


Прикладной статистический анализ данных. 9. Анализ временных рядов, часть первая.

Рябенко Евгений
riabenko.e@gmail.com

I/2016

Прогнозирование временного ряда

Временной ряд: y_1, \dots, y_t, \dots , $y_t \in \mathbb{R}$, — значения признака, измеренные через постоянные временные интервалы.



Задача прогнозирования — найти функцию f_T :

$$y_{T+d} \approx f_T(y_T, \dots, y_1, d) \equiv \hat{y}_{T+d|T},$$

где $d \in \{1, \dots, D\}$ — отсрочка прогноза, D — горизонт прогнозирования.

Предсказательный интервал



Пример: в апреле 1997 года в Гранд-Форкс, Северная Дакота, произошло наводнение. Город был защищён дамбой высотой в 51 фут; согласно прогнозу, высота весеннего паводка должна была составить 49 футов; истинная высота паводка оказалась равной 54 футам.

50000 жителей было эвакуировано, 75% зданий повреждено или уничтожено, ущерб составил несколько миллиардов долларов.



На исторических данных точность прогнозов метеорологической службы составляла ± 9 футов.

Регрессия

Простейшая идея: сделать регрессию на время.



Остатки не выглядят как шум:



Автокорреляционная функция (ACF)

Наблюдения временного ряда автокоррелированы.

Автокорреляция:

$$r_\tau = r_{y_t y_{t+\tau}} = \frac{\sum_{t=1}^{T-\tau} (y_t - \bar{y})(y_{t+\tau} - \bar{y})}{\sum_{t=1}^T (y_t - \bar{y})^2}, \quad \bar{y} = \frac{1}{T} \sum_{t=1}^T y_t.$$

$r_\tau \in [-1, 1]$, τ — лаг автокорреляции.

Проверка значимости отличия автокорреляции от нуля:

временной ряд: $Y^T = Y_1, \dots, Y_T$;

нулевая гипотеза: $H_0: r_\tau = 0$;



альтернатива: $H_1: r_\tau \neq 0$;

статистика: $T(Y^T) = \frac{r_\tau \sqrt{T-\tau-2}}{\sqrt{1-r_\tau^2}}$;

$T(Y^T) \sim St(T-\tau-2)$ при H_0 .

Автокорреляционная функция (ACF)

Коррелограмма:



Компоненты временных рядов





Тренд — плавное долгосрочное изменение уровня ряда.

Сезонность — циклические изменения уровня ряда с постоянным периодом.





Цикл — изменения уровня ряда с переменным периодом (цикл жизни товара, экономические волны, периоды солнечной активности).

Ошибка — непрогнозируемая случайная компонента ряда.

Компоненты временных рядов




Компоненты временных рядов




Компоненты временных рядов

STL-декомпозиция:





Снятие сезонности

Часто для удобства интерпретации ряда сезонная компонента вычитается:



Календарные эффекты

Иногда упростить структуру временного ряда можно за счёт учёта неравномерности отсчётов:




Стационарность

Ряд y_1, \dots, y_t **стационарен**, если $\forall s$ распределение y_t, \dots, y_{t+s} не зависит от t , т. е. его свойства не зависят от времени.

Ряды с трендом или сезонностью нестационарны.


Ряды с непериодическими циклами стационарны, поскольку нельзя предсказать заранее, где будут находиться максимумы и минимумы.

Стационарность




Стационарность

Нестационарны из-за сезонности:




Стационарность

Нестационарны из-за тренда:




Стационарность

Нестационарны из-за меняющейся дисперсии:



Стационарность



Стационарны:



Стабилизация дисперсии

Для рядов с монотонно меняющейся дисперсией можно использовать стабилизирующие преобразования.

Часто используют логарифмирование:





Преобразования Бокса-Кокса

Параметрическое семейство стабилизирующих дисперсию преобразований:

$$y'_t = \begin{cases} \ln y_t, & \lambda = 0, \\ (y_t^\lambda - 1) / \lambda, & \lambda \neq 0. \end{cases}$$

Параметр λ выбирается так, чтобы минимизировать дисперсию или максимизировать правдоподобие модели.



