

Универсальные локально-линейные ядерные оценки для производной регрессионной функции

Докладчик: Петренко Сергей,
НГУ

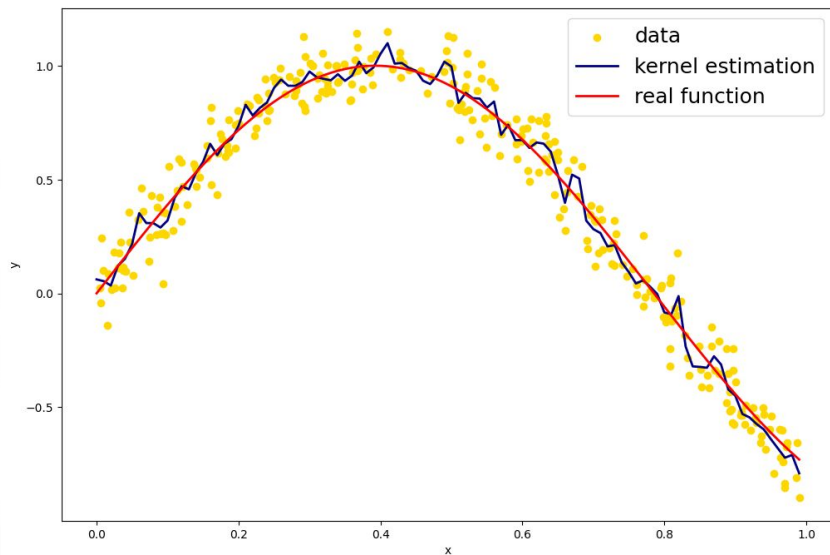
Научный руководитель:
Линке Ю.Ю. д-р физ.-мат. наук,
ИМ СО РАН

Работа выполнена при поддержке
Математического Центра в Академгородке,
соглашение с Министерством науки
и высшего образования Российской Федерации
№ 075-15-2025-348



mathematics
& mechanics

ПОСТАНОВКА ЗАДАЧИ РЕГРЕССИИ



Пусть наблюдения $\{(z_i, X_i); i = 1, \dots, n\}$ имеют структуру:

$$X_i = f(z_i) + \varepsilon_i$$

где $\{z_i\}$ - регрессоры, которые известны, $\{\varepsilon_i\}$ - ненаблюдаемые случайные ошибки (центрированные случайные величины).

Задача состоит в оценивании гладкой регрессионной функции или её производных:

$$f : [0, 1] \rightarrow \mathbb{R}$$


БОЛЬШОЕ ЧИСЛО РАБОТ ПОСВЯЩЕНО ОЦЕНИВАНИЮ ПРОИЗВОДНОЙ:

- Liu, Yang (2024), Prasangika, Tang, Yao (2023), Liu, Li (2023), Comte, Marie (2023),
- Bouzebda, Chaouch, Biha (2022), Calónico, Cattaneo Farrell (2022),
- Liu, De Brabanter (2020), Cattaneo, Farrell (2020), Xie, Sun, Liu (2020),
- Wang, Yu, Lin, Tong (2019), Bercu, Capderou, Durrieu (2019), Dai, Tong, Genton (2016), Song (2016),
- Wang, Lin (2015), Benhenni, Degras (2014), Zheng, Gallagher, Kulasekera (2013),
- De Brabanter, K., De Brabanter, J., De Moor, Gijbels (2013), Martins-Filho, Saraiva (2012),
- Chen, Zhang (2010), Lu, Linton (2007), Newell, Einbeck (2007),
- Delecroix, Rosa (2007), Boente, Rodriguez (2006), Horng (2006), Qin, Tsao (2005),
- Gijbels, Goderniaux (2004), Beran, Feng (2002), Jiang, Mack (2001), Zhou, Wolfe (2000),
- Fan, Gasser, Gijbels, Brockmann, Engel (1997), Masry, Fan (1997), Fan, Gijbels (1995),
- Mack, Muller (1989), Muller, Schmitt (1987), Hardle, Gasser (1985), Gasser, Muller (1984) и др.

