

# Прогнозирование временных рядов

Воронцов Константин Вячеславович

vokov@forecsys.ru

<http://www.MachineLearning.ru/wiki?title=User:Vokov>

Этот курс доступен на странице вики-ресурса

<http://www.MachineLearning.ru/wiki>

«Машинное обучение (курс лекций, К.В.Воронцов)»

Видеолекции: <http://shad.yandex.ru/lectures>

МФТИ • 18 октября 2019

- 1 Задачи прогнозирования**
  - Понятие временного ряда
  - Примеры прикладных задач
  - Обзор методов прогнозирования
- 2 Адаптивные методы краткосрочного прогнозирования**
  - Экспоненциальное скользящее среднее
  - Модели с трендом и сезонностью
  - Анализ адекватности адаптивных моделей
- 3 Адаптивная селекция и композиция**
  - Адаптивная селекция
  - Адаптивная композиция
  - Эксперименты с адаптивными композициями

## Временной ряд

$y_0, y_1, \dots, y_t, \dots$  — временной ряд,  $y_i \in \mathbb{R}$

$\hat{y}_{t+d}(w) = f_{t,d}(y_1, \dots, y_t; w)$  — модель временного ряда,

где  $d = 1, \dots, D$ ,  $D$  — горизонт прогнозирования,

$w$  — вектор параметров модели

Метод наименьших квадратов:

$$Q_t(w) = \sum_{i=t_0}^t (\hat{y}_i(w) - y_i)^2 \rightarrow \min_w$$

Проблемы:

- рядов может быть очень много
- поведение рядов может описываться разными моделями
- модель должна быстро перестроиться для момента  $t + 1$
- функция потерь может быть неквадратичной

## Эконометрика — основной источник задач прогнозирования

Примеры эконометрических временных рядов:

- рыночные цены
- объёмы продаж в торговых сетях
- объёмы потребления и цены электроэнергии
- объёмы грузовых и пассажирских перевозок
- дорожный трафик (прогнозирование пробок)

Основные явления в эконометрических временных рядах:

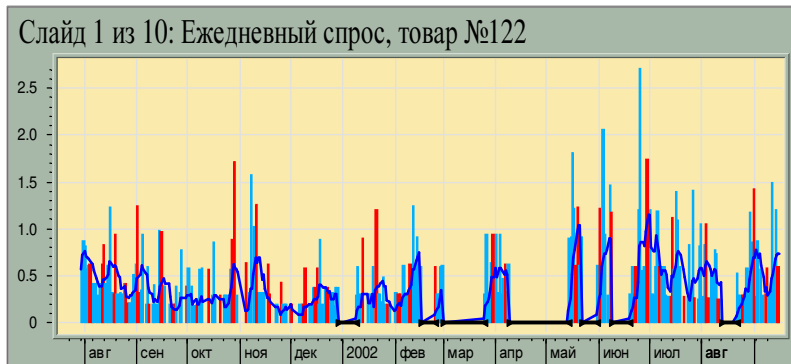
- тренды
- сезонности
- разладки (смены модели ряда)

---

*Марно Вербик.* Путеводитель по современной эконометрике, 2008.

## Пример. Задача прогнозирования объёмов продаж


Ежедневные объёмы продаж товара



**Особенности задачи:** огромное число рядов, продажи зависят от типа товара, тренды, сезонность, пропуски, праздники, промоакции, скачки, плохо работают сложные модели

## Пример. Задача прогнозирования цен электроэнергии

Почасовые цены электроэнергии на бирже NordPool, 2000г.



Особенности задачи: три вложенные сезонности, скачки

## Линейная модель авторегрессии

В роли признаков —  $n$  предыдущих наблюдений ряда:

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

В роли объектов  $\ell = t - n + 1$  моментов в истории ряда:

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

Функционал квадрата ошибки:

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

## Беглый обзор методов прогнозирования

- Модели авторегрессии и скользящего среднего  
ARMA, ARIMA, GARCH,...
- Адаптивные методы краткосрочного прогнозирования
- Адаптивная авторегрессия
- Адаптивная селекция моделей
- Адаптивная композиция моделей
- Нейросетевые модели
- Гусеница [Голяндина, 2003]
- Прогнозирование плотности распределения (density forecast)
- Квантильная регрессия

---

Лукашин Ю. П. Адаптивные методы краткосрочного прогнозирования временных рядов. Финансы и статистика, 2003.



