

Многомерное масштабирование

Многомерное масштабирование (*MDS*) - это средство визуализации уровня сходства отдельных объектов в наборе данных. *MDS* используется для перевода информации о попарных расстояниях между n объектами в наборе данных в конфигурацию n точек, отображаемых в абстрактное декартово пространство. С технической точки зрения, *MDS* относится к набору связанных методов ординации, используемых при визуализации информации, в частности, для отображения информации, содержащейся в матрице расстояний. Это форма нелинейного уменьшения размерности. Учитывая матрицу расстояний расстояниями между каждой парой объектов в наборе данных, и выбрав число измерений N , *MDA* алгоритм помещает каждый объект в N -мерном пространстве (низкоразмерное представление), так что между объектами расстояния сохранялись как можно лучше. Для $N = 1, 2$ и 3 полученные точки можно визуализировать на диаграмме рассеяния.

Формально можно задачу многомерного шкалирования сформулировать следующим образом. Имеется обучающая выборка объектов $\mathbf{X}^p = \{x_1, \dots, x_p\} \subset \mathbf{X}$. Заданы расстояния $R_{ij} = \rho(x_i, x_j)$ для некоторых пар обучающих объектов $(i, j) \in D$. Требуется для каждого объекта $x_i \in \mathbf{X}^p$ построить его признаковое описание вектор $x_i = (x_i^1, \dots, x_i^n)$ в евклидовом пространстве $\mathbb{R}^n$ так, чтобы евклидовы расстояния d_{ij} между объектами x_i и x_j :

$$d_{ij}^2 = \sum_{d=1}^n (x_i^d - x_j^d)^2 \quad (1)$$

как можно точнее приближали исходные расстояния R_{ij} для всех $(i, j) \in D$.

Данное требование можно формализовать по-разному; один из наиболее распространённых способов через минимизацию функционала, называемого стрессом:

$$S(\mathbf{X}^p) = \sum_{(i,j) \in D} w_{ij} (d_{ij} - R_{ij})^2 \rightarrow \min \quad (2)$$

где минимум берётся по совокупности pn переменных $(x_i^d)_{i=1,p}^{d=1,n}$

Размерность n обычно задаётся небольшая. В частности, при $n = 2$ многомерное шкалирование позволяет отобразить выборку в виде множества точек на плоскости. Плоское представление, как правило, иска-

жено ($S > 0$), но в целом отражает основные структурные особенности многомерной выборки, в частности, её кластерную структуру. Поэтому двумерное шкалирование часто используют как инструмент предварительного анализа и понимания данных.

Веса w_{ij} задаются исходя из целей шкалирования. Обычно берут $w_{ij} = (R_{ij})^\gamma$. При $\gamma < 0$ приоритет отдаётся более точному приближению малых расстояний; при $\gamma > 0$ больших расстояний. Наиболее адекватным считается значение $\gamma = -2$, когда функционал стресса приобретает физический смысл потенциальной энергии системы p материальных точек, связанных упругими связями; требуется найти равновесное состояние системы, в котором потенциальная энергия минимальна. Функционал стресса $S(\mathbf{X}^p)$ сложным образом зависит от pn переменных, имеет огромное количество локальных минимумов, и его вычисление довольно трудоёмко. Поэтому многие алгоритмы многомерного шкалирования основаны на итерационном размещении объектов по одному. На каждой итерации оптимизируются евклидовы координаты только одного из объектов, а координаты остальных объектов, вычисленные на предыдущих итерациях, полагаются фиксированными. Кратко формально опишем варианты реализации MDS

Классическое многомерное масштабирование

MDS также известен как масштабирование Торгерсона – Гауэра. Он, как уже говорилось выше, принимает входную матрицу, определяющую различия между парами элементов, и выводит координатную матрицу, конфигурация которой минимизирует функцию потерь, называемую деформацией. На практике *MDS* стремится аппроксимировать исходное пространство данных его представлением пространством более низкой размерности, минимизируя функцию потерь. Общие формы функций потерь называются напряжением на расстоянии *MDS* и деформацией в классической *MDS*. Напряжение определяется:

$$S_{train_D}(x_1, x_2, \dots, x_N) = \left(\frac{\sum_{i,j} (b_{ij} - \mathbf{x}_i^T \mathbf{x}_j)^2}{\sum_{i,j} b_{ij}^2} \right)^{1/2} \quad (3)$$

где $\mathbf{x}_i$ вектор в N - мерном пространстве; $\mathbf{x}_i^T \mathbf{x}_j$ - скалярное произведение векторов $\mathbf{x}_i$ и $\mathbf{x}_j$; b_{ij} - элементы матрицы $\mathbf{B}$ определенные на шаге 2 следующего алгоритма, которые вычисляются из расстояний.

