

Занятие 10

Метод главных компонент и
другие методы
исследования многомерных
связей

Многомерные методы анализа: краткое повторение

1. Данные: **много** количественных **переменных** (зависимых)
2. На основании **матрицы корреляций** или **ковариаций** получаем **новые переменные** (не коррелирующие друг с другом) = компоненты – линейные комбинации исходных (R-mode analysis)
3. **Первая** переменная описывает максимум **изменчивости** между объектами = имеет наибольшее собственное значение (eigenvalue)
4. Для каждой компоненты есть список **коэффициентов** (eigenvector) и список **корреляций** (loadings); величина тех и других показывает, какие переменные вносят вклад в компоненты
5. можно рассчитать значения компонент для **объектов**
6. На основании **матрицы дистанций** между объектами тоже можно получить новые независимые переменные (Q-mode analysis)

Мы уже рассмотрели задачу сравнения **ГРУПП** по нескольким зависимым переменным (MANOVA и дискриминантный анализ).

НОВЫЕ ЗАДАЧИ:

1. **Уменьшить число исходных переменных** с минимальными потерями информации (чтобы использовать их в дальнейшем анализе);
2. Обнаружить **скрытые закономерности** в данных, которые не выявляются при анализе отдельных переменных (путём помещения объектов в пространство новых переменных, scaling).

Поясняющий пример:

Мы изучаем кроликов. Сначала взвешиваем каждого из 100 кроликов на безмене, потом на весах с гирьками, потом на электронных кухонных весах.

Потом мы хотим исследовать влияние питания на вес кроликов.

Неужели мы возьмём в анализ все три переменные? Ведь, очевидно, вес кролика – только **одна** его характеристика, а не три. Скорее всего, мы захотим превратить **все переменные** в **одну**.



Мы хотим

Найти те реальные факторы, которые определяют изменчивость (объясняют действие) большого количества измеренных нами реальных переменных.

Подразумевается, что таких факторов гораздо меньше, чем исходных переменных.

Скажем, я люблю торт «Прага», эскимо, шоколадные трюфели, пирожное «Картошка».


Не люблю голубцы, солянку, щи, борщ. Всего 8 переменных.

Но на самом деле мне нравится вкус шоколада и не нравится вкус капусты, и эти 2 фактора и определяют мои вкусовые предпочтения.



Подразумевается, что наши реально измеренные переменные на самом деле являются линейными комбинациями этих подлежащих факторов.

Наша задача – выявить эти факторы и именно их использовать в дальнейшем анализе.



2 коррелирующие
переменные превращаются в
одну компоненту

Анализ главных компонент (principal component analysis, PCA)

n объектов

p переменных

PCA трансформирует переменные в новые **не коррелирующие** друг с другом **главные компоненты** (их k , от 1 до p) = **факторы** (principal components = factors).

Это линейные комбинации исходных переменных, аналогичные дискриминантным функциям, только деления на группы теперь нет.

Для каждого объекта рассчитываются значения новых компонент, которые можно использовать в другом анализе.

$$z_{ik} = c_1 y_{i1} + c_2 y_{i2} + \dots + c_j y_{ij} + \dots + c_p y_{ip}$$

Этап 0. Подготовка данных к анализу.

- ✓ Проверка распределений переменных на соответствие нормальному (строгое соответствие не обязательно);
- ✓ Трансформация данных (напр., логарифмирование некоторых переменных);
- ✓ Исключение аутлаеров;
- ✓ Стандартизация данных (если переменные – в разных шкалах);
- ✓ проверка, нет ли слишком сильно коррелирующих переменных ($r > 0.95$; иначе невозможны будут операции с матрицами).



Этап 1. Получение компонент

Для каждой компоненты (= фактора) получаем **eigenvalue** и **eigenvector**.

Eigenvalues: их получают из матрицы корреляций, их сумма = числу переменных, т.е., дисперсия каждой переменной в среднем принимается за 1. Первая компонента объясняет как можно больше общей дисперсии и имеет максимальное eigenvalue. Разумно оставлять только те компоненты, для которых eigenvalues > 1 , т.е., объясняющие больше общей дисперсии, чем средняя переменная; число компонент будет меньше числа исходных переменных. Напоминание: они независимы между собой, т.е., ортогональны.


Eigenvector (в программе - Factor Score Coefficients). показывает вклад каждой переменной в компоненты.

Компоненты можно получать и из матрицы ковариаций; это осмысленно, если нам принципиально нужно оставить различия в абсолютных значениях переменных.

Этап 1. Получение компонент

Компоненты специально получаются ортогональными, т.е., они не коррелируют друг с другом.

Компонент получается **меньше, чем переменных**, в идеале – 1-3.



Чтобы компонент получилось мало, и их было легко интерпретировать, между исходными переменными должны быть **корреляции**.

Если корреляции слабые, уменьшить число переменных не получится!

Этап 2. Интерпретация компонент: **eigenvectors** и **factor loadings**

1. Смотрим на **eigenvectors**: чем дальше коэффициент от нуля, тем больше вклад переменной в данную компоненту.
2. Смотрим на **factor loadings** (корреляции Пирсона для компоненты с каждой из исходных переменных): чем дальше от нуля, тем сильнее корреляция компоненты с переменной.

