

“CURSO DE R INTERMEDIO Y AVANZADO PARA CIENCIA DE DATOS”

Este curso está basado en conocer los fundamentos de la programación mediante el uso de la herramienta IDE Rstudio y lenguaje de programación R, que cuenta con diferentes bibliotecas con funcionalidades estadísticas y gráficas, que permite la programación orientada a Objetos, manejo básico en R, importación y conexión a base de datos, manipulación de los Datos, técnicas para el preprocesamiento, entendimiento, limpieza, transformación de los datos, técnicas para la visualización e identificación de datos inconsistentes y Outliers, balanceo y Discretización de datos, así como técnicas para la reducción de la dimensionalidad de los datos todo ello con un enfoque hacia la Ciencia de los Datos.

CONTENIDO:

1. ANÁLISIS EXPLORATORIO DE LOS DATOS (3H)
 - Gráfico de Densidad.
 - Diagramas de dispersión.
 - Boxplot.
 - Visualización 3D.
 - Ejercicio de aplicación
2. LIMPIEZA E IDENTIFICACIÓN DE VALORES FALTANTES (3H)
 - Identificación de datos faltantes.
 - Visualización de datos faltantes.
 - Imputación de datos faltantes.
 - Ejercicio de aplicación
3. IDENTIFICACIÓN Y TRATAMIENTO DE OUTLIERS (3H)
 - Identificación de Outliers.
 - Tratamiento de Outliers.
 - Ejercicio de aplicación
4. BALANCEO DE DATOS (3H)
 - Tratamiento de data no balanceada.
 - Balanceo de datos.
 - Estrategias de balanceo.
 - Ejercicio de aplicación
5. DISCRETIZACIÓN DE DATOS (3H)
 - Principales estrategias para reducir datos.
 - Discretización con intervalos de igual amplitud.
 - Discretización con intervalos de igual frecuencia.
 - Discretización k medias.
 - Método de Entropía.
 - Método CHIMerge
 - Ejercicio de aplicación
6. ANÁLISIS DE COMPONENTES PRINCIPALES. (3H)
 - Introducción al análisis de componentes principales.

- Prueba de esfericidad de Barlett.
 - Estimación de los componentes principales.
 - ¿Qué es el Análisis de Componentes Principales (PCA)?
 - ¿Por qué usar PCA?
 - Algoritmos de Dimensionalidad.
 - Varianza total y varianza explicada.
 - Interpretación de los componentes principales.
 - Ejercicio de aplicación
7. MÉTODOS DE PARTICIONAMIENTO (3H)
- Introducción a los métodos de particionamiento jerárquico.
 - ¿Qué es el análisis clúster?
 - ¿Qué no es el análisis clúster?
 - Medidas de Similaridad, distancia y proximidad.
 - Distancia Euclidiana.
 - Segmentación con Método K – medias.
 - Estableciendo el número óptimo de clúster.
 - Suma de cuadrados, silueta y Calinski y Harabasz.
8. TÉCNICAS NO SUPERVISADAS - ANÁLISIS CLÚSTER I (3H)
- Elaboración de la matriz de distancias (disimilaridad).
 - Método k-medias.
 - Identificación del número óptimo de clúster.
 - Perfilamiento del clúster.
9. TÉCNICAS NO SUPERVISADAS - ANÁLISIS CLÚSTER II (3H)
- Procesamiento de datos y aplicación de Método k-medias.
 - Caso de uso aplicación técnica Clustering,
 - Identificación del número óptimo de clúster.
 - Suma de cuadrados, silueta y Calinski y Harabasz.
10. TÉCNICAS PAM - CLARA - FANNY (3H)
- Métodos de particionamiento alrededor de Medoides (PAM).
 - Clustering in Large Applications (CLARA)
 - Fuzzy Analysis (FANNY)
 - Identificación del número óptimo de clúster.
 - Suma de cuadrados, silueta y Calinski y Harabasz.
11. MÉTODOS JERÁRQUICOS AGLOMERATIVO Y DIVISIVO (3H)
- Método jerárquico aglomerativo: AGNES.
 - Métodos jerárquico divisivos: DIANA.
 - Estableciendo el número óptimo de clúster.
 - Suma de cuadrados, silueta y Calinski y Harabasz.
 - Ejercicio de aplicación.
12. REGRESIÓN LINEAL SIMPLE (3H)
- Supuestos para el modelo de regresión lineal.
 - Modelo y estimación de coeficientes.
 - Indicadores MSE, RMSE, SSE, SST.

