

**UNIVERSIDAD DE BUENOS AIRES**  
Facultad de Ciencias Económicas

Departamento de Economía

Asignatura: **BIG DATA Y MACHINE LEARNING**

Código: **527**

***Plan Vigente (\*)***

Cátedra: **DEPTO. ECONOMÍA**

Carrera: (\*) Lic. en Economía (RCS N° 1696/24)

**Aprobado por Res. Consejo Directivo (FCE)**

**Nro.: 4586/26**

En caso de contradicción entre las normas previstas en la publicación y las dictadas con carácter general por la Universidad o por la Facultad, prevalecerán éstas últimas.

## **1) ENCUADRE GENERAL**

### **a) Contenidos mínimos**

Motivación, Objetivos y Dinámica del curso. Introducción: Definiciones de Data mining, big data. Debate del Rol de Big Data. Aprendizaje supervisado y no supervisado. Análisis descriptivo: Visualización de datos. Histogramas, Kernels y distribuciones. Aplicaciones. Métodos No Supervisados: Componentes principales y la Maldición de la Dimensionalidad. Clusters. Regresión. Modelos lineales, linealizables y no lineales. Clasificación: Clasificador de Bayes. Regresión logística. Vecinos cercanos. Análisis discriminante. Aplicaciones. Análisis ROC. Comparación de métodos y regresión de Poisson. Métodos de Remuestreo. Problemas de Overfitting. Cross-validation. Bootstrap. Regularización y elección de modelos: Lasso, ridge. Elastic net. Comparación de métodos. Regularización e Inferencia Causal. Aplicaciones. Lasso, Ridge. Elastic net. Comparación de métodos. Modelos lineales que reducen la dimensionalidad: Regresión de Componentes principales (PCR) y Regresión parcial local (PLS). Modelos no lineales: Polinomios, Splines, Regresión Local por KNN & Kernels. CART: árboles de regresión y clasificación. Métodos de Ensamble I: Bagging, boosting. Random Forest. Casual Random Forest. Aplicaciones. Introducción a Economía de la Privacidad & Datos censurados. Análisis de Supervivencia: Función de supervivencia y riesgo. Método de proporcional de Cox.

### **b) Razones que justifican la inclusión de la asignatura dentro del plan de estudios. Su importancia en la formación profesional**

El mercado laboral que busca a los recién graduados de las universidades, se demanda y valora las habilidades analíticas, computacionales y comunicativas. Para ilustrar, una rápida búsqueda de empleos para economistas en cualquier sitio de ofertas de trabajo, mostrará que éstas son las habilidades más comunes en los puestos vacantes. Para aumentar la probabilidad de empleo de los alumnos de la Licenciatura en Economía, invertir en el desarrollo de dichas habilidades de los estudiantes mejorará significativamente las oportunidades laborales de los graduados.

El curso desarrolla habilidades técnicas, computacionales, y de pensamiento crítico que son las habilidades más de los graduados de Licenciatura en Economía. El estudiante será versátil para el uso de datos, ya sea con recopilación de datos primarios o el manejo de datos secundarios. Además, el curso lleva a los estudiantes de la Licenciatura en Economía a sintetizar ideas complejas de manera sencilla para el público en general.

El curso se basa en Python, un lenguaje de programación estadístico potente y de amplio uso. No requiere conocimiento previo, pero sí ganas de aprender y experimentar.

### **c) Ubicación de la asignatura en el currículum y requisitos para su estudio.**

Se ubica en el Ciclo Profesional Orientado de la Licenciatura en Economía, materia optativa. Tiene como requisito la probación de la asignatura Econometría I.

### **d) Objetivos del aprendizaje (Misión de la asignatura)**

El objetivo de este curso es presentar las herramientas estadísticas, matemáticas, y computacionales más utilizadas para hacer predicciones y clasificaciones confiables. El curso

presenta casos aplicados de cada herramienta en el ámbito investigación, políticas públicas y de negocios. Mediante el entendimiento teórico y práctico, los estudiantes desarrollan un pensamiento crítico de las ventajas y limitaciones de cada herramienta computacional y descubren distintas bases de datos disponibles. El curso desafía a los estudiantes a: (i) programar, manejar distintas bases de datos y crear sus propias bases, (ii) realizar dos presentaciones orales de una base de datos y aplicación vista en clase. En resumen, estos objetivos del curso apuntan a que el alumno desarrolle gran versatilidad para comprender, utilizar y presentar datos e ideas según la demanda en su futuro desarrollo profesional (sea académico o no académico).