## Экспоненциальное скользящее среднее (ЭСС)

Простейшая регрессионная модель — константа  $\hat{y}_{t+1} = c$ , наблюдения учитываются с весами, убывающими в прошлое:

$$\sum_{i=0}^t \beta^{t-i} (y_i - c)^2 \rightarrow \min_c, \quad \beta \in (0, 1)$$

Аналитическое решение — формула Надарая-Ватсона:

$$c \equiv \hat{y}_{t+1} = \frac{\sum_{i=0}^t \beta^i y_{t-i}}{\sum_{i=0}^t \beta^i}$$

Запишем аналогично  $\hat{y}_t$ , оценим  $\sum_{i=0}^t \beta^i \approx \sum_{i=0}^{\infty} \beta^i = \frac{1}{1-\beta}$ ,

получим  $\hat{y}_{t+1} = \hat{y}_t \beta + (1 - \beta) y_t$ , заменим  $\alpha = 1 - \beta$ :

$$\hat{y}_{t+1} = \hat{y}_t + \alpha (y_t - \hat{y}_t) = \alpha y_t + (1 - \alpha) \hat{y}_t,$$

$\alpha \in (0, 1)$  называется параметром сглаживания.

## Рекуррентная формула для среднего арифметического

Экспоненциальное скользящее среднее (ЭСС):

$$\hat{y}_{t+1} = \hat{y}_t + \alpha(y_t - \hat{y}_t)$$

Среднее арифметическое:

$$\hat{y}_{t+1} = \frac{1}{t+1} \sum_{i=0}^t y_i = \hat{y}_t + \frac{1}{t+1}(y_t - \hat{y}_t)$$

При  $\alpha_t = \frac{1}{t+1}$  имеем среднее арифметическое

При  $\alpha_t = \text{const}$  имеем экспоненциальное скользящее среднее

Условие сходимости к среднему (для стационарных задач):

$$\sum_{t=1}^{\infty} \alpha_t = \infty, \quad \sum_{t=1}^{\infty} \alpha_t^2 < \infty$$

ЭСС подходит также и для нестационарных задач

## Подбор параметра сглаживания

Чем больше  $\alpha$ , тем больше вес последних точек,  
при  $\alpha \rightarrow 1$  тривиальный прогноз  $\hat{y}_{t+1} = y_t$ .

Чем меньше  $\alpha$ , тем сильнее сглаживание,  
при  $\alpha \rightarrow 0$  тривиальный прогноз  $\hat{y}_{t+1} = \bar{y}$ .

Оптимальное  $\alpha^*$  находим по скользящему контролю:

$$Q(\alpha) = \sum_{t=T_0}^{T_1} (\hat{y}_t(\alpha) - y_t)^2 \rightarrow \min_{\alpha}$$


Эмпирические правила:

если  $\alpha^* \in (0, 0.3)$ , то ряд стационарен, ЭСС работает;

если  $\alpha^* \in (0.3, 1)$ , то ряд нестационарен, нужна модель тренда.

## Модели с трендом и сезонностью

Пример. Сочетания тренда и сезонности (модельные данные)



Ряд 1 — сезонность без тренда

Ряд 2 — линейный тренд, аддитивная сезонность

Ряд 3 — линейный тренд, мультипликативная сезонность

Ряд 4 — экспоненциальный тренд, мультипликативная сезонность

## Модель Хольта

Линейный тренд без сезонных эффектов:

$$\hat{y}_{t+d} = a_t + b_t d,$$

где  $a_t$ ,  $b_t$  — адаптивные коэффициенты линейного тренда

Рекуррентная формула:

$$a_t = \alpha_1 y_t + (1 - \alpha_1)(a_{t-1} + b_{t-1});$$

$$b_t = \alpha_2(a_t - a_{t-1}) + (1 - \alpha_2)b_{t-1};$$

где  $\alpha_1, \alpha_2$  — параметры сглаживания.

Частный случай — модель линейного роста Брауна:

$$\alpha_1 = 1 - \beta^2, \quad \alpha_2 = 1.$$

## Модель Тейла–Вейджа

Линейный тренд с аддитивной сезонностью периода  $s$ :

$$\hat{y}_{t+d} = (a_t + b_t d) + \theta_{t+(d \bmod s)-s}.$$

$a_t + b_t d$  — тренд, очищенный от сезонных колебаний,  
 $\theta_0, \dots, \theta_{s-1}$  — сезонный профиль периода  $s$ , без тренда.

