



Mathematical methods of forecasting





Intelligent systems, Phystech



2022

$$s_t = \alpha \sum_{i=0}^{t-1} (1-\alpha)^i x_{t-i}$$

SSA



man

ana

ber

ser

$$X = U \Lambda V^T$$

$m \times n$ $m \times n$ $n \times n$

$$\hat{X} = \sum_{k=1}^r X_k$$

$$\sum V = \Lambda^2 V$$

$$a = [1, 3, 5]$$

$$[1, 0, 0, 0]$$

$$X_k = U_k \Lambda_k V_k^T$$

$$\hat{X} = U^T W$$

— kam wpor SSA.

uaz
kan
q


dim 1000
dim 3000

V_x

$$\Sigma = \frac{1}{n} X^T X$$

Linear Maps (geometrically) are spatial transforms that...

1. Keep gridlines parallel $X^T X = I$
2. Keep gridlines evenly spaced $u v^T = u \otimes v$
3. Keep the origin stationary



(Images taken from the American Math Society.)



SIAM.

$$\sigma_{\min}(A) \geq \tau$$

$$X = U \Lambda V^T$$

$\Lambda = \begin{pmatrix} \lambda_1 & & \\ & \ddots & \\ & & \lambda_n \end{pmatrix}$
 $\lambda_i \geq 0$

Рассмотрим квадратичный алгоритм решения этой задачи. Найдем последовательно векторы $\mathbf{u}_k, \mathbf{v}_k$ и сингулярные числа λ_k для $k = 1, \dots, r$. В качестве этих векторов берутся нормированные значения векторов \mathbf{a}_k и \mathbf{b}_k , соответственно


$$X = X_1 + \dots \quad \mathbf{u}_k = \frac{\mathbf{a}_k}{\|\mathbf{a}_k\|} \quad \text{и} \quad \mathbf{v}_k = \frac{\mathbf{b}_k}{\|\mathbf{b}_k\|}$$

Векторы \mathbf{a}_k и \mathbf{b}_k находятся как пределы последовательностей векторов $\{\mathbf{a}_{k_s}\}$ и $\{\mathbf{b}_{k_s}\}$, соответственно

$$\mathbf{a}_k = \lim_{s \rightarrow \infty} (\mathbf{a}_{k_s}) \quad \text{и} \quad \mathbf{b}_k = \lim_{s \rightarrow \infty} (\mathbf{b}_{k_s})$$

Сингулярное число λ_k находится как произведение норм векторов

$$\lambda_k = \|\mathbf{a}_k\| \cdot \|\mathbf{b}_k\|$$



$X^T A, X^T B$
 \downarrow
 X, X^T
B.

Рис. 13. Итеративная процедура оценивания сингулярных векторов.

Процедура нахождения последовательностей векторов $\mathbf{a}_{k_s}, \mathbf{b}_{k_s}$ $\mathbf{u}_k, \mathbf{v}_k$ начинается с выбора наибольшей по норме строки \mathbf{b}_{1_1} матрицы \mathbf{X} . Для $k = 1$ формулы нахождения векторов $\mathbf{a}_{1_s}, \mathbf{b}_{1_s}$ имеют вид:

$$\mathbf{a}_{1_s} = \frac{\mathbf{X} \mathbf{b}_{1_s}^T}{\mathbf{b}_{1_s}^T \mathbf{b}_{1_s}^T}, \quad \mathbf{b}_{1_{s+1}} = \frac{\mathbf{a}_{1_s}^T \mathbf{X}}{\mathbf{a}_{1_s}^T \mathbf{a}_{1_s}}, \quad s = 1, 2, \dots$$

Для вычисления векторов $\mathbf{u}_k, \mathbf{v}_k$ при $k = 2, \dots, r$ используется вышеприведенная формула, с той разницей, что матрица \mathbf{X} заменяется на скорректированную на k -м шаге матрицу $\mathbf{X}_{k+1} = \mathbf{X}_k - \mathbf{u}_k \lambda_k \mathbf{v}_k$. На рисунке ?? показаны две итерации, $s = 1, 2$, первого шага $k = 1$ упрощенной процедуры нахождения сингулярного разложения.

