Institución Universitaria
Reacreditada en Alta Calidad
80 Años

Boletín Informativo

Departamento de educación y Ciencias Básicas

2025-1

Primer Boletín

Notas científicas, informativas y más.

Docente Ramiro Humberto Hoyos Zuluaga
Fuentes: Propia, Departamento de Educación y Ciencias Básicas, Dirección de Planeación ITM

Nuevos estudiantes en los dos programas que pertenecen al Departamento de Educación y Ciencias Básicas

En el primer semestre del año 2025, el Departamento de Educación y Ciencias Básicas admitió a 86 nuevos estudiantes en su programa de pregrado en Química Industrial y a 12 en la Maestría en Ciencias: Innovación en Educación. Esto da un total de 464 estudiantes matriculados actualmente en pregrado y 27 en la maestría. De esta manera, el número total de estudiantes, entre nuevos y antiguos, asciende a 491, quienes están siendo formados profesionalmente en los programas del Departamento de Educación y Ciencias Básicas.

Acompañamiento desde el Departamento en la formación de estudiantes de la Institución Universitaria ITM, en el componente de las áreas de Ciencias Básicas

El acompañamiento a los estudiantes de la Institución Universitaria ITM se realiza desde el Departamento de Educación y Ciencias Básicas, el cual ofrece 942 cursos transversales en su componente de formación en las áreas de ciencias básicas. Además, en el programa de Química Industrial se imparten 73 cursos distribuidos a lo largo de todos los semestres, y en la Maestría en Ciencias: Innovación en Educación, se ofrecen actualmente 12 cursos.

Red Confianza

La Institución Universitaria ITM cuenta con el acompañamiento de la Red Confianza como parte de la estrategia del Programa de Diversidad e Inclusión, el cual promueve la inclusión social desde los diferentes programas académicos. En este contexto, es importante señalar que la distribución de los estudiantes matriculados en el programa de Química Industrial es la siguiente: 5 estudiantes presentan alguna discapacidad, 25 pertenecen a diferentes etnias, 48 son caracterizados como víctimas y 47 están clasificados por género. De esta forma, la institución fomenta la responsabilidad social, el respeto, la tolerancia y, sobre todo, la inclusión social con calidad humana.

Ilustración generada con DALL·E: inclusión social

Sesiones del Consejo de Facultad de Ciencias Exactas y Aplicadas 2025-1

Desde el Departamento de Educación y Ciencias Básicas, invitamos a todos los profesores y estudiantes que forman parte activa de la facultad a tener en cuenta el siguiente calendario de sesiones de nuestro consejo. Esto con el fin de evitar reprocesos por la entrega de solicitudes y trámites en fechas diferentes a las señaladas, que requieran el aval del mismo.

FECHA SESIONES DEL CONSEJO	FECHA LÍMITE ENTREGA SOLICITUDES	HORA LÍMITE PARA RADICACIÓN DE SOLICITUDES
ENERO 22	ENERO 17	**12:00 m.**
FEBRERO 05	ENERO 31	
FEBRERO 19	FEBRERO 14	
MARZO 05	FEBRERO 28	
MARZO 19	MARZO 14	
ABRIL 02	MARZO 28	
ABRIL 23	ABRIL 11	
MAYO 07	MAYO 02	
MAYO 21	MAYO 16	
JUNIO 04	MAYO 30	
JUNIO 18	JUNIO 13	
JULIO 02	JUNIO 27	
JULIO 16	JULIO 11	

Recuerde que cualquier modificación a este calendario será comunicada de manera oportuna. Asimismo, cada solicitud debe incluir los documentos requeridos como soporte; en caso de no presentarlos, se notificará al solicitante para que realice la respectiva subsanación.

Docente: Ramiro Humberto Hoyos Zuluaga, Fuente: Organización del evento

2025, Año Internacional de la Ciencia y las Tecnologías Cuánticas
Seminario Permanente CONCIENCIA ITM

En el marco de la celebración propuesta por Naciones Unidas para declarar el año 2025 como el Año Internacional de la Ciencia y las Tecnologías Cuánticas, se conformó un equipo organizador del evento con los profesores Santiago Pérez Walton, Richard Benavides Palacios y Ramiro Humberto Hoyos Zuluaga. Este equipo, desde el ITM y en el contexto del Seminario Permanente CONCIENCIA ITM, presentó a las directivas universitarias en el mes de enero una propuesta que consistió en realizar, durante todo el año académico, una charla mensual sobre temas y tópicos de la Mecánica Cuántica, desarrollados en las universidades de Medellín y su área metropolitana por profesores e investigadores de estas.
En este orden de ideas, el pasado 28 de febrero se llevó a cabo el lanzamiento de dicho evento con la primera charla titulada *El universo cuántico de las partículas fundamentales*, dictada por el PhD en altas energías y profesor asociado de la UdeA, José David Ruiz Álvarez. Esta charla es una de las siete programadas desde el Departamento de Educación y Ciencias Básicas para conmemorar la celebración.

Fuente: Comunicaciones ITM, primera charla del evento CONCIENCIA ITM titulada *El universo cuántico de las partículas fundamentales*, desarrollada por el PhD en altas energías y profesor asociado de la Universidad de Antioquia José David Ruiz Álvarez.

Para el equipo organizador y, en general, para nuestra planta docente y la comunidad académica del ITM, es motivo de orgullo contar con invitados de talla nacional e internacional, entre los cuales se encuentra Richard Hamilton Benavides Palacios, profesor de nuestra institución universitaria.