Преобразования Бокса-Кокса

После построения прогноза для трансформированного ряда его нужно преобразовать в прогноз исходного:

$$\hat{y}_t = \begin{cases} \exp(\hat{y}'_t), & \lambda = 0, \\ (\lambda\hat{y}'_t + 1)^{1/\lambda}, & \lambda \neq 0. \end{cases}$$

- Если некоторые $y_t \leq 0$, преобразования Бокса-Кокса невозможны (нужно прибавить к ряду константу).
- Часто оказывается, что преобразование вообще не нужно.
- Можно округлять значение λ , чтобы упростить интерпретацию.
- Как правило, стабилизирующее преобразование слабо влияет на прогноз и сильно — на предсказательный интервал.

Дифференцирование

Дифференцирование ряда — переход к попарным разностям его соседних значений:


$$\begin{aligned}y_1, \dots, y_T &\longrightarrow y'_2, \dots, y'_T, \\y'_t &= y_t - y_{t-1}.\end{aligned}$$

Дифференцированием можно стабилизировать среднее значение ряда и избавиться от тренда и сезонности.

Может применяться неоднократное дифференцирование; например, для второго порядка:

$$\begin{aligned}y_1, \dots, y_T &\longrightarrow y'_2, \dots, y'_T \longrightarrow y''_3, \dots, y''_T, \\y''_t &= y'_t - y'_{t-1} = y_t - 2y_{t-1} + y_{t-2}.\end{aligned}$$

Дифференцирование



Критерий KPSS: для исходного ряда $p < 0.01$, для ряда первых разностей — $p > 0.1$.

Сезонное дифференцирование


Сезонное дифференцирование ряда — переход к попарным разностям его значений в соседних сезонах:

$$y_1, \dots, y_T \longrightarrow y'_{s+1}, \dots, y'_T,$$

$$y'_t = y_t - y_{t-s}.$$

Сезонное дифференцирование

Antidiabetic drug sales



Критерий

для

KPSS:

исходного

ряда $p < 0.01$, для

логарифмированного —

 $p < 0.01$, после сезонного

дифференцирования —


 $p > 0.1$.

Комбинированное дифференцирование

Сезонное и обычное дифференцирование может применяться к одному ряду в любом порядке.

Если ряд имеет выраженный сезонный профиль, рекомендуется начинать с сезонного дифференцирования — после него ряд уже может оказаться стационарным.

Комбинированное дифференцирование



Критерий KPSS

KPSS: для исходного ряда $p < 0.01$, для логарифмированного — $p < 0.01$, после сезонного дифференцирования — $p = 0.0355$,
после ещё одного дифференцирования — $p > 0.1$.

Остатки

Остатки — разность между фактом и прогнозом:

$$\hat{\varepsilon}_t = y_t - \hat{y}_t.$$

Прогнозы \hat{y}_t могут быть построены с фиксированной отсрочкой:



$$\hat{y}_{R+d|R}, \dots, \hat{y}_{T|T-d},$$

или с фиксированным концом истории при разных отсрочках:

$$\hat{y}_{T-D+1|T-D}, \dots, \hat{y}_{T|T-D}.$$



Необходимые свойства остатков прогноза

- Несмешённость — равенство среднего значения нулю:






Необходимые свойства остатков прогноза

- Стационарность — отсутствие зависимости от времени:




Необходимые свойства остатков прогноза

- Неавтокоррелированность — отсутствие неучтённой зависимости от предыдущих наблюдений:





Желательные свойства остатков прогноза

- Нормальность:



Желательные свойства остатков прогноза

- Гомоскедастичность — однородность дисперсии:



Проверка свойств остатков

- Несмешённость — критерий Стьюдента или Уилкоксона.
 - Стационарность — визуальный анализ, критерий KPSS.
 - Неавтокоррелированность — коррелограмма, Q-критерий Льюнга-Бокса.
-
- Нормальность — q-q plot, критерий Шапиро-Уилка.
 - Гомоскедастичность — визуальный анализ, критерий Бройша-Пагана (при регрессии квадратов остатков на время).