Требуется минимизировать евклидово расстояние от вектора \mathbf{y} до вектора $\mathbf{X}\mathbf{w}$. Этот вектор лежит в пространстве столбцов матрицы \mathbf{X} , так как $\mathbf{X}\mathbf{w}$ — это линейная комбинация столбцов этой матрицы с коэффициентами w_1, \dots, w_n . Задача оценки \mathbf{w} эквивалентна задаче нахождения точки $\mathbf{p} = \mathbf{X}\mathbf{w}$, ближайшей к \mathbf{y} и находящейся в пространстве столбцов матрицы \mathbf{X} . Следовательно, вектор \mathbf{p} должен быть проекцией \mathbf{y} на пространство столбцов, вектор регрессионных остатков $\mathbf{X}\mathbf{w} - \mathbf{y}$ должен быть ортогонален этому пространству. Рассмотрим произвольный вектор $\mathbf{X}\mathbf{v}$, ортогональный вектору регрессионных остатков $\mathbf{X}\mathbf{w} - \mathbf{y}$:

$$(\mathbf{X}\mathbf{v})^T(\mathbf{X}\mathbf{w} - \mathbf{y}) = \mathbf{v}^T(\mathbf{X}^T\mathbf{X}\mathbf{w} - \mathbf{X}^T\mathbf{y}) = 0.$$

Так как это равенство должно быть справедливо для произвольного вектора \mathbf{v} , то $\mathbf{X}^T\mathbf{X}\mathbf{w} - \mathbf{X}^T\mathbf{y} = 0$, см. рис. ???. Если столбцы матрицы \mathbf{X} линейно независимы, то матрица $\mathbf{X}^T\mathbf{X}$ обратима и уравнение имеет единственное решение относительно параметров.

$$\hat{\mathbf{x}} = \mathbf{w} = (\mathbf{X}^T\mathbf{X})^{-1}\mathbf{X}^T\mathbf{y} \quad (38)$$




Рис. 6. Проекция вектора зависимой переменной на пространство столбцов матрицы плана.

Проекция вектора \mathbf{y} на пространство столбцов матрицы \mathbf{X} имеет вид

$$\mathbf{p} = \mathbf{X}\mathbf{w} = \mathbf{X}(\mathbf{X}^T\mathbf{X})^{-1}\mathbf{X}^T\mathbf{y} = \mathbf{P}\mathbf{y}.$$

Матрица $\mathbf{P} = \mathbf{X}(\mathbf{X}^T\mathbf{X})^{-1}\mathbf{X}^T$ называется матрицей проектирования. Она идемпотентна, $\mathbf{P}^2 = \mathbf{P}$, и симметрична, $\mathbf{P}^T = \mathbf{P}$.

SSA can be used as a model-free technique so that it can be applied to arbitrary time series including non-stationary time series. The basic aim of SSA is to decompose the time series into the sum of interpretable components such as trend, periodic components and noise with no a-priori assumptions about the parametric form of these components.

Consider a real-valued time series $\mathbf{X} = (\mathbf{x}_1, \dots, \mathbf{x}_N)$ of length N . Let L ($1 < L < N$) be some integer called the *window length* and $K = N - L + 1$.

Main algorithm

1st step: Embedding.

