



A. PROPUESTA PROYECTO DE INVESTIGACIÓN INTERNO SIN FINANCIAMIENTO

1. TIPO DE INVESTIGACIÓN:

Básica		Aplicada	X
--------	--	----------	---

2. UNIDAD EJECUTORA (*Departamento, Instituto o Estructura de Investigación*):

1. Departamento de Electrónica, Telecomunicaciones y Redes de Información, DETRI.

3. LÍNEA(S) DE INVESTIGACIÓN:

1. Multimedia

4. TÍTULO DEL PROYECTO (*mínimo 10 palabras*):

Generación de señales volcánicas artificiales del Volcán Cotopaxi usando modelos GAN (Generative Adversarial Networks)

5. RESUMEN (*máximo 200 palabras*)

Con la creciente capacidad de recopilar grandes volúmenes de datos sísmicos volcánicos, el proceso de detección y etiquetado de estos registros es cada vez más desafiante. Claramente, analizar todos los datos disponibles mediante la inspección manual ya no es una opción viable. Los modelos de aprendizaje automático supervisado podrían considerarse para automatizar el análisis de los datos adquiridos por las estaciones de monitoreo in situ. Sin embargo, la aplicación directa de tales algoritmos es desafiante, dada la alta complejidad de las formas de onda y la cantidad escasa y a menudo desequilibrada de datos etiquetados. A la luz de esto y motivados por el amplio éxito que las Redes Generativas Adversarias (GAN) han visto en la generación de imágenes, esta propuesta de proyecto pretende proponer un método basado en modelos GAN para generar eventos volcánicos-tectónicos (Volcano-tectonic, VT) y de período largo (Long Period, LP) del volcán Cotopaxi. La validez de las señales artificiales serán evaluadas usando la Distancia de Frechet o métricas similares. Finalmente, se comparará el método basado en modelos GAN con la conocida técnica estadística de Bootstrapping para la generación de señales artificiales.

6. PALABRAS CLAVE (*4-6*)

Aprendizaje Automático, Redes Generativas Antagónicas, Generación de señales artificiales, Señales Sísmicas Volcánicas.



7. OBJETIVOS

7.1. OBJETIVO GENERAL

Generar señales volcánicas artificiales a partir de una base de datos del volcán Cotopaxi usando modelos GAN (Generative Adversarial Network)

7.2. OBJETIVOS ESPECÍFICOS

- a. Proponer un método basado en un modelo GAN condicional para generar eventos sísmicos artificiales del volcán Cotopaxi del tipo VT (Volcano-Tectonic) y LP (Long Period).
- b. Evaluar la calidad de los eventos generados por el método propuesto mediante métricas objetivas.
- c. Comparar el método propuesto con la generación de señales volcánicas artificiales basada en la técnica estadística de Bootstrapping.
- d. Difundir los resultados obtenidos en la comunidad politécnica y científica, nacional e internacional a través de artículos científicos, disertaciones y divulgación en congresos.

8. HIPÓTESIS (opcional)

No aplica.

9. DETALLE DE LOS RESULTADOS ESPERADOS (con relación a los objetivos)

En base a los objetivos específicos del proyecto, y acorde a la metodología y cronograma planteados se esperan los siguientes resultados.

Proponer un método basado en un modelo GAN condicional para generar eventos sísmicos artificiales del volcán Cotopaxi del tipo VT (Volcano-Tectonic) y LP (Long Period).

- a. Modelo entrenado de una GAN condicional capaz de generar señales sísmicas artificiales tipo VT y LP similares a las verdaderas.
- b. Código fuente para el entrenamiento y generación de señales artificiales usando el método propuesta basado en GAN condicional

Evaluar la calidad de los eventos generados por el método propuesto mediante métricas objetivas.

- a. Análisis de las señales sísmicas artificiales generadas por la GAN condicional mediante métricas objetivas.

Comparar el método propuesto con la generación de señales volcánicas artificiales basada en la técnica estadística de Bootstrapping.

