

Выбор иерархических моделей в авторегрессионном прогнозировании

И. В. Фадеев

Московский физико-технический институт
Факультет управления и прикладной математики
Кафедра интеллектуальных систем

Научный руководитель к.ф.-м.н., н.с. ВЦ РАН В. В. Стрижов

Москва,
2013 г.

Цель: разработать метод построения прогностических моделей, описывающих периодические временных ряды и включающие инвариантные преобразования.


Предмет исследования: пучки временных рядов.

Методы исследования: авторегрессионное прогнозирование, полупараметрическое и иерархическое моделирование.


Обзор литературы (1)

- Lawton, Sylvestre, Maggio (1972):
Self modeling nonlinear regression —
модель SEMOR, Shape-Invariant Model.
- Kneip, Engel (1995):
Model estimation in nonlinear regression under shape
invariance.
- Gamboa, Loubes (2007):
Semi-parametric estimation of shifts.
- Hurtgen, Gervini (2008):
Semiparametric shape-invariant models for periodic data.
- Vimond (2010):
Efficient estimation for a subclass of shape invariant models.
- Bertrand, Fhima, Guillen (2010):
Off-line detection of multiple change points with the Filtered
Derivative with p-Value method.

Потребление электроэнергии, неделя



Потребление электроэнергии, будни



Гипотеза порождения данных (1)

Рассматриваются N временных рядов длины n :

$$\mathbf{x}_i = (x_{i1}, x_{i2}, \dots, x_{in}), \quad i = 1, \dots, N.$$

Пусть

$$\mathbf{x}_i = \mathbf{f}(\mathbf{z}_0, \boldsymbol{\alpha}_i) + \boldsymbol{\varepsilon}_i, \quad \mathbf{z}_0 \in \mathbb{R}^n, \boldsymbol{\alpha}_i \in \mathbb{R}^m, \quad \boldsymbol{\varepsilon}_i \sim \mathcal{N}(0, E_n \sigma^2),$$

где $\mathbf{f} : \mathbb{R}^n \rightarrow \mathbb{R}^n$ — параметрическое семейство преобразований, \mathbf{z}_0 — форма, соответствующая выборке \mathbf{x}_i .

Пусть преобразование \mathbf{f} определяет в \mathbb{R}^n отношение эквивалентности:

$$\mathbf{x}_i \sim \mathbf{x}_j \iff \exists \boldsymbol{\alpha} : \mathbf{x}_j = \mathbf{f}(\mathbf{x}_i, \boldsymbol{\alpha}).$$

Гипотеза порождения данных (2)

Определяется множество $\mathbb{Z} \subset \mathbb{R}^n$ так, что оно содержит ровно по одному представителю от каждого класса эквивалентности.

Условие

$$z_0 \in \mathbb{Z}$$

однозначно определяет форму z_0 и параметры α_i .

Любой вектор $x_i \in \mathbb{R}^n$ однозначно представим в виде

$$x_i = f(z_i, \alpha_i), \quad z_i \in \mathbb{Z},$$

что позволяет ввести преобразования $u : \mathbb{R}^n \rightarrow \mathbb{R}^n$,

$v : \mathbb{R}^n \rightarrow \mathbb{R}^m$, такие, что

$$x_i = f(u(x), v(x)), \quad u(x) \in \mathbb{Z}.$$

$u(x)$ — форма вектора x — инвариант относительно преобразования f .

Примеры семейств преобразований

- Прибавление полинома:

$$f_j(\mathbf{x}, \boldsymbol{\alpha}) = x_j + \sum_{m=0}^k \alpha_m j^m, \quad j = 1, \dots, n,$$

$$\mathbf{v}(\mathbf{x}) = \underset{\boldsymbol{\alpha}}{\operatorname{argmin}} \sum_{j=1}^n \left(\sum_{m=0}^k \alpha_m j^m - x_j \right)^2,$$

$$u_j(\mathbf{x}) = x_j - \sum_{m=0}^k v_m(\mathbf{x}) j^m.$$

- Растяжение:

$$f_j(\mathbf{x}, \boldsymbol{\alpha}) = g(x_j, \boldsymbol{\alpha}), \quad j = 1, \dots, n,$$

где g — семейство монотонных функций; например,

$$f_j(\mathbf{x}, \boldsymbol{\alpha}) = \alpha_0 x_j^{\alpha_1}, \quad j = 1, \dots, n.$$

Оценка формы полупараметрической модели (1)

Пусть

$$\hat{z}_0 = \frac{1}{N} \sum_{i=1}^N u(\mathbf{x}_i). \quad (1)$$

Теорема 1. Пусть преобразование u удовлетворяет условию Липшица с константой L , т. е. для любых $\mathbf{x}_i, \mathbf{x}_j$

$$||\mathbf{u}(\mathbf{x}_i) - \mathbf{u}(\mathbf{x}_j)|| \leq L ||\mathbf{x}_i - \mathbf{x}_j||.$$

Тогда почти наверно существует минимальный размер выборки N_0 такой, что

$$||\hat{z}_0 - z_0|| < L\sigma n + \varepsilon_0, \quad \forall N : N > N_0,$$

где \hat{z}_0 — оценка (1), ε_0 — любое положительное число.

