

# Прогностические мультимодели разномасштабных временных рядов интернета вещей

Нейчев Радослав Георгиев

МФТИ, ФУПМ

Кафедра «Интеллектуальные системы»

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

29 июня 2016

# Цели работы


Решается проблема прогнозирования большого числа разнородных мультимасштабных временных рядов.

## Проблемы


- Временные ряды, генерируемые устройствами, представлены с различной частотой дискретизации.
- Ввиду разнородности данных, генерируемых интернетом вещей, их описание с помощью единой модели затруднительно.

## Метод


- Для построения авторегрессионной матрицы временные ряды оптимально ресемплируются. Отношение частот приводится к рациональным числам.
- Для повышения качества прогноза используется смесь моделей (экспертов).




Необходимо найти отображение  $f : X \rightarrow Y$ , доставляющее наименьшую ошибку.



Представление временного ряда.



Порождение пары объект-ответ.



Генерация объектов.



- Decision forests for Classification, Regression, Density Estimation, Manifold Learning and Semi-Supervised Learning. *A. Criminisi, J. Shotton, E. Konucoglu* / Microsoft Research technical report TR-2011-114.
- Short-Term Load Forecasting Using Random Forests. *Gregor Dudec* / Intelligent systems, 2014.
- Kernel-based mixture of experts models for linear regression. *J. Santarcangelo, X. Zhang* / IEEE 2015.
- Stresstest procedure for feature selection algorithms. *A.M. Katrutsa, V.V. Strijov* / Chemometrics and Intelligent Laboratory Systems 2015.

Для рядов  $s_1, \dots, s_l$  строится матрица объект-признак:

$$\mathbf{X}^* = \left[ \begin{array}{c|ccc} \hat{\mathbf{y}}' & \mathbf{x}'_0 & \mathbf{x}''_0 & \dots \\ \mathbf{y}'_1 & \mathbf{x}'_1 & \mathbf{x}''_1 & \dots \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{y}'_m & \mathbf{x}'_m & \mathbf{x}''_m & \dots \end{array} \right] = \left[ \begin{array}{c|c} \hat{\mathbf{y}} & \mathbf{x}_0 \\ \hline \mathbf{Y} & \mathbf{X} \\ \hline m \times r & m \times n \end{array} \right].$$


Для получения прогноза  $\hat{\mathbf{y}} = \hat{\mathbf{f}}(\mathbf{x}_0)$  требуется найти отображение  $\hat{\mathbf{f}} : \mathbf{X} \rightarrow \mathbf{Y}$ , такое что

$$\hat{\mathbf{f}} = \arg \min_{\mathbf{f}} S(\mathbf{f}, \mathbf{X}, \mathbf{Y}),$$




где  $S(\mathbf{f}, \mathbf{X}, \mathbf{Y})$  — фиксированная функция ошибки.  
В качестве  $\hat{\mathbf{f}}$  выступает смесь моделей (экспертов).

# Шлюзовая функция

*Шлюзовая функция* (англ. gating function) — отображение  $\pi(\mathbf{x}, \mathbf{v}) : X \rightarrow [0, 1]$ , определяющее вероятность того, что соответствующая ей модель  $\mathbf{f}$  описывает объект  $\mathbf{x} \in X$ , где  $X$  — пространство объектов.



Если в смеси моделей заменить веса моделей на шлюзовые функции  $\pi_k(\mathbf{x}, \mathbf{v})$ , получится **смесь экспертов**.



Смесь двух экспертов (полиномов второй степени) на синтетических данных.



Пусть есть  $K$  линейных моделей  $\mathbf{f}_1, \dots, \mathbf{f}_K$ , пару  $(\mathbf{x}, \mathbf{y})$   $k$ -ая модель описывает с вероятностью  $p(k|\mathbf{x}, \mathbf{w})$ . С учетом всех моделей

$$\begin{aligned} p(\mathbf{y}|\mathbf{x}, \boldsymbol{\theta}) &= \sum_{k=1}^K p(\mathbf{y}, k|\mathbf{x}, \boldsymbol{\theta}) = \sum_{k=1}^K p(k|\mathbf{x}, \boldsymbol{\theta})p(\mathbf{y}|k, \mathbf{x}, \boldsymbol{\theta}) = \\ &= \sum_{k=1}^K \frac{\exp(\mathbf{v}_k^T \mathbf{x})}{\sum_{k'=1}^K \exp(\mathbf{v}_{k'}^T \mathbf{x})} \exp\left(\left(-\frac{1}{2\beta_k}(\mathbf{y} - \mathbf{w}_k^T \mathbf{X})^T(\mathbf{y} - \mathbf{w}_k^T \mathbf{X})\right)\right). \end{aligned}$$

За  $\boldsymbol{\theta}$  обозначен вектор гиперпараметров

$$\boldsymbol{\theta} = [\mathbf{w}_1, \dots, \mathbf{w}_k, \boldsymbol{\pi}(\mathbf{x}, \mathbf{v}), \beta]^T,$$

где  $\mathbf{B} = \beta \mathbf{I}_m$  — ковариационная матрица  $\mathbf{y}$ .

