

Nuevas herramientas para el modelado de reservorios: simulación secuencial multipunto en sistemas fluviales de alta sinuosidad

Por *Ing. Claudio Larriestra* e *Ing. Hugo Gómez*

El método de simulación multipunto fue ejecutado para modelar la alta sinuosidad de lechos de río del reservorio de la formación Mina El Carmen (golfo de San Jorge); para ello se utilizó un modelo con las formas del río Samborombón, Buenos Aires. Se concluyó que los métodos de simulación multipunto son más apropiados para estimar la incertidumbre de sistemas altamente sinuosos.

Este trabajo busca analizar el comportamiento de la simulación estadística multipunto cuando se trata de modelar reservorios de alta incertidumbre como la que se presenta asociada a los reservorios de la formación Mina El Carmen, Cretácico Superior de la cuenca del golfo San Jorge, República Argentina. El área investigada corresponde al yacimiento Diadema Argentina, propiedad de la compañía Capsa, donde se muestran los pozos utilizados en este estudio (figura 1).

La formación Mina El Carmen se depositó en ambiente fluvial meandriforme de mediana a baja energía; la relación arena-arcilla es muy baja, y existen numerosos intervalos pelíticos que constituyen los sellos locales para los cuerpos arenosos lenticulares y bajo grado de conectividad. Estas características se mantienen en forma constante en toda la cuenca ya que corresponde a un momento de nivelación y baja pendiente.

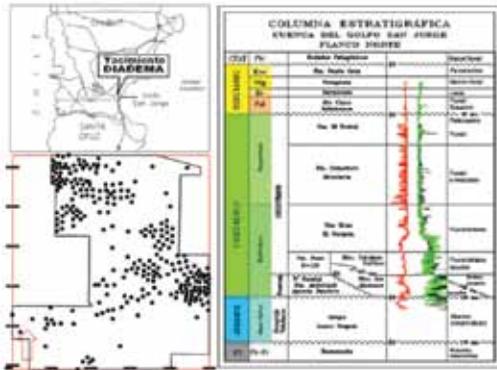


Figura 1. Mapa de la ubicación y columna estratigráfica del Grupo Chubut.

Las reflexiones sísmicas son de tipo subparalelo, semicontinuas o irregularmente continuas, de baja a media amplitud y sólo excepcionalmente pueden ser identificados los sistemas de canales. Las direcciones de transporte principales son desde el Norte y el Nordeste con un arribo subordinado desde el Sur.

Dadas estas características, resulta difícil predecir la ocurrencia de reservorios en esta formación de edad probablemente Aptiana-Albiana, a los que se les atribuye una distribución casi aleatoria por su baja correlatividad.

Con la perforación de pozos *infill* se han documentado nuevos reservorios en posiciones temporales equivalentes a los drenados por pozos preexistentes, por lo que se deduce que el distanciamiento estándar actualmente utilizado entre pozos es superior al ancho de estos depósitos. Por lo tanto, se hace necesario disponer de una herramienta que permita predecir la probabilidad de ocurrencia de nuevos reservorios en pozos intermedios para ajustar el patrón de desarrollo.

Metodología

Simulación secuencial estocástica multipunto

Las geometrías curvilíneas, como fajas de canales en reservorios fluviales o valles incisos sobre una topografía, son muy difíciles de modelar usando métodos estadísticos apoyados en dos puntos, como los variogramas o variogramas cruzados. En general, los métodos geoestadísticos (simulación indicadora o *gaussiana* truncada) sólo pueden reproducir las proporciones y los variogramas. Una excepción constituye el modelado en presencia de muchos datos y con distribución equiareal, donde es posible reproducir formas complejas (Goya, et ál. 2008), aunque sólo ocasionalmente es posible disponer de estas dos condiciones en los campos desarrollados. Xu (1996) propuso una alternativa de aproximación para la reproducción de la curvilinealidad, y es por medio de la simulación previa, mediante cambios en las direcciones locales y relaciones de anisotropía. Esta técnica genera patrones cambiantes de direcciones y anisotropía en las facies, pero no puede reproducir la continuidad de las formas curvilíneas.

Formas definidas como las mencionadas sólo pueden ser aproximadas con métodos más específicos como los algoritmos *booleanos*, basados en objetos.

