

Классификация временных рядов в пространстве параметров порождающих моделей

Карасиков Михаил

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

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

Москва, 2015 г.

Исследуется

Задача построения пространства признаков для многоклассовой классификации временных рядов

Проблема

Построение краткого интерпретируемого признакового описания временных рядов

Цели исследования:

- построение алгоритма многоклассовой классификации, использующего в качестве признаков временных рядов параметры моделей временных рядов и их распределения,
- обобщение методов классификации временных рядов, использующих явное признаковое описание,
- повышение качества решения задач классификации временных рядов.

- Time-series data mining / P. Esling, C. Agon // ACM Comput. Surv. — 2012.— December.— Vol. 45, no. 1.— Pp. 12:1–12:34.
- Segment and combine approach for non-parametric time-series classification / P. Geurts, L. Wehenkel // Knowledge Discovery in Databases: PKDD 2005.— Springer, 2005.— Pp. 478–485.
- Human activity recognition using smart phone embedded sensors: A linear dynamical systems method / W. Wang, H. Liu, L. Yu, F. Sun // Neural Networks (IJCNN), 2014 International Joint Conference on.— 2014.—July.— Pp. 1185–1190. //doi.acm.org/10.1145/1964897.1964918.

Дано: $X = \{x_i = [x_i^{(1)}, \dots, x_i^{(t)}] : i \in \mathcal{I}\}$ — временные ряды,
 Y — множество меток классов,
 $\mathcal{D} \subset X \times Y$ — обучающая выборка.

Модель классификации: $a = b \circ \mathbf{f} \circ S$, где

S — алгоритм сегментации $S : x \mapsto \{s^{(1)}, \dots, s^{(p)}\}$,

где $s^{(k)} = [x^{(t_k)}, \dots, x^{(t_{k+1}-1)}]$.

\mathbf{f} — признаковое описание набора сегментов,

b — алгоритм многоклассовой классификации.

Метод обучения $\mu : \mathcal{D} \mapsto a$

выбирается по скользящему контролю:

$$\mu^* = \arg \min_{\mu} \widehat{CV}(\mu, \mathcal{D}).$$

Сегменты временных рядов описывается моделями вида

$$g(\mathbf{w}, x) \in X, \text{ где } \mathbf{w} \in \mathbb{R}^n.$$

Параметры настроенной модели определяются по формуле

$$\mathbf{w}_g(x) = \arg \min_{\mathbf{w} \in \mathbb{R}^n} \rho(g(\mathbf{w}, x), x).$$

Исследуются

- Модель линейной регрессии
- Модель авторегрессии (AR)
- Фурье-модель
- Вейвлет-модель

. Пусть задан многокомпонентный временной ряд

$$x = [\mathbf{x}^{(1)}, \dots, \mathbf{x}^{(t)}], \text{ где } \mathbf{x}^{(k)} = [x_0^{(k)}, \dots, x_n^{(k)}]^\top.$$

Модель линейной регрессии одной из компонент на остальные:

$$g(\mathbf{w}, x) = [\hat{\mathbf{x}}^{(1)}, \dots, \hat{\mathbf{x}}^{(t)}], \text{ где } \hat{\mathbf{x}}^{(k)} = [\hat{x}_0^{(k)}, x_1^{(k)}, \dots, x_n^{(k)}]^\top,$$

$$\hat{\mathbf{x}}_0 = \begin{bmatrix} \hat{x}_0^{(1)} \\ \vdots \\ \hat{x}_0^{(t)} \end{bmatrix} = \underbrace{\begin{bmatrix} x_1^{(1)} & \dots & x_n^{(1)} \\ \vdots & \ddots & \vdots \\ x_1^{(t)} & \dots & x_n^{(t)} \end{bmatrix}}_X \underbrace{\begin{bmatrix} w_1 \\ \vdots \\ w_n \end{bmatrix}}_{\mathbf{w}}.$$

Тогда, выбрав в качестве ρ евклидово расстояние, получим

$$\mathbf{w}_g(x) = \arg \min_{\mathbf{w} \in \mathbb{R}^n} \rho(g(\mathbf{w}, x), x) = \left(X^\top X \right)^{-1} X^\top \mathbf{x}_0.$$

Задан временной ряд

$$x = [x^{(1)}, \dots, x^{(t)}], \quad x^{(k)} \in \mathbb{R}, \quad k = 1, \dots, t.$$

Модель аппроксимации — авторегрессионная модель порядка p :

$$g(\mathbf{w}, x) = [x^{(1)}, \dots, x^{(p)}, \hat{x}^{(p+1)}, \dots, \hat{x}^{(t)}],$$

где

$$\hat{x}^{(k)} = w_0 + \sum_{i=1}^p w_i x^{(k-i)}, \quad k = p+1, \dots, t.$$

Признаковое описание $\mathbf{w}_g(x)$ определяется аналогично случаю линейной регрессии.

