



POSGRADO EN  
ING. ESTADÍSTICA  
Y DATA SCIENCE  
FIEECS-UNI

2026

# Maestría en Ciencias e Ing. Estadística

---

Unidad de Posgrado  
Facultad de Ingeniería Económica, Estadística y Ciencias Sociales  
**Universidad Nacional de Ingeniería**

---



# Presentación

La *Maestría en Ciencias e Ingeniería Estadística (MCIES)* forma parte del **Ecosistema Integral de Ciencia de Datos e Ingeniería Estadística de la FIEECS-UNI**. Este ecosistema integra tres programas — MDS, MCIES y DCIES— que se complementan y permiten articular formación aplicada, desarrollo teórico y trabajo de investigación.

La MCIES está dirigido a profesionales que buscan una formación sólida en **Estadística, Probabilidad y Modelado Computacional**, con énfasis en entender los fundamentos de los métodos y en desarrollar criterios para evaluar su validez y alcance.

Este programa promueve pensamiento crítico, bases conceptuales claras y el desarrollo de capacidades para investigación.

El rol de la MCIES dentro del ecosistema puede resumirse así:

- La **MDS** recoge problemas provenientes de la práctica profesional e industria
- El **MCIES** los estructura bajo modelos estadísticos y matemáticos formales.
- El **DCIES** profundiza en nuevos métodos y herramientas que luego se incorporan a la formación de las maestrías.

De esta manera, la MCIES contribuye a convertir problemas reales en modelos analizables, dando soporte tanto a aplicaciones avanzadas como a investigaciones de mayor alcance.







## Identidad del Programa

El MCIES es un programa centrado en la estadística moderna y el modelado científico, con apoyo en matemáticas aplicadas y computación. Su objetivo es formar profesionales capaces de analizar, formular y evaluar modelos estadísticos con sustento teórico y práctico.

La formación enfatiza:

- comprensión de principios estadísticos y probabilísticos,
- formulación rigurosa de problemas,
- lectura crítica de literatura especializada,
- validación computacional de modelos.

El programa está orientado a:

- quienes desean profundizar en estadística con bases teóricas claras,
- profesionales que trabajan con fenómenos complejos y modelos estocásticos,
- estudiantes interesados en continuar estudios doctorales en estadística o áreas afines.







## Perfil del Graduado

Al finalizar la maestría, el graduado estará preparado para:

### Formación Académica

- continuar estudios de doctorado en estadística, matemáticas aplicadas o computación científica,
- participar en grupos de investigación y seminarios especializados,
- elaborar y presentar trabajos académicos con base estructurada.

### Desempeño Profesional

- diseñar, analizar y evaluar modelos estadísticos pertinentes a diferentes contextos,
- implementar métodos de inferencia, simulación y optimización,
- participar en proyectos cuantitativos en sectores como finanzas, ingeniería, salud, energía, geociencias y políticas públicas.

### Competencias Conceptuales

- identificar supuestos, limitaciones y posibles extensiones de los modelos,
- integrar estadística, probabilidad y computación para abordar problemas complejos,
- plantear soluciones con sustento matemático y criterio técnico.





## Dirigida a

### **Científicos y Profesionales de Datos:**

- Estadísticos, ingenieros, matemáticos, físicos, economistas cuantitativos y profesionales afines que buscan una formación sólida y teóricamente bien fundamentada para abordar problemas complejos con modelos avanzados y herramientas computacionales modernas.

### **Investigadores y Futuros Doctorandos**

- Quienes desean prepararse para estudios de doctorado en estadística, matemáticas aplicadas, ciencia de datos o áreas afines, desarrollando capacidad para leer críticamente artículos de investigación, formular problemas novedosos y escribir producción científica de alto nivel.

### **Docentes Universitarios y Académicos en Formación:**

- Profesionales que ejercen o proyectan ejercer la docencia universitaria y requieren profundizar en teoría estadística, inferencia moderna y métodos de aprendizaje de máquina, integrando rigor matemático con aplicaciones en IA y Deep Tech.

### **Profesionales de Sectores Intensivos en Datos**

- Especialistas en banca y riesgo, seguros, manufactura, agroexportación, geociencias, energía, salud, biología, telecomunicaciones, sector público y regulación, que necesitan diseñar, validar y defender modelos cuantitativos robustos ante reguladores, stakeholders y equipos técnicos.

### **Expertos en Datos, Programadores y Desarrolladores**

- Ingenieros de datos, científicos de datos, desarrolladores de software y profesionales con base en programación que desean comprender en profundidad los fundamentos estadísticos y probabilísticos de los modelos que implementan, y extenderlos hacia nuevas metodologías para IA, Big Data y sistemas complejos.

### **Profesionales que buscan Reconversión Cuantitativa**

- Personas provenientes de otras disciplinas que, tras un programa de nivelación en matemáticas, estadística y computación, desean reorientar su carrera hacia la Ingeniería Estadística, con una visión que combina teoría, computación y aplicaciones avanzadas en un mismo ecosistema académico.



## Líneas de Investigación

### **Aprendizaje Estadístico:**

Se centra en el desarrollo teórico, metodológico y aplicado del análisis de datos, combinando fundamentos probabilísticos con herramientas modernas de inferencia y modelado.

En el MCIES, las líneas de interés incluyen:

- Inferencia estadística para problemas de Optimización Estocástica, en escenarios neutrales al riesgo o con aversión al riesgo (Teoremas del Límite Central, Pruebas de Hipótesis e Intervalos de Confianza No Asintóticos).
- Estadística Computacional y Métodos No Paramétricos (Remuestreo, Bootstrap, Simulación Monte Carlo).
- Inferencia Bayesiana para Modelos Jerárquicos, Fusión de Datos y el Tratamiento de Datos Censurados, Faltantes o Perdidos.
- Modelado de Series Temporales No Lineales y de Alta Dimensión.
- Modelado Espacial y Análisis de Teledetección Multiespectral.

### **Modelado Estocástico:**

Esta área de Teoría de Probabilidad, con amplias aplicaciones prácticas, se centra en el estudio de Ecuaciones Diferenciales Estocásticas y Procesos de Difusión de Itô. Incluye la resolución numérica de estas ecuaciones y la estimación estadística de sus parámetros. Además, ecuaciones para modelar fenómenos biológicos, físicos y financieros, donde las cantidades de interés están sujetas a perturbaciones aleatorias.

