



MAESTRÍA  
EN CIENCIAS E  
**INGENIERÍA ESTADÍSTICA**



FACULTAD DE  
INGENIERÍA  
ECONÓMICA,  
ESTADÍSTICA Y  
CIENCIAS  
SOCIALES

**UNIDAD DE POSGRADO**

“Un enfoque mixto entre  
Estadística Computacional y  
Aprendizaje de Máquina”

.....  
**20  
24**  
.....

**PROCESO DE ADMISIÓN**  
**ABRIL**

# Presentación

La Maestría en Ciencias e Ingeniería Estadística (MCIES) es un programa altamente calificado con un enfoque mixto, mezclando conocimientos de Matemática y Ciencias de la Computación en el campo de la Estadística.

El objetivo de nuestro programa es formar a la próxima generación de investigadores, profesores universitarios y expertos, en el área de interfaz entre Estadística y Aprendizaje de Máquina, con la capacidad de marcar una diferencia tangible en estos campos. Así mismo, otro objetivo es incentivar el cambio de paradigma y enfoque acerca de Estadística y Aprendizaje de Máquina que nuestro país necesita para satisfacer la demanda de desarrollo científico, tecnológico e industrial de estas dos áreas en constante desarrollo y evolución.

El programa MCIES está diseñado para investigadores en ciencia y tecnología, así como también, profesores universitarios y profesionales en área de ciencia de datos. Los estudiantes del programa obtendrán una formación sólida en Estadística, Probabilidad y Machine Learning, con lo cual estarán preparados para una carrera exitosa en una amplia variedad de industrias, incluyendo finanzas, tecnología, ingeniería, manufactura y más. Además, los graduados de nuestro programa estarán bien equipados para continuar su educación a nivel de doctorado, si así lo desean.

Nuestro equipo de profesores investigadores está compuesto por expertos en Estadística, Matemática y Ciencias de la Computación, con experiencia tanto académica como industrial. Todos nuestros profesores son doctores de universidades muy prestigiosas, lo cual contribuye a la excelencia del nivel científico de nuestro programa. Los estudiantes tendrán la oportunidad de trabajar en estrecha colaboración con estos docentes, quienes les brindarán una orientación personalizada en el desarrollo de habilidades y en la investigación de temas de interés.





# MODALIDAD ONLINE

Las clases se realizarán en la plataforma ZOOM, dentro de esta plataforma podrás:

- Contar con un docente impartiendo la clase en vivo y conectado durante todo el tiempo que dure la sesión.
- Hacer preguntas o comentarios al docente en tiempo real (hablado o por chat).




# AULA VIRTUAL

La Unidad de Posgrado se compromete con la educación digital, ya que cuenta con una plataforma de aula virtual para el desarrollo de las clases, en el cual podrán encontrar las sesiones virtuales, materiales de clases, tareas, evaluaciones, etc.

# PLANA DOCENTE

Nuestro equipo docente, científicos internacionales, está comprometido a impartir sus conocimientos y experiencias, enfocándose en un aprendizaje constante y en la aplicación práctica de las tendencias actuales del sector.



# Perfil del Graduado

Al finalizar el programa MCIES, los graduados estarán preparados para continuar estudios de doctorado en universidades peruanas o extranjeras; participar en proyectos de investigación interdisciplinarios; y para ejercer la docencia universitaria.


## Líneas de Investigación

- Estadística Computacional e Inferencia Variacional
- Modelos Geoespaciales
- Simulación Estocástica de Sistemas Complejos
- Procesamiento de Información Estocástica
- Finanzas Cuantitativas
- Procesos Gaussianos para Aprendizaje de Máquina
- Aprendizaje Profundo y Optimización Bayesiana
- Aprendizaje por Refuerzo
- Visión computacional y Procesamiento de Lenguaje Natural