Критерий KPSS (Kwiatkowski-Philips-Schmidt-Shin)

- ряд ошибок прогноза: $\varepsilon^T = \varepsilon_1, \dots, \varepsilon_T$;
- нулевая гипотеза: H_0 : ряд ε^T стационарен;
- альтернатива: H_1 : ряд ε^T описывается моделью
вида $\varepsilon_t = \alpha \varepsilon_{t-1}$;
- статистика: $KPSS(\varepsilon^T) = \frac{1}{T^2} \sum_{i=1}^T \left(\sum_{t=1}^i \varepsilon_t \right)^2 / \lambda^2$;
 $KPSS(\varepsilon^T)$ при H_0 имеет табличное распределение.

Другие критерии для проверки стационарности: Дики-Фуллера, Филлипса-Перрона и их многочисленные модификации (см. Patterson K. *Unit root tests in time series, volume 1: key concepts and problems*. — Palgrave Macmillan, 2011).

Q-критерий Льюнга-Бокса

ряд ошибок прогноза: $\varepsilon^T = \varepsilon_1, \dots, \varepsilon_T$;


нулевая гипотеза: $H_0: r_1 = \dots = r_L = 0$;

альтернатива: $H_1: H_0$ неверна;

статистика: $Q(\varepsilon^T) = T(T+2) \sum_{\tau=1}^L \frac{r_\tau^2}{T-\tau}$;

$Q(\varepsilon^T) \sim \chi_{L-K}^2$ при H_0 ,

K — число настраиваемых параметров модели ряда.



Авторегрессия

$$AR(p): \quad y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \cdots + \phi_p y_{t-p} + \varepsilon_t,$$

где y_t — стационарный ряд с нулевым средним, ϕ_1, \dots, ϕ_p — константы ($\phi_p \neq 0$), ε_t — гауссов белый шум с нулевым средним и постоянной дисперсией σ_ε^2 .

Если среднее равно μ , модель принимает вид

$$y_t = \alpha + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \cdots + \phi_p y_{t-p} + \varepsilon_t,$$

где $\alpha = \mu (1 - \phi_1 - \cdots - \phi_p)$.

Другой способ записи:

$$\phi(B) y_t = (1 - \phi_1 B - \phi_2 B^2 - \cdots - \phi_p B^p) y_t = \varepsilon_t,$$

где B — разностный оператор ($B y_t = y_{t-1}$).

Линейная комбинация p подряд идущих членов ряда даёт белый шум.

Авторегрессия

Чтобы ряд AR(p) был стационарным, должны выполняться ограничения на коэффициенты. Например,

- в AR(1) необходимо $-1 < \phi_1 < 1$;
- в AR(2) необходимо $-1 < \phi_2 < 1, \phi_1 + \phi_2 < 1, \phi_2 - \phi_1 < 1$.

С ростом p вид ограничений усложняется.

Скользящее среднее

$$MA(q): \quad y_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \cdots + \theta_q \varepsilon_{t-q},$$

где y_t — стационарный ряд с нулевым средним, $\theta_1, \dots, \theta_q$ — константы ($\theta_q \neq 0$), ε_t — гауссов белый шум с нулевым средним и постоянной дисперсией σ_ε^2 .

Если среднее равно μ , модель принимает вид

$$y_t = \mu + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \cdots + \theta_q \varepsilon_{t-q}.$$

Другой способ записи:

$$y_t = \theta(B) \varepsilon_t = (1 + \theta_1 B + \theta_2 B^2 + \cdots + \theta_q B^q) \varepsilon_t,$$

где B — разностный оператор.

Линейная комбинация q подряд идущих компонент белого шума ε_t даёт элемент ряда.

Скользящее среднее

Чтобы ряд модель MA(q) была обратимой, должны выполняться ограничения на коэффициенты. Например,

- в MA(1) необходимо $-1 < \theta_1 < 1$;
- в MA(2) необходимо $-1 < \theta_2 < 1$, $\theta_1 + \theta_2 > -1$, $\theta_1 - \theta_2 < 1$.

С ростом q вид ограничений усложняется.

