

Прогнозирование временных рядов



Содержание

- Примеры задач
- Модель авторегрессии
- Модель скользящего среднего
- Модель ARMA
- ARIMA - интегрированная ARMA
- Подбор параметров модели.
Авторегрессионный спектр

Примеры задач


Динамика цен на нефть Brent (ICE.Brent, USD за баррель)




Динамика кросс-курса евро к доллару США (EUR/USD)




Тиковые данные



Потребление электроэнергии




Скорость движения автомобилей в разные дни недели с 15:00 до 21:00




Авторегрессионная модель

- Случайный процесс называется стационарным, если случайное распределение значений функции зависит только от предыдущих значений и расстояния по времени до них, но не от самих значений времени




$$X_t = c + \sum_{i=1}^p a_i X_{t-i} + \varepsilon_t,$$



Авторегрессионная модель


- Реализации стационарного случайного процесса могут быть периодическими
Пример: процесс $X(t)=\sin(t+s)$, где s – равномерно распределенная на $[0;2\pi]$ случайная величина
- $X(t) = X(t-2\pi)$



Авторегрессионный процесс первого порядка AR(1)

- Стационарный процесс – марковский, если значение зависит только от ближайшего предыдущего значения
- Пример: случайное блуждание

$$X_t = c + rX_{t-1} + \varepsilon_t$$



Поиск коэффициентов авторегрессии

- Метод наименьших квадратов:

$$\hat{y}_{t+1}(w) = \sum_{j=1}^n w_j y_{t-j+1},$$

$$F_{\ell \times n} = \begin{pmatrix} y_{t-1} & y_{t-2} & y_{t-3} & \dots & y_{t-n} \\ y_{t-2} & y_{t-3} & y_{t-4} & \dots & y_{t-n-1} \\ \dots & \dots & \dots & \dots & \dots \\ y_n & y_{n-1} & y_{n-2} & \dots & y_1 \\ y_{n-1} & y_{n-2} & y_{n-3} & \dots & y_0 \end{pmatrix}, \quad y_{\ell \times 1} = \begin{pmatrix} y_t \\ y_{t-1} \\ \dots \\ y_{n+1} \\ y_n \end{pmatrix}$$

$$Q_t(w, X^\ell) = \sum_{i=n}^t (\hat{y}_i(w) - y_i)^2 = \|Fw - y\|^2 \rightarrow \min_w$$

Единичный корень

- Характеристический полином модели:

$$y_t = \sum_{i=1}^p a_i y_{t-i} + \varepsilon_t \quad a(z) = 1 - \sum_{i=1}^p a_i z^i$$

- Если существует корень внутри единичной окружности, то модель – взрывная
- Если есть корни на единичной окружности, то наблюдается тренд и для устойчивого моделирования нужно или находить и вычитать тренд, или дифференцировать ряд

Тест Дики – Фуллера

- Является одним из тестов на единичные корни

$$y_t = \theta y_{t-1} + \varepsilon_t \quad \rightarrow \quad y_t - y_{t-1} = \theta y_{t-1} - y_{t-1} + \varepsilon_t$$



$$\Delta y_t = (\theta - 1)y_{t-1} + \varepsilon_t \quad \rightarrow \quad \Delta y_t = b y_{t-1} + \varepsilon_t$$

- Параметр b оценивается с помощью метода наименьших квадратов, после чего проверяется статистическая значимость оценки. Расчётная статистика имеет распределение Дики – Фуллера:

$$\hat{\tau} = \frac{\hat{b}}{se(\hat{b})} \sim DF_I$$


Модель скользящего среднего (Moving Average - MA)

$$X_t = \mu + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \cdots + \theta_q \varepsilon_{t-q}$$



Модель ARMA (autoregressive moving average)

$$X_t = c + \varepsilon_t + \sum_{i=1}^p \alpha_i X_{t-i} + \sum_{i=1}^q \beta_i \varepsilon_{t-i}.$$



ARIMA - интегрированная модель авторегрессии скользящего среднего (Box-Jenkins model)