Шаги классического алгоритма *MDS*:

Классическая *MDS* использует тот факт, что координатная матри-

ца $\mathbf{X}$ сможет быть получена разложением на собственные значения из $\mathbf{B} = \mathbf{X}\mathbf{X}^T$. Матрица $\mathbf{B}$ получается из матрицы близости $\mathbf{D}$ с помощью двойного центрирования.

1. Получить квадратную матрицу близости $\mathbf{D}^{(2)} = [d_{ij}^2]$.
2. Применить двойное центрирование: $\mathbf{B} = \frac{1}{2}\mathbf{C}\mathbf{D}^{(2)}$, здесь $\mathbf{C} = \mathbf{I} - \frac{1}{p}\mathbf{J}_p$ где p - количество объектов; $\mathbf{I}$ - это единичная матрица размерности $p \times p$; $\mathbf{J}_p$ также единичная матрица размерности $p \times p$.
3. Из матрицы $\mathbf{B}$ получаем m наибольших собственных значений $\lambda_1, \lambda_2, \dots, \lambda_m$ и соответствующие собственные вектора $\mathbf{e}_1, \mathbf{e}_2, \dots, \mathbf{e}_m$ (m - требуемая размерность редуцированного пространства объектов).
4. Получение $\mathbf{X} = \mathbf{E}_m \mathbf{\Lambda}_m^{1/2}$, где $\mathbf{E}_m$ матрица их m собственных векторов; $\mathbf{\Lambda}_m$ - диагональная матрица из m собственных значений матрицы $\mathbf{B}$

Классическая *MDS* предполагает евклидовы расстояния.

Метрическое многомерное масштабирование (*mMDS*)

Это надмножество классической *MDS*, которое обобщает процедуру оптимизации на множество функций потерь и входных матриц известных расстояний с весами и т. Д. Полезная функция потерь в этом контексте называется стрессом (см. выше), который часто минимизируется с помощью процедуры, называемой мажоризацией стресса. Метрика *MDS* минимизирует функцию затрат, называемую «стресс», которая представляет собой остаточную сумму квадратов:

$$S_{stress_D}(x_1, x_2, \dots, x_N) = \left(\sum_{i \neq j=1, \dots, N} (d_{ij} - \|\mathbf{x}_i - \mathbf{x}_j\|)^2 \right)^{1/2} \quad (4)$$

При масштабировании показателей используется преобразование степени с показателем степени, управляемым пользователем. $\gamma : d_{ij}^\gamma$ и $d_{ij}^{2\gamma}$. В классическом масштабировании $\gamma = 1$.

Неметрическое многомерное масштабирование (*nMDS*)

В отличие от метрической *MDS*, неметрическая *MDS* находит как непараметрическую монотонную связь между различиями в матрице элемент-элемент и евклидовыми расстояниями между элементами, так и расположением каждого элемента в низкоразмерном пространстве. Взаимосвязь обычно определяется с помощью изотонической регрессии: пусть $\mathbf{x}$ обозначим вектор близости, $\mathbf{f}(\mathbf{x})$ монотонное преобразование $\mathbf{x}$, а также d точечные расстояния; затем необходимо найти координаты, которые минимизируют так называемое напряжение:

$$S_{stress} = \sqrt{\frac{\sum (\mathbf{f}(\mathbf{x}) - d)^2}{\sum d^2}} \quad (5)$$

Существует несколько вариантов этой функции затрат. Программы *MDS* автоматически минимизируют стресс, чтобы получить решение. Ядро неметрического алгоритма *MDS* - это двойной процесс оптимизации. Сначала нужно найти оптимальное монотонное преобразование близости. Во-вторых, точки конфигурации должны быть расположены оптимальным образом, чтобы их расстояния как можно ближе соответствовали масштабируемой близости. Основные шаги неметрического алгоритма *MDS*:

1. Найти случайную конфигурацию точек, например, путем выборки из нормального распределения.
2. Вычислить расстояния d между точками.
3. Найти оптимальное монотонное преобразование близости, чтобы получить оптимально масштабированные данные $\mathbf{f}(\mathbf{x})$.
4. Минимизировать напряжение между оптимально масштабированными данными и расстояниями, найдя новую конфигурацию точек.
5. Сравнить напряжение с некоторым критерием. Если напряжение достаточно мало, выйти из алгоритма, иначе вернуться к 2.

