

Прикладная статистика 13. Анализ временных рядов.

6 декабря 2013 г.

Меры качества точечного прогноза

Mean squared error:

$$MSE = \frac{1}{D} \sum_{d=1}^D (\hat{y}_{T+d|T} - y_{T+d})^2.$$

Mean absolute percentage error:

$$MAPE = \frac{100}{D} \sum_{d=1}^D \left| \frac{\hat{y}_{T+d|T} - y_{T+d}}{y_{T+d}} \right|.$$

Mean absolute scaled error:

$$MASE = \frac{1}{D} \sum_{d=1}^D |\hat{y}_{T+d|T} - y_{T+d}| \bigg/ \frac{1}{T-1} \sum_{t=2}^T |y_t - y_{t-1}|.$$

Информационные критерии

AIC — информационный критерий Акаике:

$$AIC = \log \left(\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2 \right) + \frac{T + 2k}{T},$$

где k — число параметров модели;

$AICc$ — он же с поправкой на случай небольшого размера выборки:

$$AICc = \log \left(\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2 \right) + \frac{n + k}{T - k - 2};$$

BIC (SIC) — байесовский (Шварца) информационный критерий:

$$BIC = \log \left(\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2 \right) + \frac{k \log T}{T}.$$

Относительное качество прогноза

U-коэффициент Тейла оценивает качество прогноза относительно прогноза последним значением:

$$U(d) = \sqrt{\frac{\sum_{t=R}^{T-d} (\hat{y}_{t+d|t} - y_{t+d})^2}{\sum_{t=R}^{T-d} (y_t - y_{t+d})^2}}, \quad d = 1, \dots, D.$$

Если $U(d) = 1$, то прогноз $\hat{y}_{t+d|t}$ так же хорош, как «наивный прогноз» последним значением; если $U(d) < 1$, прогноз $\hat{y}_{t+d|t}$ лучше наивного, $U(d) > 1$ — хуже.

Сравнение качества двух прогнозов

y_1, \dots, y_T — временной ряд,

$\hat{y}_{1R}, \dots, \hat{y}_{1T}$ — прогноз на период R, \dots, T первым методом,

$\hat{\epsilon}_{1R}, \dots, \hat{\epsilon}_{1T}$ — остатки первого прогноза,

$\hat{y}_{2R}, \dots, \hat{y}_{2T}$ — прогноз на период R, \dots, T вторым методом,

$\hat{\epsilon}_{2R}, \dots, \hat{\epsilon}_{2T}$ — остатки второго прогноза;

$g(y_t, \hat{y}_{it})$ — произвольная функция потерь,

$$d_t = g(y_t, \hat{y}_{1t}) - g(y_t, \hat{y}_{2t}).$$

H_0 : среднее $d_t = 0$,

H_1 : среднее $d_t < \neq > 0$.

Непараметрические критерии

$$H_0: \text{med } d_t = 0,$$

$$H_1: \text{med } d_t < \neq > 0.$$

Критерий знаков:

$$T = \sum_{t=R}^T [d_t > 0].$$

Критерий знаковых рангов Уилкоксона:

$$W = \sum_{t=R}^T r(|d_t|) \text{sign}(d_t).$$

Критерий Диболда-Мариано

Будем для простоты считать, что $R = 1$.

Пусть d_1, \dots, d_T — выборочная траектория слабо стационарного случайного процесса, тогда

$$\sqrt{T} (\bar{d} - \mu) \xrightarrow{d} N(0, f),$$

где $\bar{d} = \frac{1}{T} \sum_{t=1}^T d_t$, μ — неизвестное среднее значение процесса, f — его дисперсия.


Критерий Диболда-Мариано

нулевая гипотеза: $H_0: \mathbb{E}d_t = 0;$

альтернатива: $H_1: \mathbb{E}d_t <\neq> 0;$

статистика: $B = \frac{\bar{d}}{\sqrt{\hat{f}/T}}, \hat{f} = \sum_{\tau=-M}^M \hat{r}_\tau, M = T^{1/3};$

$B \sim N(0, 1)$ при $H_0;$



достигаемый уровень значимости:

$$p(b) = \begin{cases} 1 - \text{ncdf}(b, 0, 1), & H_1: \mathbb{E}d_t > 0, \\ \text{ncdf}(b, 0, 1), & H_1: \mathbb{E}d_t < 0, \\ 2(1 - \text{ncdf}(|b|, 0, 1)), & H_1: \mathbb{E}d_t \neq 0. \end{cases}$$

Критерий Диболда-Мариано

Модификация для коротких рядов (Harvey, Leybourne, Newbold):

$$B^* = \frac{B}{\sqrt{\frac{T+1-2d+\frac{d(d-1)}{T}}{T}}},$$

где d — отсрочка прогноза.