# Dirigida a:

- **Profesionales Analíticos:** Aquellos que buscan perfeccionar sus habilidades analíticas y destacarse en la interpretación avanzada de datos.
  - **Expertos en Datos:** Profesionales que desean elevar su perfil en el mercado laboral al especializarse en análisis de datos y estadísticas avanzadas.
  - **Directores de Estrategia:** Líderes empresariales que buscan optimizar la toma de decisiones estratégicas basadas en evidencia cuantitativa.
  - **Profesionales de Finanzas y Marketing:** Especialmente aquellos interesados en el análisis de datos para la formulación de estrategias de finanzas y marketing efectivas.
  - **Investigadores Innovadores:** Aquellos con un interés en la investigación avanzada en estadística e ingeniería estadística, con aplicaciones prácticas en diversos campos.
  - **Programadores y Desarrolladores:** Profesionales con una base en programación que desean aplicar sus habilidades en el análisis de datos a gran escala, especialmente en contextos de Big Data.
- 

# 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 (26 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	Algebra Lineal y Optimización Computacional	3	Ninguno
MES112	Elementos de Análisis Real	3	Ninguno
MES120	Estructuras de Datos y Algoritmos	3	Ninguno
Total de Créditos		13	

## CICLO II

CÓDIGO	CURSO	CRÉDITOS	REQUISITO
MES201	Modelos Estadísticos para el Análisis de Datos	3	MES101
MES202	Métodos Computacionales para Aprendizaje Estadístico	3	MES120
MES211	Introducción a Modelado Estocástico	3	MES112
MES221	Fundamentos en Aprendizaje de Máquina	4	MES111
Total de Créditos		13	



### CICLO III

CÓDIGO	CURSO	CRÉDITOS	REQUISITO
MES301	Visión computacional y Procesamiento de Lenguaje Natural	3	MES221
MES302	Seminarios de Investigación I	4	MES221 MES201
MES331	Electivo 1	3	Ninguno
MES332	Electivo 2	3	Ninguno
Total de Créditos		<b>13</b>	

### CICLO IV

CÓDIGO	CURSO	CRÉDITOS	REQUISITO
MES401	Seminario de Investigación II	3	MES302
MES402	Plan de Tesis	3	MES302
MES403	Electivo 3	3	Ninguno
Total de Créditos		<b>9</b>	



# 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 26 créditos. El candidato a máster realizará como mínimo tres de los siguientes cursos electivos:

CÓDIGO	CURSO	REQUISITO	CONCENTRACIÓN
DES501	<b>Estadística para Datos de Alta Dimensión</b>	<b>MES201 MES202</b>	Estadística
DES502	<b>Análisis de Datos Funcionales</b>		
DES503	<b>Ondaletas para Análisis de Series de Tiempo</b>		
DES504	<b>Análisis de Datos Topológicos</b>		
DES511	<b>Modelado usando Ecuaciones Diferenciales Estocásticas</b>	<b>MES211</b>	Modelado Estocástico
DES512	<b>Procesos de Decisión Markoviano</b>		
DES521	<b>Aprendizaje por Refuerzo</b>	<b>MES221</b>	Aprendizaje e Inteligencia Artificial
DES522	<b>Temas Avanzados en Aprendizaje de Máquina</b>		
DES523	<b>Tópicos en Inteligencia Artificial</b>		
DES524	<b>Aprendizaje Profundo Bayesiano</b>		
DES525	<b>Modelos Gráficos</b>		

# Algebra Lineal y Optimización Computacional



## Parte 1 (Álgebra Lineal):

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

## Parte 2 (Optimización):

Funciones de Varias Variables, Motivación y Ejemplos. Normas y Distancias en el Espacio  $R^n$ . Puntos de Acumulación. Aplicaciones Continuas. Conjuntos Abiertos y Cerrados. Conjuntos Compactos. Conjuntos Convexos. Funciones Convexas y Estrictamente Convexas. Derivadas Parciales. Derivadas Direccionales. Diferenciabilidad. Regla de la Cadena. Fórmula de Taylor. Funciones de  $R^n$  a  $R$ . 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 e Intervalos Encajantes. Conceptos topológicos en  $\mathbb{R}^n$ : Normas, Producto Interno, Conjuntos Abiertos, Conjuntos Cerrados y Conjuntos Compactos. Secuencias Numéricas. Límite Superior e Inferior. Continuidad de Funciones: Puntual y Uniforme. Diferenciabilidad: Derivadas Direccionales, Derivada como Aplicación Lineal, Fórmula de Taylor y Extremos de una Función Real. Integral de Riemann, Criterios de Integrabilidad y Teorema Fundamental del Cálculo. Series Numéricas. Criterios de Convergencia. Serie de Funciones. Integral. Introducción a 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 1 (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) y Teorema Central del Límite (TCL).