Анализ наименьшего пространства (*SSA*) Луи Гутмана является примером неметрической процедуры *MDS*.

Обобщенное многомерное масштабирование (*GMD*)

Расширение метрического многомерного масштабирования, в котором целевым пространством является произвольное гладкое неевклидово пространство. В случаях, когда различия - это расстояния на поверхности, а целевое пространство - это другая поверхность, *GMD* позволяет найти вложение одной поверхности в другую с минимальным искажением.

Анализируемые данные представляют собой совокупность M объектов, для которых определена функция расстояния, $d_{i,j}$: дистанция между i -тым и j -ым объектами. Эти расстояния являются элементами матрицы несходства D .

Целью *MDS* является зная D , найти M векторов $\mathbf{x}_1, \dots, \mathbf{x}_M \in \mathbb{R}^N$ таких, что $\|\mathbf{x}_i - \mathbf{x}_j\| \approx d_{ij}$ для всех $i, j \in 1, \dots, M$

где $\|\cdot\|$ - векторная норма. В классическом *MDS* эта норма является евклидовым расстоянием, но, в более широком смысле, это может быть

метрическая или произвольная функция расстояния.

Другими словами, *MDS* пытается найти отображение M объектов в $\mathbb{R}^N$ таким образом, что расстояния сохраняются.

Если размер N выбран 2 или 3, то можно построить вектора $\mathbf{x}_i$ чтобы получить визуализацию сходства между M объектами. При этом важно, что эти векторы не уникальны при данном евклидовом расстоянии они могут произвольно перемещаться, вращаться и отражаться, поскольку эти преобразования не изменяют попарные расстояния $\|\mathbf{x}_i - \mathbf{x}_j\|$

Существуют различные подходы к определению векторов $\mathbf{x}_i$. Обычно МДС формулируется как задача оптимизации, где $\mathbf{x}_1, \dots, \mathbf{x}_M$ доставляют минимум некоторой функции стоимости:

$$\arg \min_{\mathbf{x}_1, \dots, \mathbf{x}_M} \sum_{i < j} (\|\mathbf{x}_i - \mathbf{x}_j\| - d_{ij})^2 \quad (6)$$

Затем решение может быть найдено с помощью методов численной оптимизации. Для некоторых специально выбранных функций стоимости минимизаторы могут быть сформулированы аналитически в терминах разложения собственных матриц.

[originalsource](#)

Пример реализации алгоритма *MDS* на *python* и *R*.

Для расчетов использовались данные о Российских регионах. В *python* реализации исходным было $3D$ пространство, регионы размечены на три класса. Для *R* реализации исходное пространство $4D$, а регионы размечены на четыре класса.

В *scikitlearn* мы задаем два параметра `ncomponents = 2` (размерность выходного редуцируемого пространства) и `metric = True` (метрический MDS) или `False` (неметрический MDS) остальные параметры принимаются по умолчанию

Код *python* :

```
'''python
from mpl_toolkits.mplot3d import Axes3D
import numpy as np
import scipy.stats as st
import matplotlib.pyplot as plt
from pandas import Series, DataFrame
import pandas as pd
from sklearn.manifold import MDS
```

```

result =pd.read_table('dan04.txt',sep='\s+')
print(result)

X =DataFrame(result, columns=['P10','P11','P14'])
X=np.array (X)

SUMX=X[:,0] +X[:,1] + X[:,2]
X[:,0] =X[:,0] /SUMX
X[:,1] =X[:,1] /SUMX
X[:,2] =X[:,2] /SUMX


YT=result['P18']
y=np.array(YT)


XX1=result.query("P18 in [0]")
XX2=result.query("P18 in [1]")
XX3=result.query("P18 in [2]")


XX1 =DataFrame(XX1, columns=['P10','P11','P14'])
XX1=np.array (XX1)
XX2 =DataFrame(XX2, columns=['P10','P11','P14'])
XX2=np.array (XX2)
XX3 =DataFrame(XX3, columns=['P10','P11','P14'])
XX3=np.array (XX3)


SUMX1=XX1[:,0] +XX1[:,1] + XX1[:,2]
XX1[:,0] =XX1[:,0] /SUMX1
XX1[:,1] =XX1[:,1] /SUMX1
XX1[:,2] =XX1[:,2] /SUMX1


SUMX2=XX2[:,0] +XX2[:,1] + XX2[:,2]
XX2[:,0] =XX2[:,0] /SUMX2
XX2[:,1] =XX2[:,1] /SUMX2
XX2[:,2] =XX2[:,2] /SUMX2