- a. Análisis comparativo del método propuesto basado en GAN en relación a la generación basada en Bootstrapping en términos de métricas objetivas.
- b. Código fuente de la técnica estadística Bootstrapping para generación de señales artificiales

Difundir los resultados obtenidos en la comunidad politécnica y científica, nacional e internacional a través de artículos científicos, disertaciones y divulgación en congresos.

- a. Generación de dos proyectos de titulación



- b. Un artículo enviado a revista indexada en SCOPUS, SCIELO o WoS o una presentación en congreso

Como resultado final, y citando el objetivo general:

Generar señales volcánicas artificiales a partir de una base de datos del volcán Cotopaxi usando modelos GAN (Generative Adversarial Network)

- a. Informe final del proyecto
- b. Una base de datos de al menos 1000 eventos artificiales generados por el método propuesto basado en GAN condicional.

10. IMPACTO DE LA INVESTIGACIÓN (científico, social, económico u otros (máximo una carilla))

La predicción de desastres naturales es un tema de creciente interés que enfatiza la seguridad pública y minimiza la perturbación social y económica producida por tales fenómenos. Aunque las catástrofes naturales son impredecibles, proporcionar información adecuada sobre los peligros basada en su conocimiento científico juega un papel crucial en los sistemas de alerta temprana (McNutt, 2015). El monitoreo continuo de volcanes activos, por ejemplo, permite a los expertos comprender mejor su dinámica interna y entregar pronósticos y advertencias efectivos para reducir los efectos asociados de los eventos volcánicos y erupciones que podrían ser letales para las poblaciones cercanas (Chouet, 1994).

En este sentido, los clasificadores de aprendizaje automático (*Machine Learning Classifiers*, MLC) ayudan a descubrir y comprender patrones dentro de los datos. Estos han demostrado ser herramientas exitosas (como segunda opinión) para analizar datos en varios campos de estudio, incluida la sismología volcánica. Algunos ejemplos de aplicaciones de MLCs en el contexto de clasificación de eventos sísmicos volcánicos se han desarrollado a partir de modelos de aprendizaje supervisado como redes neuronales artificiales (Curilem, 2009), redes neuronales profundas (Titos, 2018), máquina de vectores de soporte (SVM) (Curilem, 2016), bosques aleatorios (Pérez, 2020a), árboles de decisión (Lara-Cueva, 2016), modelos ocultos de Markov (Bhatti, 2016), algoritmos evolutivos (Asim, 2018) y modelos de mezcla gaussiana (GMM) (Venegas, 2019). Además, otros enfoques se han basado en el aprendizaje no supervisado (Duque, 2020) y el aprendizaje semi-supervisado (Brusil, 2019).

Los modelos tradicionales de aprendizaje supervisado requieren datos etiquetados para aprender adecuadamente el espacio de características durante la etapa de entrenamiento y luego clasificar nuevos datos (Pérez, 2020a). Sin embargo, la cantidad de muestras para entrenar y probar los MLCs de última generación como modelos de aprendizaje profundo es una gran preocupación debido a las limitaciones de los datos. Entre estas limitaciones se puede mencionar a la cantidad insuficiente de instancias de alta calidad en los datos de entrenamiento, etiquetas faltantes y la representación desequilibrada de clases, entre otras. Estos problemas se vuelven difíciles de solucionar cuando los especialistas recopilan y etiquetan datos manualmente, especialmente cuando las estaciones sísmicas comienzan a registrar más muestras de una clase que otras, creando datos con una representación de clase desequilibrada, por ejemplo, los conjuntos de datos publicados en (Pérez, 2020b).