Nos acompañarán en este magno evento los siguientes profesores universitarios e investigadores con una destacada trayectoria docente e investigativa en temas relacionados con la Mecánica Cuántica: José David Ruiz Álvarez, Richard Hamilton Benavides Palacios, Jorge Mario Osorio Guillén, Sebastián Duque Mesa, Román Castañeda, Boris Anghelo Rodríguez Rey y Jorge Mahecha Gómez. Cabe resaltar que, para la clausura del Año Internacional de la Ciencia y la Tecnología Cuánticas, se tiene programado un panel de cierre con la participación de la mayoría de los ponentes mencionados, cuya asistencia ha sido confirmada en su mayoría. Además, se han contactado otros profesores para que participen en este panel final.

¿Qué es y en qué consiste la Mecánica Cuántica?

Es una teoría de la física que describe cómo funcionan los sistemas a nivel subatómico, es decir, a escalas extremadamente pequeñas que componen los átomos, tales como electrones, protones, neutrones, entre otros. Existe una gran diferencia entre esta y la mecánica clásica, ya que, con la mecánica clásica, podemos describir el comportamiento de los objetos en escalas macroscópicas, como, por ejemplo, el movimiento de una pelota que rueda, de un cuerpo que cae, el movimiento de un automóvil o de los objetos que cotidianamente nos rodean a escala macro. Estos comportamientos podemos percibirlos en su conjunto con nuestros sentidos o con herramientas tecnológicas no muy sofisticadas, que nos ayuden a describir completamente su comportamiento.

En términos científicos, podemos decir que la Mecánica Cuántica aborda varias hipótesis fundamentales que constantemente desafían nuestra intuición sobre cómo verdaderamente funciona el universo, explicadas bajo premisas y conceptos que retan nuestra cognición.

La siguiente ilustración resume algunos de los aspectos más relevantes de la mecánica cuántica, los cuales serán definidos posteriormente.

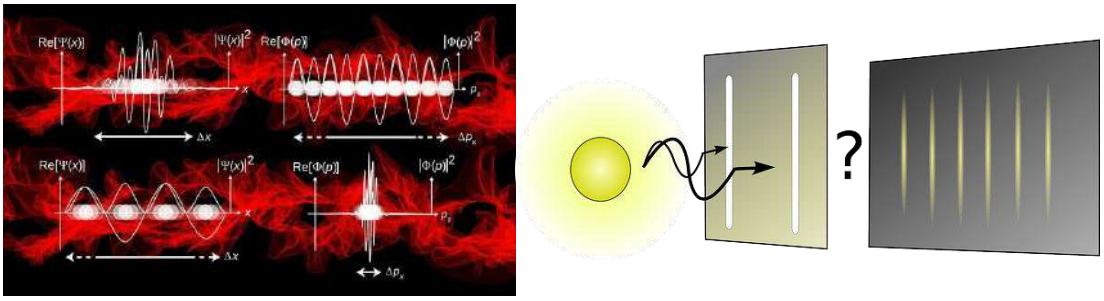

Fuente: https://pixabay.com/es/images/search/mec%c3%a1nica%20cu%c3%a1ntica%20cuantizaci%c3%b3n/

1. **Cuantización**: La energía no es continua, sino que está "cuantizada". Esto significa que las partículas, como los electrones en un átomo, solo pueden tener ciertos niveles de energía específicos y no valores intermedios. Estos niveles son como "peldaños" en una escalera, donde la partícula solo puede estar en uno de ellos, pero no entre ellos. Es similar a las personas que participan en un espectáculo en un escenario con sillas numeradas, donde no se

permite que nadie esté de pie, por lo que cada persona solo puede ocupar una de las sillas asignadas.

2. **Dualidad onda-partícula**: Las partículas subatómicas, como los electrones o los fotones, muestran tanto propiedades de partículas como de ondas. Este fenómeno se observa en el famoso experimento de la doble rendija, donde la luz y las partículas se comportan como ondas cuando no se observan directamente, pero como partículas cuando se miden.

3. **Principio de incertidumbre de Heisenberg**: Es imposible conocer con precisión ciertos pares de propiedades de una partícula de manera simultánea, como su posición y su momento (la cantidad de movimiento). Cuanto más precisamente tratemos de medir una de estas propiedades, menor será la precisión sobre la otra. Esto no es una limitación de nuestras herramientas de medición, sino una propiedad fundamental de la naturaleza.

4. **Superposición**: Las partículas pueden estar en varios estados al mismo tiempo, lo que significa que un electrón, por ejemplo, puede estar en múltiples ubicaciones dentro de un átomo simultáneamente. Este fenómeno es conocido como superposición cuántica. Solo cuando se mide o se observa el sistema, la partícula "elige" un estado definido.

5. **Entrelazamiento cuántico**: Dos partículas pueden estar entrelazadas de tal manera que el estado de una de ellas depende instantáneamente del estado de la otra, incluso si están separadas por grandes distancias. Este fenómeno, que Einstein denominó "acción fantasmal a distancia", ha sido confirmado experimentalmente y constituye un aspecto clave de la mecánica cuántica.

6. **Función de onda**: En la mecánica cuántica, el estado de una partícula se describe mediante una función de onda, que es una función matemática que proporciona la probabilidad de encontrar una partícula en una determinada ubicación o con ciertas características. La probabilidad de encontrar la partícula en un lugar específico está dada por el cuadrado de la magnitud de la función de onda.