### **Aprendizaje Automático e Inteligencia Artificial:**

Esta línea de investigación busca desarrollar y aplicar métodos de aprendizaje automático en el análisis de datos estructurados y no estructurados, incluyendo datos numéricos, categóricos, textuales, imágenes, gráficos y series de tiempo. Los objetivos incluyen:

- Desarrollo de algoritmos, lenguajes y metodologías para la manipulación de bases de datos complejas
- Tareas como clasificación, Regresión, Identificación de Clusters, Sistemas de Recomendación, Optimización, Extracción y Representación del Conocimiento
- Modelado de dominios de conocimiento, Minería de Datos, Minería Textual, Visualización, Análisis de Sentimientos, Análisis de Datos de Alta Dimensión y Criptografía





## Ventajas

- Profesores Científicos que realizan día a día en sus centros laborales diferentes aplicaciones de acuerdo a la maestría.
- Posibilidad de integrar las líneas de carreras dentro de instituciones públicas y privadas.
- Los cursos propuestos hacen de la maestría la mejor opción para aquellos que quieran destacar en diversas industrias.
- La maestría considera conceptos modernos complementados con una orientación a formar científicos, académicos y profesionales de la industria.
- Prestigio de una universidad de más de 143 años con ventajas comparativas a nivel cuantitativo aplicado.
- Las aplicaciones van de la mano del entendimiento profundo de los fundamentos garantizando la calidad de sus resultados.

## Beneficios

- Diploma en Ingeniería Estadística a nombre de la Universidad Nacional de Ingeniería a los alumnos que aprueben los ciclos I y II (28 créditos académicos).
- Malla curricular acorde a las necesidades y tendencias actuales en el área de Ciencias de Datos y Estadística.
- Desarrollo de habilidades académicas y científicas para el área de Ingeniería Estadística.



## Plan Curricular

El programa MCIES está diseñado de tal forma que en el primer ciclo los estudiantes puedan obtener bases teóricas sólidas, esto a través de cursos formativos en programación, probabilidad y matemática computacional. En ciclos sucesivos, se introducen cursos relacionados a cada área de concentración, los cuales serán reforzados con los cursos electivos.

### CICLO I

| CÓDIGO            | CURSO                                       | CRÉDITOS | REQUISITO |
|-------------------|---------------------------------------------|----------|-----------|
| MES101            | Probabilidad e Inferencia Estadística       | 4        | Ninguno   |
| MES111            | Álgebra Lineal y Optimización Computacional | 4        | Ninguno   |
| MES112            | Elementos de Análisis Real                  | 4        | Ninguno   |
| MES120            | Estructuras de Datos y Algoritmos           | 3        | Ninguno   |
| Total de Créditos |                                             | 15       |           |

### CICLO II

| CÓDIGO            | CURSO                                                 | CRÉDITOS | REQUISITO        |
|-------------------|-------------------------------------------------------|----------|------------------|
| MES201            | Modelos Estadísticos para el Análisis de Datos        | 4        | MES101<br>MES111 |
| MES202            | Métodos Computacionales en Probabilidad y Estadística | 3        | MES120           |
| MES211            | Procesos Estocásticos                                 | 3        | MES112           |
| MES221            | Introducción al Aprendizaje de Máquina                | 3        | MES111<br>MES120 |
| Total de Créditos |                                                       | 13       |                  |





# Maestría en Ciencias e Ing. Estadística

Unidad de Posgrado

## CICLO III

| CÓDIGO            | CURSO                                                    | CRÉDITOS | REQUISITO        |
|-------------------|----------------------------------------------------------|----------|------------------|
| MES301            | Aprendizaje Multimodal                                   | 4        | MES221           |
| MES302            | Seminarios de Investigación I                            | 4        | MES221<br>MES201 |
| DES505            | Electivo 1: Geostatística y Teledetección Multiespectral | 4        | MES201<br>MES202 |
| DES504            | Electivo 2: Inferencia Causal                            | 4        | MES201<br>MES202 |
| Total de Créditos |                                                          | 16       |                  |

## CICLO IV

| CÓDIGO            | CURSO                         | CRÉDITOS | REQUISITO        |
|-------------------|-------------------------------|----------|------------------|
| MES401            | Seminario de Investigación II | 4        | MES301<br>MES302 |
| Total de Créditos |                               | 4        |                  |





## Cursos Electivos

El candidato a Master debe completar 48 créditos entre cursos obligatorios y electivos. Se puede optar por llevar diferentes electivos después de completar los 28 créditos. El candidato a máster realizará como mínimo tres de los siguientes cursos electivos:

| CÓDIGO | CURSO                                                      | REQUISITO        | ÁREAS DE INVESTIGACIÓN                |
|--------|------------------------------------------------------------|------------------|---------------------------------------|
| DES501 | Estadística para Datos de Alta Dimensión                   | MES201<br>MES202 | Estadística                           |
| DES502 | Análisis de Datos Funcionales                              |                  |                                       |
| DES503 | Series de Tiempo y Análisis de Ondaletas                   |                  |                                       |
| DES504 | Inferencia Causal                                          |                  |                                       |
| DES505 | Geoestadística y Teledetección Multiespectral              |                  |                                       |
| DES511 | Cálculo Estocástico y sus Aplicaciones a Finanzas          | MES211           | Modelado Estocástico                  |
| DES512 | Ecuaciones Diferenciales Estocásticas y Teoría de Difusión |                  |                                       |
| DES513 | Modelos de Volatilidad para Derivativos                    |                  |                                       |
| DES514 | Gestión de Riesgos y Optimización de Portafolios           |                  |                                       |
| DES521 | Aprendizaje por Refuerzo                                   | MES221           | Aprendizaje e Inteligencia Artificial |
| DES522 | Aprendizaje Estadístico de Máquina Avanzado                |                  |                                       |
| DES523 | Tópicos en Inteligencia Artificial                         |                  |                                       |
| DES524 | Aprendizaje Profundo                                       |                  |                                       |
| DES525 | Modelos Gráficos                                           |                  |                                       |





**Maestría en Ciencias e Ing. Estadística**  
Unidad de Posgrado

# Cursos

---



**INFORMES:** +51 903 236 156 – Srta. Lisbeth

**30 Marzo**





# Álgebra Lineal y Optimización Computacional

## PARTE I: ÁLGEBRA LINEAL

- **Matrices y Vectores**
- **Sistemas Lineales:**
  - Eliminación Gaussiana, Factorización LU
- **Espacios y Subespacios Vectoriales:**
  - Bases y Dimensión, Rango de una Matriz
- **Ortogonalidad:**
  - Proyecciones, Ortogonalización de Bases, Mínimos Cuadrados
- **Valores Propios y Vectores Propios:**
  - Diagonalización
- **Transformaciones Lineales**
- **Descomposición en Valores Singulares**

## PARTE II: OPTIMIZACIÓN

- **Funciones de Varias Variables:**
  - Motivación y Ejemplos, Normas y Distancias en  $\mathbb{R}^n$ , Puntos de Acumulación.
- **Aplicaciones Continuas:**
  - Conjuntos Abiertos y Cerrados, Conjuntos Compactos, Conjuntos Convexos, Funciones Convexas y Estrictamente Convexas.
- **Cálculo Diferencial**
  - Derivadas Parciales y Direccionales, Diferenciabilidad, Regla de la Cadena, Fórmula de Taylor.
- **Funciones de  $\mathbb{R}^n$  a  $\mathbb{R}$** 
  - Gradientes, Teorema de Schwarz, Máximos y Mínimos Locales, Condiciones Necesarias y Suficientes, Condiciones de Máximo y Mínimo con Restricciones, Multiplicadores de Lagrange y Karush-Kuhn-Tucker (KKT)

## REFERENCIAS

- STRANG, G. **Introduction to Linear Algebra**. Wellesley-Cambridge Press, 1993.
- LUENBERGER, D. **Linear and Non-Linear Programming**. Addison- Wesley Reading, 1984.
- APOSTOL, T. **Calculus**. Second edition, John Wiley, 1969.
- BERTSEKAS, D. **Nonlinear Programming**. Athena Publishing, 1999.