En efecto, la manera más directa de reproducir formas curvilíneas es parametrizarlas, y mediante mecanismos de

selección aleatoria, generar familias de objetos que luego serán insertados dentro del volumen que se va a modelar para su aceptación o rechazo (Bridge y Leeder 1979, Haldorsen y Damsleth, 1990; entre otros). Este método tiene limitaciones importantes, como que cada clase de objeto requiere una parametrización específica y que, debido al carácter cambiante de la geomorfología, es muy difícil reflejar que los parámetros de forma sean válidos para todo el volumen a modelar. Por otra parte, el respeto a los datos duros puede ser muy difícil de alcanzar cuando existe una cantidad importante de datos.

Guardiano y Srivastava (1993) presentan un algoritmo de simulación que introduce la estadística multipunto en la simulación secuencial estocástica, donde a partir del entrenamiento sobre una imagen tipo se generan realizaciones estocásticas que estadísticamente son similares a la imagen empleada. Las probabilidades de cada una de las facies son obtenidas directamente de la imagen de entrenamiento, lo que ocasiona una demanda muy alta de tiempo de computación, ya que debe ser explorada ante cada punto no simulado para inferir su distribución de probabilidad condicional específica.

Strebelle (2002) plantea el algoritmo SNESIM (Single Normal Equation) basado en los conceptos de Guardiano y Srivastava (óp. cit.), pero optimizado en la velocidad de búsqueda y proceso. Este algoritmo fue utilizado para efectuar la simulación estocástica de los canales de la formación Mina El Carmen.

Algoritmo SNESIM

Se basa en la simulación de un punto ubicado en el centro de una plantilla de búsqueda que permitirá definir conjuntos locales de datos (eventos). Las repeticiones de estos eventos de datos para cada facies proporcionarán un medio para simular el punto medio de la plantilla.

Se considera un atributo S (litología) que toma K estados (litofacies) posibles ($s_k, k=1, \dots, K$). S puede ser una variable categórica o una continua discretizada.

Un evento de datos d_n de tamaño n centrado en la posición u a simular está constituido por:

- una geometría definida por n vectores comprendidos entre el punto a simular y cada punto vecino ($h_i, i=1, \dots, n$) y
- n valores de S correspondientes a dichos puntos, $s(u+h_i)=s(u_i), i=1, \dots, n$

Luego, a partir de una imagen de entrenamiento T se explora la ocurrencia del evento de datos d_n de manera de que si se encuentra J veces en el volumen (figura 2), el histograma de los valores centrales de la plantilla $s_j(u_j), j=1, \dots, n$ puede ser usado como una aproximación a la distribución de probabilidad condicional de la facies k dado el evento $d_n: f(u; k | d_n)$.

Debido a que en la imagen de entrenamiento es casi imposible encontrar suficientes réplicas para cada uno de K_n resultados posibles del evento de d_n , Guardiano y Srivastava (óp. cit.) recomiendan aplicar el método para $K \leq 4$.

El principio de cualquier método de simulación estocástica se basa en el conocimiento de la función de probabilidad condicionada de la variable aleatoria $S(u)$, que en las formas convencionales (simulación secuencial

gaussiana y/o indicadora) es estimada en el nodo u a partir de alguna de las formas de *kriging* (predicción lineal o inferencia bayesiana), de manera que:
 $Prob\{S(u)=s_k | d_n\} = f(u; k | d_n), k = 1, \dots, K$ (Deutsch y Journel, 1998).

La otra alternativa es derivarla de la imagen de entrenamiento como se ha explicado más arriba.

A diferencia de los métodos de simulación secuenciales convencionales, en vez utilizar el estadístico bipuntual (variograma), Strebelle (óp. cit.) sugiere considerar conjuntamente los n datos condicionantes del evento de datos d_n , lo que requiere conocer la covarianza de $n+1$ puntos para medir la dependencia de $S(u)$ sobre el evento de datos d_n .

Si se define a A_k como una variable indicadora aleatoria asociada a la ocurrencia del estado s_k en la posición u : $A_k = 1$ si $S(u)=s_k$, $A_k = 0$ de lo contrario.

Y, de la misma forma, se define a D como una variable indicadora de la ocurrencia del evento de datos d_n constituidos por n datos condicionantes:

$D = 1$ si $S(u_i) = s_{k_i} \forall i=1, \dots, n$ o $D = 0$ de lo contrario

Si la covarianza de los $n+1$ puntos existe, la probabilidad condicional exacta está dada por la expresión de *kriging simple* (Journel, 1993):

$$Prob\{A_k=1 | D = 1\} = E\{A_k\} + \lambda[1-E\{D\}]$$

Donde $D = 1$ es el evento de datos observado, $E\{D\} = Prob\{D = 1\}$ es la probabilidad de que el evento de datos condicionantes ocurra, $E\{A_k\} = Prob\{S(u) = s_k\}$ es la probabilidad a priori en la posición u de que el estado sea s_k .