```

```

SUMX3=XX3[:,0] +XX3[:,1] + XX3[:,2]
XX3[:,0] =XX3[:,0] /SUMX3
XX3[:,1] =XX3[:,1] /SUMX3
XX3[:,2] =XX3[:,2] /SUMX3

# Преобразование данных, уменьшающее размерность до 2
mod_mds = MDS(n_components=2, metric = True)
X_mds = mod_mds .fit_transform(X)
X_mds.shape

XI =DataFrame(X_mds, columns=['1','2'])
XI = XI.join(YT)

XI1=XI.query("P18 in [0]")
XI2=XI.query("P18 in [1]")
XI3=XI.query("P18 in [2]")

XI1 =DataFrame(XI1, columns=['1','2'])
XI1=np.array (XI1)
XI2 =DataFrame(XI2, columns=['1','2'])
XI2=np.array (XI2)
XI3 =DataFrame(XI3, columns=['1','2'])
XI3=np.array (XI3)

#построение исходного графика 3 D
fig = plt.figure(1, figsize=(10, 8))
ax = fig.add_subplot(111, projection='3d')

xs1 = XX1[:,0]
ys1 = XX1[:,1]
zs1 = XX1[:,2]

xs2 = XX2[:,0]
ys2 = XX2[:,1]
zs2 = XX2[:,2]

xs3 = XX3[:,0]

```

```

ys3 = XX3[:,1]
zs3 = XX3[:,2]

ax.scatter(xs1, ys1, zs1,c='g', cmap=plt.cm.nipy_spectral,
edgecolor='k',s=80,label='A')
ax.scatter(xs2, ys2, zs2,c='r', cmap=plt.cm.nipy_spectral,
edgecolor='k',s=80,label='P')
ax.scatter(xs3, ys3, zs3,c='b', cmap=plt.cm.nipy_spectral,
edgecolor='k',s=80,label='D')
ax.set_title("Исходное пространство предикторов",fontsize=16,
fontweight='bold')
ax.set_xlabel('P10',fontsize=14, fontweight='bold')
ax.set_ylabel('P11',fontsize=14, fontweight='bold')
ax.set_zlabel('P14',fontsize=14, fontweight='bold')
ax.legend(loc="best")

y = np.choose(y, [1, 2, 0]).astype(np.float)

fig = plt.figure(2,figsize=(10, 8))
plt.clf()
plt.cla()

plt.scatter(XI1[:, 0], XI1[:, 1], c='g',
cmap=plt.cm.nipy_spectral, edgecolor='k',s=100,label='A')

plt.scatter(XI2[:, 0], XI2[:, 1], c='r',
cmap=plt.cm.nipy_spectral, edgecolor='k',s=100,label='P')

plt.scatter(XI3[:, 0], XI3[:, 1], c='b',
cmap=plt.cm.nipy_spectral, edgecolor='k',s=100,label='D')

plt.title("Снижение размерности методом MDS"
,fontsize=16, fontweight='bold')

plt.xlabel("MDS1",fontsize=14, fontweight='bold')

plt.ylabel("MDS2",fontsize=14, fontweight='bold')
plt.legend(loc='best')

```




Рис. 1: Исходное 3D пространство описания регионов

```
plt.show()
'''
```

Графические результаты:

Как видно из графиков реализованный в `sklearn.manifold` модуль MDS при заданных параметрах в метрическом варианте гораздо лучше сохраняет топологию объектов, чем неметрический вариант многомерного масштабирования.

Код R :

```
'''r
library(gmodels)
library(lattice)
library(vegan)
library(grDevices)
library(reshape2)
```




Рис. 2: Редуцированное 2D пространство mMDS




Рис. 3: Редуцированное 2D пространство nMDS

```

library(ggplot2)
library(ggthemes)
library(psych)
library(caret)

load("xRegion.RData")

#ФОРМИРОВАНИЕ data.frame ОСНОВНЫЕ
#СОЦИАЛЬНО-ЭКОНОМИЧЕСКИЕ ПОКАЗАТЕЛИ РЕГИОНОВ РФ
xreg <-data.frame(P1=x$Pok_001,P2=x$Pok_002,P3=x$Pok_003,
P4=x$Pok_004,
P5=x$Pok_005,P6=x$Pok_006,P7=x$Pok_007,P8=x$Pok_008,
P9=x$Pok_009,P10=x$Pok_010,
P11=x$Pok_011,P12=x$Pok_012,P13=x$Pok_013,P14=x$Pok_014,
P15=x$Pok_015,P16=x$Pok_016,
P17=x$Pok_017,P18=x$Pok_018)
#xreg
#Формирование фактора тип экономики региона
xreg_f <- as.factor(x$Pok_018)

#выбор исследуемого подмножества показателей регионов
w=c(10,11,14,16)
reg.ekon <-xreg[,w]
valreg <-rowSums(reg.ekon)
xreg_nor <-reg.ekon/valreg
Y <- xreg_nor
X=Y
X <- as.matrix(X)

#Метод nMDS=====

#метрики "euc", "man", "bray", "jac", "kul"
x.mds = metaMDS(X, distance = "euc")
x.mds
#plot(x.mds)
data.scores = as.data.frame(scores(x.mds))
y.MDS <-data.frame(y1=data.scores[,1],y2=data.scores[,2],Econ=xreg_f)