# Elementos de Análisis Real

**Números Reales:** Axiomatización y intervalos encajantes.

**Conceptos Topológicos en  $\mathbb{R}^n$ :**

- Normas
- Producto interno
- Conjuntos abiertos
- Conjuntos cerrados
- Conjuntos compactos

**Secuencias Numéricas:** Límite superior e inferior.

**Continuidad de Funciones:**

- Puntual
- Uniforme

**Diferenciabilidad:**

- Derivadas direccionales
- Derivada como aplicación lineal
- Fórmula de Taylor
- Extremos de una función real

**Integral de Riemann:** Criterios de integrabilidad y teorema fundamental del cálculo.

**Series Numéricas:** Criterios de convergencia.

**Series de Funciones:** Integral.

**Introducción a la Teoría de Integración de Lebesgue.**

## REFERENCIAS

- RUDIN. W. **Principles of Mathematical Analysis**, 1953.
- SPIVAK, M. **Calculus**. Berkeley, CA: Publish or Perish, 1980.
- BUCK, R. **Advanced Calculus**. 2d ed. New York: McGraw-Hill, 1965.
- APOSTOL, T. **Calculus**. Second edition, John Wiley, 1969.



# Probabilidad e Inferencia Estadística

## PARTE I: PROBABILIDAD

### Espacios de Probabilidad y Cálculo de Probabilidades:

- Reglas Fundamentales y Regla de Bayes, Probabilidad Condicional e Independencia.

### Variables Aleatorias:

- Funciones de Distribución, Función de Densidad y Masa, Distribuciones Comunes, Discretas y Continuas, Transformaciones de Variables Aleatorias y sus Distribuciones.

### Valor Esperado de una Variable Aleatoria:

- Momentos y Función Generatriz de Momentos
- **Variables Aleatorias Múltiples:** Distribución Marginal y Conjunta, Covarianza y Correlación

### Convergencia de Variables Aleatorias:

- Ley de los Grandes Números (LGN), Teorema Central del Límite (TCL).

## PARTE II: INFERENCIA ESTADÍSTICA

### Introducción a la Estadística Frecuentista:

- Distribución Muestral de un Estimador, Teoría de Decisión Frecuentista, Propiedades Deseables de un Estimador, Minimización de Riesgo Empírico, Patologías de la Estadística Frecuentista.

### Introducción a la Estadística Bayesiana:

- Prioris No-Informativas, Prioris de Jeffreys, Prioris Robustas y Mixtura de Prioris Conjugadas, Resúmenes de Distribuciones Posteriori, Estimación MAP e Intervalos de Credibilidad, Selección de Modelo Bayesiano, Occam's Razor Bayesiano, Verosimilitud Marginal (Evidencia), Factores de Bayes, Paradoja de Jeffreys-Lindley, Bayes Jerárquico y Bayes Empírico, Teoría de Decisión Bayesiana.

## REFERENCIAS

- Casella, G. & Berger, R. L. (2021). **Statistical Inference**. Cengage Learning.
- Murphy, K. P. (2012). **Machine Learning: A Probabilistic Perspective**. MIT Press.
- Ross, S. M. (2014). **Introduction to Probability Models**. Academic Press.





# Estructuras de Datos y Algoritmos

## **Introducción:** Big O

## **Estructuras de Datos Comunes:**

- Grafos
- Strings
- Filas
- Listas
- Arrays

## **Complejidad de Algoritmos:**

Medidas de complejidad

## **Tipos de Algoritmos:**

- Algoritmos codiciosos
- Programación dinámica
- Programación lineal
- Algoritmos de divide y conquista
- Algoritmos sobre strings

## **Problemas NP-Completos:**

Reducciones NP

## **Presentación de Proyectos**

## **REFERENCIAS**

- Thomas H Cormen, Charles E Leiserson, Ronald L Rivest, Clifford Stein. **Introduction to Algorithms**. MIT-Press, (2008).
- Dasgupta, S., Papadimitriou, C. H. & Vazirani, U. V. **Algorithms**. McGraw-Hill, (2008).
- Kleinberg, J., & Éva Tardos. **Algorithm Design**. Addison Wesley, (2005).
- Hetland, M. L., (2010). **Python Algorithms: Mastering Basic Algorithms in the Python Language**. Apress.



# Modelos Estadísticos para el Análisis de Datos

## **Modelo Lineal General:**

- Inferencia: Intervalos de confianza y pruebas de hipótesis
- Geometría del modelo lineal
- Experimentos controlados y aleatorizados
- ANOVA: Factores e interacciones

## **Modelos Lineales Generalizados:**

- Familia de distribución exponencial
- Ajustes, inferencia y diagnóstico

## **Modelos Mixtos:**

- Ejemplos simples y teoría general
- Inferencia Intensiva por Computadora a través de remuestreo

## **Modelos Aditivos Generalizados:**

- Ejemplos simples de suavización
- Interacciones suavizadas y descomposición ANOVA suavizada

## **Regresión Sparse:**

- Modelo lineal, Lasso, Elastic Net, Lasso Group

## **Modelos Sparse y Denoising:**

- Representación de Frecuencia, Wavelets, Métodos Pursuit, Umbralización, Variación Total.

## **REFERENCIAS**

- Wood, S. N. (2017). **Generalized Additive Models: An Introduction with R**. CRC press.
- Congdon, P. (2014). **Applied Bayesian Modelling**. John Wiley & Sons.
- Verbeke, G., Molenberghs, G., & Verbeke, G. (1997). **Linear Mixed Models for Longitudinal Data**. (pp. 63-153). Springer New York.
- Dobson, A. J., & Barnett, A. G. (2018). **An Introduction to Generalized Linear Models**. CRC press.