Afortunadamente, algunos enfoques de aprendizaje automático pueden abordar estas limitaciones. Uno de ellos es la Redes Generativas Antagónicas (*Generative Adversarial Network*, GAN) (Goodfellow, 2014), que es un conjunto de técnicas que aprenden de las muestras en un conjunto de entrenamiento y luego generan nuevas muestras de datos con la misma configuración estadística que las del conjunto de entrenamiento. Los modelos GAN son



técnicas de vanguardia en la generación de datos sintéticos, principalmente utilizados para datos de imágenes (Karras, 2019). Su rápido desarrollo tiene el potencial de afectar muchas áreas científicas donde las aplicaciones de aprendizaje automático son populares (Alqahtani, 2019). Sin embargo, en el contexto de la sismología, se han realizado investigaciones limitadas sobre las GAN que funcionen directamente con datos sísmicos (Wang, 2019). Además, según el conocimiento de los autores, no existe evidencia clara de que estos modelos se utilicen para clasificar micro-terremotos originados por volcanes, quizás porque la generación de señales sin procesar en el dominio del tiempo es particularmente desafiante debido a la estructura altamente variable de la forma de onda sísmica.

En este proyecto, se propone explorar los modelos GAN para aumentar así los datos etiquetados disponibles para entrenar MLCs con éxito.

11. ESTADO DEL ARTE, E INVESTIGACIONES PREVIAS DEL EQUIPO (máximo tres carillas)

Varios enfoques se han centrado en generar datos sintéticos como señales (unidimensionales) e imágenes (bidimensionales) utilizando diferentes métodos (Alqahtani, 2019). Dado que estamos proponiendo un modelo GAN para generar señales unidimensionales, nuestro objetivo en esta sección es resaltar los enfoques desarrollados previamente en el mismo alcance de nuestra propuesta. En este sentido, algunos trabajos exitosos han creado formas de onda de audio en el dominio del tiempo con modelos autorregresivos y no autorregresivos.

Se desarrolló un modelo autorregresivo avanzado (WaveNet) en (Oord, 2016), para generar muestras de voz y música altamente realistas, utilizando un *autoencoder* convolucional. De manera similar, en (Vasquez, 2019), se creó un modelo que produce muestras de audio de alta fidelidad, que capturan la estructura en escalas de tiempo. Por el contrario, los modelos no autorregresivos son significativamente más rápidos que sus homólogos autorregresivos, principalmente debido a su capacidad de paralelización en aceleradores de hardware de aprendizaje profundo. Por ejemplo, en (Oord, 2018), el modelo WaveNet se combinó con un nuevo método llamado destilación de densidad de probabilidad (*Probability Density Distillation*, PDD) para generar muestras de voz. Este enfoque aprovecha la computación paralela para acelerar en órdenes de magnitud el método de la generación anterior (WaveNet). De manera similar, en (Ping, 2018), se propuso otra solución para la generación en paralelo de formas de onda utilizando WaveNet. En este caso, el uso de un método de flujo autorregresivo inverso gaussiano (IAF) para calcular la divergencia de Kullback-Leibler (KL) en forma cerrada simplifica el algoritmo de entrenamiento y proporciona una destilación muy eficiente. Recientemente, el MelGAN propuesto en (Kumar, 2019), que se basa en una arquitectura convolucional de retroalimentación, pudo generar audio sin procesar y mejorar otros modelos de inversión del espectrograma de Mel.

Los modelos WaveGAN (Donahue, 2018) y GANSynth (Engel, 2019) atrajeron una atención importante por su notable desempeño. WaveGAN genera audio sin procesar de dígitos hablados generando espectrogramas y convirtiéndolos de nuevo en audio usando el algoritmo de GriffinLim. Mientras tanto, GANSynth crea audio de instrumentos musicales utilizando una representación espectral de notas en magnitud logarítmica. Otro intento reciente de generar audio es la GAN guiada (Haque, 2020), una arquitectura que genera muestras de audio de alta calidad después de haber sido entrenada con una cantidad mínima de muestras etiquetadas como guía.