- Programación en Python y manejo de repositorios colaborativos de GitHub
- Conocimiento de aplicaciones en investigación académica y no académica de los algoritmos visto en clases
- Manejo de distintas bases de datos y conocimiento en profundidad de la Encuesta Permanente de Hogares (INDEC).
- Habilidades de presentación y comunicación del uso de las herramientas vista en clases

## **2) PROGRAMA ANALITICO**

Tras una breve introducción a la materia, clarificando de terminología comúnmente usada en Big Data y Machine Learning, debates generales y una introducción a análisis descriptivo y buena visualización de datos; el curso se organiza en tres grandes partes. Primero, revisamos con los métodos no supervisados y no paramétricos que generalmente son usados en una etapa de análisis exploratorio y descriptivo de los datos. En la segunda parte, iniciamos con los métodos supervisados clásicos de regresión lineal, clasificación, problema de sobreajuste de la predicción y métodos de remuestreo. En la tercera parte, cubrimos métodos de regularización, modelos no lineales, algoritmo de árboles y revisamos los métodos basados en árboles para regresión y clasificación. En la última parte del curso, el nivel de dificultad y complejidad de los métodos empieza a aumentar.

### ***0. Introducción a Big Data En Economía y Visualización***

**Unidad 1:** Big Data, terminología y debate en Economía. Visualización de datos.

**Objetivo de aprendizaje:** En esta unidad, el objetivo es introducir al alumno en la terminología usada y aclarar sus diferencias.

#### **Temas a desarrollar:**

- Definiciones de Big Data, Machine Learning
- Discutir una buena visualización de la información de estadística descriptiva

**Unidad 2:** Introducción al programa Python y uso de repositorio de GitHub

**Objetivo de aprendizaje:** Descargar, abrir y empezar a familiarizarse con el lenguaje de programación en Python. Interiorizarse con el uso de repositorios de GitHub. Manejos de base de datos en Python.

#### **Temas a desarrollar:**

- Introducción a Python, descarga de Anaconda y Git

- Introducción al uso GitHub
- Carga y visualización de Bases de Datos en Python
- Librería de Pandas y Matplotlib para estadística descriptiva

### **Unidad 3:** Herramientas flexibles y prácticas para manejo de base de datos

**Objetivo de aprendizaje:** Introducir dos grandes herramientas de manejo de datos en Python: uso de APIs y WebScrapping.

**Temas a desarrollar:**

- Conceptos básicos sobre web: HTML, CSS y JavaScript
- WebScrapping de titulares de un diario
- Uso de APIs y ejemplos con Mercado Libre y Datos de Series de Tiempo de la República Argentina

#### ***I. Análisis exploratorio de Datos: Métodos supervisados y no paramétricos***

### **Unidad 4:** Métodos no supervisados I: Análisis de Componentes Principales (PCA)

**Objetivo de aprendizaje:** Entender el primer método no supervisado de análisis de componentes principales y distintas aplicaciones en economía.

**Temas a desarrollar:**

- Introducción a Métodos No Supervisados
- Análisis de componentes Principales
- Aplicación de PCA en Economía Urbana

### **Unidad 5:** Métodos no supervisados II: Clúster

**Objetivo de aprendizaje:** Entender el algoritmo de K-medias clúster, ventajas y desventajas del algoritmo jerárquico y discutir distintas aplicaciones en economía.

**Temas a desarrollar:**

- Algoritmo de Clúster K-medias y alternativas
- Clúster jerárquico y visualización en dendogramas
- Aplicación de Clúster en Macroeconomía y Economía de la Desigualdad

### **Unidad 6:** Métodos no paramétricos I: Histogramas

**Objetivo de aprendizaje:** Revisar el concepto de función de densidad no condicional de una variable aleatoria y el uso de herramientas no paramétricas en economía.

**Temas a desarrollar:**

- Revisión de conceptos de función de densidad y función de probabilidad acumulada de una variable aleatoria

- Definición de Histogramas y optimización del ancho de banda
- Aplicación de Histogramas en Economía Laboral

#### **Unidad 7:** Métodos no paramétricos II: Kernels

**Objetivo de aprendizaje:** Entender el método no paramétrico de kernels, y las ventajas y limitaciones de su uso en Economía.