# Métodos Computacionales en Probabilidad e Inferencia

## **Simulación de Variables Aleatorias:**

- Método de Transformación Inversa
- Método de Aceptación-Rechazo

## **Simulación de Variables Aleatorias Multidimensionales:**

- Método de Cambio de Variable
- Método de Superposición

## **Métodos Monte-Carlo (MC):**

- Integración Vía MC
- Muestreo por Importancia
- Métodos de Re-muestreo
- Control y Aceleración de Convergencia

## **Métodos de Optimización vía MC:**

- Optimización Numérica
- Gradiente Estocástico
- Simulated Annealing
- Algoritmo EM

## **Métodos de Monte-Carlo vía Cadenas de Markov (MCMC):**

- Muestreador de Gibbs
- Metropolis-Hastings
- Monte-Carlo Hamiltoniano
- Monte-Carlo Secuencial (Filtrado de Partículas)

## **REFERENCIAS**

- Robert, C. P., Casella, G., & Casella, G. (2010). **Introducing Monte Carlo Methods with R.** (Vol. 18). New York: Springer.
- Asmussen, S., & Glynn, P. W. (2007). **Stochastic Simulation: Algorithms and Analysis.** (Vol. 57, pp. 487-488). New York: Springer.
- Kroese, D. P., Taimre, T., & Botev, Z. I. (2011). **Handbook of Monte Carlo Methods.** John Wiley & Sons.





# Procesos Estocásticos

## Cadenas de Markov

- Definiciones y Propiedades Elementales
- Propiedad Fuerte de Markov
- Estados Recurrentes y Transitorios
- Cadena de Markov Reversible
- Tasa de Convergencia al Equilibrio
- Estadísticas de las Cadenas de Markov

## Proceso de Poisson

- Procesos Puntuales y Procesos de Conteo
- Propiedades Markovianas del Proceso de Poisson
- Comportamiento a Largo Plazo

## Procesos de Markov con Saltos

- Generador Infinitesimal
- Cadena de Markov Asociada
- Reversibilidad
- Métodos de Verosimilitud y Enfoque Bayesiano en Filogenia
- Modelos de Evolución
- Aplicación a Ecuaciones Diferenciales Parciales Discretizadas
- Simulated Annealing (Recocido Simulado)

## REFERENCIAS

- E. Pardoux. **Markov Processes and Applications Algorithms, Networks, Genome and Finance**. (2008) John Wiley & Sons
- Karlin, S., & Taylor, H. M. (1975). **A First Course in Stochastic Processes**. (2nd ed.). Academic Press.
- Norris, J. R. (1997). **Markov Chains**. Cambridge University Press. (Cambridge series on statistical and probabilistic mathematics; No. 2).



# Introducción al Aprendizaje de Máquina

## **Introducción a Machine Learning:**

- Definición y Conceptos Básicos
- Aprendizaje Supervisado y No Supervisado
- Aplicaciones y Casos de Uso

## **Algoritmos Clásicos:**

- K-Nearest Neighbors (KNN)
- K-Means
- Distance-Weighted Nearest Neighbor (DWNN)
- Naive Bayes
- Árboles de Decisión

## **Redes Neuronales y Máquinas de Soporte Vectorial:**

- Perceptrón y Perceptrón Multicapa
- Máquinas de Soporte Vectorial (SVM)
- Feedforward, Backpropagation y Función de Pérdida

## **Planeamiento de Experimentos:**

- K-fold Cross Validation
- Learning Curves
- Métricas de Evaluación
- Técnicas de Ensemble

## **Reducción de Dimensionalidad:**

- Análisis de Componentes Principales (PCA)
- T-Distributed Stochastic Neighbor Embedding (TSNE)
- Uniform Manifold Approximation and Projection (UMAP)

## **Introducción a Aprendizaje Profundo**

## **Introducción a Visión por Computador**

## **Introducción al Procesamiento del Lenguaje Natural**

## **REFERENCIAS**

- Murphy, K. P. (2012). **Machine Learning: A Probabilistic Perspective**. MIT Press.
- Bishop, C. M., & Nasrabadi, N. M. (2006). **Pattern Recognition and Machine Learning**. (Vol. 4, No. 4, p. 738). New York: Springer.
- MacKay, D. J. (2003). **Information Theory, Inference and Learning Algorithms**. Cambridge University Press.



# Aprendizaje Multimodal

## PARTE I: VISIÓN COMPUTACIONAL

- Introducción, Álgebra Lineal
- Filtrado y Textura
- Detección y Descripción de Características
- Bordes, Líneas, Círculos y Segmentos
- Introducción al Reconocimiento
- Redes Neuronales Convolucionales (CNN)

## PARTE II: PROCESAMIENTO DE LENGUAJE NATURAL

- Procesamiento de Texto, Extracción de Características Dispersas para Texto, Bolsa de Palabras (bag-of-words)
- Extracción de Características Densas para Texto (word2vec, glove)
- Aprendizaje Profundo para NLP: Redes Neuronales Recurrentes (LSTM, GRU, etc.)
- Transformers (BERT)
- Large Language Models (LLM): GPT, PALE, y otros.

## PARTE III: APRENDIZAJE POR REFUERZO

- Problema del Bandido, Explotación vs Exploración
- Cadenas de Markov, Funciones de Política y Valor. ¿Cómo mejorar una política

## REFERENCIAS

- Szeliski, R. (2022). **Computer Vision: Algorithms and Applications**. Springer Nature.
- Grauman, K., & Leibe, B. (2011). **Visual Object Recognition**. (No. 11). Morgan & Claypool Publishers.
- Jurafsky, D. (2000). **Speech & Language Processing**. Pearson Education India.





## Inferencia Causal

- **Fundamentos:** causalidad vs predicción, Marco de Resultados Potenciales, identificación causal (supuestos clave) y vínculo con SCM.
- **Diseño Experimental y Validez:** Experimentos Aleatorios Controlados, aleatorización, validez interna vs externa e incumplimiento (ITT).
- **Regresión Causal:** regresión lineal como estimador causal, sesgo por variable omitida y soporte común.
- **Grafos Causales:** DAGs y d-separación, operador  $do()$  y criterio de puerta trasera.
- **Selección de Covariables:** criterios de ajuste, mediadores y colisionadores (malos controles).
- **Instrumentos y LATE:** variables instrumentales, MC2E, LATE y restricción de exclusión.
- **Propensity Score:** matching, balance de covariables e IPTW.
- **Doble Robustez y ML Causal:** AIPW, eficiencia vs robustez y Double Machine Learning.
- **Cuasi-experimentos y panel:** Diferencia en Diferencias (tendencias paralelas) y efectos fijos.
- **Temas Avanzados:** do-calculus, causal discovery y aprendizaje causal con deep learning.

### REFERENCIAS

- Bareinboim, E., Correa, J. D., Ibeling, D., & Icard, T. (2022). On Pearl's hierarchy and the foundations of causal inference. In **Probabilistic and Causal Inference: The Works of Judea Pearl** (pp. 507–556).
- Hernán, M. A., & Robins, J. M. (2020). **Causal Inference: What If**. Chapman & Hall/CRC.
- Pearl, J. (2009). **Causality: Models, Reasoning, and Inference** (2nd ed.). Cambridge University Press.



