

Выбор ансамбля локальных моделей в задачах анализа сигналов

Сайранов Данил Айдарович

Московский физико-технический институт
Физтех-школа прикладной математики и информатики
Факультет управления и прикладной математики
Кафедра «Интеллектуальные системы»

Научный руководитель: д.ф.-м.н. В.В. Стрижов

МФТИ, 2020

Классификация временных рядов

Цель

Предложить способ построения ансамбля моделей локальной аппроксимации для классификации сигналов носимых устройств.

Гипотеза

Ансамбль моделей локальной аппроксимации предпочтительнее в парето-оптимальном смысле универсальной модели (нейросети): точнее, устойчивее, проще.





Задача

Требуется построить признаковое описание временных рядов на используя параметры моделей локальной аппроксимации.

Метод

Предложить критерий сложности ансамбля для выбора оптимального признакового описания.

Классификация временных рядов



- **Кузнецов М. П., Ивкин Н. П.**, *Алгоритм классификации временных рядов акселерометра по комбинированному признаковому описанию*, Машинное обучение и анализ данных, 2015.
- **Карасиков М. Е., Стрижов В. В.**, *Классификация временных рядов в пространстве параметров порождающих моделей*, Информатика и её применения, 2016.
- **Иванычев С. Д.**, *Выбор оптимальных моделей локальной аппроксимации для классификации временных рядов*, Выпускная квалификационная работа бакалавра, 2018.
- **A. M. Katrutsa, V. V. Strijov**, *Comprehensive study of feature selection methods to solve multicollinearity problem according to evaluation criteria*, Expert Systems with Applications, 2016
- **Cybenko, G. V.**, *Approximation by Superpositions of a Sigmoidal function*, Mathematics of Control Signals and Systems, 1989.

Временной ряд:

$$S : T \rightarrow \mathbb{R}, \text{ где } T = \{t_0, t_0 + d, t_0 + 2d, \dots\}$$

Сегмент временного ряда:

$$\mathbf{x}_i = [S(t_i), S(t_i - d), \dots, S(t_i - (n - 1)d)], \mathbf{x}_i \in \mathbf{X} \equiv \mathbb{R}^n$$

Выборка: $\mathcal{D} = \{(\mathbf{x}_i, y_i)\}_{i=1}^N$, $y_i \in \{1, \dots, K\}$

\mathbf{X} — набор сегментов данных акселерометра,

y — метки классов движения.

Универсальная модель

Многослойная полносвязная нейронная сеть

Моделью локальной аппроксимации g называется модель, аппроксимирующая временной ряд $x(t)$ на отрезке времени $[t, t - \Delta t]$:

$$g : [t, t - \Delta t] \rightarrow \hat{\mathbf{x}}.$$

Параметры \mathbf{w} модели $g = g(\mathbf{w})$ оптимизируются в соответствии функции ошибки:

$$\hat{\mathbf{w}} = \arg \min S(\mathbf{w}) = \|\hat{\mathbf{x}} - \mathbf{x}\|.$$

Признаковое описание φ генерируется методом локальной аппроксимации для каждой временной точки t :

$$\varphi = \varphi(\mathbf{g}, \mathbf{w}, \mathbf{x}).$$

Метод

Оптимальные параметры $\mathbf{g}_i(\mathbf{x})$ определяются как

$$\mathbf{g}_i(\mathbf{x}) = \arg \min_{\mathbf{w} \in \mathbb{R}^{n_g}} (g(\mathbf{w}, \mathbf{x}), \mathbf{x})$$

\mathbf{g}_i - модель локальной аппроксимации.

Пространство сегментов \mathbf{X} отображается набором функций $\mathbf{g} = [\mathbf{g}_1, \dots, \mathbf{g}_k]$ в пространство признаков описаний Φ .

Модель	Структурные параметры
AR-авторегрессия	Порядок
ARMA	Порядок
ARIMA	Порядок
Фурье-модель (FFT)	Кол-во главных частот
Сингулярный спектр (SSA)	Кол-во сингулярных чисел
Self-Modelling Regression (SEMOR)	-

AR-авторегрессия

Структурный параметр: порядок m ,

$$x_t = w_0 + \sum_{i=1}^m w_i x_{t-i},$$

где w_0 — константа, w_1, \dots, w_m — параметры модели.

ARMA

Структурные параметры: порядки m и n ,

$$x_t = w_0 + \sum_{i=1}^m w_i x_{t-i} + \sum_{i=1}^n \theta_i \varepsilon_{t-i},$$

где w_0 — константа, $w_1, \dots, w_m, \theta_1, \dots, \theta_n$ — параметры модели, $\varepsilon_{t-1}, \dots, \varepsilon_{t-n}$ — ошибки.