**Temas a desarrollar:**

- Definición de Kernel, ancho de banda y sesgo del método no paramétrico
- Aplicación de Kernel en Economía Laboral

#### **II. Análisis de Predicción: Métodos Supervisados de Regresión y Clasificación. Problema de sobreajuste y técnicas de remuestreo**

#### **Unidad 8:** Métodos Supervisado: Regresión lineal

**Objetivo de aprendizaje:** Introducción a métodos supervisados, tipo de variable objetivo a predecir y naturaliza del problema de predicción en economía.

**Temas a desarrollar:**

- Introducción a Métodos Supervisados: Regresión vs. Clasificación
- Modelo de Regresión lineal
- Trade-off sesgo varianza
- Aplicación de regresión lineal en teoría del consumidor y comercio internacional

#### **Unidad 9:** Clasificación I: Logit & Vecinos Cercanos (KNN)

**Objetivo de aprendizaje:** Introducción al problema de clasificación con métodos tradicionales de regresión lineal y logística. Repaso del Métodos de Máxima Verosimilitud. Medidas de bondad de ajuste en clasificación y relación con problemas en economía.

**Temas a desarrollar:**

- Problema de regresión lineal con variable dependiente binaria
- Modelo de Regresión Logística
- Predicción semi-paramétrica con Vecinos Cercanos (KNN)
- Medidas de Precisión
- Aplicación en Migración y Economía del Crimen

#### **Unidad 10:** Clasificación II: Análisis Discriminante (LDA & QDA). Curvas ROC. Comparaciones

**Objetivo de aprendizaje:** En esta unidad se continua la discusión del problema de clasificación y trade-offs en la predicción de verdaderos y falsos positivos. Se destacan las ventajas y desventajas de otros métodos y comparan los resultados de clasificación de todos los métodos.

**Temas a desarrollar:**

- Análisis Discriminante Lineal (LDA) y Cuadrático (QDA)
- Ventajas y Desventajas de LDA
- Extensiones para variables categóricas
- Curvas ROC y resultados matemáticos
- Mención de Naive Bayes
- Varias aplicaciones en medición de Pobreza y Economía Agrícola

**Unidad 11: Método de Remuestreo: Validación Cruzada**

**Objetivo de aprendizaje:** En esta unidad se discute el problema de sobreajuste de los datos a la predicción dentro de la muestra y su solución con la creación de muestras de entrenamientos y testeo. Conceptualizamos e ilustramos el error de predicción afuera y dentro de la muestra. Ilustramos el uso del enfoque de validación cruzada con varias particiones.

**Temas a desarrollar:**

- Problema de sobreajuste de la predicción (Overfitting)
- Muestras de entrenamiento y testeo
- Técnica de Remuestreo de Validación Cruzada
- Enfoque de k-particiones de validación

**III. Análisis de Predicción I: Métodos más complejos de regularización, no lineales y basados en árboles****Unidad 12: Métodos de Regularización: LASSO, Ridge, Elastic Net**

**Objetivo de aprendizaje:** En esta unidad, se definen los modelos lineales de regularización y explican los dos métodos principales de LASSO y Ridge. Escenario de datos con ventajas y desventajas de estos dos grandes métodos y la comparación con Elastic Net

**Temas a desarrollar:**

- Repaso del problema de sobreajuste de la predicción (Overfitting)
- Modelos de regularización
- LASSO
- Ridge
- Ventajas (cuando  $n < p$ ) y desventajas con alta colinealidad
- Elastic Net y comparaciones

**Unidad 13: Modelos basados en métodos de reducción de la dimensionalidad: PCR & PLS**

**Objetivo de aprendizaje:** En esta unidad, se repasa el problema de la maldición de la dimensionalidad cuando estimamos modelos lineales de regresión. Definimos las ventajas y desventajas de regresión usando métodos de reducción de la dimensionalidad como Componentes Principales (PCA ya visto en la unidad 4) y Mínimos cuadrados parciales (PLS).

**Temas a desarrollar:**

- Repaso de la maldición de la dimensionalidad
- Regresión por Componentes Principales (PCR)
- Regresión de Mínimos Cuadrados Parciales (PLS)

**Unidad 14:** Modelos no lineales

**Objetivo de aprendizaje:** En esta unidad, se presenta una serie de modelos más flexibles no lineales, donde discutimos datos que favorecen o no la implementación y diversas aplicaciones de estas herramientas en economía.

