

Метод «Гусеница»–SSA для анализа временных рядов с пропусками

Осипов Евгений Вадимович, 522-я группа

Санкт-Петербургский Государственный Университет
Математико-механический факультет
Кафедра статистического моделирования

Научный руководитель — к.ф.-м.н. Н.Э. Голяндина
Рецензент — к.ф.-м.н. В.В. Некруткин

Постановка задачи

- Базовый метод «Гусеница»–SSA эффективно решает задачу выявления составляющих временного ряда:
 - трендовой,
 - гармонических,
 - шумовых.
- Метод применим для рядов без пропусков.
- Многие реальные временные ряды часто содержат пропуски.
- *Задача:*
построить модифицированный алгоритм, который
 - решает те же задачи,
 - заполняет пропуски.

Понятия метода «Гусеница»–SSA

- $F_N = (f_0, \dots, f_{N-1})$, L — длина окна;
- Вектора вложения $\{X_i\}_{i=1}^K$, $K = N - L + 1$,
 $X_i = (f_{i-1}, \dots, f_{i+L-1})^T$, $\mathbf{X} = [X_1 : \dots : X_L]$;
- $\mathcal{L}^{(L)}(F_N) = \text{span}(X_1, \dots, X_L)$ — траекторное пространство,
его базис $\{U_i\}$ — собственные вектора $\mathbf{S} = \mathbf{X}\mathbf{X}^T$,
SVD матрицы \mathbf{X} : $\mathbf{X} = \sum \sqrt{\lambda_i} U_i V_i^T$;
- Выделение $F_N^{(1)}$ из $F_N = F_N^{(1)} + F_N^{(2)}$:
 - выбор $\{i_1, \dots, i_r\}$ и построение $\mathcal{L}^{(1)} = \text{span}(U_{i_1}, \dots, U_{i_r})$;
 - проектирование векторов $\{X_i\}_{i=1}^K$ на $\mathcal{L}^{(1)} \longrightarrow \widehat{\mathbf{X}}^{(1)} = [\widehat{X}_1^{(1)} : \dots : \widehat{X}_L^{(1)}]$;
 $\widehat{X}_i^{(1)} = \boldsymbol{\Pi}^{(1)} X_i$;
 - диагональное усреднение: $\widehat{\mathbf{X}}^{(1)} \longrightarrow \widehat{F}_N^{(1)}$.

Понятия метода «Гусеница»–SSA

- $F_N = (f_0, \dots, f_{N-1})$, L — длина окна;
- Вектора вложения $\{X_i\}_{i=1}^K$, $K = N - L + 1$,
 $X_i = (f_{i-1}, \dots, f_{i+L-1})^T$, $\mathbf{X} = [X_1 : \dots : X_L]$;
- $\mathcal{L}^{(L)}(F_N) = \text{span}(X_1, \dots, X_L)$ — траекторное пространство,
его базис $\{U_i\}$ — собственные векторы $\mathbf{S} = \mathbf{X}\mathbf{X}^T$,
SVD матрицы \mathbf{X} : $\mathbf{X} = \sum \sqrt{\lambda_i} U_i V_i^T$;
- Выделение $F_N^{(1)}$ из $F_N = F_N^{(1)} + F_N^{(2)}$:
 - выбор $\{i_1, \dots, i_r\}$ и построение $\mathcal{L}^{(1)} = \text{span}(U_{i_1}, \dots, U_{i_r})$;
 - проектирование векторов $\{X_i\}_{i=1}^K$ на $\mathcal{L}^{(1)}$ $\longrightarrow \widehat{\mathbf{X}}^{(1)} = [\widehat{X}_1^{(1)} : \dots : \widehat{X}_L^{(1)}]$;
 $\widehat{X}_i^{(1)} = \boldsymbol{\Pi}^{(1)} X_i$;
 - диагональное усреднение: $\widehat{\mathbf{X}}^{(1)} \longrightarrow \widehat{F}_N^{(1)}$.