## Parte 2 (Inferencia Estadística):

Introducción a Estadística Frecuentista. Distribución Muestral de un Estimador. Teoría de Decisión Frecuentista. Propiedades Deseables de un Estimador. Minimización de Riesgo Empírico. Patologías de Estadística Frecuentista. Introducción a 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. 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 más Comunes: Grafos, Strings, Filas, Listas, Arrays etc. Complejidad de Algoritmos y Medidas de Complejidad. Tipos de Algoritmos: Algoritmos Codiciosos, Programación Dinámica, Programación Lineal, Algoritmo Divide y Conquista. Algoritmos sobre Strings. Problemas NP-Completos. NP reducciones. Presentación de proyectos.

## REFERENCIAS

- 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.

```
1 # get random forest model
2 import numpy as np
3 from sklearn.model_selection import train_test_split
4 from sklearn.metrics import mean_squared_error, r2_score
5
6
7 # load data from train.csv
8 train_df = pd.read_csv('data/train.csv')
9 train_df['target'] = train_df['target'].astype(int)
10
11 # split the data into training and testing sets
12 X_train, X_test, y_train, y_test = train_test_split(train_df[['x1', 'x2', 'x3', 'x4', 'x5', 'x6', 'x7', 'x8', 'x9', 'x10', 'x11', 'x12', 'x13', 'x14', 'x15', 'x16', 'x17', 'x18', 'x19', 'x20', 'x21', 'x22', 'x23', 'x24', 'x25', 'x26', 'x27', 'x28', 'x29', 'x30', 'x31', 'x32', 'x33', 'x34', 'x35', 'x36', 'x37', 'x38', 'x39', 'x40', 'x41', 'x42', 'x43', 'x44', 'x45', 'x46', 'x47', 'x48', 'x49', 'x50', 'x51', 'x52', 'x53', 'x54', 'x55', 'x56', 'x57', 'x58', 'x59', 'x60', 'x61', 'x62', 'x63', 'x64', 'x65', 'x66', 'x67', 'x68', 'x69', 'x70', 'x71', 'x72', 'x73', 'x74', 'x75', 'x76', 'x77', 'x78', 'x79', 'x80', 'x81', 'x82', 'x83', 'x84', 'x85', 'x86', 'x87', 'x88', 'x89', 'x90', 'x91', 'x92', 'x93', 'x94', 'x95', 'x96', 'x97', 'x98', 'x99', 'x100'], train_df['target'], test_size=0.2, random_state=42)
13
14 # fit random forest model
15 rf = RandomForestRegressor()
16 rf.fit(X_train, y_train)
17
18 # predict labels of test set
19 y_pred = rf.predict(X_test)
```

# Modelos Estadísticos para el Análisis de Datos

Regresión Lineal Múltiple (RLM): Técnicas de Inferencia del Modelo Lineal General, Aplicaciones, Selección de Variables. Modelos Lineales Generalizados (MLG): Estructura que Incorpora una Introducción a la Familia Exponencial de Distribuciones, Procedimientos de Inferencia. Datos Categóricos: Casos Especiales de Modelos Lineales Generalizados que Conducen a Regresión Logística y Modelos Log-Lineales, Uso en Análisis de Datos. Introducción a los Modelos Aditivos Generalizados (MAG): Splines de Regresión Penalizados y Estimación Penalizada. Introducción al Modelado No Lineal y al Modelado Mixto (MLGM), Uso para Datos Longitudinales y Agrupados.

## 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 para Aprendizaje Estadístico

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.
- Ross, S. M. (2022). *Simulation*. Academic Press.