Form the *trajectory matrix* of the series \mathbf{X} , which is the $L \times K$ matrix

$$\mathbf{X} = [X_1 : \dots : X_K] = (\mathbf{x}_{ij})_{i,j=1}^{L,K} = \begin{bmatrix} \mathbf{x}_1 & \mathbf{x}_2 & \mathbf{x}_3 & \dots & \mathbf{x}_K \\ \mathbf{x}_2 & \mathbf{x}_3 & \mathbf{x}_4 & \dots & \mathbf{x}_{K+1} \\ \mathbf{x}_3 & \mathbf{x}_4 & \mathbf{x}_5 & \dots & \mathbf{x}_{K+2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \mathbf{x}_L & \mathbf{x}_{L+1} & \mathbf{x}_{L+2} & \dots & \mathbf{x}_N \end{bmatrix}$$

where $\mathbf{X}_i = (\mathbf{x}_i, \dots, \mathbf{x}_{i+L-1})^T$ ($1 \leq i \leq K$) are *lagged vectors* of size L . The matrix \mathbf{X} is a Hankel matrix which means that \mathbf{X} has equal elements \mathbf{x}_{ij} on the anti-diagonals $i + j = \text{const}$.

2nd step: Singular Value Decomposition (SVD).

Perform the singular value decomposition (SVD) of the trajectory matrix \mathbf{X} . Set $\mathbf{S} = \mathbf{X}\mathbf{X}^T$ and denote by $\lambda_1, \dots, \lambda_L$ the *eigenvalues* of \mathbf{S} taken in the decreasing order of magnitude ($\lambda_1 \geq \dots \geq \lambda_L \geq 0$) and by $\mathbf{U}_1, \dots, \mathbf{U}_L$ the orthonormal system of the *eigenvectors* of the matrix \mathbf{S} corresponding to these eigenvalues.


Set $d = \text{rank } \mathbf{X} = \max\{i, \text{ such that } \lambda_i > 0\}$ (note that $d = L$ for a typical real-life series) and $\mathbf{V}_i = \mathbf{X}^T \mathbf{U}_i / \sqrt{\lambda_i}$ ($i = 1, \dots, d$). In this notation, the SVD of the trajectory matrix \mathbf{X} can be written as

$$\mathbf{X} = \mathbf{X}_1 + \dots + \mathbf{X}_d,$$

where

$$\mathbf{X}_i = \sqrt{\lambda_i} \mathbf{U}_i \mathbf{V}_i^T$$

are matrices having rank 1; these are called *elementary matrices*. The collection $(\sqrt{\lambda_i}, \mathbf{U}_i, \mathbf{V}_i)$ will be called the *i*th *eigen triple* (abbreviated as ET) of the SVD. Vectors \mathbf{U}_i are the left singular vectors of the matrix \mathbf{X} , numbers $\sqrt{\lambda_i}$ are the singular values and provide the singular spectrum of \mathbf{X} ; this gives the name to SSA. Vectors $\sqrt{\lambda_i} \mathbf{V}_i = \mathbf{X}^T \mathbf{U}_i$ are called vectors of principal components (PCs).



$U = V X^T$
 $n \times m$
 $m \times n$
 $h \ll n$
 5 steps


Проекция p точки b на прямую, определенную вектором a , задается формулой

$$p = \frac{a^T b}{a^T a} a.$$

Расстояние (в квадрате) от этой точки до прямой равняется


$$\begin{aligned} \left\| b - \frac{a^T b}{a^T a} a \right\|^2 &= b^T b - 2 \frac{(a^T b)^2}{a^T a} + \left(\frac{a^T b}{a^T a} \right)^2 a^T a = \\ &= \frac{(b^T b)(a^T a) - (a^T b)^2}{(a^T a)}. \end{aligned}$$

Это позволяет нам повторить рис. 3.1 уже с указанием формулы для определения точки p (рис. 3.3).



Проекция вектора b на вектор a .

The simplest problem statement in machine learning



f is the forecasting model,

S is the criterion,

T is an optimization algorithm,

$\hat{\mathbf{w}}$ is some solution,

$$\hat{\mathbf{w}} = \arg \min S(\mathbf{w}|y, f).$$

¹These notations are equivalent: $x_i, x(i), i \rightarrow x$.