Оценка формы полупараметрической модели (2)

Пусть

$$\hat{z}_0 = \operatorname{argmin}_{\mathbf{u}(\mathbf{x}_j)} \sum_{i=1}^N \|\mathbf{u}(\mathbf{x}_i) - \mathbf{u}(\mathbf{x}_j)\|^2. \quad (2)$$

Теорема 2. Пусть преобразование \mathbf{u} удовлетворяет условию Липшица с константой L , т. е. для любых $\mathbf{x}_i, \mathbf{x}_j$


$$\|\mathbf{u}(\mathbf{x}_i) - \mathbf{u}(\mathbf{x}_j)\| \leq L\|\mathbf{x}_i - \mathbf{x}_j\|.$$

Тогда почти наверно существует минимальный размер выборки N_0 такой, что


$$\|\hat{z}_0 - z_0\| < \frac{31}{2}L\sigma\sqrt{n} + \varepsilon_0, \quad \forall N : N > N_0,$$

где \hat{z}_0 — оценка (2), ε_0 — любое положительное число.

Форма сегментов в модели сдвига



Потребление электроэнергии, будни и выходные



Кластеризация выборки

Пусть существует разбиение индексов


$\mathcal{I} = \{1, \dots, N\} = \mathcal{I}_1 \cup \dots \cup \mathcal{I}_s$ такое, что

$$\mathbf{x}_i = \mathbf{f}(\mathbf{z}_{0k}, \boldsymbol{\alpha}_i) + \boldsymbol{\varepsilon}_i, \quad i \in \mathcal{I}_k, \quad \mathbf{z}_{0k} \in \mathbb{Z}, \quad k = 1, \dots, s.$$


Для нахождения разбиения выполняем кластеризацию, определив функцию расстояния

$$\rho_{ij} = \|\mathbf{u}(\mathbf{x}_i) - \mathbf{u}(\mathbf{x}_j)\|, \quad i, j \in \mathcal{I}.$$

Пример кластеризации



Формы сегментов, будни и выходные



Критерий различимости форм на подгруппах (1)

Пусть существует априорное разбиение индексов

$$\mathcal{I} = \tilde{\mathcal{I}}_1 \cup \tilde{\mathcal{I}}_2.$$

Нулевая гипотеза:

$$\frac{E[\rho_{ij}|i,j \in \tilde{\mathcal{I}}_1] + E[\rho_{ij}|i,j \in \tilde{\mathcal{I}}_2]}{2} = E[\rho_{ij}|i \in \tilde{\mathcal{I}}_1, j \in \tilde{\mathcal{I}}_2],$$

$$D = E_{12} - \frac{E_{11} + E_{22}}{2} = 0.$$

Альтернатива:

$$D > 0.$$

Оценки матожиданий

$$\hat{E}_{12} = \frac{\sum_{i \in \tilde{\mathcal{I}}_1, j \in \tilde{\mathcal{I}}_2} \rho_{ij}}{|\tilde{\mathcal{I}}_1||\tilde{\mathcal{I}}_2|},$$

$$\hat{E}_{11} = \frac{\sum_{i,j \in \tilde{\mathcal{I}}_1, i < j} \rho_{ij}}{|\tilde{\mathcal{I}}_1|(|\tilde{\mathcal{I}}_1| - 1)/2}, \quad \hat{E}_{22} = \frac{\sum_{i,j \in \tilde{\mathcal{I}}_2, i < j} \rho_{ij}}{|\tilde{\mathcal{I}}_2|(|\tilde{\mathcal{I}}_2| - 1)/2}.$$

Критерий различимости форм на подгруппах (2)