# Aprendizaje Estadístico de Máquina Avanzado

- Regresión Lineal en Baja y Alta Dimensión
- Técnicas de Clasificación Lineal: LDA, QDA, Regresión Logística con Regularización, SVM.
- Regresión y Clasificación No Paramétrica: Suavización por Kernel, Regresiones Polinomiales Locales, Suavización de Alto Orden, Regresiones Spline, Regresión Logística No Paramétrica.
- Espacios de Hilbert de Kernel Reproductor (RKHS) y Kernels de Mercer.
- Estimación de Densidad por Kernel
- Clustering: K-Means, Modelos de Mixtura, Clustering Basado en Densidad, Clustering Jerárquico, Clustering Espectral.
- Tests Estadísticos de Alta Dimensión
- Concentración de Medidas
- Teoría Minimax
- Esparsidad y LASSO
- Modelos Gráficos

## REFERENCIAS

- Chris Bishop (2006). **Pattern Recognition and Machine Learning.**
- Luc Devroye, László Györfi, Gábor Lugosi (1996). **A Probabilistic Theory of Pattern Recognition.**
- László Györfi, Michael Kolher, Adam Krzyżak, Harro Walk (2002). **A Distribution Free Theory of Nonparametric Regression.**
- Trevor Hastie, Robert Tibshirani, Jerome Friedman (2001). **The Elements of Statistical Learning.**
- Larry Wasserman (2004). **All of Statistics: A Concise Course in Statistical Inference.**
- Larry Wasserman (2005). **All of Nonparametric Statistics.**





# Geostatística y Teledetección Multiespectral

- Procesamiento de Datos Espaciales con Python, Google Earth Engine y QGIS
- Cálculo de Índices Espectrales: NDVI, SAVI, NDWI, NDBI
- Corrección Atmosférica y Ajustes Radiométricos
- Extracción y Suavizado de Series Temporales Satelitales
- Interpolación Estadística: Kriging Simple, Análisis Geoestadístico Aplicado al NDVI
- Estimación y Ajuste del Semivariograma: Modelos Esférico, Exponencial y Gaussiano
- Análisis de Errores y Mapas de Incertidumbre
- Procesos Gaussianos: Enfoques Bayesianos, Funciones Kernel y Comparación con Kriging
- Aplicaciones en Agricultura, Hidrología, Minería e Incendios Forestales
- Estudios de Caso con Validación Cruzada y Análisis Espacial

## REFERENCIAS

- Gavin, H.P. & Khanal, S. (2021). **Interpolation, Kriging, Gaussian Processes**. Duke University.
- Cressie, N.A.C. (1991). **Statistics for Spatial Data**. Wiley
- Rasmussen, C.E. & Williams, C.K.I. (2006). **Gaussian Processes for Machine Learning**. MIT Press.
- Chilès, J.-P. & Delfiner, P. (2012). **Geostatistics: Modeling Spatial Uncertainty**. Wiley.
- Isaaks, E. H. & Srivastava, R. M. (1989). **Applied Geostatistics**. Oxford University Press.





# Calculo Estocástico y sus Aplicaciones a Finanzas

- Procesos estocásticos y movimiento browniano
- Integral de Itô: construcción de la integral estocástica, propiedades y extensiones
- Lema de Itô y Teorema de representación de martingalas
- Ecuaciones diferenciales estocásticas (EDS): existencia y unicidad, soluciones fuertes y débiles
- Teoría de difusión: procesos de difusión de Itô, generadores infinitesimales, fórmula de Dynkin, operador característico
- Ecuaciones de Kolmogórov hacia atrás y ecuaciones de Fokker-Planck
- Aplicaciones a matemática financiera: mercados, portafolios y arbitraje financiero, completitud de mercados
- Derivativos financieros, pricing de opciones y modelo de Black-Scholes

## REFERENCIAS

- Oksendal, B. (2013). **Stochastic Differential Equations: An Introduction with Applications**. Springer Science & Business Media.
- Hsiung Kuo. (2006). **Introduction to Stochastic Integration**.
- Lamberton, D., & Lapeyre, B. (2011). **Introduction to Stochastic Calculus Applied to Finance**. Chapman and Hall/CRC.
- Klebaner, F. C. (2012). **Introduction to Stochastic Calculus with Applications**. World Scientific Publishing Company.
- Pavliotis, G. A. (2014). **Stochastic Processes and Applications**. Texts in applied mathematics, 60.



## Aprendizaje por Refuerzo

- Procesos de Decisión de Markov
- Planificación por Programación Dinámica
- Model-Free Prediction y Control
- Value Function Approximation
- Métodos Policy Gradient
- Algoritmos Actor-Critic
- Integración de Learning y Planificación
- Trade-offs Exploración vs. Explotación

### REFERENCIAS

- Sutton, R. S., & Barto, A. G. (2018). **Reinforcement Learning: An Introduction**. MIT press.
- François-Lavet, V., Henderson, P., Islam, R., Bellemare, M. G., & Pineau, J. (2018). **An introduction to Deep Reinforcement Learning**. Foundations and Trends in Machine Learning, 11(3-4), 219-354.



## Modelos Gráficos

- Razonamiento Bayesiano
- Redes Bayesianas
- Modelos Gráficos Dirigidos y No Dirigidos
- Inferencia en Modelos Gráficos
- Modelos Ocultos de Markov
- Algoritmo Junction Tree
- Toma de Decisiones Bajo Incertidumbre
- Procesos de Decisión de Markov
- Learning con Datos Faltantes
- Inferencia Aproximada Mediante Muestreo

### REFERENCIAS

- Murphy, K. P. (2012). **Machine Learning: A Probabilistic Perspective**. MIT press.
- Bishop, C. M., & Nasrabadi, N. M. (2006). **Pattern Recognition and Machine Learning**. (Vol. 4, No. 4, p. 738). New York: springer.
- MacKay, D. J. (2003). **Information Theory, Inference and Learning Algorithms**. Cambridge university press.





**Maestría en Ciencias e Ing. Estadística**  
Unidad de Posgrado

# Plana Docente

---





# Maestría en Ciencias e Ing. Estadística

Unidad de Posgrado

Plana Docente - MCIES



**Erick Chacón**

PhD. y MSc. en Estadística por la Universidad de Lancaster, UK. Actualmente es investigador postdoctoral en el Grupo de Investigación de Estadística Geoespacial (GeoHealth) de la Universidad de Ciencia y Tecnología del Rey Abdullah (KAUST), Arabia Saudita. Además, es docente del programa de Doctorado en Ciencias e Ingeniería Estadística (DCIES) de la FIEECS-UNI. También se ha desempeñado como Investigador Asociado Senior en Ciencia de Datos Medioambientales, DSNE - Lancaster University, UK; y como Consultor en la Sociedad Alemana para la Cooperación Internacional (GIZ), y la Secretaría del Consejo Nacional de Seguridad Vial, Lima-Perú. También se desempeña como Coordinador Académico del programa MCIES de la FIEECS-UNI.