La mecánica cuántica ha tenido un enorme impacto en la ciencia y la tecnología modernas. Ha llevado al desarrollo de tecnologías como los semiconductores, la computación cuántica y la resonancia magnética (RM). Sin embargo, la teoría cuántica también sigue siendo misteriosa y está llena de paradojas. Aunque ha sido increíblemente exitosa a nivel experimental, muchos aspectos conceptuales aún son objeto de debate y reflexión.

Principales aplicaciones de la mecánica cuántica

La mecánica cuántica ha tenido un impacto profundo en varias áreas de la ciencia y la tecnología modernas, dando lugar a aplicaciones que hoy en día son fundamentales para la vida cotidiana. Algunas de las aplicaciones más importantes de la mecánica cuántica incluyen:

Electrónica y semiconductores

La tecnología de semiconductores se basa en principios cuánticos. Los transistores, que son la base de los circuitos electrónicos modernos, funcionan gracias a la mecánica cuántica. El comportamiento de los electrones en materiales semiconductores, como el silicio, se entiende a través de la teoría cuántica, lo que permite la fabricación de dispositivos como computadoras, teléfonos móviles y otros aparatos electrónicos.

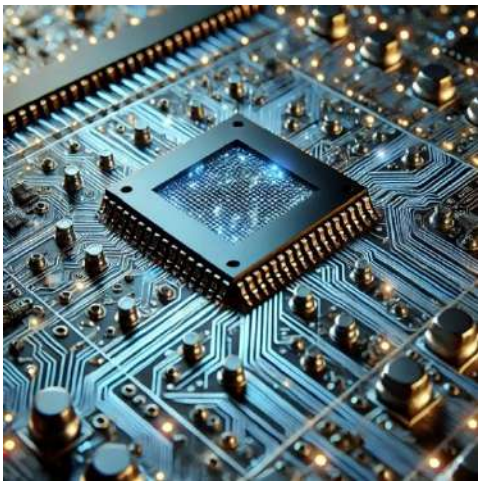

Imagen generada con DALL·E de un semiconductor moderno, mostrando su estructura interna con transistores y conexiones microscópicas.

Láseres

Los láseres (amplificación de luz por emisión estimulada de radiación) son una de las aplicaciones más visibles de la mecánica cuántica. Funcionan porque las partículas de luz (fotones) interactúan de acuerdo con las leyes cuánticas. Los láseres se utilizan en una amplia gama de aplicaciones, desde la cirugía ocular (como la corrección de la vista mediante LASIK) hasta la lectura de discos ópticos (CD, DVD, Blu-ray), comunicaciones por fibra óptica y escáneres de códigos de barras.

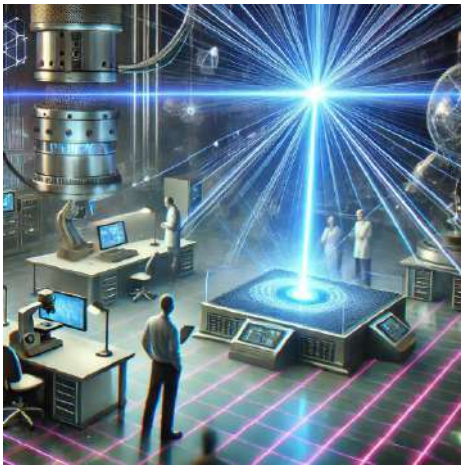

Ilustración generada con DALL·E de un láser cuántico en un entorno de laboratorio futurista.

Resonancia magnética (RM)

La resonancia magnética es una técnica de imagen médica que se basa en principios cuánticos. Utiliza campos magnéticos y ondas de radio para obtener imágenes detalladas de los órganos internos. A nivel subatómico, los protones en los núcleos de los átomos presentes en los tejidos del cuerpo interactúan con los campos magnéticos mediante "giros", los cuales se pueden medir para crear imágenes.

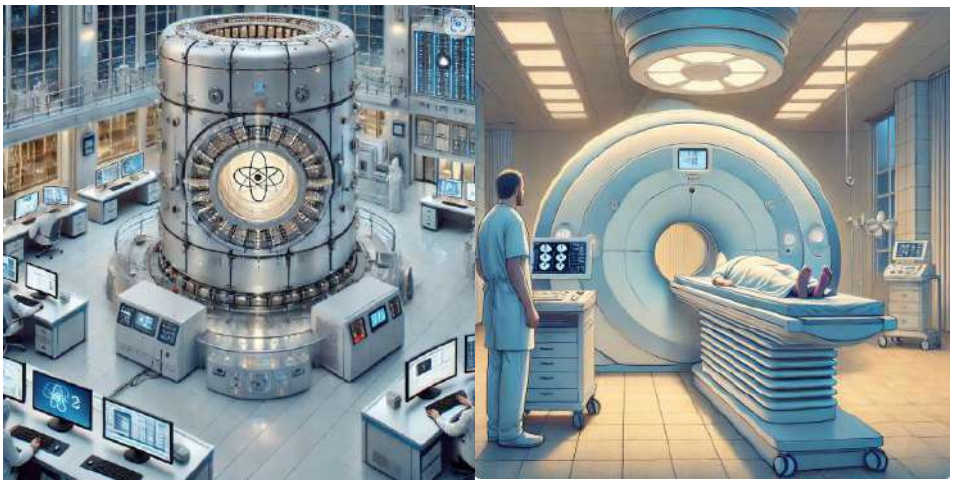

Ilustración generada con DALL·E: Resonador magnético nuclear en un entorno hospitalario

Computación cuántica

La computación cuántica es un campo emergente basado en los principios de la mecánica cuántica que promete revolucionar el poder de cálculo. Los bits cuánticos (qubits) pueden representar más de un estado al mismo tiempo debido al principio de superposición. Esto permite que las computadoras cuánticas realicen ciertos cálculos mucho más rápido que las computadoras tradicionales. Actualmente, se investiga el uso de la computación cuántica para resolver problemas complejos en áreas como criptografía, simulaciones moleculares, inteligencia artificial y optimización.