Понятия метода «Гусеница»–SSA

- F_N — ряд *конечного ранга* d , если $\dim \mathcal{L}^{(L)}(F_N) = d \quad \forall L.$
- *Любой ряд, являющийся линейной комбинацией произведений полиномов, экспонент и гармоник, является рядом конечного ранга.*
- Прогнозирование значений ряда в $\mathcal{L}^{(L)}(F_N)$, т.е. получение последней компоненты вектора вложения в виде линейной комбинации остальных.
- $F_N^{(1)}$ и $F_N^{(2)}$ *слабо разделимы*, если $\mathcal{L}^{(1)} \perp \mathcal{L}^{(2)}$ и $\mathcal{K}^{(1)} \perp \mathcal{K}^{(2)}$.
- Наличие разделимости дает возможность выделить $F_N^{(1)}$ из $F_N^{(1)} + F_N^{(2)}$.

Построение базиса $\mathcal{L}^{(L)}(F_N)$

- $F_{12} = (\star \star \star \star \star \star \cdot \cdot \cdot \star \star), \quad L = 5, d = 2$

$$\mathbf{X} = \begin{pmatrix} \star & \star & \star & \star & \star & \star & \cdot & \cdot \\ \star & \star & \star & \star & \star & \cdot & \cdot & \cdot \\ \star & \star & \star & \star & \cdot & \cdot & \cdot & \cdot \\ \star & \star & \star & \cdot & \cdot & \cdot & \cdot & \star \\ \star & \star & \cdot & \cdot & \cdot & \cdot & \star & \star \end{pmatrix}.$$

- **Предложение 1** Если среди векторов вложения, не содержащих пропущенные значения, найдется хотя бы d линейно независимых, то траекторное пространство столбцов находится точно.
- **Предложение 2** Если ряд F_N имеет ранг d , $e_1, e_L \notin \mathcal{L}^{(L)}(F_N)$, и ряд имеет $L + d - 1$ подряд идущих непропущенных значений, то траекторное пространство столбцов находится точно.

Проектирование векторов вложения

- $F_N = F_N^{(1)} + F_N^{(2)}$, разделимость $(\mathcal{L}^{(1)} \perp \mathcal{L}^{(2)})$, $\{R_i\}_{i=1}^d$ – базис $\mathcal{L}^{(1)}$;
- $X = \begin{pmatrix} X \Big|_{\mathcal{I} \setminus \mathcal{P}} \\ \cdot \end{pmatrix} \xrightarrow{\text{I}} \begin{pmatrix} X^{(1)} \Big|_{\mathcal{I} \setminus \mathcal{P}} \\ \cdot \end{pmatrix} \xrightarrow{\text{II}} \begin{pmatrix} X^{(1)} \Big|_{\mathcal{I} \setminus \mathcal{P}} \\ X^{(1)} \Big|_{\mathcal{P}} \end{pmatrix},$
 \mathcal{P} – множество индексов пропущенных значений в X , $\mathcal{I} = \{1, \dots, L\}$;
- **Предложение 3** Пусть $\mathcal{L}^{(1)} \Big|_{\mathcal{I} \setminus \mathcal{P}} \perp \mathcal{L}^{(2)} \Big|_{\mathcal{I} \setminus \mathcal{P}}$.
 Тогда $X^{(1)} \Big|_{\mathcal{I} \setminus \mathcal{P}} = \Pi_{\mathcal{I} \setminus \mathcal{P}}^{(1)} \left(X \Big|_{\mathcal{I} \setminus \mathcal{P}} \right)$ и для $\mathbf{R} = [R_1 : \dots : R_d]$

