo de este trabajo fueron utilizadas 14 imágenes (Tabla 1), las cuales fueron tomadas por alguno de los dos sensores MODIS (Terra o Aqua).

4.2. Percepción remota

Los aerosoles exhiben una transmitancia variable en los rangos de 8-10 y 10-12 μm [1]. Debido a que los canales de las imágenes MODIS cubren este rango espectral, se obtuvieron imágenes de este sensor y se utilizó el método de Split window para determinar áreas de ceniza volcánica en cada evento eruptivo.

En la figura 1, se ilustra la transmisión espectral de la ceniza y del hielo en las bandas 28, 29, 30, 31 del sensor MODIS. Es posible observar su variación de la transmisión espectral o entre las bandas 30 y 31 (11 μm y 12 μm) del sensor. Esto nos ayuda a discernir entre nubes meteorológicas y nubes de ceniza volcánica.

Tabla 4. Métricas de evaluación para cada modelo.

Modelo	Exactitud	Precisión	Sensibilidad	Puntaje F1
MLP	93.05	98	15	26
R. Oversampling	93.15	89	18	30
R. Undersampling	93.09	49	21	29
SMOTE	93.11	75	19	31

El método de diferencia de temperatura de brillo fue utilizado para detectar las nubes de ceniza volcánica. El método consiste en obtener la diferencia de temperatura de brillo que existe entre dos imágenes adquiridas a dos longitudes de banda diferentes dentro de espectro infrarrojo (11 μm y 12 μm) con el fin de discriminar entre las nubes de ceniza volcánica y las nubes meteorológicas.

4.3. Entrenamiento perceptron multicapa

Durante el diseño de la arquitectura de la red neuronal se considero el uso de batch normalization debido a que nos permite entrenar nuestra red de una manera mas rápida mediante la estandarización de la salidas de cada una de nuestras capas. Por otro lado, se opto por el uso de dropout como una estrategia para reducir las posibilidades de caer en overfitting. La arquitectura del modelo utilizado consiste en 4 capas ocultas con batch normalization y dropout en cada una de ellas (Figura 2).

Base de datos. Las imágenes ocupadas fueron modificadas de la siguiente manera. Cada imagen fue recortada píxel por píxel de modo que cada píxel formaba una nueva imagen. De esta manera tenemos ahora imágenes de dimensión 1×16 y la base de datos para el entrenamiento consiste en 1728000 imágenes y para la validación consiste en 691200 imágenes.

Métricas de evaluación. Un método común para determinar el rendimiento de un clasificador es a través del uso de una matriz de confusión. Una matriz de confusión de dos clases, en este caso ceniza y no ceniza, se vería de la siguiente manera (tabla 2). Las columnas de la matriz representan las predicciones realizadas por el clasificador para cada clase, y las filas los valores reales por cada clase. por lo cual la matriz queda dividida en 4 clases, TP, FN, FP y TN, que significan lo siguiente:

- **TP – True Positives:** Es el número verdaderos positivos, es decir, de predicciones correctas para la clase ceniza.
- **FN – False Negatives:** Es el número de falsos negativos, es decir, la predicción es negativa cuando el valor real es positivo, en nuestro caso la la predicción es No ceniza cuando debería ser Ceniza. A estos casos también se les denomina errores de tipo II.
- **FP – False Positives:** Es el número de falsos positivos, es decir, la predicción es positiva cuando el valor real es negativo, en nuestro caso la predicción es Ceniza cuando debería ser No ceniza. A estos casos también se les denomina errores de tipo I.
- **TN – True Negatives:** Es el número de verdaderos negativos, es decir, de predicciones correctas para la clase no ceniza.

Tabla 5. Prueba de hipótesis.

Modelo	\hat{p}	x	n
MLP	15	8379	56170
SMOTE	19	10857	56170

La matriz de confusión nos permite calcular las siguientes métricas.

- **Exactitud** se refiere a la dispersión del conjunto de valores obtenidos a partir de mediciones repetidas de una magnitud. Cuanto menor es la dispersión mayor la precisión.