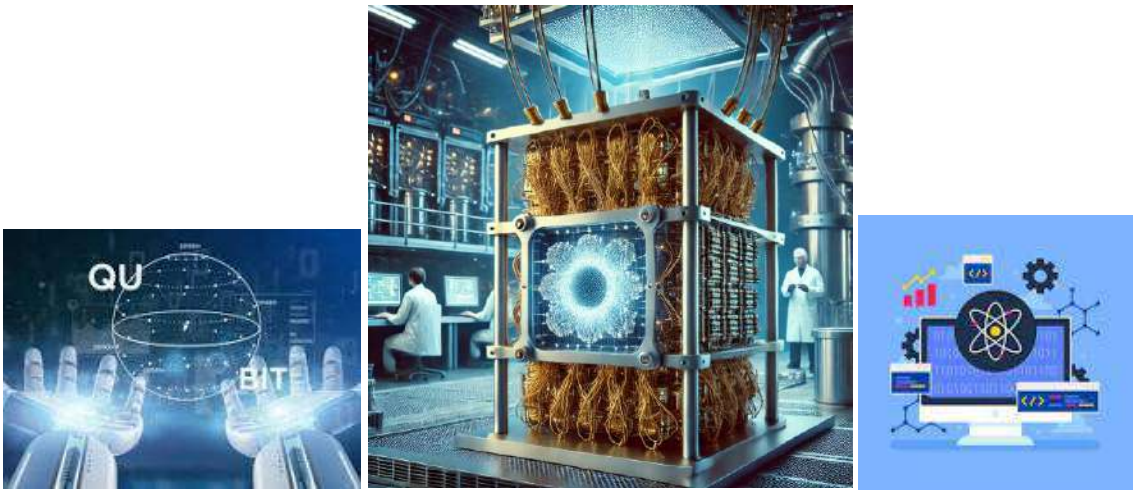

Ilustración generada de un procesador cuántico con DALL·E

Criptografía cuántica

La criptografía cuántica utiliza los principios de la mecánica cuántica para crear métodos de comunicación extremadamente seguros. Un ejemplo es el intercambio cuántico de claves (QKD, por sus siglas en inglés), que emplea el entrelazamiento cuántico y el principio de incertidumbre para garantizar que cualquier intento de interceptar la clave de comunicación altere inmediatamente la información, haciéndolo detectable. Esto podría mejorar significativamente la seguridad de las comunicaciones electrónicas.

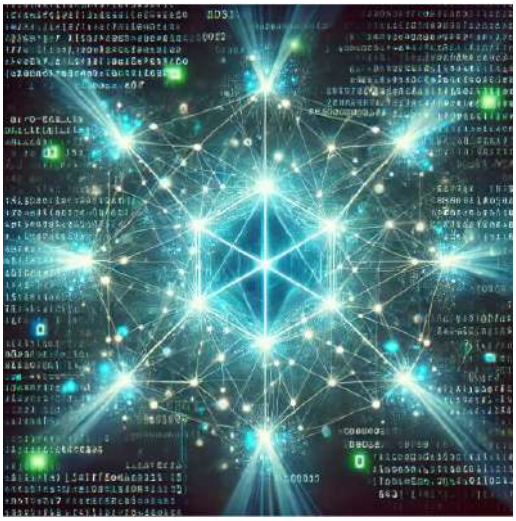

Ilustración generada con DALL·E

Sensores cuánticos

Los sensores cuánticos aprovechan los efectos cuánticos, como la interferencia y el entrelazamiento, para lograr mediciones de gran precisión. Estos sensores pueden utilizarse en una variedad de aplicaciones, desde la medición extremadamente precisa de campos magnéticos (como en la magnetometría cuántica) hasta la detección de pequeñas variaciones en el tiempo y el espacio. Los sensores cuánticos tienen aplicaciones potenciales en navegación, geolocalización, análisis químico y más.

Ilustración generada con DALL·E

Entre muchas otras aplicaciones también tenemos:

Energía solar

La tecnología de células solares también se beneficia de los principios cuánticos. Las células solares funcionan aprovechando el efecto fotovoltaico, en el que los fotones de la luz solar excitan los electrones en un material semiconductor, generando electricidad. El estudio cuántico de la materia y las interacciones de los fotones con los electrones ha permitido mejorar la eficiencia de las células

solares. En el futuro, la mecánica cuántica podría contribuir al desarrollo de tecnologías solares más avanzadas, como las células solares de perovskita

Teletransportación cuántica
Aunque aún se encuentra en una etapa experimental, la teletransportación cuántica se refiere a la transferencia de información cuántica (como el estado de un qubit) de una partícula a otra a través del entrelazamiento cuántico, sin mover físicamente la partícula en sí. Este fenómeno está siendo estudiado para aplicaciones futuras en comunicaciones y redes cuánticas.

