

Guía para ETS: Análisis de Series de Tiempo

Unidad I: Características de series de tiempo

1. Describir qué es una serie de tiempo y mencionar tres características que la diferencian de otros tipos de datos.
2. Explicar la diferencia entre series estacionarias y no estacionarias, y la importancia de esta distinción para el modelado estadístico.
3. Describir las condiciones de estacionariedad en sentido amplio (media, varianza y autocovarianza constantes).
4. Explicar qué es la autocorrelación y la autocorrelación parcial, y cómo se interpretan en el análisis de series.
5. Identificar y explicar la función de autocorrelación (ACF) y la función de autocorrelación parcial (PACF).
6. Describir la importancia y aplicación de la prueba de Ljung-Box para verificar autocorrelación en residuos.

Unidad II: Procesos lineales en tiempo discreto

1. Describir los modelos AR, MA, ARMA, ARIMA y SARIMA, incluyendo sus componentes y cuándo se aplican.
2. Explicar el propósito y método de diferenciación para hacer una serie estacionaria.
3. Describir el método de máxima verosimilitud para estimar parámetros y sus ventajas.
4. Explicar cómo se determina el orden de los componentes (p , d , q) y estacionales (P , D , Q) usando gráficos ACF y PACF.
5. Identificar qué añade un modelo ARMAX respecto a un ARIMA.
6. Interpretar métricas de rendimiento de modelos y proponer mejoras basadas en diagnóstico de residuos.

Unidad III: Análisis espectral y filtrado

1. Diferenciar periodicidad y comportamiento cíclico en series de tiempo con ejemplos.
2. Definir densidad espectral y explicar qué información proporciona sobre la serie.
3. Describir la transformada de Fourier y su relación con la densidad espectral.
4. Explicar las ventajas y limitaciones de métodos paramétricos y no paramétricos para estimación espectral.
5. Describir la coherencia espectral entre dos series y el significado de la fase del espectro cruzado.
6. Explicar el uso de filtros lineales y modelos de regresión con retraso para extracción de señales.

Segmento práctico: Flujo de Análisis en Python

Ejemplo:

```
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
from statsmodels.tsa.arima.model import ARIMA
from statsmodels.graphics.tsaplots import plot_acf, plot_pacf
from statsmodels.stats.diagnostic import acorr_ljungbox
from scipy.signal import periodogram

# Simulación de serie de tiempo con tendencia y estacionalidad
np.random.seed(123)
n = 200
t = np.arange(n)
seasonal = 10 * np.sin(2 * np.pi * t / 24) # Estacionalidad diaria (periodo 24)
trend = 0.05 * t
noise = np.random.normal(0, 2, size=n)
series = 20 + trend + seasonal + noise

# Convertir a DataFrame para manejo
df = pd.DataFrame({'value': series},
index=pd.date_range(start='2020-01-01', periods=n, freq='H'))

# Visualización de la serie
df['value'].plot(title='Serie de Tiempo Simulada', figsize=(10, 4))
plt.show()

# Visualización ACF y PACF
plot_acf(df['value'], lags=50, title='Función de Autocorrelación (ACF)')
plt.show()
plot_pacf(df['value'], lags=50, title='Función de Autocorrelación Parcial (PACF)')
plt.show()

# Diferenciación para hacer estacionaria
df['diff'] = df['value'].diff().dropna()

# Modelado ARIMA(p,d,q) con p=2, d=1, q=2 (ejemplo)
model = ARIMA(df['value'], order=(2,1,2))
model_fit = model.fit()
```

```

print(model_fit.summary())

# Diagnóstico de residuos
residuals = model_fit.resid
plt.figure(figsize=(10,4))
plt.plot(residuals)
plt.title('Residuos del Modelo ARIMA')
plt.show()

# Prueba de Ljung-Box para autocorrelación en residuos
lb_test = acorr_ljungbox(residuals, lags=[10], return_df=True)
print('Prueba Ljung-Box:', lb_test)

# Análisis espectral: periodograma
freqs, power = periodogram(df['value'].dropna(), fs=1)
plt.figure(figsize=(10,4))
plt.semilogy(freqs, power)
plt.title('Periodograma de la Serie')
plt.xlabel('Frecuencia')
plt.ylabel('Densidad espectral de potencia')
plt.show()

```

1. Identificación y explicación del tipo de análisis realizado en el código (dominio del tiempo vs dominio de frecuencia).
2. Explicar la función y utilidad de la transformada de Fourier en el análisis de series de tiempo.
3. Proponer y justificar un filtro lineal adecuado para eliminar componentes no deseados (tendencia, ruido, etc.) en la serie.
4. Interpretar resultados de análisis de series múltiples usando espectros cruzados y coherencia, incluyendo la detección de relaciones dinámicas entre variables.