En cuanto al campo de la actividad sísmica, se han utilizado algunos métodos generativos, incluidos los modelos GAN. En (Sen, 2019), por ejemplo, se desarrolló un método de *autoencoder* variacional llamado SaltSeg para interpretar imágenes sísmicas. Otros estudios aplicaron modelos GAN para reconstruir datos sísmicos faltantes o sub muestreados (Oliveira, 2018; Siahkoochi, 2018) y para transformar una imagen sísmica en un modelo de velocidad de onda sísmica (Mosser, 2018). Además, en (Zhang, 2020) se creó una red U-Net anidada de enlace residual (RLU-Net) para detectar la llegada de señales microsísmicas en entornos de baja relación señal / ruido (SNR). Este estudio destacó el papel crucial del entrenamiento adversario que hace que el modelo sea preciso y eficiente. Finalmente, Wang (2019) utilizó un modelo GAN para generar señales sísmicas de terremotos sin procesar en el dominio del tiempo

Aunque los métodos basados en GAN se han utilizado en el campo sísmico, no hay evidencia (que sepan los autores de esta propuesta) de su uso para generar datos sintéticos de actividad sísmica volcánica como se pretende realizar en este proyecto.

Investigaciones previas del equipo de investigación de esta propuesta

N. Pérez, F. Granda, D. Benítez, F. Grijalva, and R. Lara. Toward real-time volcano seismic events' classification: A new approach using mathematical morphology and similarity criteria. *IEEE Transactions on Geoscience and Remote Sensing*, 2021 (In Press)

Lara-Cueva, R., Larco, J. C., Benítez, D. S., Pérez, N., Grijalva, F., & Ruiz, M. (2020). On finding possible frequencies for recognizing microearthquakes at Cotopaxi volcano: A machine learning based approach. *Journal of Volcanology and Geothermal Research*, 407, 107092.

Pérez, N., Venegas, P., Benitez, D., Grijalva, F., Lara, R., & Ruiz, M. (2020). Benchmarking Seismic-Based Feature Groups to Classify the Cotopaxi Volcanic Activity. *IEEE Geoscience and Remote Sensing Letters*.

Duque, A., González, K., Pérez, N., Benítez, D., Grijalva, F., Lara-Cueva, R., & Ruiz, M. (2020). Exploring the unsupervised classification of seismic events of Cotopaxi volcano. *Journal of Volcanology and Geothermal Research*, 403, 107009.

Pérez, N., Benítez, D., Grijalva, F., Lara-Cueva, R., Ruiz, M., & Aguilar, J. (2020). ESeismic: Towards an Ecuadorian volcano seismic repository. *Journal of Volcanology and Geothermal Research*, 106855.

Brusil, C., Grijalva, F., Lara-Cueva, R., Ruiz, M., & Acuña, B. (2019, November). A Semi-Supervised Approach for Microseisms Classification from Cotopaxi Volcano. In *2019 IEEE Latin American Conference on Computational Intelligence (LA-CCI)* (pp. 1-6). IEEE.

Zambrano, A. M., Perez, I., Palau, C., & Esteve, M. (2016). Future Generation Computer Systems. Technologies of Internet of Things applied to an Earthquake Early Warning System. DOI 10.1016/j.future.2016.10.009

12. DESCRIPCIÓN DETALLADA DEL PROYECTO, INCLUIDO METODOLOGÍA (máximo tres carillas)

De acuerdo a los objetivos planteados, se describirá la metodología en tres etapas: propuesta de un método para la generación de señales volcánicas artificiales basado en un modelo GAN condicional, evaluación del método propuesto y comparación con la generación con Bootstrapping.



Propuesta de un método para la generación de señales volcánicas artificiales basado en un modelo GAN condicional

Se partirá de la base de datos *pública* ESeismic descrita en (Pérez, 2020b) que contiene 1187 eventos sísmicos de las siguientes clases: VT, LP, sismos regionales y tremores. Como la mayor parte de eventos de esta base corresponden a VT y LP, solo se generarán eventos artificiales de estos dos tipos. La base de datos contiene señales en tiempo de dos estaciones del volcán Cotopaxi (estaciones denominadas VC1 y BREF). Las señales serán preprocesadas para mantener la mayor cantidad de información relevante y eliminar artefactos a través de filtros convencionales de procesamiento digital de señales.