Se representa por la proporción entre el número de predicciones correctas (tanto positivas como negativas) y el total de predicciones, y se calcula mediante la ecuación 4.1:

$$\frac{TP + TN}{TP + TN + FP + FN} \quad (2)$$

- **Precisión** se refiere a lo cerca que está el resultado de una medición del valor verdadero. Es representada por la proporción entre los positivos reales predichos por el algoritmo y todos los casos positivos. Se calcula según la siguiente ecuación 4.2:

$$\frac{TP}{TP + FP} \quad (3)$$

- **Sensibilidad** es una valor que nos indica la capacidad de nuestro clasificador para discriminar los casos positivos de los negativos. También se conoce como Tasa de Verdaderos Positivos. Es la proporción de casos positivos que fueron correctamente identificados por el clasificador. Se calcula según la ecuación 4.3:

$$\frac{TP}{TP + FN} \quad (4)$$

- **Puntaje F1** es la combinación de las métricas de precisión y sensibilidad. La mejor puntuación es igual a 1 y la peor a 0 (Ecuación 4.4):

$$2 \times \frac{\text{Precision} \times \text{Sensibilidad}}{\text{Precision} + \text{Sensibilidad}} \quad (5)$$

5. Resultados

Con el objetivo de mejorar el rendimiento de la red neuronal perceptron multicapa es necesario optimizar los hiperparametros utilizados . Los parámetros a optimizar fueron: Batch size, tasa de aprendizaje, optimizador y el dropout. Por otra parte, con la finalidad de obtener mejores resultados en la clasificación, diferentes técnicas de balanceo de datos fueron aplicadas. A continuación se muestran los resultados obtenidos mediante la aplicación de estas técnicas. En la figura 3 se muestran las gráficas de exactitud vs época para cada uno de los experimentos.

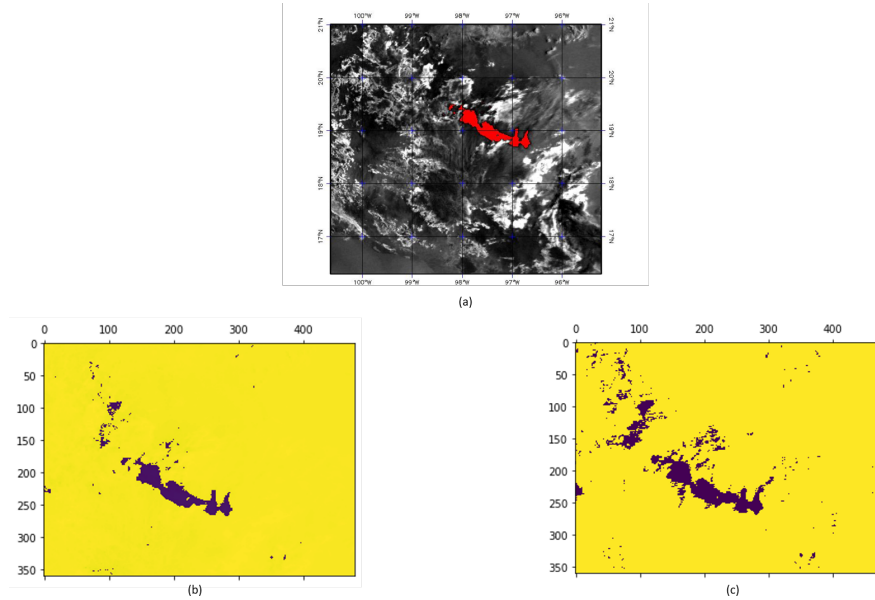


Fig. 4. (a)Imagen con ceniza volcánica; (b)Imagen etiquetada; (c)Predicción del modelo.

Como se puede observar, al entrenar la red con un conjunto de datos sin balancear se cae en el problema de overfitting. Las técnicas de balanceo de datos, en especial la técnica SMOTE, logran mejorar considerablemente las curvas de exactitud. En la Tabla 3 observamos los valores de exactitud obtenidos en cada uno de nuestros experimentos y además son comparados con resultados de trabajos previos.

Como fue explicado anteriormente, la exactitud no es la métrica mas adecuada a tomar en cuenta para este tipo de problemas, cabe destacar que en este trabajo fue considerada con el único fin de comparar resultados con trabajos previos. Es por esto que a continuación se muestran los resultados obtenidos en las demás métricas, (Tabla 4).