Временной ряд называется интегрированным порядка k , если разности ряда порядка k являются стационарными

$$\triangle^d X_t = c + \sum_{i=1}^p a_i \triangle^d X_{t-i} + \sum_{j=1}^q b_j \varepsilon_{t-j} + \varepsilon_t$$

Y_t → AR filter → Integration filter → MA filter → ε_t
(long term) (stochastic trend) (short term) (white noise error)

$$\text{ARIMA (2,0,1) } y_t = a_1 y_{t-1} + a_2 y_{t-2} + b_1 \varepsilon_{t-1}$$



$$\text{ARIMA (3,0,1) } y_t = a_1 y_{t-1} + a_2 y_{t-2} + a_3 y_{t-3} + b_1 \varepsilon_{t-1}$$

ARIMA (1,1,0) $\Delta y_t = a_1 \Delta y_{t-1} + \varepsilon_t$, where $\Delta y_t = y_t - y_{t-1}$

ARIMA (2,1,0) $\Delta y_t = a_1 \Delta y_{t-1} + a_2 \Delta y_{t-2} + \varepsilon_t$ where $\Delta y_t = y_t - y_{t-1}$

ARIMA










Forecasts for AUTOSALE/CPI from November '91
ARIMA(1,0,0)x(0,1,0)12 with constant



Общий план решения задачи предсказания

- Подготовка данных – сведение к стационарному случайному процессу
- Определение типа модели
- Оценка параметров
- Предсказание

Модели с трендом и сезонным эффектом



а)


б)

в)

Моделирование с помощью ARIMA(p,d,q)

- Стационарность – определение правильного d , исключение сезонности
- Подбор p и q , используя ACF, PACF и unit root тесты
- Проверка – расчет оценки качества
- Оценка невязки – является ли она белым шумом?
- Предсказание

Авторы Бокс и Дженкинс предлагают схему:



Стационарность

- Процесс из разностей какого порядка является стационарным?
- Исключить сезонность, используя
 - сезонные добавки/множители к среднему значению за этот сезон
 - сезонную ARIMA(p,d,q) \times (P,D,Q) модель, например ARIMA(0,0,0) \times (0,1,0): $\hat{Y}_t = Y_{t-12} + \mu$


Автокорреляция (ACF)

- Корреляция между значениями процесса, с зафиксированным расстоянием по времени между ними
- Частичная автокорреляция (PACF) - “часть корреляции между Y_t и Y_{t-k} , которая не объясняется промежуточными корреляциями”. Коэффициент в AR-модели


Признаки AR модели

- Процесс стремится вернуться к некоторому среднему значению
- ACF убывает плавно, PACF - резко


Time Series Plot for AR



Estimated Autocorrelations for AR






Estimated Partial Autocorrelations for AR



Признаки МА модели


- Похожа на белый шум
- ACF убывает резко, PACF - постепенно



AR или MA

- Все зависит от порядка дифференцирования процесса
- Исходный процесс обычно похож на AR
- После вычисления нескольких разностей он превращается в MA-процесс
- Не нужно дифференцировать слишком много раз – это переобучение

Пример




Original series: nonstationary


1st difference: AR signature

2nd difference: MA signature

Пример ARIMA(1,1,0)



Пример ARIMA(0,2,1)




Подбор параметров модели

←Positive autocorrelation


No autocorrelation

Negative autocorrelation→


Time Series Plot for NONSTA




Time Series Plot for AR




Time Series Plot for NOISE




Time Series Plot for MA




Time Series Plot for OVERDIFF




Estimated Autocorrelations for NONSTA




Estimated Autocorrelations for AR




Estimated Autocorrelations for NOISE




Estimated Autocorrelations for MA



Estimated Autocorrelations for OVERDIFF



Estimated Partial Autocorrelation for NONSTA



add DIFF

add AR

add MA

remove DIFF

add DIFF


Nonstationary

Auto-Regressive

White Noise

Moving-Average Overdifferenced

Сезонная ARIMA-модель



Original series: nonstationary

Seas. diff: need AR(1) & SMA(1)

Both diff: need MA(1) & SMA(1)

Реализация на Python

- Siddharth Yadav. “Everything you can do with a time series”
- <https://www.kaggle.com/thebrownviking20/everything-you-can-do-with-a-time-series>