Чтобы найти оценку максимального правдоподобия  $\hat{\theta}$

$$\hat{\theta} = \operatorname{argmax}_{\theta} \ln p(\mathbf{y}|\theta),$$

введем скрытые индикаторные переменные  $Z = [\mathbf{z}_1, \dots, \mathbf{z}_m]$ ,  $z_{ik} \in \{0, 1\}$ , такие что

$$z_{ik} = 1 \Leftrightarrow y_i \sim \mathcal{N}(\mathbf{w}_k^T \mathbf{x}_i, \beta).$$

В таком случае логарифм правдоподобия имеет вид

$$p(\mathbf{y}|X, Z, \theta) = \sum_{i=1}^m \sum_{k=1}^K z_{ik} (\ln \pi_k(\mathbf{x}_i, \mathbf{v}_k) + \ln \mathcal{N}(y_i | \mathbf{w}_k^T \mathbf{x}_i, \beta)).$$

Перейдем к матожиданию по  $Z$  и применим **EM-алгоритм** для максимизации  $E_Z[p(\mathbf{y}, Z|X, \theta)]$ .

# EM-алгоритм для смеси экспертов

**E-шаг:** По правилу Байеса

$$\gamma_{ik}^{r+1} = E(z_{ik}) = p(k|\mathbf{x}_i, \boldsymbol{\theta}^r) = \frac{\pi_k(\mathbf{x}_i, \mathbf{v}_k) \mathcal{N}(\mathbf{y}_i | \mathbf{x}_i^T \mathbf{w}_k^r, \beta^r)}{\sum_{k'=1}^K \pi_{k'}(\mathbf{x}_i, \mathbf{v}_{k'}) \mathcal{N}(\mathbf{y}_i | \mathbf{x}_i^T \mathbf{w}_{k'}^r, \beta^r)}.$$

**M-шаг:** Пересчитывается оценка параметров

$$\mathbf{v}_k^{r+1} = \operatorname{argmax}_{\mathbf{v}} \sum_{i=1}^m \gamma_{ik}^{r+1} \ln \pi_k(\mathbf{x}_i, \mathbf{v}),$$

$$\mathbf{w}_k^{r+1} = \operatorname{argmax}_{\mathbf{w}_k} \left[ - \sum_{i=1}^m \gamma_{ik}^{r+1} (y_i - \mathbf{w}_k^T \mathbf{x}_i)^2 \right],$$

$$\beta_k^{r+1} = \operatorname{argmax}_{\beta} \left[ n \ln \beta - \frac{1}{\beta} (y_i - \mathbf{x}_i^T \mathbf{w}_k^{r+1})^2 \right].$$

В случае смеси моделей вместо выражения для  $\mathbf{v}_k^{r+1}$  используется  $\pi_k^{r+1} = \frac{1}{n} \sum_{i=1}^m \gamma_{ik}^{r+1}$

## Цель эксперимента


Показать, что разбиение обучающей выборки и применение к подвыборкам простых моделей позволяет получать адекватные результаты.

Сравнивались прогнозы, полученные с помощью следующих моделей:



- MLR — Векторная линейная регрессия с  $l_2$  регуляризацией.
- Нейронные сети.
- SVR — Support Vector Regression machine.
- Random Forest — простой вариант смеси моделей.

Данные по потреблению электроэнергии в Польше за период 1999-2004, включающие в себя:



- Почасовые значения потребления электроэнергии (52512 наблюдений)
- Шесть временных рядов, фиксирующих природные показатели: максимальная и минимальная температуры, влажность, количество осадков, сила ветра, облачность (2188 наблюдений).



# Построение матрицы объект-признак и результаты



Модель	Train	Test
Baseline	0.213	0.211
MLR	0.120	0.126
MSVR	0.076	0.082
Random Forest	0.069	0.084
Neural network	0.176	0.184



# Основные результаты данной работы

- Предложен комплексный подход к прогнозированию временных рядов, позволяющий работать с разномасштабными данными.
- Теоретически обоснована применимость мультимodelей к задаче прогнозирования и произведена практическая проверка данного подхода в рамках вычислительного эксперимента.

## Список публикаций:

- ① Выбор оптимального набора признаков из мультикоррелирующего множества в задаче прогнозирования. *Нейчев Р.Г., Катруца А.М., Стрижов В.В.* / Заводская лаборатория. №3 2016. Том 2.
- ② Отбор мультикоррелирующих признаков в задаче векторной авторегрессии. *Ахтямов П.И., Нейчев Р.Г., Стрижов В.В.* / готовится к подаче.
- ③ Feature generation for multiscale time series forecasting. *Мотренко А.П., Нейчев Р.Г., Исаченко Р.В., Попова М.С., Стрижов В.В.* / подана на ICDM 2016.