Simulaciones cuánticas
La simulación de sistemas cuánticos complejos, como las interacciones entre partículas subatómicas o los comportamientos de materiales a nivel cuántico, es una de las áreas más prometedoras. Las computadoras cuánticas podrían simular estos sistemas de manera mucho más eficiente que las computadoras clásicas, lo que abriría nuevas posibilidades para el desarrollo de materiales, fármacos y soluciones en áreas como la química, la física y la biología.

En conclusión, la mecánica cuántica no solo ha cambiado nuestra comprensión del universo a nivel fundamental, sino que también ha dado lugar a una variedad de aplicaciones tecnológicas que ya están presentes en nuestra vida cotidiana y que, en el futuro, podrían revolucionar aún más sectores de diversas áreas tecnológicas, como la computación, las comunicaciones, la medicina y la energía, entre otras.

Docente: Luis Fernando Duque Gómez

Automated velocity estimation by Deep Learning based seismic-to-velocity mapping

Duque, L.[1]*, Gutiérrez, G. [2]*, Arias, C.[1]*, Rüger, A.[3], Jaramillo, H.[4]
[1]Instituto Tecnológico Metropolitano, [2] MOONBLOCK, [3]Colorado School of Mines, [4]University of Medellín

Summary

We propose a novel method for velocity estimation that leverages the newest advances in Deep Learning (DL) technology. This method is fully automatic and maps seismic shot-domain data to corresponding depth-domain velocity fields via two neural networks.
Our new method is conceptually different from conventional methods such as seismic tomography or Full Waveform Inversion (FWI) that minimize a fixed objective function. Here, a system of neural networks automatically and continuously learns an objective function while training the seismic-to-velocity mapping.
The newly introduced method avoids many of the drawbacks of conventional velocity estimation techniques, such as dependence on initial models or cycle-skipping. It uses the full seismic wavefield and avoids picking of first-arrival traveltimes. The system needs to be trained with hundreds or thousands of examples of seismic data paired with their corresponding velocity models relevant for the current project. Training the system is the main computationally demanding step and produces a mapping function that contains the seismic "know-how" for the presumed geologic setting. The computational cost of the subsequent estimation of velocity from new seismic data is negligent.
Our first tests on complex two-dimensional synthetic data produce impressive results, underlining the potential of DL for velocity analysis.

Introduction

Velocity models are required to convert recorded seismic data into subsurface images that can be analyzed by seismic interpreters. Building and verifying these velocity models is a crucial step in seismic imaging and can devour weeks or months of expert human resources. Increasingly large data volumes or continuous recording of data can easily overwhelm available domain experts, or, at minimum, significantly increases the time required for high-quality, iterative velocity modeling.

Velocity models can be computed by a variety of methods. In the last years, full-waveform inversion (FWI) emerged as a powerful technique to obtain previously unachievable, high-resolution velocity models. These high-quality velocity models make it possible to explore geological structures of the Earth's subsurface that were until recently extremely difficult to image.
Despite its high potential, FWI technology intrinsically suffers from a number of drawbacks including its substantial computational cost. The success of the method is strongly dependent on an adequate initial velocity model. Poor initial guesses can cause the inversion to deviate and predict sub-optimum and often non-geological models. FWI also presents problems of nonlinearity due to the form of its cost function or other physical phenomena that cannot be adequately synthesized. Other issues may come with the acquisition; for example, the lack of low frequencies in recorded data or missing long recording offsets.

Due to the importance and difficulty of velocity-model estimation, a variety of new and advanced techniques have been explored including invoking artificial intelligence (AI) algorithms. AI has been developed several decades ago and is applied in computer vision, medicine, and social sciences among other areas of knowledge. In our industry, AI has gained popularity in diverse geophysical areas such as: waveform recognition, first-break picking (Murat, M. E., and Rudman, A. J.,1992), well-log analysis (Huang et al., 1996), and seismic inversion (Röth, G., and Tarantola, A., 1994). We will focus our attention on the last item on the list (seismic inversion) to optimize velocity fields, similar to the research by Araya-Polo et al., (2018) who implemented a deep-learning tomography algorithm, using semblance as input feature for a neural network. Machine learning is a branch of AI

in which computer systems have the ability to learn from data. In recent years machine learning has become a popular trend due to rapid developments of big data and social networks. The cutting edge of machine learning called Deep Learning (DL) is a rebirth of the traditional single hidden layer neural networks but with added layers. Advanced, cloud-based DL networks can efficiently process huge data volumes and promise to detect highly non-linear and nuanced relationships that occur in complicated natural phenomena. Here we develop a DL method to find 2D velocity models that may reduce the computational cost and shortcomings of traditional seismic inversion processes.

Conditional Adversarial Generative Networks

The process of using seismic data to predict a velocity model can be seen as an example of image-to-image translation, mapping an input image (seismic data) to an output image (the corresponding velocity field). This may seem far-fetched, but the AI community already produced previously considered unachievable results including the mapping between pairs such as: sketches to street scene; sketches to facade; aerial to map; day to night; black and white to color; and edges to photos (Isola et al., 2016).

Other applications with heterogeneous data are image to text and sound processing (Michelsanti, D., and Tan, Z. H., 2017). Similar to those applications, our approach finds structure in the relation of two very different images, namely, the relation between a seismogram and the velocity model of the subsurface it represents.