Se estudiará el modelo GAN condicional descrito en (Mirza, 2014) que es el primer trabajo en proponer una GAN condicionada sobre las etiquetas de la base de datos ESeismic. Dado que dicho modelo fue concebido inicialmente para trabajar con imágenes, se adaptará la arquitectura de la red neuronal a la naturaleza unidimensional de las señales volcánicas del Cotopaxi. Por otro lado, se analizará la conveniencia de usar una representación espectral en magnitud y/o fase o inclusive una representación tiempo frecuencia para alimentar la GAN.

Evaluación del método propuesto

Se evaluará el método propuesto mediante métricas comúnmente utilizadas en modelos GAN como la Distancia de Frechet (*Frechet Distance*, FD) o similares. Estas métricas miden la similitud entre dos vectores de características obtenidas de instancias reales y artificiales. Puntajes de la FD bajos indican una alta similitud estadística.

Comparación

Como técnica de referencia se implementará la conocida técnica estadística denominada Bootstrapping. Bootstrapping será usado para generar señales artificiales que serán comparadas con las generadas por el método propuesto basado en GAN. La generación con Bootstrapping será realizada a lo largo del espacio de características que puede ser temporal, espectral o de tiempo-frecuencia. Al igual que en el modelo GAN, se evaluará la conveniencia de usar dichos espacios de características. La comparación entre ambos métodos será evaluada en términos de la FD.

Referencias

Alqahtani, H., Kavakli-Thorne, M., & Kumar, G. (2019). Applications of generative adversarial networks (gans): An updated review. *Archives of Computational Methods in Engineering*, 1-28.

Asim, K. M., Idris, A., Iqbal, T., & Martínez-Álvarez, F. (2018). Seismic indicators based earthquake predictor system using Genetic Programming and AdaBoost classification. *Soil Dynamics and Earthquake Engineering*, 111, 1-7.

Bhatti, S. M., Khan, M. S., Wuth, J., Huenupan, F., Curilem, M., Franco, L., & Yoma, N. B. (2016). Automatic detection of volcano-seismic events by modeling state and event duration in hidden Markov models. *Journal of Volcanology and Geothermal Research*, 324, 134-143.

Brusil, C., Grijalva, F., Lara-Cueva, R., Ruiz, M., & Acuña, B. (2019, November). A Semi-Supervised Approach for Microseisms Classification from Cotopaxi Volcano. In *2019 IEEE Latin American Conference on Computational Intelligence (LA-CCI)* (pp. 1-6). IEEE.

Chouet, B. A., Page, R. A., Stephens, C. D., Lahr, J. C., & Power, J. A. (1994). Precursory swarms of long-period events at Redoubt Volcano (1989–1990), Alaska: their origin and use as a forecasting tool. *Journal of Volcanology and Geothermal Research*, 62(1-4), 95-135.



Curilem, G., Vergara, J., Fuentealba, G., Acuña, G., & Chacón, M. (2009). Classification of seismic signals at Villarrica volcano (Chile) using neural networks and genetic algorithms. *Journal of volcanology and geothermal research*, 180(1), 1-8.

Curilem, M., Huenupan, F., Beltrán, D., San Martín, C., Fuentealba, G., Franco, L., ... & Yoma, N. B. (2016). Pattern recognition applied to seismic signals of Llaima volcano (Chile): An evaluation of station-dependent classifiers. *Journal of Volcanology and Geothermal Research*, 315, 15-27.

Donahue, C., McAuley, J., & Puckette, M. (2018). Adversarial audio synthesis. *arXiv preprint arXiv:1802.04208*.