$$\Pi_{\mathcal{I} \setminus \mathcal{P}}^{(1)} = \mathbf{R} \Big|_{\mathcal{I} \setminus \mathcal{P}} \left(\mathbf{R} \Big|_{\mathcal{I} \setminus \mathcal{P}} \right)^T + \mathbf{R} \Big|_{\mathcal{I} \setminus \mathcal{P}} \left(\mathbf{R} \Big|_{\mathcal{P}} \right)^T \left(\mathbf{E}_{|\mathcal{P}|} - \mathbf{R} \Big|_{\mathcal{P}} \mathbf{R}^T \Big|_{\mathcal{P}} \right)^{-1} \mathbf{R} \Big|_{\mathcal{P}} \left(\mathbf{R} \Big|_{\mathcal{I} \setminus \mathcal{P}} \right)^T;$$
- **Предложение 4** Пусть $\text{span}(e_i | i \in \mathcal{P}) \cap \mathcal{L}^{(1)} = \{0_L\}$.
 Тогда $X^{(1)} \Big|_{\mathcal{P}} = \left(\mathbf{E}_{|\mathcal{P}|} - \mathbf{R} \Big|_{\mathcal{P}} \mathbf{R}^T \Big|_{\mathcal{P}} \right)^{-1} \mathbf{R} \Big|_{\mathcal{P}} \mathbf{R}^T \Big|_{\mathcal{I} \setminus \mathcal{P}} X^{(1)} \Big|_{\mathcal{I} \setminus \mathcal{P}}$.

Группы пропусков и их заполнение

- Пропуски \rightarrow группы (внутренние, левые/правые, сплошные);

$$L = 3, \quad F_{19} = (\star \star \underset{(1)}{\underset{\curvearrowleft}{\star}} : \underset{(2)}{\underset{\curvearrowright}{\star \star \star \star}} \underset{(3)}{\underset{\curvearrowright}{\star \star \star \star}} \dots)$$

(1) — левая, (2) — внутренняя сплошная, (3) — правая сплошная;

- Группа пропусков \longleftrightarrow набор векторов вложсения группы пропусков

$$(2) : \begin{pmatrix} \star & \star & \cdot & \cdot & \cdot \\ \star & \cdot & \cdot & \cdot & \star \\ \cdot & \cdot & \cdot & \star & \star \end{pmatrix};$$

- Разные способы заполнения пропусков

$$\begin{pmatrix} \star & \star & \color{red}{\triangle} & \color{green}{\triangle} & \color{blue}{\triangle} \\ \star & \color{red}{\triangle} & \color{green}{\triangle} & \color{blue}{\triangle} & \star \\ \color{red}{\triangle} & \color{green}{\triangle} & \color{blue}{\triangle} & \star & \star \end{pmatrix}.$$

Заполнение группы пропусков

- $$\begin{pmatrix} f_{i_1-3} & f_{i_1-2} & f_{i_1-1} & \cdot & \cdot \\ f_{i_1-2} & f_{i_1-1} & \cdot & \cdot & f_{i_1+2} \\ f_{i_1-1} & \cdot & \cdot & f_{i_1+2} & f_{i_1+3} \\ \cdot & \cdot & f_{i_1+2} & f_{i_1+3} & f_{i_1+4} \end{pmatrix};$$
- $$X|_{\mathcal{P}} = (\mathbf{E}_{|\mathcal{P}|} - \mathbf{R}|_{\mathcal{P}} \mathbf{R}^T|_{\mathcal{P}})^{-1} \mathbf{R}|_{\mathcal{P}} \mathbf{R}^T|_{\mathcal{I} \setminus \mathcal{P}} X|_{\mathcal{I} \setminus \mathcal{P}};$$
- Применение формулы к каждому вектору набора векторов *вложеия группы* — «*Одновременное восстановление пропусков*»;
- Другой способ — «*Последовательное восстановление слева (справа)*» на основе формулы при $\mathcal{P} = \{L\}$ ($\mathcal{P} = \{1\}$).
$$\begin{pmatrix} f_{i_1-3} & f_{i_1-2} & f_{i_1-1} & L_1 & L_2 \\ f_{i_1-2} & f_{i_1-1} & L_1 & L_2 & f_{i_1+2} \\ f_{i_1-1} & L_1 & L_2 & f_{i_1+2} & f_{i_1+3} \\ L_1 & L_2 & f_{i_1+2} & f_{i_1+3} & f_{i_1+4} \end{pmatrix}.$$

Построение модифицированного алгоритма

Два способа построения модифицированного алгоритма:

- Формальная замена скалярного произведения на операцию “ * “:

$A = (a_1, \dots, a_m)^T$ — с множеством индексов пропусков \mathcal{A} ,

$B = (b_1, \dots, b_m)^T$ — с множеством индексов пропусков \mathcal{B} ,

$$A^T * B = \gamma \sum_{k:k \notin \mathcal{A} \cup \mathcal{B}} a_k b_k, \quad \text{где } \gamma = \frac{m}{m - |\mathcal{A} \cup \mathcal{B}|};$$

- Использование предложенных способов заполнения пропусков в выбранном подпространстве.