## **Líneas de Investigación y Desarrollo:**

- Estadística Bayesiana
- Modelado Causal
- Modelado Espacio-temporal
- Métodos Computacionales Intensivos



**Helder Rojas**

PhD. en Física Matemática por el departamento de Matemáticas Fundamentales de la UNED, España. MSc. en Estadística por el Instituto de Matemáticas y Estadística de la Universidad de Sao Paulo (IME-USP), Brasil. Seguidamente, se desempeñó como investigador postdoctoral en el Centro para Ciencias de la Complejidad del Departamento de Matemáticas del Imperial College London, UK. Es Docente del programa de Doctorado en Ciencias e Ingeniería Estadística (DCIES) y Coordinador Académico del programa de Maestría en Ciencia de Datos (MDS) de la FIEECS-UNI. Además, tiene experiencia en ciencia de datos e inteligencia artificial en corporaciones del sector financiero Brasileiro, Colombiano y Peruano. Actualmente se desempeña como gerente de IA Generativa en el Banco de Crédito del Perú (BCP).

## **Líneas de Investigación y Desarrollo:**

- Análisis Estocástico
- Finanzas Cuantitativas
- Aprendizaje de Máquina
- Deep Learning
- IA generativa



# Maestría en Ciencias e Ing. Estadística

Unidad de Posgrado



**Jorge  
Guevara**

Ph.D. en Ciencias de la Computación por el Instituto de Matemática y Estadística de la Universidad de São Paulo (Brasil). Fue investigador visitante en el laboratorio LITIS del INSA Rouen (Francia) y se desempeñó como científico de investigación en IBM Research. Cuenta con amplia experiencia en investigación industrial aplicada, utilizando modelos de machine learning e IA generativa para la predicción de recursos naturales y la modelación de procesos climáticos y meteorológicos.

## **Líneas de Investigación y Desarrollo:**

- Deep Learning & Machine Learning
- IA Generativa
- Probabilistic Modeling
- AI based Weather Generators



**Nils  
Murrugarra**

PhD. en Ciencias de la Computación por la Universidad Pittsburgh, USA. MSc. en Ciencias de la Computación por el Instituto de Ciencias Matemáticas y de Computación de la Universidad de Sao Paulo (ICMC-USP), Brasil. Anteriormente fue profesor en el Departamento de Ciencias de la Computación en Weber State University, USA; e investigador científico en Snap Inc. Actualmente es docente en la Universidad Pittsburgh, USA.

## **Líneas de Investigación y Desarrollo:**

- Visión Computacional
- Multi-model Learning
- Transfer Learning
- Aprendizaje por Refuerzo
- Aprendizaje Profundo
- Aprendizaje por Transferencia

Plana Docente - MCIES





# Maestría en Ciencias e Ing. Estadística

Unidad de Posgrado




**Melba Torres**

PhD. student en Sistemas Inteligentes en el Departamento de Inteligencia Artificial de la UNED (España), con énfasis en Aprendizaje por Refuerzo impulsado por LLMs. MSc. en Estadística por el Instituto de Matemática y Estadística de la Universidad de São Paulo (IME-USP). Tiene experiencia en ciencia de datos en diversas corporaciones del sector financiero Brasileiro, tales como: KPMG, Banco Santander y Mercado Libre. Actualmente se desempeña como Senior Data Scientist en Itaú Unibanco en São Paulo, Brasil.

## Líneas de Investigación y Desarrollo:

- Reinforcement Learning
- Generative AI
- Sistemas Inteligentes



**Miguel  
Galarreta**

PhD. y M.Sc. en Ciencias de la Computación por el Instituto de Matemática y Estadística de la Universidad de São Paulo (IME-USP), Brasil. Ha sido profesor en instituciones como la UNI, la UNSAAC y UNIFIEO (Brasil). Ingeniero de Software en Big Techs, con trayectoria en empresas globales como Amazon Brasil. Actualmente trabaja en Uber Brasil como Ingeniero de Software.

## Líneas de Investigación y Desarrollo:

- Procesamiento de Imágenes Médicas y Visión Computacional
- Aprendizaje Computacional
- Ingeniería de Software

Plana Docente - MCIES



# Maestría en Ciencias e Ing. Estadística

Unidad de Posgrado



**Julio  
Delgado**

MSc. en Ciencias de la Computación por el Instituto de Matemática y Estadística de la Universidad de São Paulo (IME-USP). Tiene experiencia en el diseño e implementación de plataformas analíticas en la nube y lakehouses corporativos. Actualmente es Senior Data Architect en Indra y, previamente, trabajó en Bluetab (an IBM Company) y Accenture Brasil en proyectos de modernización de ecosistemas de datos y soluciones Big Data para banca, seguros, retail y fintech.

## **Líneas de Investigación y Desarrollo:**

- Big Data
- Arquitectura de Software
- Computación de Alta Performance
- Computación Teórica
- Ingeniería de Datos



**Kevin  
Fernandez**

MSc. en Geociencias por el Instituto de Geociencias de la Universidad de São Paulo (USP), Brasil. Ingeniero Civil por la Universidad de Ciencias Aplicadas (UPC). Con experiencia en técnicas de Aprendizaje Automático aplicadas al análisis de imágenes satelitales, series temporales y sistemas de predicción en geociencias. Investiga el uso de Inteligencia Artificial Generativa para la simulación de escenarios geológicos, generación sintética de datos y mapas, y fortalecimiento de modelos predictivos con datos escasos.

## **Líneas de Investigación y Desarrollo:**

- Modelado Predictivo en Geociencias
- Análisis de Datos Espaciales
- Integración de Ciencia de Datos y Computación en Geociencias

Plana Docente - MCIES



# Maestría en Ciencias e Ing. Estadística

Unidad de Posgrado



**Amao Suxo**

MSc. en Matemática Aplicada por el Instituto de Matemática y Ciencias Afines (IMCA). Ingeniero Estadístico de la Universidad Nacional de Ingeniería (UNI). Ha complementado su formación con especializaciones en econometría aplicada, Business Analytics con enfoque en Machine Learning, Deep Learning e Inteligencia Artificial Generativa. Tiene experiencia en investigación aplicada en oceanografía, desarrollada en el Instituto de Investigación para el Desarrollo (IRD) de Francia. Actualmente, es Gerente Analítico del Centro de Excelencia en Model Risk Management de BCP/CREDICORP.