**Temas a desarrollar:**

- Regresión Polinómica
- Regresión escalonada (step-function)
- Splines
- Regresión local por Kernels
- Aplicaciones en Economía de Género, Economía Política e Historia Económica

**Unidad 15:** Árboles de Regresión y Clasificación (CART)

**Objetivo de aprendizaje:** En esta unidad, se desarrolla en profundidad el algoritmo de particiones binarias recursivas, también conocido como CART.

**Temas a desarrollar:**

- Árboles de Regresión
- Árboles de clasificación
- Aplicación en Economía de la desigualdad

**Unidad 16:** Métodos de Ensamble basados en árboles

**Objetivo de aprendizaje:** En esta última unidad, vemos los algoritmos más sofisticados de gran poder predictivos, pero de poca interpretabilidad económica de “ensamble”.

**Temas a desarrollar:**

- Bagging
- Boosting (o AdaBoos) y Gradient Boosting
- Random Forest
- Discusión teórica en economía experimental, economía de la salud y economía del crimen

### 3) BIBLIOGRAFIA

#### a) BIBLIOGRAFÍA OBLIGATORIA

Los libros de referencia del curso son:

- James, G., Witten, D., Hastie, T., Tibshirani, R., & Taylor, J. (2023) *An introduction to statistical learning: With applications in Python*. Springer Nature. Descarga [gratis](#)
- Sosa Escudero, W. (2021) *Big data*, 7a edición, Siglo XXI Editores, Buenos Aires
- Sosa Escudero, W. (2024) *Viajar al futuro (y volver a contarlo)*, 1a edición, Siglo XXI Editores Argentina, Buenos Aires.

### Artículos Académicos obligatorios

#### b) BIBLIOGRAFIA AMPLIATORIA

Un libro recomendado (pero avanzado) para profundizar varias unidades vista en clase es:

- Friedman, J., Hastie, T., & Tibshirani, R. (2001) *The elements of statistical learning* (Vol. 1). Springer, Berlin: Springer series in statistics.

### Material de aplicaciones de las herramientas vistas en clases por unidad<sup>1</sup>

#### 1. Introducción a Big Data En Economía y Visualización

<b>Unidad 1:</b> Big Data, terminología y debate en Economía. Visualización de datos.
---

- Anderson, C. (2008). The end of theory. *Wired* magazine, 16(7), 16-07.
- Athey, S. (2017). Beyond prediction: Using big data for policy problems. *Science*, 355(6324), 483-485. <http://science.sciencemag.org/content/sci/355/6324/483.full.pdf>
- Lambert, K. J., & Fegley, T. (2023). Economic Calculation in Light of Advances in Big Data and Artificial Intelligence. *Journal of Economic Behavior and Organization*, 206, 243–250. <https://doi.org/10.1016/j.jebo.2022.12.009>
- Nickerson, D., & Rogers, T. (2014). Political Campaigns and Big Data, *Journal of Economic Perspectives*, vol. 28(2), pp. 51-74.
- Sosa Escudero, W. (2014). Big data: ¿otra vez arroz?, *Diario Clarin*, 6/4/2014.
- Sosa Escudero, W. (2016). Al infinito y más allá: Funes, Borges y big data, *Diario La Nacion*, 12/6/2016.
- Sosa Escudero, W., Anauati, V y Brau, W. (2022), Poverty and inequality studies with machine learning, en Matyas, L. y Chen, F., *Econometrics with Machine Learning*, Springer, New York
- Schwabish, J. A. (2014). An economist's guide to visualizing data. *Journal of Economic Perspectives*, 28(1), 209-234.

#### I. Análisis exploratorio de Datos: Métodos supervisados y no paramétricos

<b>Unidad 4:</b> Métodos no supervisados I: Análisis de Componentes Principales (PCA)
---

- Diamond, R. (2016). The determinants and welfare implications of US Workers' diverging location choices by skill: 1980-2000. *American Economic Review*, 106(3), 479–524.

---

<sup>1</sup> No todas las unidades tienen material de aplicaciones ya que algunas unidades son puramente técnicas y la lectura de material ampliatorio es la documentación del programa de Python.