El desarrollo de la ecuación normal del *kriging* brinda el peso λ y es: $\lambda Var\{D\} = Cov\{A_k, D\}$ y, operando algebraicamente, se concluye que:

$$Prob\{A_k=1 | D = 1\} = Prob\{A_k = 1, D = 1\} / Prob\{D = 1\} \quad (1)$$

Strebelle (óp. cit.) que es la relación de Bayes.

Exploración de la imagen de entrenamiento y simulación secuencial

El denominador de la expresión (1) puede ser inferido a partir del conteo de repeticiones $c(d_n)$ del evento de datos condicionante $d_n = \{S(u_a) = s_{k_a}, a = 1, \dots, n\}$ en la imagen de entrenamiento. Cada repetición tiene la misma cantidad de datos y valores de facies.

El numerador es obtenido a partir del conjunto de repeticiones anterior ($c(d_n)$) donde se consideran las repeticiones $c_k(d_n)$ en las que el valor central $S(u)$ de la plantilla de búsqueda es igual a s_k la facies considerada.

La probabilidad condicional requerida es aproximadamente equivalente a la proporción $c_k(d_n)/c(d_n)$ (2) Strebelle (óp. cit.).

La simulación secuencial se realiza siguiendo un conjunto de pasos, a saber:

- a) Se delimita un tamaño para la plantilla de búsqueda que permitirá capturar los eventos.
- b) Se explora la imagen o volumen de entrenamiento para determinar la ocurrencia de eventos y sus valores cen-

trales (facies de la posición central u del evento).

Ambos valores son utilizados para construir un árbol de búsqueda, método que permite una rápida recuperación de la información durante la etapa de simulación. La definición de los eventos de datos se realiza dentro de la plantilla de búsqueda definida alrededor de cada nodo de la imagen.

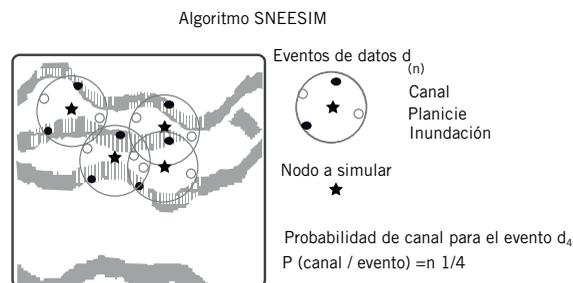


Figura 2. Fundamento del algoritmo SNEESIM (Strebelle, óp. cit.).

La exploración de la imagen de entrenamiento se realiza por única vez a diferencia del algoritmo propuesto de Guardiano y Srivastava (óp. cit.) que realizaba dicha exploración cada vez que se simulaba un nuevo dato.

En SNEESIM todo nodo simulado e incorporado como dato duro hará que el evento de datos no coincida con los almacenados en el árbol de búsqueda, por lo que Strebelle (óp. cit.) propone eliminar los puntos más lejanos de a uno por vez hasta que el nuevo evento de datos coincida con un mínimo de eventos (C_{min}) residentes en el árbol de búsqueda. De no satisfacerse este requerimiento, la probabilidad condicional será reemplazada por la probabilidad marginal (global) p_k de la facies k .

- c) Se asigna los valores condicionantes al nodo más cercano en la grilla de simulación y se define un sendero aleatorio con los nodos a simular.
- d) En cada nodo a simular se capturan todos los datos condicionantes que abarca la plantilla (evento d_n) y se recuperan del árbol de búsqueda todas las proporciones de (2) correspondientes al evento d_n para todas las facies presentes.
- e) Se simula un valor de facies k en el nodo u a partir de la distribución de facies leída del árbol de búsqueda. Dicho valor es agregado como dato duro para la simulación de los siguientes nodos. Se continúa con los pasos c) y d) hasta completar la grilla, y se completa de esta manera una realización.

Resultados

A los efectos de la comparación, se tomaron dos niveles conspicuos y productivos en la base del intervalo. Los niveles son representados por cortes horizontales (*layers*) a la parte media de estos, contenidos en el volumen de probabilidad de canales. Dichos volúmenes son producto del cómputo de probabilidad de existencia/no existencia de canal en 30 realizaciones estocásticas.