These advances in AI was made possible by a new generation of objective functions that tries to make a system's output indistinguishable from reality. This is exactly what has been achieved by Generative Adversarial Networks (GANs). The basic setup of this learning scheme consists of one network (G) generating new data from an adapting distribution, and another one (D) that tries to differentiate the

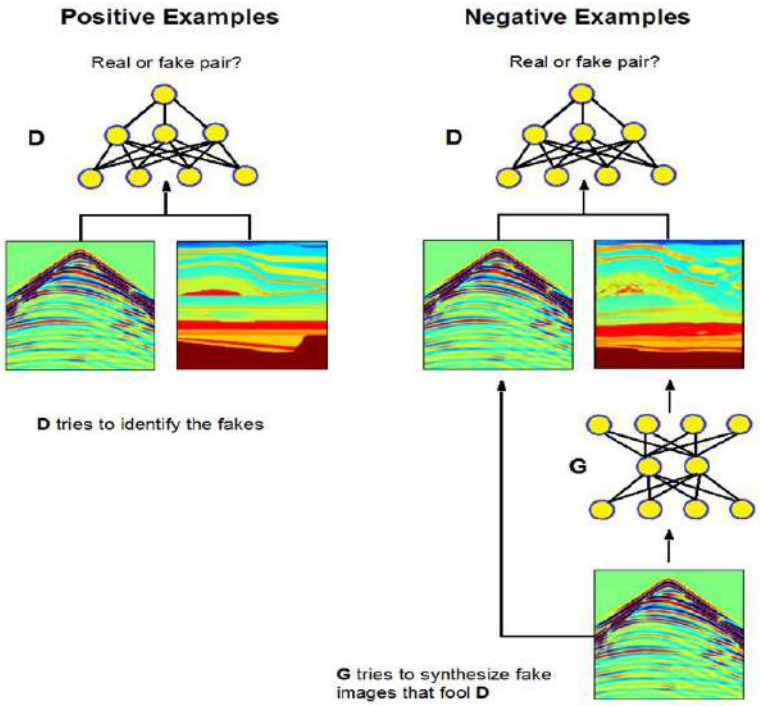

Figure 1*: Training procedure for the conditional generative adversarial network, using faked (perturbed) velocity models while preserving the shot data.*

generated image from the real data. Two competing networks, one of them is learning how to fool the other. At each iteration two cost functions should be minimized. First, the discriminator loss function:

$$L_D = -\frac{1}{n}\sum_{i=1}^{n} y_i[\log D(s_i, v_i)] + (1 - y_i)\left[\log\left(1 - D(s_i, G(s_i))\right)\right] \quad (1)$$

where y_i is the label for the i-th seismogram-velocity pair (s_i, v_i). The value of this label is 0 when the pair is fake and 1 when the pair is real. The expression (1) is known as binary cross entropy loss function. $D(s_i, v_i)$ is the value obtained when the network D is applied to a real pair (s_i, v_i) and is a value between 0.0 and 1. D is trained to minimize (1) which means that $D(s_i, v_i)$ should tend to 1 as the iteration number increases. $G(s_i)$ is the velocity model produced by G given s_i. The minimization of (1) also means that $D(s_i, G(s_i))$ should tend to 0 as D gets more trained. The second function to minimize is the generator loss function:

$$L_G = -\frac{1}{n}\sum_{i=1}^{n} y_i[log(D(s_i, G(s_i)\,)] + \lambda\frac{1}{n}\sum_{i=1}^{n} |v_i - G(s_i)|. \quad (2)$$

The first term in L_G is similar to the first term of (1). G is trained to make the value of $D(s_i, G(s_i))$ tend to 1. The second term in (2) is a regularizer term, used to ensure that the velocity models $G(s_i)$ does not deviate too far from the *true velocity models* v_i. The second term is a mean absolute error loss function and λ a constant that controls the importance of the second term (we used $\lambda = 100$). The order of training is important: first D should be trained which implies that (1) should be minimized varying the parameters of the D network but leaving the parameters of G constant (they are given random values at the first iteration). When the first training of D is done it is ready to discriminate between real and fake pairs and the next step is the training of G, minimizing (2) and leaving the parameters of D static. This pair of trainings is called an *epoch.* The procedure is repeated over several epochs (100 in our case). Within each epoch, D learns more to discriminate pairs and G learns to produce better velocity models. A graphical representation of the procedure is shown in Figure 1.

Two-dimensional SEG/EAGE Overthrust model testing

We used the Overthrust 3D model of 801x801x187 pixels in *x*, *y* and *z*-direction, respectively, (Aminzadeh et al., 1997) and took every slice in the [*xz*]and[*yz*] planes, obtaining a total of 1602 2D velocity models of 801x187 pixels. From this initial set of 1602 velocity models, we took out boxes of 187x187 pixels at random positions. This was done to ensure a high variability in the set of models and avoid overfitting. Each 187x187 pixel velocity model is associated to a seismogram produced synthetically by a propagation of a *9Hz* Ricker wavelet placed at the center of the model. The sampling was *0.025* km in space and *1.4* ms in time with 1179 temporal and 187 spatial grid points. A geophone was placed at every point of the grid on the surface. This procedure produced 1602 seismogram-velocity pairs from which we took 75% to train the neural networks and 25% to test it.