Duque, A., González, K., Pérez, N., Benítez, D., Grijalva, F., Lara-Cueva, R., & Ruiz, M. (2020). Exploring the unsupervised classification of seismic events of Cotopaxi volcano. *Journal of Volcanology and Geothermal Research*, 403, 107009.

Engel, J., Agrawal, K. K., Chen, S., Gulrajani, I., Donahue, C., & Roberts, A. (2019). Gansynth: Adversarial neural audio synthesis. *arXiv preprint arXiv:1902.08710*.

Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... & Bengio, Y. (2014). Generative adversarial nets. *Advances in neural information processing systems*, 27, 2672-2680.

Haque, K. N., Rana, R., & Schuller, B. (2020). Guided generative adversarial neural network for representation learning and high fidelity audio generation using fewer labelled audio data. *arXiv preprint arXiv:2003.02836*.

Karras, T., Laine, S., & Aila, T. (2019). A style-based generator architecture for generative adversarial networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4401-4410).

Kumar, K., Kumar, R., de Boissiere, T., Gestin, L., Teoh, W. Z., Sotelo, J., ... & Courville, A. C. (2019). Melgan: Generative adversarial networks for conditional waveform synthesis. In *Advances in Neural Information Processing Systems* (pp. 14910-14921).

Lara-Cueva, R. A., Benítez, D. S., Carrera, E. V., Ruiz, M., & Rojo-Álvarez, J. L. (2016). Automatic recognition of long period events from volcano tectonic earthquakes at cotopaxi volcano. *IEEE Transactions on Geoscience and Remote Sensing*, 54(9), 5247-5257.

McNutt, S. R. (2005). Volcanic seismology. *Annu. Rev. Earth Planet. Sci.*, 32, 461-491.

Mosser, L., Kimman, W., Dramsch, J., Purves, S., De la Fuente Briceño, A., & Ganssle, G. (2018, June). Rapid seismic domain transfer: Seismic velocity inversion and modeling using deep generative neural networks. In *80th eage conference and exhibition 2018* (Vol. 2018, No. 1, pp. 1-5). European Association of Geoscientists & Engineers.

Mirza, M., & Osindero, S. (2014). Conditional generative adversarial nets. *arXiv preprint arXiv:1411.1784*.

Oliveira, D. A., Ferreira, R. S., Silva, R., & Brazil, E. V. (2018). Interpolating seismic data with conditional generative adversarial networks. *IEEE Geoscience and Remote Sensing Letters*, 15(12), 1952-1956.

Oord, A. V. D., Dieleman, S., Zen, H., Simonyan, K., Vinyals, O., Graves, A., ... & Kavukcuoglu, K. (2016). Wavenet: A generative model for raw audio. *arXiv preprint arXiv:1609.03499*.

Oord, A., Li, Y., Babuschkin, I., Simonyan, K., Vinyals, O., Kavukcuoglu, K., ... & Casagrande, N. (2018, July). Parallel wavenet: Fast high-fidelity speech synthesis. In *International conference on machine learning* (pp. 3918-3926). PMLR.

Pérez, N., Venegas, P., Benítez, D., Lara-Cueva, R., & Ruiz, M. (2020a). A new volcanic seismic signal descriptor and its application to a data set from the cotopaxi volcano. *IEEE Transactions on Geoscience and Remote Sensing*.

Pérez, N., Benítez, D., Grijalva, F., Lara-Cueva, R., Ruiz, M., & Aguilar, J. (2020b). ESeismic: Towards an Ecuadorian volcano seismic repository. *Journal of Volcanology and Geothermal Research*, 106855.



Ping, W., Peng, K., & Chen, J. (2018). Clarinet: Parallel wave generation in end-to-end text-to-speech. *arXiv preprint arXiv:1807.07281*.

Sen, S., Kainkaryam, S., Ong, C., & Sharma, A. (2019). SaltSeg: A β -variational autoencoder constrained encoder-decoder architecture for accurate geologic interpretation. In *SEG Technical Program Expanded Abstracts 2019* (pp. 2493-2497). Society of Exploration Geophysicists.