- Ejercicio de aplicación.

13. REGRESIÓN LOGÍSTICA (3H)

- Introducción a la regresión logística.
- Modelos y Técnicas de selección de variables.
- Evaluación Modelo haciendo uso de las métricas Matriz de Confusión, accuracy, sensibilidad, especificidad, AUC y curva ROC.
- Ejercicio de aplicación.

14. ANÁLISIS DISCRIMINANTE LINEAL (3H)

- Introducción al análisis discriminante lineal (LDA).
- Modelo y estimación de coeficientes.
- Técnica de selección de variables (Lambda de Wilks y tasa de acierto).
- Ejercicio de aplicación.

15. ANÁLISIS CUADRÁTICO Y REGULARIZADO (3H)

- Introducción al análisis discriminante Cuadrático (QDA).
- Introducción al análisis discriminante Regularizado (RDA).
- Modelo y estimación de coeficientes.
- Evaluación Modelo haciendo uso de las métricas de accuracy, sensibilidad, especificidad, AUC y curva ROC.
- Ejercicio de aplicación.

16. APRENDIZAJE BASADO EN ÁRBOLES DE DECISIÓN I (3H)

- Introducción a los árboles de decisión.
- Creación y lógica de los árboles de decisión.
- Árboles de decisión basado en el algoritmo CART.
- Medidas de impureza.

17. APRENDIZAJE BASADO EN ÁRBOLES DE DECISIÓN II (3H)

- Combinar arboles de Decisión mediante bosques aleatorios.
- Criterios de particiones, parada
- Poda de los árboles de decisión.
- Maximizar la ganancia en la información.
- Ejercicio de aplicación.

18. ÁRBOL DE CLASIFICACIÓN RANDOM FOREST (3H)

- Introducción del Algoritmo Random Forest.
- Características del Algoritmo Random Forest.
- Selección de variables en el Algoritmo Random Forest.
- Mediciones del Algoritmo Random Forest
- Ventajas y Desventajas del Algoritmo Random Forest

19. MÁQUINAS DE SOPORTE VECTORIAL (3H)

- Definición de Máquinas de Soporte vectorial (SVM).
- Casos no separables linealmente.
- Definición de hiperplanos, Kernel.
- Tipos de Kernel (Lineal, Radial, Polinómico)

- Ejercicio de aplicación

20. ENTRENAMIENTO Y EVALUACIÓN DE LOS MODELOS (3H)

- SVM con Kernel Lineal
- SVM con Kernel Radial
- SVM con Kernel Polinomial
- Comparando el entrenamiento en los modelos.
- Comparando el accuracy entre los modelos data training y data test
- Evaluación del modelo Optimo.

21. EVALUACIÓN DEL CURSO

REQUISITOS:

TENER CONOCIMIENTOS BÁSICOS DE R. TENER EN CUENTA QUE HAY 24 HORAS DE CLASE DE R BÁSICO COLGADO EN LA PAGINA WEB DEL COESPE LIMA.

INICIO:

14 DE OCTUBRE

HORARIO:

MARTES Y JUEVES DE 7:30 A 10:30PM.

DURACION:

60 HORAS

MODALIDAD:

VIRTUAL

COSTO:

GRATUITO PARA LOS MIEMBROS DEL COESPE DE TODAS LAS REGIONES.

CERTIFICADO:

SE OTORGARÁ 01 CERTIFICADO APROBATORIO CON QR A LOS QUE PASEN LA EVALUACION FINAL; 01 CERTIFICADO DE PARTICIPACION A LOS QUE NO PASEN LA EVALUACION PERO QUE COMPLETEN EL 50 % DE ASISTENCIA. PARA ELLO TENDRAN QUE CANCELAR EL MONTO DE S/ 50.00 SOLES POR ADELANTADO Y NO HAY DEVOLUCIOIN EN CASO ABANDONE EL CURSO

INSCRIPCION:

A TRAVES DEL LINK QUE SE ENCUENTRA EN LA PAGINA WEB DEL COESPE LIMA.