El modelo utilizado como entrenamiento está constituido por un volumen con formas de canales de diferente sinuosidad construidos manualmente. Estos reproducen, de una manera simple, fajas de canales de alta sinuosidad generados en una planicie aluvial de pendiente cerca-



Figura 3. Modelo real utilizado en la confección del volumen de entrenamiento. Río Samborombón, cerca de la desembocadura.

na a cero. Como modelo se tomó el río Samborombón (provincia de Buenos Aires) en un sector cercano a la desembocadura (figura 3), donde presenta alta sinuosidad y cambio de dirección media debido posiblemente a cuestiones geomorfológicas, sedimentarias o estructurales de basamento. Este modelo no debería estar tan alejado de lo que sucedió durante la depositación de Mina El Carmen respecto de los factores autocíclicos controlantes de la evolución sedimentaria, más los factores alocíclicos representados por los sedimentos piroclásticos de caída.

La figura 4 muestra un grupo de *layers* del volumen de entrenamiento realizado mediante el uso de un programa de dibujo elemental, siendo suficientemente estacionario (las proporciones de facies de la plantilla utilizada no difieren del valor global de estas) en el sentido de Caers y Zhang (2004). Luego, usando un color para definir los canales, el archivo binario resultante fue convertido a formato ASCII para ser incorporado al *software* de simulación en el formato adecuado.

La figura 5 muestra el resultado de la probabilidad de canal luego de efectuadas 30 realizaciones. En la figura se ilustran varios cortes al volumen de probabilidad (a la izquierda) y la comparación con el modelo real del río Samborombón.

También se recurrió a la rotación a intervalos de 45 grados del evento de datos a los efectos de encontrar la mejor coincidencia con la imagen de entrenamiento en cada nodo a simular. Al volumen de probabilidad se ha aplicado un *cut off* con el objeto de resaltar la forma de los canales y las barras de espolón (*point bars*).

Como todo método de simulación secuencial, el respeto de los puntos-datos y las formas individuales sinusoidales permite reproducir la coexistencia de *point bars* (donde se

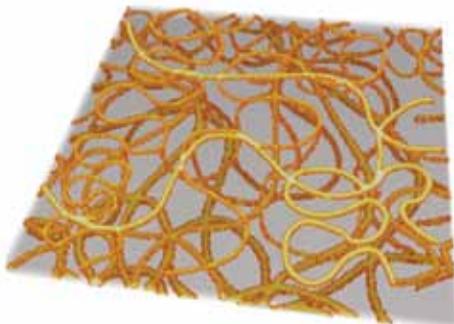


Figura 4. Grupo de *layers* del volumen de entrenamiento de canales sinuosos utilizado con SNESIM.

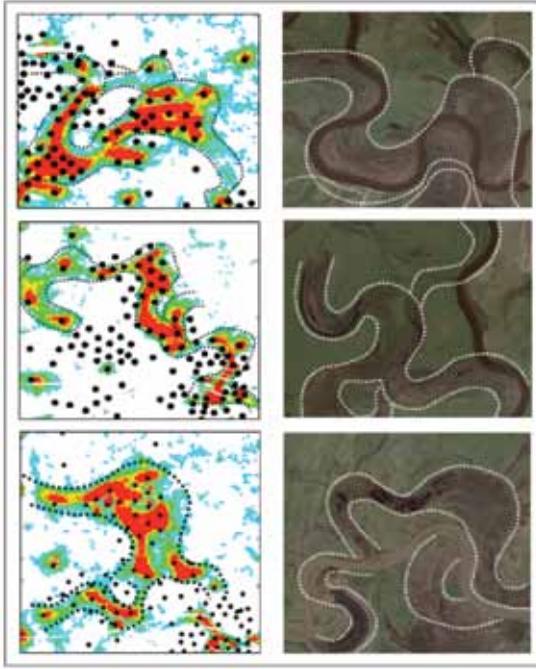


Figura 5. Comparación de formas de canales entre el volumen de probabilidad de canal y sectores del río Samborombón.

amalgaman las formas curvas) con los canales individuales, como se muestra en los tres ejemplos de la figura 5.

Por esta razón, es factible encontrar en un mismo nivel estratigráfico arenas que poseen buena correlación lateral (zonas de *point bar*), con canales aislados que los conectan y cuyo ancho es menor al distanciamiento entre pozos.