Сравнение качества нескольких прогнозов

Пусть имеется эталонный прогноз ряда (например, «наивным» методом) и k других прогнозов,

$$\hat{y}_{t+d} = \{\hat{y}_{j,t+d}\}_{j=0}^k.$$

Как проверить, что хотя бы один прогноз лучше эталонного?

Пусть f — мера качества прогноза относительно эталона, такая, что $f > 0$, когда качество эталона ниже, и $f < 0$, когда качество эталона выше. Пример:

$$f = LL(\hat{y}_{j,t+1}) - LL(\hat{y}_{0,t+1})$$

(можно добавить ещё штраф за число параметров алгоритма).

$\hat{f}_{t+d} = f(Z_{t+d}, \hat{y}_{t+d}, \hat{\beta}_t) \in \mathbb{R}^k$ — вектор оценок качества прогноза, Z_{t+d} содержит значения y_{t+d} и дополнительные предикторы x_{t+d} , $\hat{\beta}_t$ — вектор оценок параметров всех прогнозирующих алгоритмов.

Критерий reality check Уайта

нулевая гипотеза: $H_0: \max_{j=1, \dots, k} \mathbb{E}f_j^* \leq 0,$
 $\mathbb{E}f_j^* = \mathbb{E}f(Z_{t+d}, \hat{y}_{t+d}, \beta^*), \beta^* = \text{plim } \hat{\beta}_t,$
 альтернатива: $H_1: H_0$ неверна.

При выполнении ряда теоретических предположений

$$\sqrt{n} (\bar{f} - \mathbb{E}f^*) \xrightarrow{d} N(0, \Omega),$$

$$\bar{f} = \frac{1}{n} \sum_{t=R}^{T-d} \hat{f}_{t+d} \text{ — среднее относительное качество прогнозов,}$$

$$n = T - d - R + 1.$$

Для оценки Ω и вычисления достигаемого уровня значимости используется бутстреп или Монте-Карло.

Критерий reality check Уайта

Пример (Sullivan, Timmermann, White, 1999, 2001): к ряду промышленного индекса Доу-Джонса с 1 января 1897 по 30 июня 1998 (27447 отсчётов) было применено большое количество моделей — 7846 моделей технического анализа и 9452 календарных. В качестве эталона рассматривалась стратегия долгосрочного инвестирования. Критерий качества — средний ожидаемый доход по всем инвестициям.

Критерий Уайта показал, что лучший метод технического анализа выигрывает у эталона, в то время как лучший календарный метод, по всей видимости, переобучен — он существенно лучше эталона по критерию Диболда-Мариано, но не лучше по критерию Уайта.

Модификация Романо-Вольфа

Построив на основе критерия Уайта нисходящую процедуру, можно найти все методы, дающие прогноз лучше эталона, асимптотически контролируя при этом FWER — групповую вероятность ошибки (Romano, Wolf, 2005).

Причинность по Грейнджеру

Между рядами x_1, \dots, x_T и y_1, \dots, y_T существует **причинная связь Грейнджера** $x_t \rightarrow y_t$, если дисперсия ошибки оптимального прогноза \hat{y}_{t+1} по $y_1, \dots, y_t, x_1, \dots, x_t$ меньше, чем только по y_1, \dots, y_t .

Причинность по Грейнджеру является необходимым, но не достаточным условием причинно-следственной связи.

x_1, \dots, x_T и y_1, \dots, y_T **взаимосвязаны**, если $x_t \rightarrow y_t$ и $y_t \rightarrow x_t$.