```

```

#График регионов по классам в двухмерном пространстве NMDS
x11()
g4 <-ggplot(data= y.MDS, aes(x=y1,y=y2,colour = Econ),
  colors = "Accent")
g4 <-g4 +geom_point(size=4)
g4 <-g4 +labs(title ="Регионы в пространстве двух компонент nMDS",
  x="Компонента 1", y="Компонента 2",colour = "Классы")
g4 <-g4 + theme_fivethirtyeight() +
  scale_colour_manual( values = c('darkgoldenrod4',
  'blue','red','green'))
#g4 <-g4 + theme_stata() + scale_colour_stata()
g4

# mMDS=====

df.mds <- cmdscale(dist(X), eig = TRUE, k = 2)

df.mds$eig

#plot(df.mds$points[, 1], df.mds$points[, 2], col = xreg_f)

y2.MDS <-data.frame(y1=df.mds$points[, 1],y2=df.mds$points[, 2],Econ=xreg_f)

x11()
g4 <-ggplot(data= y2.MDS, aes(x=y1,y=y2,colour = Econ),
  colors = "Accent")
g4 <-g4 +geom_point(size=4)
g4 <-g4 +labs(title ="Регионы в пространстве двух компонент mMDS",
  x="Компонента 1", y="Компонента 2",colour = "Классы")
g4 <-g4 + theme_fivethirtyeight() +
  scale_colour_manual( values = c('darkgoldenrod4',
  'blue','red','green'))
#g4 <-g4 + theme_stata() + scale_colour_stata()
g4

'''

```

Результаты работы скрипта:




Рис. 4: Редуцированное 2D пространство mMDS

Собственные значения

```
5.594666e+00 3.431601e+00 4.873459e-01 7.099948e-16 3.665833e-16
3.070452e-16 3.003194e-16 2.319904e-16 1.603943e-16 1.397336e-16
1.298035e-16 1.220804e-16 1.173736e-16 1.128432e-16 9.612986e-17
8.106940e-17 7.306289e-17 6.340372e-17 6.186022e-17 5.229623e-17
5.140607e-17 4.800041e-17 4.519516e-17 4.333911e-17 4.005085e-17
3.899894e-17 3.493997e-17 2.595204e-17 2.565454e-17 2.552193e-17
2.544538e-17 2.204441e-17 2.026732e-17 1.588723e-17 1.560446e-17
1.514225e-17 1.458622e-17 1.231192e-17 1.587089e-18 1.538873e-18
7.924113e-19 -6.966414e-19 -2.326128e-18 -3.187938e-18 -3.493108e-18
-3.610405e-18 -5.591804e-18 -6.694794e-18 -7.343486e-18 -7.610262e-18
-7.692168e-18 -1.200938e-17 -1.346449e-17 -1.696788e-17 -1.821920e-17
-1.968668e-17 -2.774987e-17 -3.018549e-17 -3.385961e-17 -3.966822e-17
-5.018254e-17 -5.939872e-17 -6.230701e-17 -6.618591e-17 -6.664015e-17
-6.704644e-17 -7.042683e-17 -7.939269e-17 -8.706743e-17 -1.022151e-16
-1.599372e-16 -2.432393e-16 -2.744472e-16 -2.916891e-16 -3.940536e-16
-3.991335e-16 -4.352564e-16 -4.675905e-16 -5.431969e-16 -8.029666e-16
-1.331363e-15
```

Рис. 5: Собственные значения

В R метрический и неметрический методы реализованы в разных пакетах. Результаты работы метрического и неметрического методов практически совпадают. Здесь оба подхода к многомерному шкалированию хорошо сохраняют топологию регионов в редуцированном пространстве 2D.




Рис. 6: Редуцированное 2D пространство nMDS