В этих работах рассматриваются различные условия на параметры модели: регрессоры, ошибки и тд. Нас же интересуют условия на регрессоры. Мы хотим построить оценки при более общих условиях на регрессоры, чем известные ранее.


ЯДЕРНЫЕ ФУНКЦИИ

Ядро Епанечникова



$$K(t) = \frac{3}{4}(1 - t^2)I(|t| \leq 1)$$

Треугольное ядро



$$K(t) = (1 - |t|)I(|t| \leq 1)$$

ЯДЕРНЫЕ ОЦЕНКИ

Пусть $K(t)$ - ядро сглаживания - плотность симметричного распределения (обычно с носителем $[-1; 1]$).

$K_h(u) = h^{-1}K(\frac{u}{h})$ - Плотность симметричного распределения на $[-h; h]$. Нормированное ядро по h (ширине окна).

Оценка Надарая-Ватсона (1964):


$$f_{NW}^*(t) = \arg \min_{\theta} \sum_{i=1}^n (X_i - \theta)^2 K_h(t - z_i)$$

$$f_{NW}^*(t) = \frac{\sum_{i=1}^n X_i K_h(t - z_i)}{\sum_{i=1}^n K_h(t - z_i)}$$


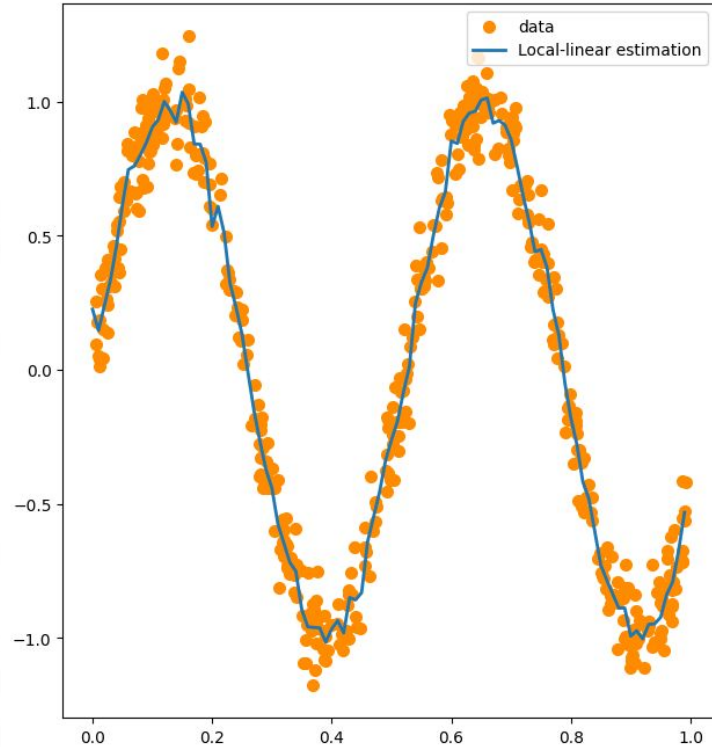
ЛОКАЛЬНО-ЛИНЕЙНЫЕ ОЦЕНКИ

$$f_{NW}^*(t) = \arg \min_{\theta} \sum_{i=1}^n (X_i - \theta)^2 K_h(t - z_i)$$

$$f(z_i) \approx f(t) + f'(t)(z_i - t)$$




$$f_{LL}^*(t) = \arg \min_{(\theta_0, \theta_1)} \sum_{i=1}^n (X_i - \theta_0 - \theta_1(z_i - t))^2 K_h(t - z_i)$$