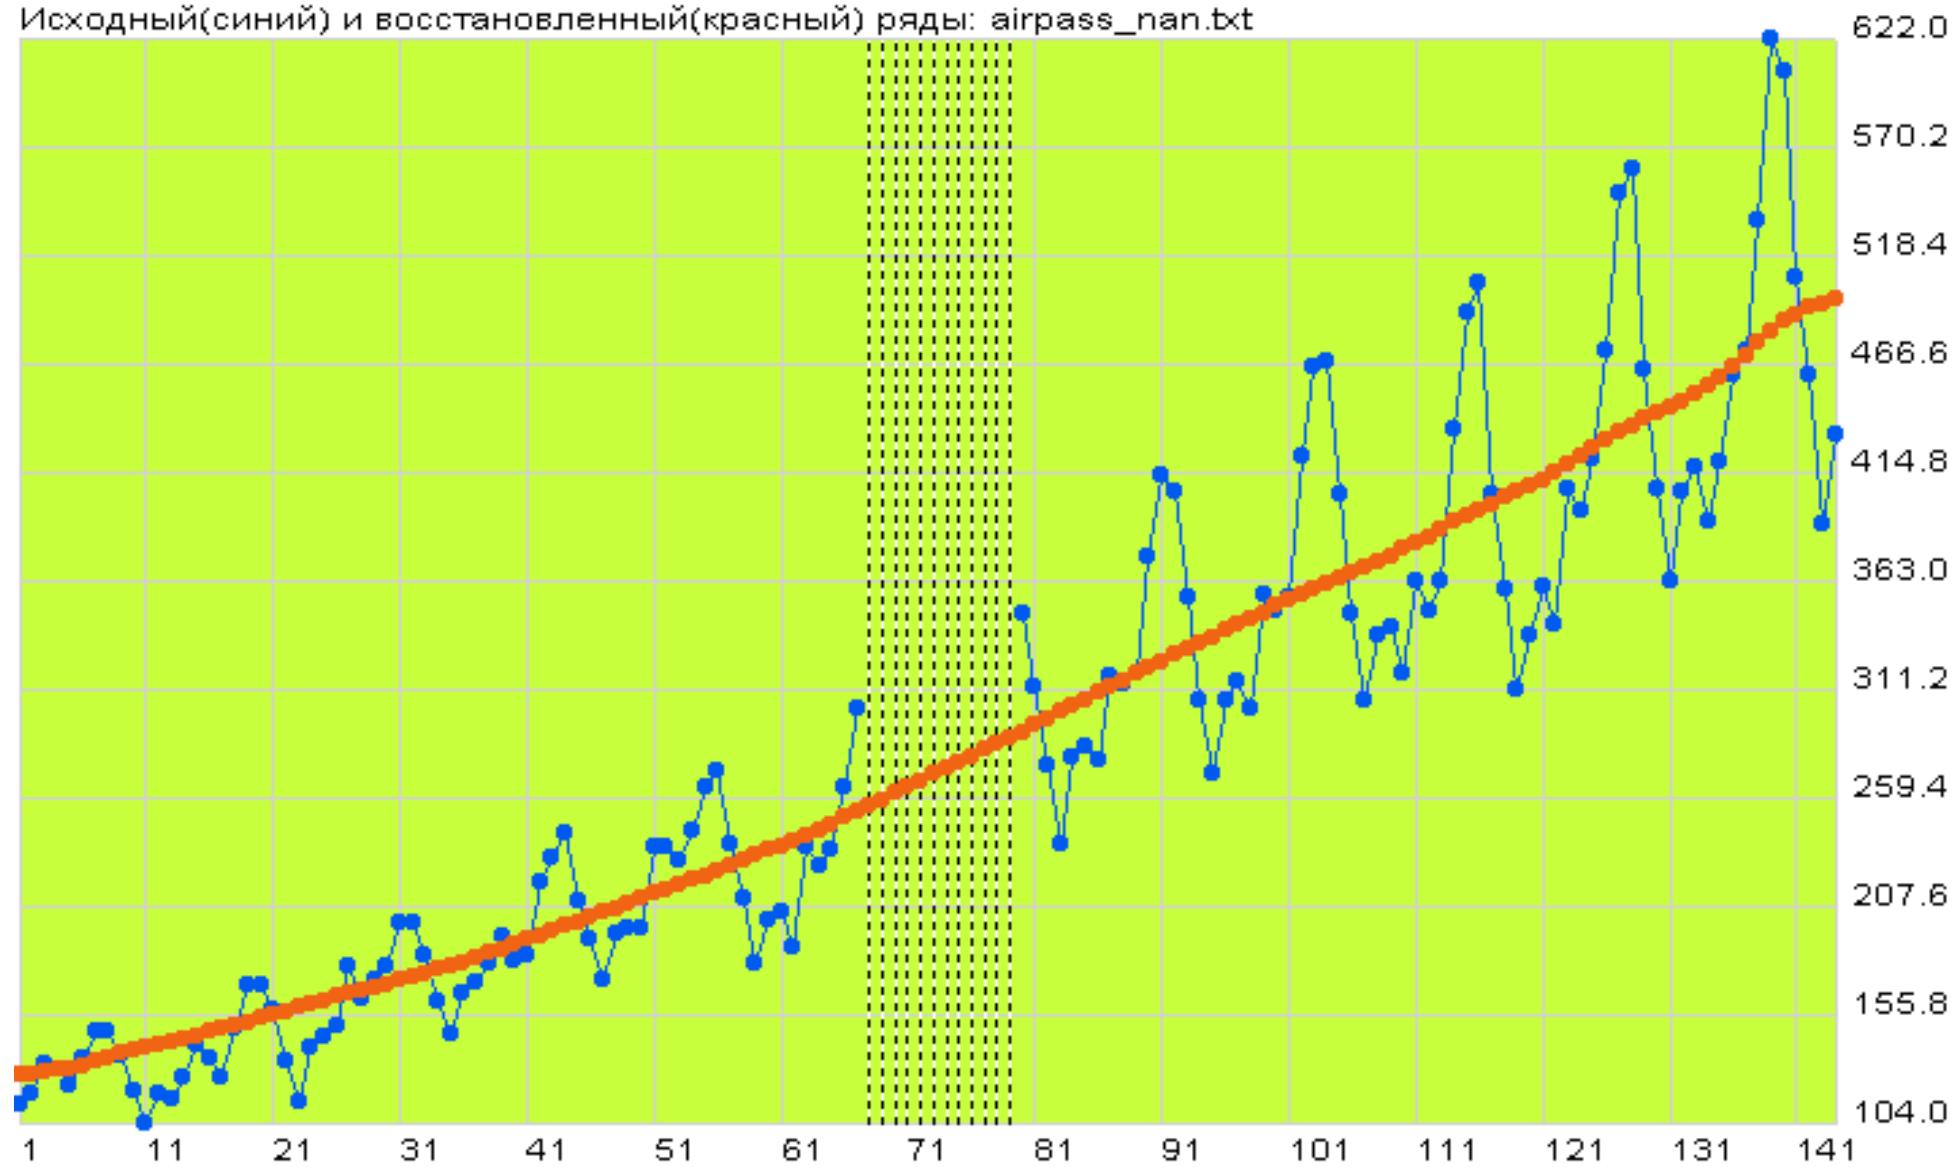
Программа

- Возможности программы позволяют обрабатывать реальные временные ряды;
- Реализовано много способов восстановления составляющих ряда с заполнением пропусков, что позволяет работать с различным расположением пропусков;
- Возможность применять различные методы к разным группам пропусков реализована в виде задания приоритетов методов.

Пример: ряд Airpass

Объемы пассажироперевозок по месяцам, отсутствует 1 год, $L = 36$

Исходный(синий) и восстановленный(красный) ряды: airpass_nan.txt



Пример: ряд Airpass

Тренд и главная часть сезонной составляющей

Исходный(синий) и восстановленный(красный) ряды: airpass_nan.txt