From the 400 tests, for visualization purposes, we picked three representative samples associated to different types of geological structures. In Figure 2 we show the synthetic data on the left frame, exact model on the right frame and predicted model in the center frame. From Figure 2a, we observe that the plain structures are well predicted although there is some loss of information in the deepest layers and some continuous reflectors are broken in the central region. Inaccuracies in predicting the shallow velocities seem to have impacted the depth placements of the reflectors. Figure 2b shows that the model reproduces a rough anticline structure lacking the finest details. Figure 2c shows the successful capture of a major fault that, although is not sharply defined, is accurately placed.

Conclusions

We successfully generate velocity fields from seismic shot data. Although the setup is somewhat academic, it nonetheless demonstrates the enormous potential of the method. We conclude that a deep neural network is able to estimate complex structures in the subsurface velocity model given enough training data, i.e., pairs of shot records and corresponding velocity fields. The success of the prediction depends on the presence of a set of training data with great variety of complex structures. By applying this technique to models divided into narrower strips, the complex structures will be broken down into a set of simple append able structures and could be more easily predicted by a single shot.

This novel and automated approach can overcome the difficulties presented in traditional velocity estimation methods and is designed to naturally cope and continuously learn with increasing data volumes. Once the neural net is trained, its seismic know-how is stored and can be used to predict velocity models from new shot data in just a few seconds of compute time.

References

Aminzadeh, F., Jean, B., & Kunz, T. (1997). *3-D salt and overthrust models*. Society of Exploration Geophysicists.

Araya-Polo, M., Jennings, J., Adler, A., & Dahlke, T. (2018). Deep-learning tomography. The Leading Edge, 37(1), 58-66. https://doi.org/10.1190/tle37010058.1

Huang, Z., Shimeld, J., Williamson, M., & Katsube, J. (1996). Permeability prediction with artificial neural network modeling in the Venture gas field, offshore eastern Canada. *Geophysics*, *61*(2), 422-436. DOI: https://doi.org/10.1190/1.1443970

Isola, P., Zhu, J. Y., Zhou, T., & Efros, A. A. (2016). Image-to-Image Translation with Conditional Adversarial Networks. *arXiv preprint arXiv:1611.07004*.

Michelsanti, D., & Tan, Z. H. (2017). Conditional generative adversarial networks for speech enhancement and noise-robust speaker verification. *arXiv preprint arXiv:1709.01703*.

Murat, M. E., & Rudman, A. J. (1992). Automated first arrival picking: A neural network approach. *Geophysical Prospecting*, *40*(6), 587-604. DOI: https://doi.org/10.1111/j.1365-2478.1992.tb00543.x

Röth, G., & Tarantola, A. (1994). Neural networks and inversion of seismic data. Journal of Geophysical Research: Solid Earth, 99(B4), 6753-6768. DOI: https://doi.org/10.1029/93JB01563

a)

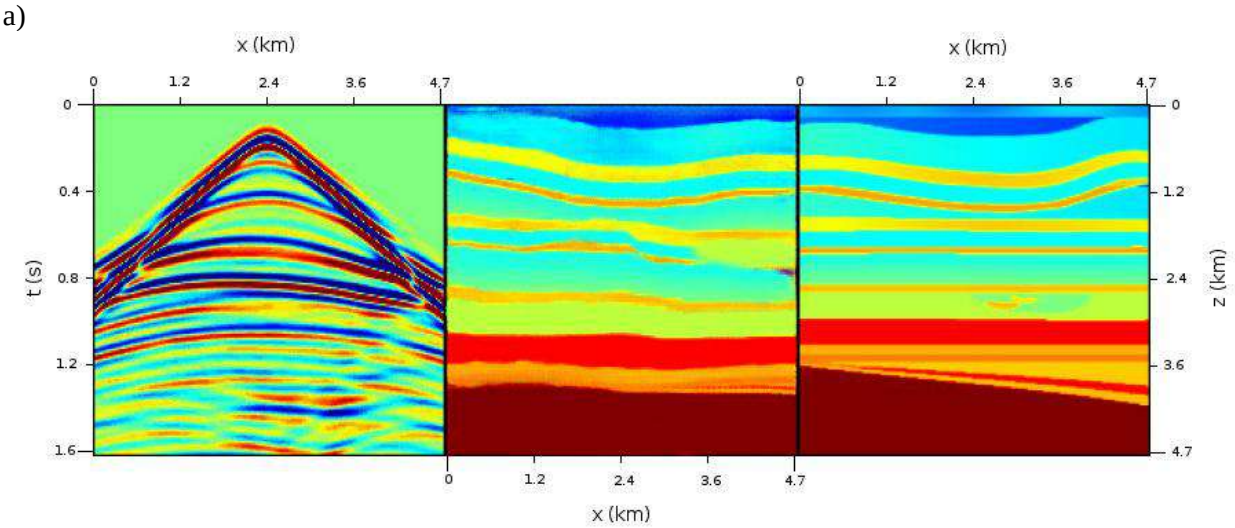

b)