$h = 0.01$, $n = 500$




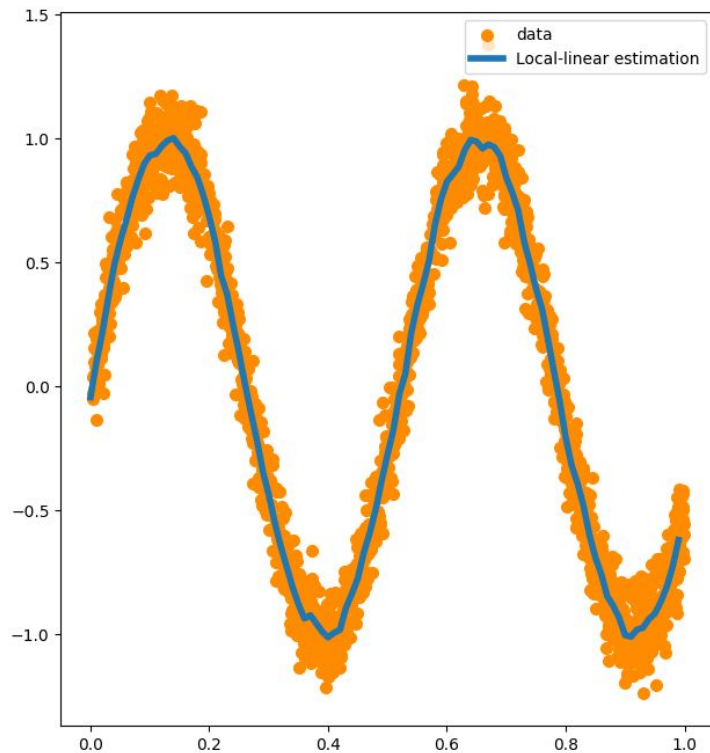
Сходимость локально линейных оценок в зависимости от количества данных. Функция (слева), производная(справа).

$h = 0.01, n = 1000$





Сходимость локально линейных оценок в зависимости от количества данных. Функция (слева), производная(справа).

$h = 0.01$, $n = 2000$



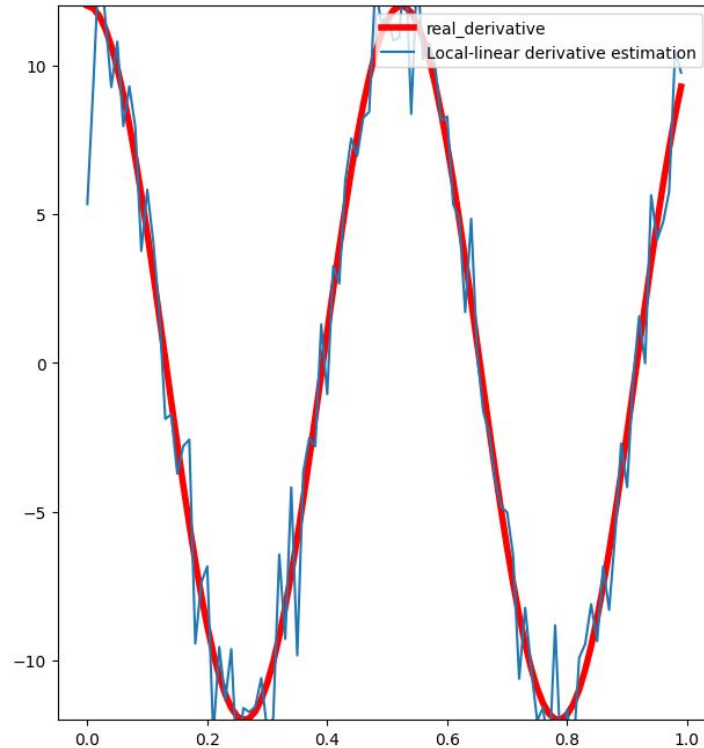

Сходимость локально линейных оценок в зависимости от количества данных. Функция (слева), производная(справа).

$h = 0.01, n = 4000$





Сходимость локально линейных оценок в зависимости от количества данных. Функция (слева), производная(справа).

$h = 0.01, n = 8000$



Сходимость локально линейных оценок в зависимости от количества данных. Функция (слева), производная(справа).

$h = 0.01, n = 16000$



Сходимость локально линейных оценок в зависимости от количества данных. Функция (слева), производная(справа).

УСЛОВИЯ НА РЕГРЕССОРЫ В РАБОТАХ ПРЕДШЕСТВЕННИКОВ

Модели с **фиксированными** и **случайными** регрессорами принято рассматривать отдельно .