Рекуррентная формула:

$$a_t = \alpha_1(y_t - \theta_{t-s}) + (1 - \alpha_1)(a_{t-1} + b_{t-1});$$

$$b_t = \alpha_2(a_t - a_{t-1}) + (1 - \alpha_2)b_{t-1};$$

$$\theta_t = \alpha_3(y_t - a_t) + (1 - \alpha_3)\theta_{t-s};$$

где  $\alpha_1, \alpha_2, \alpha_3$  — параметры сглаживания.

## Модель Уинтерса

Мультипликативная сезонность периода  $s$ :

$$\hat{y}_{t+d} = a_t \cdot \theta_{t+(d \bmod s)-s},$$

$\theta_0, \dots, \theta_{s-1}$  — сезонный профиль периода  $s$ .

Рекуррентная формула:

$$a_t = \alpha_1(y_t/\theta_{t-s}) + (1 - \alpha_1)a_{t-1};$$

$$\theta_t = \alpha_2(y_t/a_t) + (1 - \alpha_2)\theta_{t-s};$$

где  $\alpha_1, \alpha_2$  — параметры сглаживания.

## Модель Уинтерса с линейным трендом

Мультипликативная сезонность периода  $s$  с линейным трендом:

$$\hat{y}_{t+d} = (a_t + b_t d) \cdot \theta_{t+(d \bmod s)-s},$$

$a_t + b_t d$  — тренд, очищенный от сезонных колебаний,  
 $\theta_0, \dots, \theta_{s-1}$  — сезонный профиль периода  $s$ .

Рекуррентная формула:

$$a_t = \alpha_1(y_t/\theta_{t-s}) + (1 - \alpha_1)(a_{t-1} + b_{t-1});$$

$$b_t = \alpha_2(a_t - a_{t-1}) + (1 - \alpha_2)b_{t-1};$$

$$\theta_t = \alpha_3(y_t/a_t) + (1 - \alpha_3)\theta_{t-s};$$

где  $\alpha_1, \alpha_2, \alpha_3$  — параметры сглаживания.



## Модель Уинтерса с экспоненциальным трендом

Мультипликативная сезонность с экспоненциальным трендом:

$$\hat{y}_{t+d} = a_t(r_t)^d \cdot \theta_{t+(d \bmod s)-s},$$

$a_t(r_t)^d$  — экспоненциальный тренд, очищенный от сезонности,  
 $\theta_0, \dots, \theta_{s-1}$  — сезонный профиль периода  $s$ .

Рекуррентная формула:

$$a_t = \alpha_1(y_t/\theta_{t-s}) + (1 - \alpha_1)a_{t-1}r_{t-1};$$

$$r_t = \alpha_2(a_t/a_{t-1}) + (1 - \alpha_2)r_{t-1};$$

$$\theta_t = \alpha_3(y_t/a_t) + (1 - \alpha_3)\theta_{t-s};$$

где  $\alpha_1, \alpha_2, \alpha_3$  — параметры сглаживания.

## Адаптивная авторегрессионная модель

Линейная модель авторегрессии (линейный фильтр):

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

$\varepsilon_t = y_t - \hat{y}_t$  — ошибка прогноза  $\hat{y}_t$ , сделанного на шаге  $t - 1$

Метод наименьших квадратов:  $\varepsilon_t^2 \rightarrow \min_w$ .

Один шаг градиентного спуска в каждый момент  $t$ :

$$w_j := w_j + h_t \varepsilon_t y_{t-j+1}.$$

Градиентный шаг в методе скорейшего спуска:

$$h_t = \frac{\alpha}{\sum_{j=1}^n y_{t-j+1}^2},$$

где  $\alpha$  — аналог параметра сглаживания.