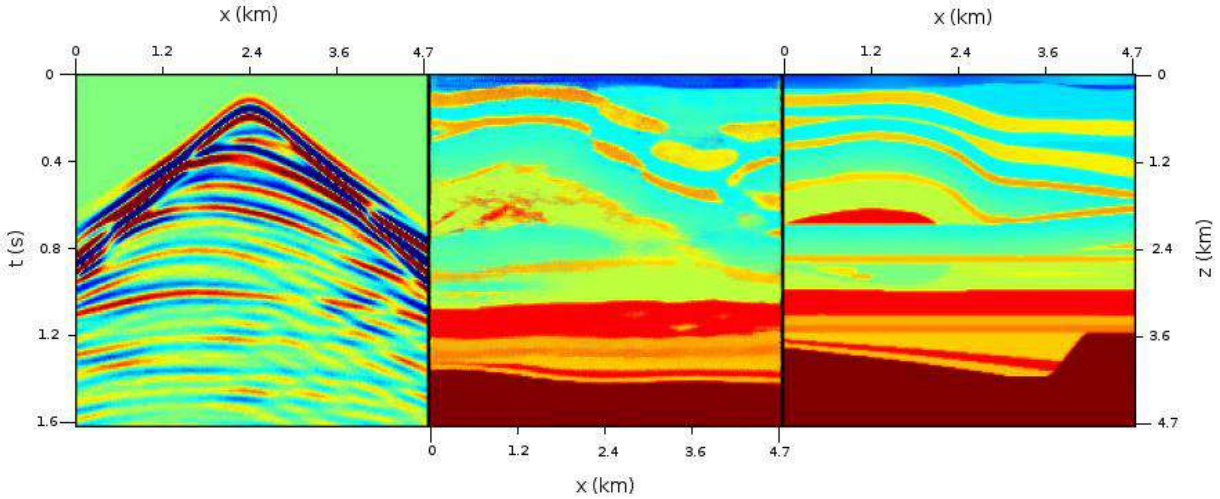

c)

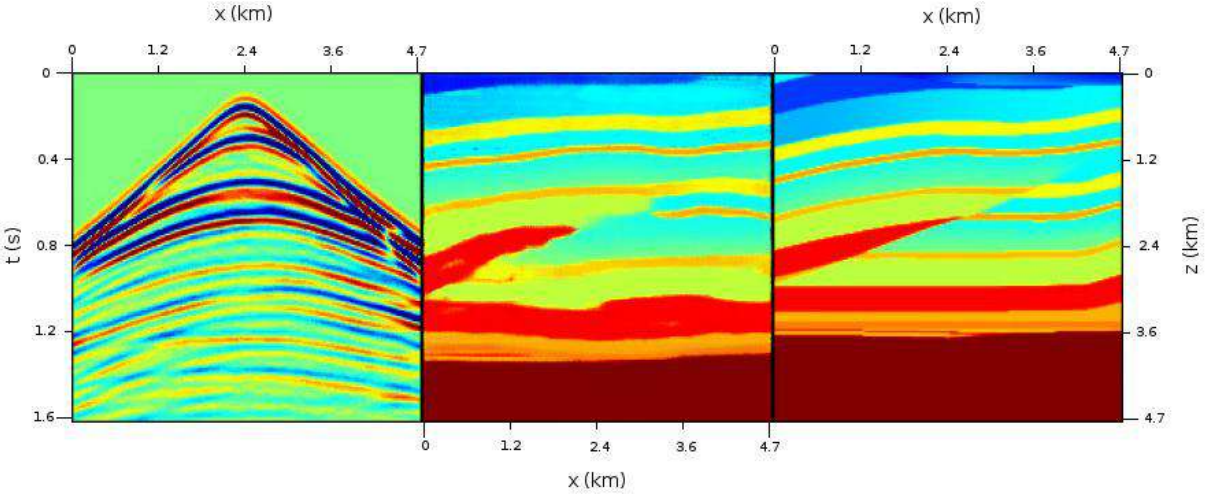

Figure 2. *Left boxes show the seismogram associated with the real velocity model on the right, the middle boxes contain the predicted model. a) Plain structure. b) Anticlinal structure. c) Faulted section caused by overthrusting.*

Nota de cierre

Esperamos haber llegado con el contenido de este boletín, a la mayor cobertura del personal que hace parte del Departamento de Educación y Ciencias Básicas y de la Facultad en general. Con esta propuesta y esfuerzo que venimos desarrollando desde la actual dirección y coordinación del departamento, buscamos mantener una comunicación abierta y disponible para toda nuestra comunidad académica; y aportar un órgano informativo que nos mantenga vigentes y actualizados de las labores que se desarrollan semestre a semestre por los diferentes estamentos, propuestas y proyectos que nos conforman académicamente año por año.

Les extendemos la invitación para este próximo 9 de abril de 2025, fecha de nuestra segunda charla en el evento *ITM 2025, Año Internacional de la Ciencia y la Tecnología Cuántica*.

Título: La Física Cuántica y la Teoría del Casi Todo

Ponente: Richard Hamilthon Benavides Palacios
Fecha: miércoles 9 de abril
Hora: 10:00 a.m a 12:00 m.
Lugar: Aula Magna

Invitamos a la comunidad académica del Departamento a ingresar al siguiente enlace https://www.itm.edu.co/facultad-ciencias-exactas-aplicadas/departamento-de-educacion-y-ciencias-basicas/#Boletines-Informativos y conocer los diferentes Boletines Informativos publicados hasta el 2025-01, los cuales cada año y durante los dos semestres que lo componen, venimos desarrollando desde el año académico 2023, con el fin de mantener informados a nuestros docentes y estudiantes, sobre las diferentes actividades ejecutadas por nuestro departamento.

NOTA Si algún docente o estudiante desea aportar una información o nota para el próximo boletín, agradecemos se comunique al correo: ramirohoyos@itm.edu.co o al celular 315 410 62 62