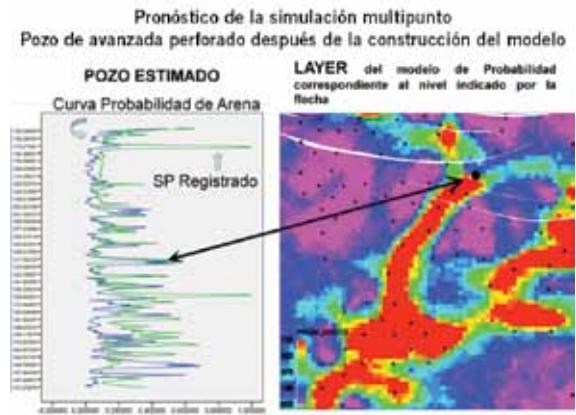


Figura 6. Estimación de pozo de avanzada. Comparación de la probabilidad de arena con el SP registrado al perforarse el pozo.

Esta relación de formas es una de las principales fuentes de incertidumbre en el pronóstico de canales en la formación Mina El Carmen y que la simulación multipunto puede resolver satisfactoriamente en algunos casos.

Por último, en la figura 6 se muestra el pronóstico realizado con el modelo de probabilidad de canal luego de 30 realizaciones y un pozo de avanzada que se perforó luego de la construcción del modelo. La comparación se efectúa mediante una curva de probabilidad de canal sintética generada en la ubicación del pozo y el perfil de SP registrado luego de su perforación.

Se aprecia que, en la mitad superior de la formación, la estimación es muy buena, mientras que su efectividad

disminuye en profundidad. Esto es debido a que menos pozos alcanzan la base de Mina El Carmen y, por ende, existen menos datos disponibles para el modelado estratigráfico (Larriestra y Gómez, 2008, 2009a y 2009b).

Conclusiones

Los ensayos de simulación efectuados sobre los canales de la formación Mina El Carmen permiten destacar las ventajas comparativas de la simulación estadística multipunto por sobre el resto de los métodos de uso corriente. No tiene la alta entropía que exhiben las simulaciones gaussianas e indicadora y supera al modelo de objetos en cuanto a la complejidad de formas que puede representar. El resultado final posee bajo desorden y adapta las propiedades de la imagen de entrenamiento a las situaciones particulares de los datos. Esto permite que coexistan en la formación Mina El Carmen, *point bars* con canales aislados.

Como todos los modelos estadísticos, este tipo de simulación depende de los datos y de su distribución espacial, por lo que en las zonas sin datos, siempre será necesario recurrir a una variable secundaria para cosimular. Se sugiere utilizar el resultado de descomposición espectral (planos de potencia espectral) en el caso de que exista alguna sensibilidad de la sísmica en ese sentido. Por último, cabe destacar que si bien los algoritmos están optimizados, el tiempo de computación es mucho más elevado en los métodos de simulación estadística multipunto. Este trabajo fue realizado con el *software* público Sgems (Remy et ál., 2010). ■

Agradecimientos

Los autores desean expresar su agradecimiento a las autoridades de CAPSA-CAPEX por el apoyo brindado en esta investigación y la autorización para su publicación.

Bibliografía

- Bridge, J. y M. Leeder (1979), *A simulation model for alluvial stratigraphy: Sedimentology*, v. 26, p.617-644.
- Caers, J. y T. Zhang (2004), "Multiple-point geostatistics: a quantitative vehicle for integrating geologic analogs into multiple reservoir models", in Grammer, G., Harris, P. and Eberli, G. eds., *Integration of outcrops and modern analogs in reservoir modeling*, AAPG, Mem. 80, p. 384-394.
- Deutsch, C. (2002), *Geostatistical reservoir modeling*, Oxford Univ. Press, New York, 376 p.
- Deutsch, C. y A. Journel (1998), *GSLIB: Geostatistical software library and user's guide*, 2nd ed., Oxford Univ. Press, New York, 368 p.
- Deutsch, C. y L. Wang (1996), *Hierarchical object-based stochastic modeling of fluvial reservoirs*, Math. Geol., v. 28, nro. 7, p. 857-880.
- Goya, F., M. Cabrera, S. Schloepke, G. Palacios, H. Verdur y C. Larriestra (2008), "Stochastic 3D Modelling in Complex Reservoir Geometries", IAPG, VII CONEXPLOR, Mar del Plata.
- Guardiano, F. y R. Srivastava (1993), "Multivariate geo-statistics: Beyond vibariate moments", in Soares, A. ed., *Geostatistics Troia*, v. 1:Kluwer Academia, Dordrecht, p.133-144.
- Haldorsen, H. y E. Damsleth (1990), *Stochastic modeling*: J- Pet. Tech. V. 42, April, p.404-412.
- Kelkar, M. y G. Perez (2002), *Applied geostatistics for reservoir characterization*, SPE, 264 p.
- Journel, A. y T. Zhang (2006), *The necessity multiple-point prior*

model, Math. Geol., v. 38, nro. 5, p. 591-610.