- Если $\{z_i\}$ неслучайны, то предполагаются те или иные условия **регулярного плотного заполнения** регрессорами области определения регрессионной функции. Например:

$$z_i = i/n, \quad z_i = g(i/n) + o(1/n), \quad \max_{i \leq n} (z_i - z_{i-1}) = O(1/n)$$

- Если $\{z_i\}$ случайны, то рассматриваются:
 - **независимые и одинаково распределенные величины**
 - **слабо зависимые величины** (например, используются условия перемешивания, схемы скользящих средних, ассоциированные с. в., марковские или мартингальные свойства, авторегрессия и др.)

Мотивация

- Можно ли построить оценки для производной неизвестной регрессионной функции при **близких к минимальным и наглядных условиях на регрессоры** (без использования условий слабой зависимости, в случае сильно зависимых величин)?
- Ранее ответ на аналогичный вопрос был получен в задаче оценивания регрессионной функции: для того, чтобы оценить регрессионную функцию, относительно регрессоров достаточно требовать лишь условие плотного заполнения этими величинами области задания регрессионной функции.

НОВЫЙ КЛАСС ОЦЕНОК

Пусть регрессоры $\{z_i; i = 1, \dots, n\}$ - это набор наблюдаемых случайных величин, с неизвестным распределением на $[0;1]$; Не обязательно независимых и одинаково распределённых, регрессоры могут зависеть от n .
Частный случай: детерминированные регрессоры.

Обозначим через $z_{n:1} \leq \dots \leq z_{n:n}$ элементы вариационного ряда.
 $\Delta z_{ni} = z_{n:i} - z_{n:i-1}$. Отклики, относящиеся к $z_{n:i}$ обозначим X_{ni}

Введём в рассмотрение следующий класс оценок для производных:

$$\hat{f}'_{ULL}(t) = \sum_{i=1}^n \frac{(z_{n:i} - t)w_{n0}(t) + w_{n1}(t)}{w_{n0}(t)w_{n2}(t) - w_{n1}^2(t)} X_{ni} K_h(t - z_{n:i}) \Delta z_{ni}.$$

$$w_{nj}(t) = \sum_{i=1}^n (t - z_{n:i})^j K_h(t - z_{n:i}) \Delta z_{ni}, \quad j = 0, 1, 2$$

ИНТУИЦИЯ ОЦЕНКИ

$$w_{nj}(t) = \sum_{i=1}^n (t - z_{n:i})^j K_h(t - z_{n:i}) \Delta z_{ni}, \quad j = 0, 1, 2$$

$$w_j(t) = \int_{t-h}^{t+h} (t - z)^j K_h(t - z) dz = h^j \int_{-1}^1 v^j K(v) dv.$$

при малых Δz_{ni} выполнено: $w_{nj}(t) \approx w_j(t)$

УСЛОВИЕ НА РЕГРЕССОРЫ, ГАРАНТИРУЮЩЕЕ ПОТОЧЕЧНУЮ СОСТОЯТЕЛЬНОСТЬ ПО ВЕРОЯТНОСТИ

**Соотношение на регрессоры,
гарантирующее поточечную
состоятельность оценки с ростом n:**

$$\delta_n = \max_{1 \leq i \leq n+1} \Delta z_{ni} \xrightarrow{p} 0$$

- Универсально относительно стохастической природы регрессоров, включает как случайные, так и детерминированные регрессоры
- Зависимость регрессоров может быть более сильной, чем в известных ранее работах
- В оценивании никак не используется характер зависимости регрессоров.

ДОПОЛНИТЕЛЬНЫЕ УСЛОВИЯ

(K): Ядерная Функция $K(t), t \in \mathbb{R}$ является плотностью симметричного распределения с носителем $[-1, 1]$, Кроме того $K(t)$ удовлетворяет условию Липшица с константой $L \geq 1$ и $K(\pm 1) = 0$.