Фурье-модель (FFT)

Структурный параметр: количество главных частот из прямого преобразования Фурье,

$$w_{2j} = \operatorname{Re} \sum_{k=1}^n x_k \exp -\frac{2\pi i}{n} kj, w_{2j+1} = \operatorname{Im} \sum_{k=1}^n x_k \exp -\frac{2\pi i}{n} kj$$

Сингулярный спектр (SSA)


Структурный параметр: количество главных собственных значений.

$$S^T S = V H V^T, H = \operatorname{diag}(\lambda_1, \dots, \lambda_m)$$

Self-Modelling Regression (SEMOR)

$$g(x, w) = w_1 + w_2 p(w_3 + w_4 t)$$

$$w_{\text{SEMOR}} = [\hat{w}_1, \hat{w}_2, \hat{w}_3, \hat{w}_4, p]$$



Промежуточная выборка

- Для модели локальной аппроксимации $\mathbf{g}_i \in \mathbf{g}$ вычисляем

$$[\varphi_i^1, \dots, \varphi_i^k]^\top = \varphi(\mathbf{g}_i, \mathbf{w}, \mathbf{x})$$

- Конкатенируем векторы параметров φ_i набора моделей.

Отбор признаков

Признаки отбираются с помощью метода QPFS.

Пусть $\mathcal{J} = \{1, \dots, n\}$ — множество индексов признаков, $\mathcal{A} \subseteq \mathcal{J}$ — его подмножество. Решается задача поиска оптимального подмножества признаков:

$$\mathcal{A}^* = \arg \min_{\mathcal{A} \subseteq \mathcal{J}} Q(\mathcal{A} | \mathbf{X}, \mathbf{y}),$$

где Q — критерий качества.

Теорема Цыбенко

Пусть $\sigma(\xi)$ любая непрерывная сигмоидная функция, например, $\sigma(\xi) = 1/(1 + e^{-\xi})$. Тогда, если дана любая непрерывная функция действительных переменных f на $I_n = [0, 1]^n$ и $\varepsilon > 0$, тогда существуют векторы \mathbf{w} и параметризованная функция $G(\mathbf{x}, \sigma, \mathbf{w}) : I_n \rightarrow \mathbb{Y}$ такая, что $|G(\mathbf{x}, \mathbf{w}) - f(\mathbf{x})| < \varepsilon$ для всех $\mathbf{x} \in I_n$, где $\mathbf{w}_i \in \mathbb{R}^n$, $G = \sum_i \sigma(\mathbf{w}_i^T \mathbf{x})$.

Определим сложность модели, как минимальное число нейронов на скрытом слое полносвязной двухслойной нейросети, которое позволяет аппроксимировать данные с заданным качеством L^* :

$$\text{Comp}_{L^*}(\mathcal{D}) = \min(N | L = L^*)$$

Данные

Данные сняты с акселерометра.

4 типа движения: ходьба, бег, подъем по лестнице, спуск по лестнице

Частота дискретизации: 100 Гц.


Сегментация

Локальные экстремумы с окном и ограничения на длину сегментов


Нормализация

Данные приведены к одной размерности с помощью кубических сплайнов


Ходьба




Бег



Подъем по лестнице




Спуск по лестнице



Отбор признаков производится с помощью метода QPFS:

- Признаки сортируются по их значимости.
- Выбирается k наиболее значимый признаков.
- Оценивается качество обобщенной линейной модели (GLM) на выделенных признаках.





Сверху: Нормализованная значимость признаков.

Снизу: Матрица корреляции признаков.

Эксперимент. Сравнение моделей

Параметры двухслойной нейронной сети оптимизируются на выборке (\mathbf{X}, \mathbf{y}) .



Параметры GLM — на выборке (φ, \mathbf{y}) .



Эксперимент. Сравнение моделей на зашумленных данных



На выборку (\mathbf{X}, \mathbf{y}) накладывается гауссовский шум:

$$\tilde{\mathbf{X}} = \mathbf{X} + \epsilon, \epsilon \in \mathcal{N}(0, 1)^{n \times N}.$$



Эксперимент. Сравнение устойчивости моделей


Проанализируем падение качества моделей при зашумлении данных. Как видно из графиков, модель GLM устойчивее универсальной модели.



Эксперимент. Сравнение моделей

Полученные результаты изобразим в трехмерном пространстве «Точность-Устойчивость-Сложность».

Полученные данные демонстрируют, что обобщенно-линейная модель обученная на промежуточных признаках предпочтительнее универсальной.



- Метод построения ансамбля локально-аппроксимирующих моделей.
- Алгоритм выбора признаков в ансамбле локально-аппроксимирующих моделей с помощью дискретного квадратичного программирования.
- Критерий сложности модели классификация.
- Программная реализация (библиотека локального моделирования)

- Проект на github:
<https://github.com/livenrlty/Local-Approximation-Models>