

L U M B R E



Modelos ARIMA y suavizado

Grado: 7

Materia: Series de Tiempo · Análisis de Datos

11/10/2026

Antes de empezar

Para predecir sin complejidad hay dos familias clásicas y poderosas: el suavizado exponencial, que da más peso a lo reciente, y ARIMA, que modela autorrelación, integración y media móvil.

QUÉ APRENDERÁS

- Ajustar modelos de suavizado exponencial y ARIMA para producir pronósticos, eligiendo sus parámetros según las características de la serie.

Modelos ARIMA y suavizado

Tres piezas y un pronóstico

ARIMA resume tres ideas: mirar atrás (autorregresión), diferenciar para estabilizar, y promediar errores pasados (media móvil). Junto al suavizado exponencial, cubre gran parte del pronóstico clásico.

VIDEO

Pronósticos con Python: modelo ARIMA

Vídeo en español que ajusta un ARIMA paso a paso y proyecta su pronóstico.



Escanea para verlo en Lumbre

<https://www.youtube.com/watch?v=NWyQafgPKG4>

Suavizado exponencial

Predice como combinación ponderada de observaciones pasadas, dando más peso a las recientes. Es simple, rápido y sorprendentemente competitivo en muchas series.


Holt y Holt-Winters

- Holt añade a la media una componente de tendencia.
- Holt-Winters incorpora además la estacionalidad.

- Cada nivel de complejidad captura un patrón distinto de la serie.

El nombre ARIMA

AutoRegressive Integrated Moving Average: p rezagos autorregresivos, d diferenciaciones para estacionarizar y q rezagos de errores en media móvil. Tres números definen el modelo.



Un buen pronóstico se acompaña siempre de su intervalo de incertidumbre creciente.

El componente AR

La parte autorregresiva predice a partir de valores pasados de la propia serie. p cuántos rezagos entrar, y se elige leyendo el corte de la PACF.

La integración (d)

El grado d cuenta cuántas veces hay que diferenciar para lograr estacionariedad. Conecta con el diagnóstico previo de la serie.

La media móvil (q)

La parte de media móvil modela el error como función de choques anteriores. q cuántos rezagos del residuo mirar, y la ACF ayuda a fijarlo.

Elegir p, d y q

Se parte de las ACF/PACF y luego se compara candidatos con criterios como el AIC o errores de validación. La búsqueda en rejilla automatiza esa selección.

ARIMA estacional (SARIMA)

Cuando hay periodicidad, SARIMA repite la estructura con rezagos estacionales. Añade sus propios P, D, Q y el periodo, cubriendo series con calendario fuerte.

Pronosticar y validar

Se proyecta hacia delante y se contrasta contra un tramo reservado. Un ARIMA bien ajustado gana a uno complejo mal elegido; la parsimonia premia.

Cuándo no basta

ARIMA es lineal y univariante. Con muchos predictores, no linealidades o grandes volúmenes, conviene mirar modelos de estado espacial, Gradient Boosting o redes.

Errores frecuentes

- Elegir p y q «a ojo» favorecedor, sin comparar candidatos con AIC ni con validación fuera de muestra.
- Evaluar dentro de la muestra: un ARIMA que aprendió de memoria el pasado puede fallar estrepitosamente el futuro.
- Olvidar que ARIMA es lineal y univariante: con predictores externos relevantes se quedará corto.

Ejemplo resuelto: predecir la demanda de la próxima semana

Tienes tres años de demanda diaria y necesitas una previsión fiable para preparar stock:

1. Estacionarizas: diferencias si hace falta y fija d según las pruebas.
2. Lees ACF y PACF para proponer candidatos de p y q.
3. Ajustas varios ARIMA y los comparas con AIC y errores en un tramo reservado.
4. Verificas que los residuos se comportan como ruido blanco, sin autocorrelación.
5. Proyectas una semana con sus intervalos y refreas el modelo cuando llegan días nuevos.

¿Para qué sirve en la realidad?

La demanda de retail, la energía o el tráfico se pronostican con estas familias: rápidos, parsimoniosos y bien entendidos, suavizado y ARIMA siguen siendo la primera referencia que cualquier analista responsable debería batir.

1. En un modelo ARIMA(p, d, q), la componente «d» representa:

- ☐ el número de rezagos autorregresivos
- ☐ las veces que se diferencia la serie para estacionarizarla
- ☐ los rezagos de error en media móvil
- ☐ el periodo estacional

2. El método de Holt-Winters amplía el suavizado exponencial para captar tendencia y estacionalidad.

- ☐ Verdadero
- ☐ Falso

ACTIVIDAD INTERACTIVA DISPONIBLE EN LUMBRE

3. ARIMA



4. Ordena el ajuste de un ARIMA para pronóstico:

Elementos:

- diferenciar hasta lograr estacionariedad
- elegir p y q leyendo ACF y PACF
- ajustar coeficientes y comprobar residuales
- proyectar y medir el error en validación

Estacionarizar	. . .
Identificar	. . .
Estimar	. . .
Validar	. . .

ARIMA https://en.wikipedia.org/wiki/Autoregressive_integrated_moving_average Modelo autorregresivo integrado de media móvil.

5. Une cada pieza del ARIMA con su función.

5.	predice desde valores pasados de la propia serie	-----
5.	veces que se diferencia para estacionarizar	-----
5.	modela el error como función de choques anteriores	-----
5.	extensión con rezagos de periodicidad	-----

Opciones: autorregresivo p · integrado d · media móvil q · sarima

Tres piezas y un pronóstico

ARIMA y suavizado

Suavizado

peso en lo reciente

holt-winters

AR

rezagos p

corte en pacf

Integración

diferencias d

estacionarizar

MA

rezagos q

acf del error

El mapa mental interactivo es interactivo en la versión online.



Suavizado exponencial https://en.wikipedia.org/wiki/Exponential_smoothing La familia de pronósticos ponderados por cercanía, simple y competitiva.

6. Tu serie tiene una estacionalidad anual marcada. ¿Usarías un ARIMA plano o un SARIMA, y por qué? Razona por las componentes del modelo.

Referencia curricular

Grado:	7
Materia:	Series de Tiempo · Análisis de Datos

Versión interactiva completa (con actividades, videos y autoevaluación):



<https://univ.lumbre.lat/object/cdia-ser-003-modelos-arima-y-suavizado>

Material educativo generado desde Lumbre · lumbre.lat