Дисперсии оценок

$$\widehat{VE}_{12} = \frac{\widehat{V}[\rho_{ij} | \tilde{\mathcal{I}}_1, j \in \tilde{\mathcal{I}}_2]}{|I_1| |I_2|} = \frac{\sum_{i \in \tilde{\mathcal{I}}_1, j \in \tilde{\mathcal{I}}_2} (\rho_{ij} - \hat{E}_{12})^2}{|\mathcal{I}_1|^2 |\mathcal{I}_2|^2},$$

$$\widehat{VE}_{11} = \frac{\sum_{i,j \in \tilde{\mathcal{I}}_1, i < j} (\rho_{ij} - \hat{E}_{11})^2}{|\mathcal{I}_1|^2 (|\mathcal{I}_1| - 1)^2 / 4}, \quad \widehat{VE}_{22} = \frac{\sum_{i,j \in \tilde{\mathcal{I}}_2, i < j} (\rho_{ij} - \hat{E}_{22})^2}{|\mathcal{I}_2|^2 (|\mathcal{I}_2| - 1)^2 / 4},$$

$$\widehat{se}_D = \sqrt{\widehat{VE}_{12} + \frac{1}{4}(\widehat{VE}_{11} + \widehat{VE}_{22})}.$$

Используя центральную предельную теорему


$$\hat{D} = \hat{E}_{12} - (\hat{E}_{11} + \hat{E}_{22})/2 \sim \mathcal{N}(0, \widehat{se}_D^2),$$

находим достижимый уровень значимости

$$p\text{-value} = 1 - \Phi\left(\frac{\hat{D}}{\widehat{se}_D}\right)$$

для нулевой гипотезы $D = 0$ против альтернативы $D > 0$.


Критерий различимости форм на подгруппах (3)



p-value = 0,5335
Пн Вс

p-value = 0,5329

Category	Пн	Вс
1	1	0
2	1	0
3	1	0
4	1	0
5	1	0
6	1	0
7	1	0
8	1	0
9	1	0
10	1	0



Критерий качества семейства преобразований

Пусть существует априорное разбиение индексов

$$\mathcal{I} = \{1, \dots, N\} = \mathcal{I}_1 \cup \dots \cup \mathcal{I}_s.$$

Необходимо выбрать преобразование f и множество Z так, чтобы минимизировать среднее внутриклассовое расстояние

$$F_1 = \frac{\sum_{i < j} [J(i) = J(j)] \rho_{ij}}{\sum_{i < j} [J(i) = J(j)]}$$

и максимизировать среднее межклассовое

$$F_2 = \frac{\sum_{i < j} [J(i) \neq J(j)] \rho_{ij}}{\sum_{i < j} [J(i) \neq J(j)]},$$


где $J(i) = k \iff i \in \mathcal{I}_k$.

Предлагается критерий качества


$$S(f) = \frac{F_2}{F_1}.$$

Двумерное шкалирование сегментов


$$f_i(\mathbf{x}, \boldsymbol{\alpha}) = x_j + \alpha_0, S(f) = 2, 39$$




$$f_j(\mathbf{x}, \boldsymbol{\alpha}) = x_j + \alpha_0 + \alpha_1 j, S(f) = 2, 74$$



$$f_j(\mathbf{x}, \boldsymbol{\alpha}) = x_j + \sum_{m=0}^5 \alpha_m j^m, S(f) = 1, 2$$



$$f(\mathbf{x}, \boldsymbol{\alpha}) = \alpha_0 \mathbf{x}, S(f) = 2, 1$$




Поиск моментов изменения формы (1)

Алгоритм поиска разладок с помощью дискретной производной и вычисления достижимых уровней значимости:

1) Вычисление дискретной производной

$$D(t, A) = \hat{z}_0(t, A) - \hat{z}_0(t - A, A),$$

где $\hat{z}_0(t, A)$ — оценка формы по выборке $\{\mathbf{x}_i : t < i \leq t + A\}$.



Поиск моментов изменения формы (2)


2) Выбор потенциальных точек разладки τ_k как локальных максимум функции $\|D(t, A)\|$, лежащих выше порога λ :

$$\|D(\tau_k, A)\| > \lambda$$

λ выбирается так, чтобы при условии отсутствия разладки выполнялось


$$P(\max_t \|D(t, A)\|) > \lambda) = p_1.$$

Значение λ оценивается бутстрепом.




Поиск моментов изменения формы (3)

3) Исключение из точек τ_k ложных тревог с помощью критерия различимости форм на подвыборках.



Прогнозирование



Заключение

- Предложен метод оценки формы и параметров в полупараметрической регрессионной модели. Доказана устойчивость оценки формы.
- Рассмотрена задача кластеризации сегментов временных рядов схожей формы на примере потребления электроэнергии.
- Адаптирован алгоритм обнаружения разладки с помощью дискретной производной для работы с последовательностью временных рядов.
- Предложена двухуровневая иерархическая модель прогнозирования потребления электроэнергии.