Критерий Грейнджера

$$y_t = \alpha + \sum_{i=1}^{k_1} \phi_{1i} y_{t-i} + \sum_{i=1}^{k_2} \phi_{2i} x_{t-i} + \varepsilon_t.$$


k_1 и k_2 выбирается по информационному критерию.

$$x_t \rightarrow y_t \Rightarrow \exists \phi_{2i} \neq 0.$$

нулевая гипотеза: $H_0: \phi_{21} = \dots = \phi_{2k_2} = 0;$

альтернатива: $H_1: H_0$ неверна;

статистика: $F = \frac{(RSS_r - RSS_{ur})/k_2}{RSS_{ur}/(T - k_1 - k_2 - 1)};$
 $F \sim F(k_2, T - k_1 - k_2 - 1)$ при $H_0;$




достигаемый уровень значимости:

$$p(f) = fcdf(1/f, T - k_1 - k_2 - 1, k_2).$$

Критерий Грейнджера

Маржа сверх процентной ставки и рост ВВП, ФРГ:



Критерий Грейнджера

y	x	k_1	k_2	$F(y \rightarrow x)$	$F(y \rightarrow x)$
$\Delta_4 \ln GDP_r$	$\Delta_4 \ln M1_r$	4	4	6.087***	1.918
		8	8	3.561**	1.443
$\Delta_4 \ln GDP_r$	$GLR - GSR$	4	4	3.160*	3.835**
		8	8	1.927(*)	2.077*
$\Delta_4 \ln M1_r$	$GLR - GSR$	4	4	5.615***	1.489
		8	8	2.521*	1.178

$\Delta_4 \ln GDP_r$ — годовой прирост ВВП в процентах, $\Delta_4 \ln M1_r$ — годовой прирост фактического количества денег в процентах, GLR — рост государственных облигаций, GSR — трёхмесячная ставка денежного рынка во Франкфурте.

(*), *, **, *** — значимость на уровне 0.1, 0.05, 0.01 и 0.001.

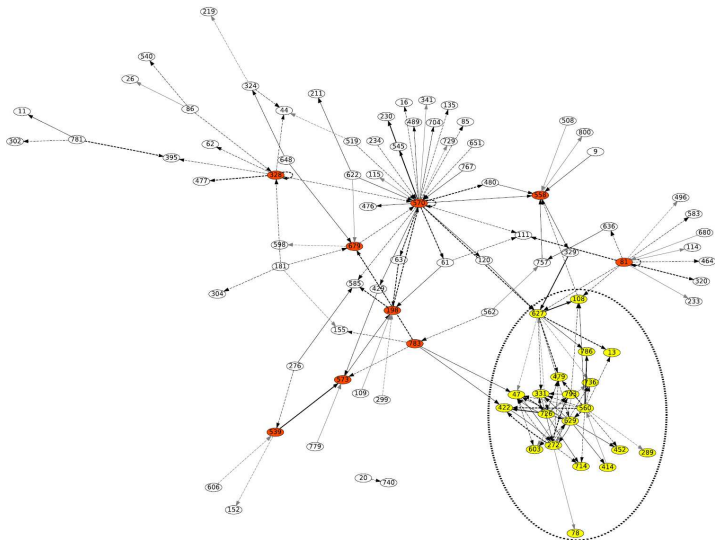
Многомерный критерий Грейнджера

Зависимость между признаками x и y может оцениваться с учётом возможной зависимости от всех остальных признаков:

$$y_t = \alpha + \sum_{i=1}^{k_1} \phi_{1i} y_{t-i} + \sum_{i=1}^{k_2} \phi_{2i} x_{t-i} + \sum_{j=1}^m \sum_{i=1}^{k_{j+2}} \phi_{(j+2)i} z_{t-i}^j + \varepsilon_t.$$

Для задач с большим количеством признаков могут использоваться регуляризаторы (лассо, ридж).


Граф причинности по Грейнджеру



Критерий Грейнджера + поправка на множественную проверку гипотез

Пример

Динамика средних ошибок прогнозов для 6 моделей (по реальным данным объёмов продаж в супермаркете):



Идея: кажется, можно успеть включить наиболее удачные модели и отключить менее удачные...