Gasparini, L., Sosa-Escudero, W., Marchionni, M., & Olivieri, S. (2013). Multidimensional poverty in Latin America and the Caribbean: new evidence from the Gallup World Poll. *Journal of Economic Inequality*, 11, 195-214.

**Unidad 5:** Métodos no supervisados II: Clúster

Caruso, G., Sosa-Escudero, W., & Svarc, M. (2015). Deprivation and the dimensionality of welfare: a variable-selection cluster-analysis approach. *Review of Income and Wealth*, 61(4), 702-722.

Levy-Yeyati, E. & Struzenegger F. (2023) Exchange Rate Regimes 20 years later: The prevalence of floats. *RedNIE Working Paper Series N182*

Lusk, J. L. (2017). Consumer research with big data: applications from the food demand survey (FoodS). *American Journal of Agricultural Economics*, 99(2), 303-320.

**Unidad 6:** Métodos no paramétricos I: Histogramas

Cengiz, D., Dube, A., Lindner, A., & Zipperer, B. (2019). The effect of minimum wages on low-wage jobs. *Quarterly Journal of Economics*, 134(3), 1405-1454.

**Unidad 7:** Métodos no paramétricos II: Kernels

Jales, H. (2018). Estimating the effects of the minimum wage in a developing country: A density discontinuity design approach. *Journal of Applied Econometrics*, 33(1), 29-51.

John DiNardo, Nicole M. Fortin and Thomas Lemieux, 1996, "Labor Market Institutions and the Distribution of Wages, 1973-1992: A Semiparametric Approach," *Econometrica*, Volume 64, Number 5 (September), pp. 1001- 1044.

**II. Análisis de Predicción: Métodos Supervisados de Regresión y Clasificación. Problema de sobreajuste y técnicas de remuestreo**

**Unidad 8:** Métodos Supervisado: Regresión lineal

Brinatti, A., Cavallo, A., Cravino, J., & Drenik, A. (2021). The international price of remote work (No. w29437). *National Bureau of Economic Research*.

Cavallo, A. (2017) "Are Online and Offline Prices Similar? Evidence from Multi-Channel Retailers" *American Economic Review*. 107 (1). 283-303.

**Unidad 9:** Clasificación I: Logit & Vecinos Cercanos (KNN)

Mougenot, B., Amaya, E., Mezones-Holguin, E., Rodriguez-Morales, A. J., & Cabieses, B. (2021). Immigration, perceived discrimination and mental health: evidence from Venezuelan population living in Peru. *Globalization and health*, 17, 1-9.

Tollenaar, N., & van der Heijden, P. G. (2013). Which method predicts recidivism best?: a comparison of statistical, machine learning and data mining predictive models. *Journal of the Royal Statistical Society Series A: Statistics in Society*, 176(2), 565-584.

**Unidad 10:** Clasificación II: Análisis Discriminante (LDA & QDA). Curvas ROC. Comparaciones

Baylé, Federico (2016) "Detección de villas y asentamientos informales en el partido de La Matanza mediante teledetección y sistemas de información geográfica" *Tesis de Maestría*.

Blumenstock, J., Cadamuro, G., & On, R. (2015). Predicting poverty and wealth from mobile phone metadata. *Science*, 350(6264), 1073-1076.

Mullally, C., Rivas, M., & McArthur, T. (2021). Using Machine Learning to Estimate the Heterogeneous Effects of Livestock Transfers. *American Journal of Agricultural Economics*

**Unidad 12:** Métodos de Regularización: LASSO, Ridge, Elastic Net

Belloni, V. Chernozhukov, C. Hansen: "High-Dimensional Methods and Inference on Structural and Treatment Effects," *Journal of Economic Perspectives*, 28 (2), Spring 2014, 29-50.

Bajari, P., Nekipelov, D., Ryan, S. P., & Yang, M. (2015). Machine learning methods for demand estimation. *American Economic Review*, 105(5), 481-485.

Chernozhukov, V., Demirer, M., Duflo, E., & Fernandez-Val, I. (2018). Generic machine learning inference on heterogeneous treatment effects in randomized experiments, with an application to immunization in India (No. w24678). *National Bureau of Economic Research*.

Danton S. Char, Michael D. Abràmoff & Chris Feudtner (2020) Identifying Ethical Considerations for Machine Learning Healthcare Applications, *American Journal of Bioethics*, 20:11, 7-17,

Kleinberg, J., Ludwig, J., Mullainathan, S., & Obermeyer, Z. (2015). Prediction policy problems. *American Economic Review*, 105(5), 491-495.