## **Líneas de Investigación y Desarrollo:**

- Aprendizaje Estadístico
- Métodos Estadísticos Multivariados
- Machine Learning
- Deep Learning



**Alfonso  
Phooco**

MSc. en Ciencias de la Computación por la Universidade de São Paulo (USP). Bachiller en Ciencias de la Computación, Universidad Nacional de San Agustín de Arequipa. Arquitecto de Datos e Inteligencia Artificial con experiencia en iniciativas de Data & AI, DevOps/MLOps y modernización de plataformas de datos en sectores tecnológico, financiero y de salud. Actualmente es Big Data Specialist en Globant, São Paulo, Brasil.

## **Líneas de Investigación y Desarrollo:**

- Big Data
- AI Engineering
- Distributed Systems
- High Performance Computation
- Software Architectures
- DevOps, MLOps/DataOps, Tech Innovation





# Maestría en Ciencias e Ing. Estadística

Unidad de Posgrado



**Lucy Choque**

PhD. y MSc. en Ciencias de la Computación por el Instituto de Matemática y Estadística de la Universidad de São Paulo (IME-USP), Brasil. Su trayectoria ha sido reconocida en congresos como WVC, CSBC, SIBGRAPI y CLEI por trabajos de tesis en visión computacional. Sus investigaciones se centran en el desarrollo de métodos computacionales para el reconocimiento de patrones, análisis de movimiento y procesamiento de imágenes, con aplicaciones en visión por computador y aprendizaje profundo. Actualmente es Investigadora Postdoctoral en la Escuela Politécnica - USP, Brazil

## **Líneas de Investigación y Desarrollo:**

- Procesamiento de Imagen
- Visión Computacional
- Aprendizaje de Máquina
- Ingeniería de Software



**Rusbert  
Calderón**

PhD. en Matemática Aplicada por el Instituto de Matemática y Estadística de la Universidad de São Paulo (IME-USP), Brasil. MSc. en Matemática Aplicada por la Universidad Federal ABC, Brasil. Fue Investigador postdoctoral en el Departamento de Matemáticas de la Universidad Católica del Norte (UCN), Chile. Actualmente es profesor investigador en el Departamento de Ciencias Básicas de la UNAM, Perú.

## **Líneas de Investigación y Desarrollo:**

- Teoría Ergódica
- Sistemas Dinámicos Simbólicos
- Formalismo Termodinámico
- Teoría Asintótica en Estadística
- Procesos Estocásticos en Finanzas



# Maestría en Ciencias e Ing. Estadística

Unidad de Posgrado



**Frank Navarro**

Ph.D. en Matemática Aplicada por el Instituto de Matemáticas y Estadística de la Universidad de São Paulo (IME-USP), Brasil. MSc. en Matemática aplicada y computacional por la Facultad de ciencias matemáticas de la Universidad Nacional Mayor de San Marcos (FCM-UNMSM), Perú. Participó en un proyecto de IA aplicada a transacciones financieras en Banco Bradesco Brasil. Actualmente es profesor permanente en la Facultad de ciencias de la UNI, y profesor permanente en la unidad de posgrado de la facultad de ciencias matemáticas de la UNMSM

## Líneas de Investigación y Desarrollo:

- Optimización
- Teorías de juegos
- Análisis Numérico
- Problemas de equilibrio



**Jaime Lincovil**

PhD. en Estadística por la Universidade de São Paulo (USP), Brasil, con formación en fundamentos lógicos y matemáticos de la inferencia estadística. Es Profesor de Matemática por la Universidad Católica de Temuco, Chile. Se ha desempeñado como académico e investigador en diversas universidades chilenas, dictando cursos de probabilidad, estadística, inferencia causal y análisis de datos. Cuenta con más de diez años de experiencia en Ciencia de Datos y Machine Learning, desarrollando pipelines de producción en Python, R y SQL, así como modelos de riesgo, analítica funcional y plataformas de experimentación A/B. Actualmente combina docencia de postgrado, supervisión de tesis en ciencia de datos y desarrollo de proyectos aplicados en analítica avanzada.

## Líneas de Investigación y Desarrollo:

- Modelamiento Estadístico
- Simulación Monte Carlo
- Gestión del riesgo financiero.





**Maestría en Ciencias e Ing. Estadística**  
Unidad de Posgrado

# Inversion

---

**INFORMES:** +51 903 236 156 – Srta. Lisbeth

**30 Marzo**





## Inversión

### INGRESO POR PRE-MAESTRIA 2026-I

Es una de las modalidades de ingreso directo a la maestría, y a la vez, prepara al postulante para iniciar con éxito el programa MCIES. Al alcanzar una vacante, ya no tiene que pagar ni rendir el examen de admisión. Los cursos que se impartirán en la Pre-Maestría son:

- Fundamentos Matemáticos para IA y Ciencia de Datos.
- Introducción a Probabilidad y Distribuciones.
- Neural Python: Computación Gráfica, Compiladores y Deep Learning.

Para más detalles, consultar por el [brochure de la Pre-Maestría 2026-I](#)

**Pago al contado:** S/ 1 600.00

**Dos cuotas:**

S/ 1 700.00

**Duración:** 7 semanas

S/ 850.00

hasta **una semana antes** de iniciar la PRE-MAESTRIA

S/ 850.00

**después de un mes** de iniciar la PRE-MAESTRIA

**Nota:** Actualmente la **PREMAESTRÍA 2026-I** se encuentra en Proceso de Inscripción hasta el 19 de Enero del 2026 PREMAESTRÍA 2026-I, que se realiza a inicios del próximo año o elegir la **Modalidad de Ingreso Ordinario** de este ciclo.

El postulante que APRUEBE todas las asignaturas con una nota igual o mayor 10 pts., obtenga un promedio ponderado igual o mayor 12 pts. y alcance vacante en estricto orden de mérito, será ADMITIDO a la maestría.

| N° | ACTIVIDAD                           | FECHA       |
|----|-------------------------------------|-------------|
| 1  | Publicación de Lista de Ingresantes | 02 de Marzo |
| 2  | Inicio de Clases Maestria           | 30 de Marzo |



## INGRESO ORDINARIO

Para participar en el ingreso ordinario, realiza la inversión indicada y completa la evaluación (20 pts).

### PROSPECTO

S/ 250.00

### DERECHO DE ADMISIÓN

S/ 875.00

- La evaluación esta comprendida por **2 fases** y se calificara sobre **20 pts**.
  - Evaluación de Ensayo. (**10pts**)
  - Entrevista Personal. (**10pts**)
- Para mas información acerca del ensayo. Ver [Guía para la elaboración del ensayo](#)
- Se acepta la entrega del ensayo al momento de matricularse o hasta el 1 de marzo a las 11:59pm.
- La nota mínima para ser admitido en la Maestría MCIES es de **14 pts**.
- Se aceptaran postulantes hasta el **01 de Marzo de 2026**.