Адаптивная селективная модель

Пусть имеется k моделей прогнозирования,
 $\hat{y}_{j,t+d}$ — прогноз j -й модели на момент $t+d$,
 $\varepsilon_{jt} = y_t - \hat{y}_{jt}$ — ошибка прогноза в момент t ,
 $\tilde{\varepsilon}_{jt} := \gamma|\varepsilon_{jt}| + (1 - \gamma)\tilde{\varepsilon}_{jt}$ — экспоненциально сглаженная ошибка.

Лучшая модель в момент времени t :

$$j_t^* = \operatorname{argmin}_{j=1,\dots,k} \tilde{\varepsilon}_{jt}.$$

Адаптивная селективная модель:

$$\hat{y}_{j,t+d} := \hat{y}_{j_t^*,t+d}$$

Требуется подбор γ , рекомендация: $\gamma = 0.01 \dots 0.1$.

Адаптивная композиция моделей

Пусть имеется k моделей прогнозирования,
 $\hat{y}_{j,t+d}$ — прогноз j -й модели на момент $t+d$,
 $\varepsilon_{jt} = y_t - \hat{y}_{jt}$ — ошибка прогноза в момент t ,
 $\tilde{\varepsilon}_{jt} := \gamma|\varepsilon_{jt}| + (1 - \gamma)\tilde{\varepsilon}_{jt}$ — экспоненциально сглаженная ошибка.

Линейная (выпуклая) комбинация моделей:

$$\hat{y}_{t+d} = \sum_{j=1}^k w_{jt} \hat{y}_{j,t+d}, \quad \sum_{j=1}^k w_{jt} = 1, \quad \forall t.$$

Адаптивный подбор весов [Лукашин, 2003]:

$$w_{jt} = \frac{(\tilde{\varepsilon}_{jt})^{-1}}{\sum_{s=1}^k (\tilde{\varepsilon}_{st})^{-1}}.$$

Требуется подбор γ , рекомендация: $\gamma = 0.01 \dots 0.1$.

Адаптация весов с регуляризацией

На каждом шаге t веса определяются по МНК и сглаживаются:

$$\begin{cases} \sum_{i=0}^t \beta^{t-i} \left(\sum_{j=1}^k w_j \hat{y}_{j,i} - y_i \right)^2 + \lambda \sum_{j=1}^k (w_j - w_{j,t-1})^2 \rightarrow \min_{w_j, j=1, \dots, k} \\ \sum_{j=1}^k w_j = 1. \end{cases}$$

β — коэффициент «забывания» предыстории,

λ — коэффициент регуляризации.


Дополнительные варианты:

- $\beta \rightarrow 0$ — локальная адаптация весов с регуляризацией (оставляем в функционале только одно слагаемое, $i = t$)
- $w_j \geq 0$ — монотонный корректор

Воронцов К. В., Егорова Е. В. Динамически адаптируемые композиции алгоритмов прогнозирования // Искусственный Интеллект, Донецк, 2006. № 2. С. 277–280.

Задача прогнозирования временных рядов продаж


Средняя ошибка прогнозов на скользящем контроле ($T = 620$)




- ЛАВР-М — лучший результат, причём можно брать $\lambda = 0$
- Ограничение монотонности — сильный регуляризатор

Фрагменты динамики весов базовых моделей

Без ограничения монотонности:



С ограничением монотонности:



Сравнение моделей

Средняя ошибка прогнозов на скользящем контроле ($T = 620$)

базовый-1	0.7142	ЛАВР+Монот	0.5899
базовый-2	0.7294	селекция+сглаживание, γ_{opt}	0.5956
базовый-3	0.7534	МНК+Монот, $\beta=0.7$	0.6314
базовый-4	0.7624	ЛАВР без Монот	0.6591
базовый-5	0.7624	МНК без Монот, $\beta=0.7$	0.6834
базовый-6	0.7664	МНК по всем данным	0.7142
базовый-7	0.7793	среднее	0.7294
базовый-8	0.7793	селекция без сглаживания	0.9107

- Базовые модели, их усреднение, неадаптивный МНК по всем данным — работают плохо
- Адаптивная селекция работает хорошо, если подобрать γ
- $\gamma_{\text{opt}} = 0.2 \dots 0.3$ — усреднение по 3...5 дням

Прикладная статистика
13. Анализ временных рядов.

Рябенко Евгений
riabenko.e@gmail.com