Предлагаются две схемы решения исходной задачи.

- Принцип голосования: обучение алгоритма b на новой обучающей выборке $\widehat{\mathcal{D}}$, составленной из сегментов временных рядов исходной обучающей выборки \mathcal{D} :

$$\widehat{\mathcal{D}} = \{(\mathbf{w}_g(s), y) : (x, y) \in \mathcal{D}, s \in S(x)\}$$

и последующая классификация

$$a(x; S, g, b) = h(\{b(\mathbf{w}_g(s)) : s \in S(x)\}).$$

- Классификация в пространстве гиперпараметров моделей (параметров распределений параметров моделей).

$\mathbf{w}_g \circ S$ дает множество наборов параметров модели:

$$W(x; S, g) = \{\mathbf{w}_g(s) : s \in S(x)\}.$$

Гипотеза порождения временного ряда

Сегменты временного ряда $s \in S(x)$ описываются моделью $g(\mathbf{w}, s)$ со случайными параметрами \mathbf{w} из параметрического семейства распределений $\{P_{\theta}\}_{\theta \in \Theta}$.

Предлагается в качестве признакового описания временного ряда использовать оценку вектора параметров распределения:

$$\mathbf{f}(x; S, g, \Theta) = \arg \max_{\theta \in \Theta} \mathcal{L}(\theta | W(x; S, g)).$$

Тогда получим алгоритм классификации временных рядов:

$$a(x) = b(\mathbf{f}(x; S, g, \Theta)).$$

- One-vs-All approach:

$$a(x) = \arg \max_{i=1, \dots, N} f_i(x), \quad f_i(x) = \begin{cases} \geq 0, & \text{если } y(x) = i, \\ < 0, & \text{если } y(x) \neq i. \end{cases}$$

- One-vs-One approach:

$$a(x) = \arg \max_{i=1, \dots, N} \sum_{\substack{j=1, \dots, N \\ j \neq i}} f_{ij}(x), \quad f_{ij}(x) = \begin{cases} +1, & \text{если } y(x) = i, \\ -1, & \text{если } y(x) = j. \end{cases}$$

- Error-Correcting Output Codes approach:

$$a(x) = \arg \min_{i=1, \dots, N} \sum_{j=1}^F L(M_j^i f_j(x)),$$

где $M \in \{-1, 0, +1\}^{N \times F}$ — матрица, строки которой состоят из кодов меток классов Y , а L — функция потерь.

Пусть $\mathbf{f}(x) \in \mathbb{R}^n$ — признаковое описание временного ряда x .

Тогда для решения задачи бинарной классификации временных рядов необходимо задать метод обучения $\mu_b : \mathcal{D} \mapsto f$.

Например,

- SVM с линейным ядром:

$$f(x; \mathbf{w}) = \text{sign}(\mathbf{w}^T \mathbf{f}(x) - w_0),$$

где \mathbf{w} и w_0 — решения оптимизационной задачи

$$\frac{1}{2C} \|\mathbf{w}\|^2 + \sum_{(x,y) \in \mathcal{D}} \left(1 - y(\mathbf{w}^T \mathbf{f}(x) - w_0)\right)_+ \rightarrow \min_{\mathbf{w} \in \mathbb{R}^n, w_0 \in \mathbb{R}};$$

- регуляризованная лог. регрессия (RLR):

$$\frac{1}{2C} \|\mathbf{w}\|^2 + \sum_{(x,y) \in \mathcal{D}} \log \left(1 + e^{-y\mathbf{w}^T \mathbf{f}(x)}\right) \rightarrow \min_{\mathbf{w} \in \mathbb{R}^n}.$$

В качестве приложения рассматривается задача классификации физической активности по данным с акселерометра.

Особенности

- Классификация физической активности людей с разными физическими характеристиками
- Форма временного ряда существенно зависит от характеристик человека
- Во временных рядах допускаются аномалии

Предположение

Форма временного ряда сохраняются для конкретного человека и типа физической активности

Цели эксперимента:

- 1 демонстрация качества предлагаемого алгоритма
- 2 изучение зависимости качества классификации от
 - алгоритма сегментации
 - модели сегмента

Временной ряд из трех компонент: $\mathbf{x} = [x_t^k]^{k=1,2,3}$.