## MATRICULA AL CICLO REGULAR

S/ 656.00

Son cuatro matrículas que se abonan al inicio de cada ciclo.

### 48 CRÉDITOS DE ENSEÑANZA (4 CICLOS)

S/ 20,352.00

En total son veinticuatro mensualidades.

S/ 424.00

Costo por cada crédito

### DESCUENTOS SOBRE EL MONTO DE CRÉDITOS

**8%**

Si paga adelantado  
todo el ciclo

**16%**

Si paga adelantado toda  
la maestría



## Cronograma Ordinario

| N° | ACTIVIDAD                                                 | FECHA                             |
|----|-----------------------------------------------------------|-----------------------------------|
| 1  | Inicio de Inscripciones al Ingreso<br>Modalidad Ordinario | Del 06 de Enero<br>al 01 de Marzo |
| 2  | Entrega de Ensayo                                         | 01 de Marzo                       |
| 3  | Entrevista a los Postulantes                              | 02-17 de Marzo                    |
| 4  | Publicación de Resultados                                 | 21 de Marzo                       |
| 5  | Inicio de Clases Maestría                                 | 30 de Marzo                       |

## REQUISITOS DE MATRÍCULA

Una vez admitido, para formalizar su matrícula, el estudiante tiene que enviar la siguiente documentación:

- Grado de bachiller o título (en copia y puede ser presentado hasta dentro de 6 meses de haber comenzado la maestría).
- Certificado de estudios universitarios de pregrado (en copia y puede ser presentado hasta dentro de 6 meses de haber comenzado la maestría).
- DNI (copia simple de ambos lados).
- Una foto reciente a color, tamaño carnet, fondo blanco y sin lentes.

Para información adicional pueden revisar el [REGLAMENTO DE ESTUDIOS DE POSGRADO UNI](#)

Para realizar el pago, deberá de [solicitar una orden](#) de pago al correo , [info.posgrado.fieecs@uni.edu.pe](mailto:info.posgrado.fieecs@uni.edu.pe), [lisbeth.05.08.97@gmail.com](mailto:lisbeth.05.08.97@gmail.com) o al número [+51 903 236 156](#) indicando su nombre completo, DNI y monto a pagar. En caso desea factura deberá indicar el RUC y los datos de la persona o empresa. Enviar su transferencia o comprobante de pago para considerarlo en la lista de participantes.

Una vez cancelada la orden de pago se le enviará la carpeta y remitida de manera virtual a [info.posgrado.fieecs@uni.edu.pe](mailto:info.posgrado.fieecs@uni.edu.pe)





## Preguntas Frecuentes

### ¿Cuál es el inicio y el horario de la maestría?

La fecha de inicio de la maestría es el 30 de Marzo. El horario es entre semana por las noches y algunos fines de semana.

### ¿Cuál es el software que se utilizará?

En la maestría llevarán un curso de teoría y estructura de algoritmos, con lo cual estarán en facultad de programar en cualquier lenguaje.

### ¿Cómo está conformada la Plana Docente?

La plana docente está conformada por científicos en producción y crecimiento por lo general trabajan en el exterior. Respecto a las líneas de investigación, cuando el alumno complete el segundo ciclo podrá elegir un Advisor y trabajar en el proyecto.

### ¿Se pueden llevar cursos libres?

Actualmente, solo se han habilitado los cursos de la Pre-Maestría como cursos libres. Los estudiantes pueden inscribirse en algunos de estos cursos, pero deben tener en cuenta que no serán válidos para el ingreso, ya que es necesario completar los tres cursos y cumplir con los requisitos de calificación establecidos.

### ¿Cuál es la modalidad de la Maestría en Ingeniería Estadística?

La modalidad de la maestría es online el cual permite ofrecer un nivel de enseñanza altamente calificado. Algunas sesiones, bajo previa coordinación serán presenciales. Como por ejemplo, evaluaciones de seminarios de tesis, presentación de trabajos científicos, participación de jornadas científicas y más.



# Maestría en Ciencias e Ing. Estadística

Unidad de Posgrado

## ¿Cuánto es la inversión en la Maestría en Ingeniería Estadística?

### Proceso de admisión

- Prospecto 250.00
- Derecho de admisión 875.00

### Proceso de ingreso

- Matrícula S/.656.00
- 48 Créditos S/.20,352.00 (también hay planes de 4,6 y 24 cuotas, descuentos del 8% y 16%)

## ¿Cuál es el beneficio de llevar la Maestría en Ingeniería Estadística?

Llevar la maestría te forma para cursar un doctorado, ya sea aquí o en el extranjero. Teniendo el doctorado ya puedes optar por una vida académica. Además Sunedu avala nuestro programa de maestría. Aún estamos en nuestra primera versión, en lo sucesivo haremos proyectos de investigación con nuestros equipos, con eso buscaremos el apoyo de CONCYTEC.

## ¿Cuál es la diferencia entre la maestría en Ciencia de Datos e Ingeniería Estadística?

La maestría en ingeniería estadística tiene un enfoque científico, también habrá proyectos orientados a soluciones industriales, pero siempre guiado por el enfoque científico. Las maestrías en estadística y ciencias datos en el ámbito peruano generalmente están enfocados en temas prácticos y de gestión analítica. En contraste, nuestro programa busca formar una nueva generación de expertos e investigadores aplicados en áreas de interface entre estadística, matemática aplicada y ciencia de datos.



# Maestría en Ciencias e Ing. Estadística

Unidad de Posgrado

## Importante

- El reembolso procede con la retención del 15% por gastos administrativos y debe ser justificado. El reembolso o la reserva procede siempre y cuando se solicite antes que inicien las clases.
- La Unidad de Posgrado se reserva el derecho de modificar el docente por motivos de fuerza mayor o por disponibilidad del profesor, garantizando que la calidad de la Maestría no se vea afectado. Toda modificación será comunicada anticipadamente a los participantes.
- La Unidad de Posgrado podrá efectuar cambios en la secuencia de los temas de acuerdo a su política de mejora continua.
- Los cursos son elegidos por el director y el coordinador académico en función a mantener la calidad del programa y la adaptación al mercado laboral y al proceso de investigación.
- De no cumplir con el quorum requerido, la Unidad de Posgrado se reserva el derecho de postergar el inicio de clases de la maestría.

## REDES

Posgrado en Ing. Estadística y Data Science – UNI



[Youtube](#)



[LinkedIn](#)



[Instagram](#)

## INFORMES:



[+51 903 236 156 – Srta. Lisbeth](#)

Grupo de Informes y Difusión – [Link](#)



[info.posgrado.fieecs@uni.edu.pe](mailto:info.posgrado.fieecs@uni.edu.pe)

**INFORMES:** +51 903 236 156 – Srta. Lisbeth

**30 Marzo**