Lusk, J. L. (2017). Consumer research with big data: applications from the food demand survey (FoodS). *American Journal of Agricultural Economics*, 99(2), 303-320.

Wüthrich, K., & Zhu, Y. (2023). Omitted variable bias of Lasso-based inference methods: A finite sample analysis. *Review of Economics and Statistics*, 105(4), 982-997.

Zou, H. y Hastie, T., 2005, Regularization and variable selection via the elastic net, *Journal of the Royal Statistical Society*, 67, 2, 301-320.

**Unidad 13:** Modelos basados en métodos de reducción de la dimensionalidad: PCR & PLS

Diamond, R. (2016). The determinants and welfare implications of US Workers' diverging location choices by skill: 1980-2000. *American Economic Review*, 106(3), 479-524.

**Unidad 14:** Modelos no lineales

Bertrand, M., Kamenica, E., & Pan, J. (2015). Gender identity and relative income within households. *Quarterly Journal of Economics*, 130(2), 571-614

Lee, D. S., Moretti, E., & Butler, M. J. (2004). Do voters affect or elect policies? Evidence from the US House. *Quarterly Journal of Economics*, 119(3), 807-859.

Nicolini, E. A. & Fuentes Mortensen, V. (2024) The evolution of population at the local level in Argentina, 1895-2010. Diminishing returns, agglomeration economies and congestion. *Unpublished*

#### Unidad 15: Árboles de Regresión y Clasificación (CART)

Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5-32.

Keely, L. C., & Tan, C. M. (2008). Understanding preferences for income redistribution. *Journal of Public Economics*, 92(5), 944-961.

Hothorn, T., & Zeileis, A. (2015). partykit: A modular toolkit for recursive partytioning in R. *Journal of Machine Learning Research*, 16(1), 3905-3909.

Varian, H. R. (2014). Big data: New tricks for econometrics. *The Journal of Economic Perspectives*, 28(2), 3-27.

#### Unidad 16: Métodos de Ensamble basados en árboles

List, J. A., Muir, I., & Sun, G. (2024). Using machine learning for efficient flexible regression adjustment in economic experiments. *Econometric Reviews*, 44(1), 2-40.

Riascos, A., & Serna, N. (2017, October). Predicting annual length-of-stay and its impact on health. *Medical Informatics and Healthcare* (pp. 27-34). PMLR.

Wager, S. and Athey, S., 2018. Estimation and Inference of Heterogeneous Treatment Effects Using Random Forests. *Journal of the American Statistical Association*, 113(523), pp.1228- 1242.

## 4) MÉTODOS DE CONDUCCIÓN DEL APRENDIZAJE

### a) **Objetivos generales a cumplir en los cursos de promoción**

El curso incentiva la colaboración en grupo de dos personas (a determinar en la primer semana de clase y según el número de alumnos inscriptos).

La aprobación del curso se basa en las siguientes actividades:

1. **Trabajos prácticos** (50% de la nota final): Los trabajos prácticos usan mayoritariamente la Encuesta Permanente de Hogares del INDEC, requieren programación (entregar código de resolución de las consignas) y un reporte que interprete los resultados y discuta las limitaciones. Es requisito entregar y aprobar todos los trabajos prácticos. Se deben entregar un total de cuatro (4) trabajos prácticos. La entrega de trabajos prácticos fuera de la fecha estipulada tiene la penalidad de 1,5 punto menos de la nota por cada día adicional de demora.
2. Dos (2) **presentaciones grupales breves** en dos instancias:
  - a. Instancia **Base de Datos** (20% de la nota): El grupo debe buscar una base de datos disponibles, contar sus características, limpieza de la base y las variables de interés. La presentación debe durar 10 minutos.

- b. Instancia **Aplicación Final** (30% de la nota): El grupo debe presentar la aplicación de una de las herramientas vista en clases usando la base de datos presentada en la instancia anterior.

En ambas instancias, cada grupo debe postear las diapositivas 24 horas antes de la presentación en el Foro académico del aula virtual designado a las presentaciones grupales. Cada minuto de demora en subir las slides resta 0,05 puntos en la nota de presentación.