(M): $f \in C^1[0, 1]$

(E) При всех $n \geq 1$ случайные погрешности $\{\varepsilon_i; i = 1, \dots, n\}$ с вероятностью 1 при всех $i, j \leq n, i \neq j$ удовлетворяют условиям:

$$\mathbb{E}_{\mathcal{F}_n} \varepsilon_i = 0, \quad \sup_{i \leq n} \mathbb{E}_{\mathcal{F}_n} \varepsilon_i^2 \leq \sigma^2, \quad \mathbb{E}_{\mathcal{F}_n} \varepsilon_i \varepsilon_j = 0, \quad i \neq j$$

ОСНОВНОЙ РЕЗУЛЬТАТ

ТЕОРЕМА 1.

Пусть выполнены условия (K), (M), (E) и предельное условие на регрессоры, тогда существует $h = h_n \rightarrow 0$ последовательность положительных чисел такая, что при $n \rightarrow \infty$:

$$\mathbb{E} \frac{\delta_n}{h^3} \rightarrow 0, \quad \mathbb{E} \frac{\delta_n^2}{h^4} \rightarrow 0$$

Тогда имеет место предельное соотношение:

$$\forall t \in [0, 1] : \quad \hat{f}'_{ULL}(t) \xrightarrow{P} f'(t)$$

ОСНОВНОЙ РЕЗУЛЬТАТ

ТЕОРЕМА 2.

Пусть выполнены условия (K), (M), (E) и предельное условие на регрессоры, тогда существует $h = h_n \rightarrow 0$ последовательность положительных чисел такая, что при $n \rightarrow \infty$:

$$\mathbb{E} \frac{\delta_n}{h^4} \rightarrow 0$$

Тогда имеет место предельное соотношение:

$$\sup_{t \in [0,1]} |\hat{f}'_{ULL}(t) - f'(t)| \xrightarrow{P} 0$$

АСИМПТОТИЧЕСКАЯ НОРМАЛЬНОСТЬ

Нам понадобится некоторое упрощение условия на случайные ошибки.

(E1) При всех $n \geq 1$ случайные погрешности $\{\varepsilon_i; i = 1, \dots, n\}$ представимы в виде

$$\varepsilon_i = \sigma(z_i)\xi_i, \quad i = 1, \dots, n,$$

где неизвестная функция $\sigma(t)$, $t \in [0, 1]$, непрерывна, $\{\xi_i; i = 1, \dots, n\}$ — независимые одинаково распределенные случайные величины с нулевым средним и единичной дисперсией, не зависящие от набора регрессоров $\{z_i; i = 1, \dots, n\}$.

АСИМПТОТИЧЕСКАЯ НОРМАЛЬНОСТЬ

Усиление теоремы Гаека-Шидака.

Теорема 2. Пусть ξ_1, ξ_2, \dots — последовательность независимых одинаково распределенных центрированных случайных величин с конечным вторым моментом $\sigma^2 = \mathbb{E}\xi_1^2$, а случайные величины a_{nk} , где $k = 1, \dots, n$; $n = 1, 2, \dots$, не зависящие от ξ_i , где $i = 1, 2, \dots$, удовлетворяют следующим двум условиям:

$$\max_{1 \leq k \leq n} |a_{nk}| \xrightarrow{p} 0, \quad \sum_{i=1}^n a_{nk}^2 = 1 \quad \text{при всех } n.$$

Тогда имеет место предельное соотношение

$$\sum_{k=1}^n a_{nk} \xi_k \xrightarrow{d} \mathcal{N}(0, \sigma^2).$$

АСИМПТОТИЧЕСКАЯ НОРМАЛЬНОСТЬ

Теорема 3. Пусть выполнены условия (M) , $(E1)$, (K) и при некотором $t \in [0, 1]$ и $h \equiv h_n$

$$\frac{\max_{k \leq n} |((z_{n:k} - t)w_{n0}(t) + w_{n1}(t))K_h(t - z_{n:k})\sigma(z_{n:i})\Delta z_{nk}|}{(\sum_{i=1}^n ((z_{n:i} - t)w_{n0}(t) + w_{n1}(t))^2 K_h^2(t - z_{n:i})\sigma^2(z_{n:i})(\Delta z_{ni})^2)^{1/2}} \xrightarrow{p} 0$$