# Introducción al Modelado Estocástico

Cadenas de Markov en Tiempo Discreto. Proceso de Poisson. Proceso de Nacimiento y Muerte. Martingala en Tiempo Discreto. Cadenas de Markov de Tiempo Continuo. Movimiento Browniano. Martingala en tiempo Continuo. Integral de Itô. Fórmula Itô. Ecuaciones Diferenciales Estocásticas. Representación de Martingalas. Cambio de Medida. Fórmula de Feynman-Kac.

## REFERENCIAS

- Grimmett, G., & Stirzaker, D. (2020). *Probability and random processes*. Oxford university press.
- Oksendal, B. (2013). *Stochastic differential equations: an introduction with applications*. Springer Science & Business Media.





# Fundamentos de Aprendizaje de Maquina

Vecinos más cercanos. Kernels y Maquinas de Soporte Vectorial (SVM) con regularización. Aprendizaje de Maquina vía Procesos Gaussianos (GPs). Arboles de Decisión (CART). Ensemble Learning. Métodos de Esparsidad. Multi-task Learning. Aprendizaje Semi-supervisado. Redes Neuronales (RNA). Factorización Matricial. Online Learning. Teoría del Aprendizaje Estadístico.

## 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.

# Visión Computacional y Procesamiento de Lenguaje Natural

## Parte 1 (Visión Computacional):

Visión de Bajo Nivel. Filtrado y Textura. Detección y Descripción de Características. Aristas, Líneas, Círculos y Segmentos. Introducción al Reconocimiento. Visión de Alto Nivel. Redes Neuronales Convolucionales.

## Parte 2 (Procesamiento de Lenguaje Natural):

Procesamiento de Textos, Extracción de Características Dispersas para Textos, Bag-of-words. Extracción de Características Densas para Textos (word2vec, glove). Deep Learning para NLP; Redes Neuronales Recurrentes (RNNs), LSTM, GRU, etc. Transformers (BERT). Large Language Models; GPT and PALE.

## 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.





# Aprendizaje por Refuerzo

Procesos de Decisión de Markov. Planificación por Programación Dinámica. Model-free Prediction y Control. Value Function Fpproximation. Métodos Policy Gradient. Algoritmos Actor-critic. Integración de Learning and 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.



# PLANA DOCENTE



## Helder Rojas

PhD. en Matemáticas 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. Actualmente es investigador postdoctoral en el Departamento de Matemáticas del Imperial College London, UK. Además, es Docente del programa de Doctorado en Ciencias e Ingeniería Estadística (DCIES) y Coordinador del programa MCIES de la FIEECS-UNI.

**Línea de Investigación:** Análisis Estocástico, Física Matemática, Mecánica Estadística, Aprendizaje Profundo.




## Nils Murrugarra-Llerena

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. Actualmente es profesor asistente en el Departamento de Ciencias de la Computación en Weber State University, USA.

**Línea de Investigación:** Visión Computacional, Multi-model Learning, Transfer Learning, Aprendizaje por Refuerzo.





### **Renzo Gomez Diaz**

PhD. y MSc. en Ciencias de la Computación por el Instituto de Matemáticas y Estadística de la Universidad de Sao Paulo (IME-USP), Brasil. Actualmente es investigador postdoctoral en el Instituto de Computación de la Universidad Estatal de Campinas (UNICAMP), Brasil. Participó en maratones de programación en Perú; y en Brasil fue entrenador de equipos que clasificaron a la Final Mundial.

Línea de Investigación: Teoría de grafos estructurales y algorítmicos, Optimización combinatoria, Complejidad Computacional, Combinatoria poliédrica.



### **Erick Chacon Montalvan**

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.

Línea de Investigación: Modelado Espacio-temporal, Métodos Computacionales Intensivos, Estadística Bayesiana, Modelado Causal.



### **Rusbert Calderon Beltran**

PhD. en Matemática Aplicada por el Instituto de Matemática y Estadística de la Universidad de Sao 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.

Línea de Investigación: Teoría Ergódica, Sistemas Dinámicos Simbólicos, Formalismo Termodinámico.