- Larriestra C. y H. Gómez (2008), "Simulación secuencial estocástica Multipunto aplicada al análisis de incertidumbre de sistemas fluviales de alta sinuosidad Fm Mina El Carmen, Cuenca del Golfo San Jorge". VII Congreso Exploración y Desarrollo de Hidrocarburos, IAPG, AAGGP, Mar del Plata. (Primer Premio Simposio de Modelado Geológico)
- Larriestra, C. y H. Gómez, (2009), "Multiple-point simulation applied to uncertainty analysis of reservoirs related to high sinuosity fluvial systems: Mina el Carmen formation, San Jorge gulf basin, Argentina" *Int. Assoc. Math. Geol. Annual Meeting*, Stanford University, USA.
- Larriestra, C. y H. Gómez (2009), "Uncertainty Analysis of Reservoirs from Meandering Fluvial Systems using Multiple Point Stochastic Simulation. Mina El Carmen Formation, San Jorge Gulf Basin, Argentina", *AAPG Annual Meeting*, Río de Janeiro, Brasil. (Award of Excellence "Top 10" Poster Presentation).
- Zhang, T., P. Switzer y A. Journel (2006), *Filter-based classification of training image patterns for spatial simulation*, Math. Geol., v.38,nro 1, p.63-80
- Remy, N., A. Boucher and J. Wu (2009), *Applied Geostatistics with SGeMS*, Cambridge Univ. Press, NY.
- Strebelle, S., (2002), *Conditional simulation of complex geological structures using multiple-point statistics*, Math. Geol., v. 34, nro. 1, p.1-21
- Xu, W. (1996), *Conditional curvilinear stochastics simulation using pixel-based algorithms*: Math. Geol., v.28, nro. 7, p. 937-949.

Claudio Larriestra es licenciado en Geología por la Universidad Nacional de Córdoba. Se desempeñó como geólogo investigador de la Universidad Nacional de Rosario, en el área de Sedimentología. Con más de veinte años de experiencia en análisis de datos aplicados a la exploración, caracterización y modelado geológico de reservorios, ha realizado trabajos para distintas compañías en varios países –Argentina, Venezuela, Bolivia, Ecuador y Perú–. Se ha desempeñado como analista de perfiles en la compañía Western Atlas Argentina y como jefe de estudios especiales para la compañía de petróleo CAPSA-CAPEX; y fue geólogo consultor independiente de exploración y evaluación de reservorios para Larriestra, Curia & Asociados. Desde 2002 preside Larriestra Geotecnologías S.A., compañía especializada en análisis estadístico de datos geológicos y geofísicos para exploración y producción, además de poseer una división de prospección geoquímica superficial. Es autor de más de 40 trabajos científicos publicados en el país y en el exterior, recibió varios premios en congresos nacionales e internacionales de su especialidad y es miembro de instituciones científicas nacionales e internacionales. Ha sido docente en la Universidad Nacional de Rosario y en la Universidad Nacional de la Patagonia.

Hugo Gómez es licenciado en Geología por la Universidad Nacional de La Plata y tiene un postgrado en Ingeniería de Reservorios por la Universidad de Buenos Aires, Exlog en Control Geológico. Ha trabajado en YPF en Control de Reservorios en Las Heras y ha sido jefe de Cutting en Cañadón Seco; ha sido geólogo de yacimiento en CAPSA-Diadema y jefe de Reservorios dedicado a Proyectos, desarrollo y control de Recuperación Secundaria. Actualmente trabaja en Geología de Desarrollo en CAPSA BA y como jefe de Geología de Desarrollo dedicado a proyectos de Primaria; también tiene experiencia en geoestadística en diferentes proyectos de caracterización para proyectos de primaria y secundaria en la CGSJ y Neuquina. Ha presentado numerosos trabajos y posters en diferentes congresos internacionales.