Siahkoohi, A., Kumar, R., & Herrmann, F. (2018, June). Seismic data reconstruction with generative adversarial networks. In *80th EAGE Conference and Exhibition 2018* (Vol. 2018, No. 1, pp. 1-5). European Association of Geoscientists & Engineers.

Titos, M., Bueno, A., Garcia, L., & Benitez, C. (2018). A deep neural networks approach to automatic recognition systems for volcano-seismic events. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(5), 1533-1544.

Vasquez, S., & Lewis, M. (2019). Melnet: A generative model for audio in the frequency domain. *arXiv preprint arXiv:1906.01083*.

Venegas, P., Pérez, N., Benítez, D., Lara-Cueva, R., & Ruiz, M. (2019). Combining filter-based feature selection methods and gaussian mixture model for the classification of seismic events from cotopaxi volcano. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(6), 1991-2003.

Wang, T., Trugman, D., & Lin, Y. (2019). SeismoGen: Seismic Waveform Synthesis Using Generative Adversarial Networks. *arXiv preprint arXiv:1911.03966*.

Zhang, J., & Sheng, G. (2020). First arrival picking of microseismic signals based on nested U-Net and Wasserstein Generative Adversarial Network. *Journal of Petroleum Science and Engineering*, 195, 107527.

13. INFRAESTRUCTURA Y EQUIPOS

- Indicar la infraestructura y equipos **disponibles** para la ejecución del proyecto, con la ubicación actual de los mismos

Este proyecto no hará uso de infraestructura o equipos de la Escuela Politécnica Nacional.



B. DATOS INFORMATIVOS

1. INFORMACIÓN DEL DIRECTOR, COLABORADOR (EPN o EXTERNO) Y COLABORADORES TÉCNICOS

Apellidos y nombres	No. de Cédula	HSS*	Departamento	Rol	Título de mayor nivel y mención.
Grijalva Arévalo Felipe Leonel	1710847441	6	DETRI	Investigador Colaborador	PhD en Ing. Eléctrica, mención en Ing. de Computación
Ana María Zambrano Vizuete	1714040258	8	DETRI	Director	PhD en Telecomunicacio nes, mención Telemática

* HSS =Horas Semana Semestre: Es el número de horas que se dedica por semana a la investigación. Este número de horas se mantiene para todo el semestre



C. DECLARACIÓN FINAL DECLARACIÓN DEL DIRECTOR DEL PROYECTO

El equipo de investigadores, representado por el Director del Proyecto declara lo siguiente:

- Que el presente proyecto es una creación original de mi autoría y del equipo de investigadores, y por tanto asumimos la completa responsabilidad legal en caso de que un tercero alegue la titularidad de los derechos intelectuales del proyecto, exonerando a la EPN de cualquier acción legal que se derive por esta causa.
- Que el presente proyecto no ha sido presentado en ninguna convocatoria de otra institución pública o privada. El incumplimiento será causal para que el proyecto no sea tomado en consideración.
- Que si el proyecto genera algún producto o procedimiento susceptible de obtener derechos de propiedad intelectual, de los cuales se deriven beneficios, aceptamos que éstos serán compartidos entre los investigadores y la institución o las instituciones participantes en el proyecto, conforme a lo establecido en el COESC.
- Que el equipo de investigadores y/o instituciones participantes se comprometen a mantener la confidencialidad de la información si ésta podría ser susceptible de protección por patentes, y solicitar la valoración de propiedad intelectual respectiva previa a cualquier publicación o difusión.
- Que para el caso de derechos de autor otorgamos una licencia de uso exclusivo con fines académicos para la o las instituciones participantes en el proyecto.
- Que aceptamos conocer y cumplir con la normativa vigente para la gestión de proyectos.

Firma del Director del Proyecto
Nombre: Ana María Zambrano Vizúete
C.I.: 1714040258