Признаки (по 31 на каждый временной ряд)

1 7 коэффициентов авторегрессии $AR(6)$:

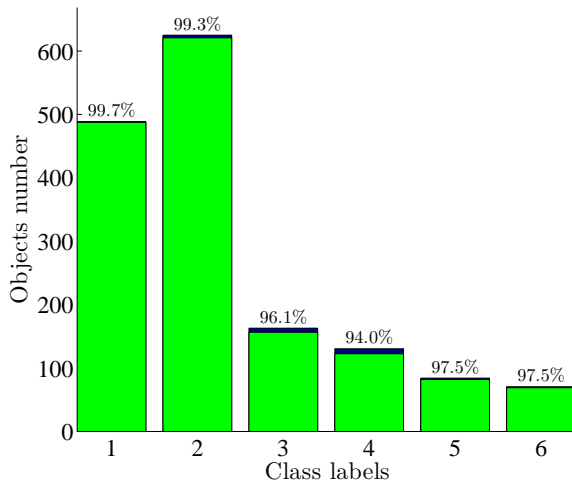
$$\arg \min_{w_0, \dots, w_6} \sum_t \left(x_t^k - w_0 - \sum_{i=1}^6 w_i x_{t-i}^k \right)^2.$$

2 Статистики:

- $\bar{x}^k = \frac{1}{T} \sum_t x_t^k$,
- $\frac{1}{T} \sum_t |x_t^k - \bar{x}^k|$,
- $\sqrt{\frac{1}{T-1} \sum_t (x_t^k - \bar{x}^k)^2}$,
- $\frac{1}{T} \sum_t \|\mathbf{x}_t\|$.

Без сегментации, классификатор RBF SVM ($\gamma = 0.8$, $C = 4$),
подход One-vs-All, 50 случайных разбиений в отношении 7 к 3.

Mean accuracy: 0.9849



Class labels:

- 1 Jogging
- 2 Walking
- 3 Upstairs
- 4 Downstairs
- 5 Sitting
- 6 Standing

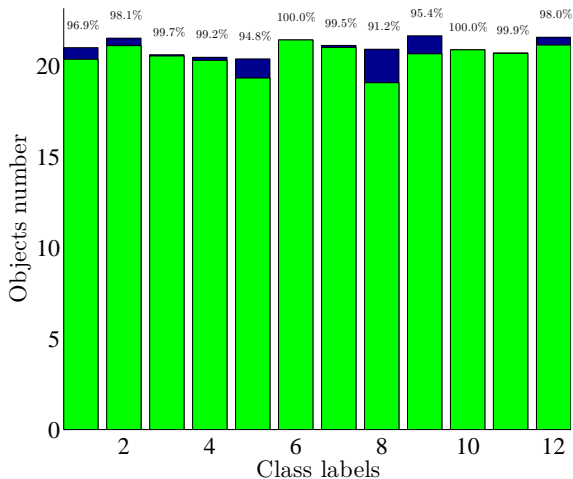
Выборка содержит: показания акселерометра и гироскопа для 12 типов физической активности.

Частота исходной выборки 100 Hz.
Приведем данные к частоте 10 Hz.

Будем решать задачу многоклассовой классификации, классификатор RBF SVM ($C = 16$, $\gamma = 0.04$), подход One-vs-All, 100 случайных разбиений в пропорции 7 к 3.

В качестве признаков берутся коэффициенты модели авторегрессии $AR(10)$ и первые 5 коэффициентов модели Фурье.

Mean accuracy: 0.9772



Class labels:

- 1 walk forward
- 2 walk left
- 3 walk right
- 4 go upstairs
- 5 go downstairs
- 6 run forward
- 7 jump up and down
- 8 sit and fidget
- 9 stand
- 10 sleep
- 11 elevator up
- 12 elevator down




Рис.: На первых 10 классах. One-vs-One, Linear SVM ($C = 0.25$).

- Метод классификации временных рядов в пространстве параметров моделей показывает высокие результаты.
- Использование модели авторегрессии не накладывает ограничений на алгоритм сегментации.
- При случайной сегментации голосование сегментов оказывается лучше алгоритма классификации в пространстве гиперпараметров.

- Предложен алгоритм построения пространства признаков.
- Предложены алгоритмы классификации временных рядов.
- Выполнена программная реализация и проведены численные эксперименты, показавшие повышение качества решения задачи классификации типов физической активности.