ARMA (Autoregressive moving average)

$$ARMA(p, q): \quad y_t = \phi_1 y_{t-1} + \cdots + \phi_p y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \cdots + \theta_q \varepsilon_{t-q},$$

где y_t — стационарный ряд с нулевым средним, $\phi_1, \dots, \phi_p, \theta_1, \dots, \theta_q$ — константы ($\phi_p \neq 0, \theta_q \neq 0$), ε_t — гауссов белый шум с нулевым средним и постоянной дисперсией σ_ε^2 .

Если среднее равно μ , модель принимает вид

$$y_t = \alpha + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \cdots + \phi_p y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \cdots + \theta_q \varepsilon_{t-q},$$

где $\alpha = \mu (1 - \phi_1 - \cdots - \phi_p)$.

Другой способ записи:

$$\phi(B) y_t = \theta(B) \varepsilon_t.$$

Согласно теореме Вольда, любой стационарный ряд может быть аппроксимирован моделью ARMA(p, q) с любой точностью.

ARIMA (Autoregressive integrated moving average)

Ряд описывается моделью $ARIMA(p, d, q)$, если ряд его разностей

$$\nabla^d y_t = (1 - B)^d y_t$$

описывается моделью $ARMA(p, q)$.

$$\phi(B) \nabla^d y_t = \theta(B) \varepsilon_t.$$

Seasonal multiplicative ARMA/ARIMA

$$ARMA(p, q) \times (P, Q)_s : \Phi_P(B^s) \phi(B) y_t = \alpha + \Theta_Q(B^s) \theta(B) \varepsilon_t,$$

где

$$\begin{aligned}\Phi_P(B^s) &= 1 - \Phi_1 B^s - \Phi_2 B^{2s} - \cdots - \Phi_P B^{Ps}, \\ \Theta_Q(B^s) &= 1 + \Theta_1 B^s + \Theta_2 B^{2s} + \cdots + \Theta_Q B^{Qs}.\end{aligned}$$

SARIMA:

$$\Phi_P(B^s) \phi(B) \nabla_s^D \nabla^d y_t = \alpha + \Theta_Q(B^s) \theta(B) \varepsilon_t.$$

Частичная автокорреляционная функция (PACF)

Частичная автокорреляция стационарного ряда y_t :

$$\phi_{hh} = \begin{cases} r(y_{t+1}, y_t), & h = 1, \\ r(y_{t+h} - y_{t+h}^{h-1}, y_t - y_t^{h-1}), & h \geq 2, \end{cases}$$

где y_t^{h-1} — регрессия y_t на $y_{t+1}, y_{t+2}, \dots, y_{t+h-1}$:

$$y_t^{h-1} = \beta_1 y_{t+1} + \beta_2 y_{t+2} + \cdots + \beta_{h-1} y_{t+h-1},$$

$$y_{t+h}^{h-1} = \beta_1 y_{t+h-1} + \beta_2 y_{t+h-2} + \cdots + \beta_{h-1} y_{t+1}.$$

Оценка параметров модели

- При заданных p, d, q коэффициенты модели оцениваются методом максимального правдоподобия; функционал качества — логарифм правдоподобия L .
- d выбирается так, чтобы ряд был стационарным.
- p и q нельзя выбирать из принципа максимума правдоподобия: L всегда увеличивается с ростом p и q .
- При выборе p и q могут помочь автокорреляционные функции ACF и PACF:
 - в модели $ARIMA(p, d, 0)$ ACF экспоненциально затухает или имеет синусоидальный вид, а PACF значимо отличается от нуля при лаге p ;
 - в модели $ARIMA(0, d, q)$ PACF экспоненциально затухает или имеет синусоидальный вид, а ACF значимо отличается от нуля при лаге q .

Информационные критерии

AIC:

$$AIC = -2L + 2(p + q + k + 1),$$

где $k = 1$ при $c \neq 0$ и $k = 0$ при $c = 0$;

AICc:

$$AICc = -2L + \frac{2(p + q + k + 1)(p + q + k + 2)}{T - p - q - k - 2};$$

BIC (SIC):

$$BIC = -2L + (\log T - 2)(p + q + k + 1).$$

Прогнозирование с помощью ARIMA

- ❶ Строится график ряда, идентифицируются необычные значения.
- ❷ При необходимости делается стабилизирующее дисперсию преобразование.
- ❸ Если ряд нестационарен, подбирается порядок дифференцирования.
- ❹ Анализируются ACF/PACF, чтобы понять, можно ли использовать модели AR(p)/MA(q).
- ❺ Обучаются модели-кандидаты, сравнивается их AIC/AICc.
- ❻ Остатки полученной модели исследуются на несмешённость, стационарность и неавтокоррелированность; если предположения не выполняются, исследуются модификации модели.
- ❼ В финальной модели t заменяется на $T + h$, будущие наблюдения — на их прогнозы, будущие ошибки — на нули, прошлые ошибки — на остатки.