Тогда имеет место сходимость по распределению:

$$B_{n,h}^{-1}(t) \left(\hat{f}_{n,h}(t) - f'(t) - r_{n,h}(t) \right) \xrightarrow{d} \mathcal{N}(0, 1),$$

где:

$$r_{n,h}(t) = \mathbb{E}_{\mathcal{F}_n}(\hat{f}_{n,h}(t) - f'(t))$$

$$B_{n,h}^2(t) = \sum_{i=1}^n \beta_{n,i}^2(t) K_h^2(t - z_{n:i}) \sigma^2(z_{n:i}) (\Delta z_{ni})^2.$$

Новизна результата

Полученный результат позволяет:

- Значительно ослабить известные ограничения на регрессоры в задаче оценивания производной регрессионной функции;
- Оценивать производную функции при отсутствии какой-либо информации о характере зависимости регрессоров;
- В данной задаче непараметрической регрессии в едином подходе рассматривать модели с детерминированными и случайными регрессорами.

Спасибо за внимание

$$\widehat{\sigma}_{n,h,\bar{h}}^2(t) = \frac{\sum_{i=1}^n \left(X_{ni} - f_{n,h}^*(z_{n:i})\right)^2 \bar{K}_{\bar{h}}(t - z_{n:i}) \Delta z_{ni}}{\sum_{i=1}^n \bar{K}_{\bar{h}}(t - z_{n:i}) \Delta z_{ni}},$$

$$\beta_{n,i}(t) = \frac{(z_{n:i} - t)w_{n0}(t) + w_{n1}(t)}{w_{n0}(t)w_{n2}(t) - w_{n1}^2(t)}$$

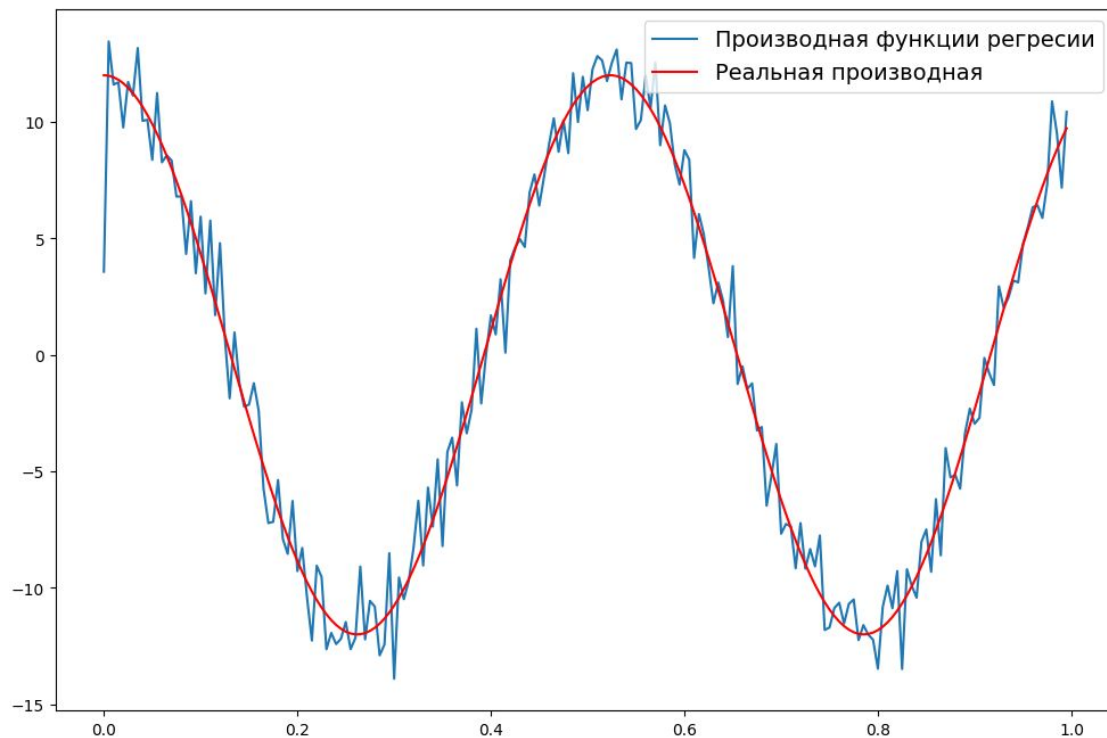
$$r_{n,h}(t) = \sum_{i=1}^n \beta_{n,i}(t) \left(f(z_{n:i}) - f(t) - f'(t)(z_{n:i} - t) \right) K_h(t - z_{n:i}) \Delta z_{ni}$$