## Следящий контрольный сигнал

$\varepsilon_t = y_t - \hat{y}_t$  — ошибка прогноза  $\hat{y}_t$ , сделанного на шаге  $t - 1$   
Следящий контрольный сигнал (tracking signal [Trigg, 1964])

$$K_t = \frac{\hat{\varepsilon}_t}{\tilde{\varepsilon}_t} \quad \begin{array}{l} \hat{\varepsilon}_t = \gamma\varepsilon_t + (1 - \gamma)\hat{\varepsilon}_{t-1} \quad \text{— ЭСС ошибки} \\ \tilde{\varepsilon}_t = \gamma|\varepsilon_t| + (1 - \gamma)\tilde{\varepsilon}_{t-1} \quad \text{— ЭСС модуля ошибки} \end{array}$$

Рекомендация:  $\gamma = 0.05 \dots 0.1$

Статистический тест адекватности (при  $\gamma \leq 0.1$ ,  $t \rightarrow \infty$ ):

гипотеза  $H_0: E\varepsilon_t = 0$ ,  $E\varepsilon_t\varepsilon_{t+d} = 0$

принимается на уровне значимости  $\alpha$ , если

$$|K_t| \leq 1.2\Phi_{1-\alpha/2}\sqrt{\gamma/(2-\gamma)},$$


$\Phi_{1-\alpha/2}$  — квантиль нормального распределения,

$\Phi_{1-\alpha/2} = \Phi_{0.975} = 1.96$  при  $\alpha = 0.05$

## Модель Тригга–Лича [Trigg, Leach, 1967]

**Проблема:** адаптивные модели плохо приспособляются к резким структурным изменениям

**Решение:**  $\alpha = |K_t|$




**Недостатки:**

- 1) плохо реагирует на одиночные выбросы;
- 2) требует подбора  $\gamma$ , при рекомендации  $\gamma = 0.05 \dots 0.1$ .

## Идея адаптивной селекции моделей

**Пример:** Динамика ЭСС ошибок прогнозов  $|\varepsilon_t|$  для 6 моделей (по реальным данным объёмов продаж в супермаркете):



**Идея:** кажется, можно успевать включать наиболее удачные модели и отключать 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  $j$ -й модели в момент  $t$ ,

$\tilde{\varepsilon}_{jt} = \gamma|\varepsilon_{jt}| + (1 - \gamma)\tilde{\varepsilon}_{j,t-1}$  — ЭСС модуля ошибки.

Лучшая модель в момент времени  $t$ :

$$j_t^* = \arg \min_{j=1,\dots,k} \tilde{\varepsilon}_{jt}$$

Адаптивная селективная модель — прогноз по лучшей модели:

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

Требуется подбор  $\gamma$ , 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  $j$ -й модели в момент  $t$ ,

$\tilde{\varepsilon}_{jt} = \gamma|\varepsilon_{jt}| + (1 - \gamma)\tilde{\varepsilon}_{j,t-1}$  — ЭСС модуля ошибки.

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  $\gamma$ , рекомендация:  $\gamma = 0.01 \dots 0.1$ .

## ЛАВР — Локальная адаптация весов с регуляризацией

На каждом шаге  $t$  веса определяются по МНК и сглаживаются:

$$\begin{cases} \sum_{i=0}^t \beta^{t-i} \left( \sum_{j=1}^k w_j \hat{y}_{j,i} - y_i \right)^2 + \lambda \sum_{j=1}^k (w_j - w_{j,t-1})^2 \rightarrow \min_{w_1, \dots, w_k} \\ \sum_{j=1}^k w_j = 1. \end{cases}$$

$\beta \in (0, 1)$  — коэффициент «забывания» предыстории,

$\lambda$  — 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, 2006.



# Задача прогнозирования временных рядов продаж

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



—●— ЛАВР-М

—○— ЛАВР-неМ


—▲— МНК-[0.7]-М

—△— МНК-[0.7]-неМ


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

# Фрагменты динамики весов $w_{jt}$ базовых моделей

Без ограничения монотонности:



С ограничением монотонности:



## Сравнение моделей

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

базовый-1	<b>0.7142</b>	ЛАВР+МоноТ	<b>0.5899</b>
базовый-2	0.7294	селекция+сглаживание, $\gamma_{opt}$	<b>0.5956</b>
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  $\gamma$
- $\gamma_{opt} = 0.2 \dots 0.3$  — усреднение по 3...5 дням

- Адаптивные методы используют, когда рядов много и прогнозировать их надо быстро
- Простые адаптивные методы усиливаются адаптивной селекцией и композицией моделей
- Простые особенности рядов (тренды, сезонности, пропуски) моделируются в базовых алгоритмах
- Требование монотонности для адаптивной композиции — мощный регуляризатор
- Более сложные зависимости моделируются адаптивными авторегрессионными моделями