Построение предсказательного интервала

Если остатки модели нормальны и гомоскедастичны, предсказательные интервалы определяются теоретически.

Например, для прогноза на следующую точку предсказательный интервал — $\hat{y}_{T+1|T} \pm 1.96\hat{\sigma}_\varepsilon$.

Если нормальность или гомоскедастичность не выполняется, предсказательные интервалы генерируются с помощью симуляции.


auto.arima

```
auto.arima(x, d=NA, D=NA, max.p=5, max.q=5,
           max.P=2, max.Q=2, max.order=5, max.d=2, max.D=1,
           start.p=2, start.q=2, start.P=1, start.Q=1,
           stationary=FALSE, seasonal=TRUE,
           ic=c("aicc", "aic", "bic"), stepwise=TRUE, trace=FALSE,
           approximation=(length(x)>100 | frequency(x)>12), xreg=NULL,
           test=c("kpss", "adf", "pp"), seasonal.test=c("ocsb", "ch"),
           allowdrift=TRUE, lambda=NULL, parallel=FALSE, num.cores=2)
```


Построить прогноз можно с помощью функции forecast:

```
forecast(object, h=ifelse(frequency(object)>1, 2*frequency(object), 10),
          level=c(80, 95), fan=FALSE, robust=FALSE, lambda=NULL,
          find.frequency=FALSE, allow.multiplicative.trend=FALSE, ...)
```

auto.arima



Потребление электричества в Турции



- недельная сезонность;
- годовая сезонность;
- праздники по исламскому календарю (год примерно на 11 дней короче, чем в грегорианском).

regARIMA

Эффекты плавающих праздников, краткосрочных маркетинговых акций и других нерегулярно повторяющихся событий удобно моделировать с помощью regARIMA:

$$\Phi_P(B^s) \phi(B) \nabla_s^D \nabla^d z_t = \Theta_Q(B^s) \theta(B) \varepsilon_t$$

+

$$y_t = \sum_{j=1}^k \beta_j x_{jt} + z_t$$

=

$$\Phi_P(B^s) \phi(B) \nabla_s^D \nabla^d \left(y_t - \sum_{j=1}^k \beta_j x_{jt} \right) = \Theta_Q(B^s) \theta(B) \varepsilon_t.$$

Оценка параметров модели

- ❶ Проверить стационарность признаков, если её нет, перейти к разностям. Для лучшей интерпретируемости разностный оператор следует применять и к признакам тоже.
- ❷ Для ряда разностей строится регрессия в предположении, что ошибки описываются моделью начального приближения (как правило, $AR(2)$ или $SARMA(2, 0, 0) \times (1, 0)_s$).
- ❸ Для остатков регрессии \hat{z}_t подбирается подходящая модель $ARMA(p_1, q_1)$.
- ❹ Регрессия перестраивается в предположении, что ошибки описываются моделью $ARMA(p_1, q_1)$.
- ❺ Анализируются остатки $\hat{\varepsilon}_t$.

Для подзадачи регрессии формальная проверка значимости признаков неприменима, для отбора признаков необходимо сравнивать значения AIC моделей со всеми подмножествами x_j .

Пример: <https://www.otexts.org/fpp/9/1>

Реализация: параметр `xreg` в функциях `auto.arima` и `Arima`.

Примеры

Средняя номинальная заработная плата в России:

<https://yadi.sk/d/pREaRfZrqPMw3>

Пример для самостоятельной работы:

<https://datamarket.com/data/list/?q=provider:tsdl>

Литература

Hyndman R.J., Athanasopoulos G. *Forecasting: principles and practice.* — OTexts, <https://www.otexts.org/book/fpp>