$$\beta_{n,i}(t) = \frac{(z_{n:i} - t)w_{n0}(t) + w_{n1}(t)}{w_{n0}(t)w_{n2}(t) - w_{n1}^2(t)}$$

$$r_{n,h}(t) = \sum_{i=1}^n \beta_{n,i}(t) (f(z_{n:i}) - f(t) - f'(t)(z_{n:i} - t)) K_h(t - z_{n:i}) \Delta z_{ni}$$

$$\nu_{n,h}(t) = \sum_{i=1}^n \beta_{n,i}(t) K_h(t - z_{n:i}) \Delta z_{ni} \varepsilon_{ni}$$

$$\widehat{f}'_{n,h}(t) = f'(t) + r_{n,h}(t) + \nu_{n,h}(t)$$



Оценка производной функции $\sin(12x)$, полученная дифференцированием оценки Надарая-Ватсона при $h = 0.005$, $n = 80000$.

КРИТИКА ДИФФЕРЕНЦИРОВАНИЯ ЯДЕРНЫХ ОЦЕНОК ДЛЯ ФУНКЦИИ

De Brabanter, K., De Brabanter, J., De Moor, B., Gijbels, I. (2013) Derivative estimation with local polynomial fitting // J. Mach. Learn. Res.

Было бы заманчиво дифференцировать ядерные оценки для регрессионной функции для получения оценок для производных регрессионной функции, но это может привести к неправильным оценкам для производных, поскольку такая процедура может работать только в случае, если очень точно оценена сама функция. Иначе прямое дифференцирование может привести к накоплению ошибок, которые увеличиваются с ростом производной.

Dai W., Tong T., Genton M.G. (2016) Optimal estimation of derivatives in nonparametric regression // J. Mach. Learn. Res.

Даже хорошая оценка для регрессионной функции может не гарантировать получение хороших оценок для производных.

К ВОПРОСУ О СКОРОСТИ СХОДИМОСТИ

Рассмотрим случай **фиксированных регрессоров с равномерной решёткой**. То есть:

$$z_i = i/n, \quad \delta_n = 1/n$$

- Локально-линейные: $nh^3 \rightarrow \infty$
- Сплайны: $nh^3 \rightarrow \infty$
- Универсально локально-линейные: $nh^3 \rightarrow \infty$

$$f_{NW}^*(t) = \frac{\sum_{i=1}^n X_i K_h(t - z_i)}{\sum_{i=1}^n K_h(t - z_i)}$$

Асимптотическая сложность построения оценки в точке t : $O(n)$

Сложность построения оценки на всей сетке: $O(n/h)$

$$f_{ULL}^*(t) = \sum_{i=1}^n \frac{W_{n0}(t)(z_{n:i} - t) - W_{n1}(t)}{W_{n2}(t)W_{n0}(t) - W_{n1}(t)^2} X_{ni} K_h(t - z_{n:i}) \Delta z_{ni},$$

$$W_{nj}(t) = \sum_{i=1}^n (z_{n:i} - t)^j K_h(t - z_{n:i}) \Delta z_{ni}, \quad j = 0, 1, 2.$$

Асимптотическая сложность построения оценки в точке t : $O(n)$

Сложность построения оценки на всей сетке: $O(n/h)$