---

### **Artem Logachov**

---

PhD. en Matemáticas por la Universidad Estatal de Novosibirsk, Rusia. Profesor Investigador en el departamento de Matemáticas Avanzadas de la Universidad Estatal de Geosistemas y Tecnologías de Siberia, Rusia. Además, también es profesor en el Laboratorio de Probabilidad y Estadística Matemática del Instituto Sobolev de Matemáticas, Rama Siberiana de la Academia Rusa de Ciencias.

Línea de Investigación: Probabilidad, Ecuaciones Diferenciales Estocásticas, Mecánica Estadística, Grandes Desviaciones.



---

### **Luis Huamanchumo**

---

PhD. en Ciencias de la Educación por la UNE, Perú. MSc en Ingeniería de Sistemas por la UNI, Perú. Además, es Licenciado en Estadística por la UNI y Economista por la Universidad del Pacifico. Actualmente es el Coordinador y Docente del programa de Doctorado en Ciencias e Ingeniería Estadística (DCIES) de la FIEECS-UNI.

Línea de Investigación: Análisis Estadístico Multivariado, Modelos Lineales, Diseño de Metodologías de Investigación, Educación Estadística.



---

### **Jaime Lincovil**

---

PhD. y MSc. en Estadística por el Instituto de Matemática y Estadística de la Universidad de Sao Paulo (IME-USP), Brasil. Fue investigador postdoctoral en el Departamento de Estadística de la Universidad Estatal de Campinas (UNICAMP). Actualmente es profesor adjunto del Departamento de Estadística de la Universidad de las Américas (UDLA), Bio-Bio, Chile. Además, es docente del programa de Doctorado en Ciencias e Ingeniería Estadística (DCIES) de la FIEECS-UNI.

Línea de Investigación: Econometría y Biométrica, Datos Funcionales y Datos de Alta Dimensionalidad, Análisis de bases de datos escalables en R y Python.

# INVERSIÓN

## PROCESO DE ADMISIÓN:

### PROSPECTO

S/ 250.00

### DERECHO DE ADMISIÓN

S/ 875.00

La evaluación de méritos comprende la entrevista personal/virtual y la evaluación del CV. La evaluación correspondiente a conocimientos se hará a través de la realización de un ensayo sobre las expectativas del postulante en relación a la maestría, y a su vez, alguna idea de investigación científica preconcebida. El postulante recibirá una guía para poder realizar el ensayo, el cual debe presentarse máximo el 15 de Abril de 2024.

## PREMAESTRÍA 2024-I (Inicio de clases 22 de enero)

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: **i) Cálculo Vectorial para Machine Learning. ii) Programación con Python. iii) Probabilidad y Distribuciones.** Para más detalles, consultar por el brochure de la Pre-Maestría 2024-I.

Pago al Contado:

S/ 1600.00

Duración: 7 semanas

Dos cuotas:

S/ 1700.00

S/ 850.00

S/ 850.00

hasta una semana antes de iniciar la PRE-MAESTRIA  
después de un mes de iniciar la PRE-MAESTRIA

**Pronto pago: 25% de descuento, hasta el 12 de enero 2024**

## PROCESO DE INGRESO:

### MATRÍCULA

S/ 656.00

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

### 48 CRÉDITOS DE ENSEÑANZA (4 CICLOS)

S/ 20,352.00

El total son veinticuatro mensualidades.

Pago al contado

### DESCUENTOS SOBRE EL MONTO DE CRÉDITOS

8%

Si paga adelantado todo el ciclo

16%

Si paga adelantado toda la maestría




# REQUISITOS

Deben ser enviados la siguiente documentación

- Curriculum vitae simple
- 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 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) o al número +51 913 045 828 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, la cual deberá ser llenada y remitida de manera virtual a [info.posgrado.fieecs@uni.edu.pe](mailto:info.posgrado.fieecs@uni.edu.pe).



# 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.

## INFORMES



+51 913 045 828  
<https://bitly/MIF-wspMe>



info.posgrado.fieecs@uni.edu.pe