Con el fin de discernir si los resultados presentados son significativamente similares, se propone realizar una prueba de hipótesis, en la cual se considerara como referencia la sensibilidad, debido a que esta métrica solo considera las muestras con presencia de ceniza volcánica. Para la prueba consideraremos lo siguiente:

$$Z = \frac{\hat{p}_1 - \hat{p}_2}{\sqrt{2\hat{p}(1 - \hat{p})/n}}, \quad (6)$$

donde:

$$\hat{p} = (x_1 + x_2)/2n. \quad (7)$$

Se considera la siguiente hipótesis nula:

$$H_0 : p_1 = p_2. \quad (8)$$

Con el fin de rechazar nuestra hipótesis nula debemos probar lo siguiente:

$$Z < -z_{\alpha}, \quad (9)$$

$$z_{\alpha} = z_{0,5} = 1,645. \quad (10)$$

Lo cual nos indicaría que:

$$p_1 < p_2. \quad (11)$$

Al calcular Z se obtiene lo siguiente:

$$Z = -17,79 < -z_{\alpha} < -1,645. \quad (12)$$

Con lo cual podemos decir con un 95 % de confianza que la mejora en el rendimiento de nuestro modelo al utilizar técnicas de balanceo de datos, como SMOTE, es significativa. En base a los resultados arrojados por los experimentos podemos observar que la técnica mas eficaz para mejorar el rendimiento de la red es el SMOTE, debido a que es el que mejor resultado arroja para la métrica puntaje F1. Los resultados obtenidos en este experimento se muestran en la figura 4.

6. Conclusiones

Se presentó la implementación y comparación de diferentes técnicas de balanceo de datos para su implementación en una red neuronal perceptron multicapa. Se observó que la implementación de la red perceptron multicapa arrojó valores mayores al 90 % en la exactitud, además se disminuyó el sobreentrenamiento mediante la implementación de técnicas de balanceo de datos. Esta red fue entrenada con una base de datos para esta red consistió en 2,419,200 ejemplos cuando no fue balanceada. Además, para la implementación de esta red, se necesito realizar el balanceo de datos con el objetivo de que existiera el mismo número de píxeles "no ceniza" y "ceniza".

En trabajos de investigación previos [6] y [4], se observa que la red neuronal implementada nos arroja un valor para la exactitud mayor al 90 %, siendo este el único valor presentado. En este trabajo se presentan valores similares en la exactitud, cabe resaltar que a diferencia de los trabajos de investigación previos, donde las redes neuronales fueron entrenadas y validadas con imágenes que pertenecen al mismo evento eruptivo, la red neuronal presentada aquí, fue entrenada y validada con diferentes eventos eruptivos. Por lo tanto, la muestra utilizada representa de mejor manera al fenómeno estudiado.

En este trabajo se presentan otros valores importantes como lo son la precisión, sensibilidad y el F1, estos valores nos dan un mejor panorama del funcionamiento del modelo. Como se puede observar los resultados del puntaje F1 siguen siendo bajos a pesar de tener una buena precisión, esto debido a que la sensibilidad sigue siendo baja. Podemos observar que a pesar de que fueron utilizadas técnicas de balanceo de datos, el modelo sigue presentando problemas a la hora de detectar píxeles con ceniza volcánica. Se recomienda seguir recolectando imágenes de diferentes eventos eruptivos con el fin de tener mas ejemplos con píxeles de ceniza volcánica y así el modelo pueda aprender de mejor manera.

Referencias

1. Ackerman, S. A.: Remote sensing aerosols using satellite infrared observations. *Journal of Geophysical Research: Atmospheres*, vol. 102, no. D14, pp. 17069–17079 (1997), doi: 10.1029/96JD03066
2. Bonasia, R., Scaini, C., Capra, L., Nathenson, M., Siebe, C., Arana-Salinas, L., Folch, A.: Long-range hazard assessment of volcanic ash dispersal for a Plinian eruptive scenario at Popocatepetl volcano (Mexico): Implications for civil aviation safety. *Bulletin of Volcanology*, vol. 76, no. 1, pp. 1–16 (2013), doi: 10.1007/s00445-013-0789-z
3. Chawla, N. V., Cieslak, D. A., Hall, L. O., Joshi, A.: Automatically countering imbalance and its empirical relationship to cost. *Data Mining and Knowledge Discovery*, vol. 17, no. 2, pp. 225–252 (2008), doi: 10.1007/s10618-008-0087-0
4. Gray, T., Bennartz, R.: Automatic volcanic ash detection from modis observations using a back-propagation neural network. *Atmospheric Measurement Techniques*, vol. 8, no. 12, pp. 5089–5097 (2015), doi: 10.5194/amt-8-5089-2015
5. Pereña, R. E.: *Historia de la actividad del volcán Popocatepetl* (2012)
6. Picchiani, M., Chini, M., Corradini, S., Merucci, L., Sellitto, P., Del Frate, F., Stramondo, S.: Volcanic ash detection and retrievals using modis data by means of neural networks. *Atmospheric Measurement Techniques*, vol. 4, no. 12, pp. 2619–2631 (2011), doi: 10.5194/amt-4-2619-2011