Asistencia y plagio: Se requiere asistir como mínimo al 75% de las clases. Velaremos por las cuestiones éticas en lo que se refiere a plagio y otras inconductas éticas.

#### **b) Metodología del proceso enseñanza - aprendizaje**

Las clases tendrán dos componentes que varían por unidad: teórico y práctico. Dependiendo del tema, una clase puede ser solo práctica (como en las primeras unidades para introducir el programa de Python y uso de GitHub) o más teórica práctica (como las unidades de métodos no paramétricos). También, los estudiantes contarán con horas de consultas online para resolver problemas de programación, preguntas teóricas y dudas de las entregas de los trabajos prácticos.

#### **c) Dinámica del dictado de las clases**

El curso es de manera semipresencial incluye dos (2) clases de dos (2) horas cada una, los días:

En este curso, vamos a trabajar en aula virtual, para compartir el material relevante, hacer anuncios, recordatorios (fechas claves), y coordinar las entregas. Por lo que se recomienda estar atentos a los anuncios en el aula virtual.

### **5) MÉTODOS DE EVALUACION**

#### **a) Curso semipresencial**

Los alumnos serán evaluados, con los trabajos prácticos y dos exámenes parciales orales mencionados arriba (ver sección 4.a) –en días y horarios de clase- (Resolución CD 386/2006). Se destaca que solo serán examinados los alumnos regulares e inscriptos en cada curso.

De acuerdo con la normativa vigente, el alumno podrá recuperar un parcial cuya nota haya sido inferior a 4 (cuatro) puntos o en caso de ausencia. La instancia de recuperatorio también podrá ser utilizada para aquellos casos que tengan calificaciones iguales o superiores a 4 (cuatro) y menores a 7 (siete) y deseen elevar la nota para alcanzar la promoción.

La calificación obtenida en el examen recuperatorio reemplazará a la nota del parcial que se recupera.

Los alumnos que de acuerdo con la Resolución CD 455/2006:

1. hubieran aprobado todas las instancias de evaluación (nota presentaciones grupales de 4 o más puntos) y la nota final fuere siete (7) puntos o más de promedio, serán

promovidos automáticamente y su calificación será el promedio ponderado resultante de ellas (ver ponderaciones en la sección 4.a).

2. hubieran aprobado todas las instancias de evaluación (nota parcial 4 o más puntos) y la nota final fuere cuatro (4) puntos o más puntos de promedio, pero inferiores a siete (7) serán considerados “regulares” a los fines de rendir un examen final de la asignatura, cabe destacar al igual que en el punto anterior sean ellas obtenidas en forma directa o luego de haber aprobado la única prueba recuperatoria a que tienen derecho,
3. que hubieran obtenido, luego de todas las instancias de evaluación, notas finales inferiores a cuatro (4) puntos de promedio se les asignará la nota “insuficiente”.

Dado que solamente serán calificados los alumnos inscriptos en la lista del curso respectivo, que brinda la Facultad, aquellos alumnos que hayan asistido a las clases en carácter de oyentes o voluntarios no podrán presentarse a rendir los exámenes parciales respectivos, por cuanto la Facultad no labrará acta alguna en tales condiciones ni se admitirán cambios de curso o la rendición de exámenes parciales en otros cursos.

**b) Régimen de examen final**

El examen final integrador comprenderá temas teóricos y prácticos de la asignatura, debiendo el alumno aprobar ambos temarios, para que su calificación resulte promediada, con un puntaje que alcance por lo menos un 60% de los contenidos. Por consiguiente, los alumnos que obtengan una calificación inferior a 4 (cuatro) puntos serán considerados insuficientes y aquellos con una calificación igual o superior a 4 (cuatro) aprobarán la asignatura con dicha nota (Resolución CD 406/2006).

Las calificaciones deberán ser informadas a los alumnos dentro de los 15 días corridos siguientes a la fecha del examen final. En caso de no existir aula disponible, el acto de lectura y entrega de notas se realizará en Sala de Profesores (Resolución CD 374/2006)

**c) Criterio de confección del promedio de notas finales**

En los casos en que fuere necesario expresar en número entero el promedio de notas parciales o de estas y el examen parcial, se aplicará el número entero superior si la fracción fuere de 0.50 puntos o más y el número entero inferior si fuere de 0.49 o menos. Cuando la nota fuese de 3.01 a 3.99 se calificará con 3 (tres) puntos. (Resolución CS 4994/93)