Компоненты **легко интерпретировать** если: каждая исходная переменная коррелирует только с одной компонентой; loadings близки либо 1/-1, либо 0 (так получается, если исходно корреляция переменных есть)

Сложно интерпретировать если: среди factor loadings много невысоких значений; некоторые переменные почти одинаково коррелируют с несколькими компонентами.

Этап 3. Вращение компонент (rotation)

Цель вращения – облегчить интерпретацию компонент: чтобы коэффициенты и loadings были близки либо 0, либо 1.

Поворачиваем компоненты так, чтобы уменьшилось число средних корреляций (loadings), и каждая переменная стала коррелировать не более чем с одной компонентой. Varimax rotation – самый распространённый и удобный метод.

Вращение сохраняет компоненты ортогональными.

Этап 4. Интерпретация новых компонент

Получение factor loadings после вращения (проверка, стало ли лучше). Рассмотрение корреляций новых, «повёрнутых» компонент с исходными переменными, понимание их биологического смысла.

Этап 5. получение значений новых переменных для каждого объекта (для дальнейшего анализа.)

Ещё раз о компонентах (факторах):

- ✓ В многомерном пространстве первая компонента располагается вдоль наибольшей дисперсии облака объектов.
- ✓ Компоненты взаимно перпендикулярны
- ✓ Компоненты – линейные комбинации исходных переменных
- ✓ Если исходные переменные не коррелируют между собой, не получится собрать много дисперсии в первых компонентах, т.е., уменьшить их число.
- ✓ Сколько компонент оставлять? Это решает исследователь так, чтобы обеспечить биологическую интерпретируемость результатов. Нет смысла оставлять компоненты, с которыми не коррелирует сильно ни одна исходная переменная. Правило «**eigenvalue = 1**».

Вращение компонент (факторов)

Полученные компоненты поворачивают для получения более чёткой структуры переменных. Обычно используют **ортогональное** вращение – факторы остаются перпендикулярными друг другу. Например, **varimax**. Не ортогональное вращение – **oblique rotation**, у него есть свои поклонники, но результаты этого метода трудно интерпретировать.

Анализ остатков – residuals, residual correlation – имеет смысл посмотреть, насколько много информации мы потеряли при сокращении числа переменных. На основе наших факторов генерируются корреляции между исходными переменными и сравниваются с реальными корреляциями. Если разница где-то велика, мы взяли слишком мало факторов.

Изучаем пищевые предпочтения павианов.

Для каждой особи мы оценили количество еды 10 разных типов, съеденной за неделю. Павианы едят разную еду, поэтому типов пищи – 10. особей в анализе – 100.

Но реальных факторов, определяющих эти предпочтения, наверняка меньше.



Мы хотим: 1) уменьшить число переменных для дальнейшего анализа; 2) определить, сколько (и каких) факторов определяют пищевые предпочтения павианов.




РСА

апельсины,
бананы,
яблоки,
помидоры,
огурцы,
мясо,
курица,
рыба,
насекомые,
черви.




10 переменных измерено для каждого животного

Principal component analysis




Подготовка: проверка на соответствие нормальному распределению; поиск аутлаеров; поиск чрезмерно сильных корреляций переменных ($r > 0.95$)

PCA



Можно задать min кол-во дисперсии, которое должен объяснять фактор, чтобы его включили в анализ. Обычно $\text{min} = 1$, что соответствует средней дисперсии одной переменной, т.к. матрица корреляций стандартизирует переменные, и сумма дисперсий в них = сумме единиц на главной диагонали = числу переменных

Сперва оценим качество новых компонент: eigenvalues




Eigenvalues (бабуины)
Extraction: Principal components

Value	Eigenvalue	% Total variance	Cumulative Eigenvalue	Cumulative %
1	6.118369	61.18369	6.11837	61.1837
2	1.800682	18.00682	7.91905	79.1905
3	0.472888	4.72888	8.39194	83.9194
4	0.407996	4.07996	8.79993	87.9993
5	0.317222	3.17222	9.11716	91.1716
6	0.293300	2.93300	9.41046	94.1046
7	0.195808	1.95808	9.60626	96.0626
8	0.170431	1.70431	9.77670	97.7670
9	0.137970	1.37970	9.91467	99.1467
10	0.085334	0.85334	10.00000	100.0000

Здесь имеет смысл оставлять только 2 компоненты (объясняют 79% всей изменчивости) – их и оставляем.

В публикацию

Scree plot: показывает какую долю всей изменчивости объясняет каждая компонента. Рекомендуют оставлять компоненты выше излома, включая саму точку излома.



РСА

Оценка качества модели из 2-х компонент

Communalities (бабуины)			
Extraction: Principal components			
Rotation: Unrotated			
Variable	From 1 Factor	From 2 Factors	Multiple R-Square
апельсины, г	0,425888	0,690307	0,559765
бананы, г	0,573012	0,817809	0,734614
яблоки, г	0,556077	0,764634	0,653962
помидоры, г	0,886667	0,887143	0,865921
огурцы, г	0,766702	0,769369	0,739078
мясо, г	0,331847	0,697844	0,541367
курица, г	0,450630	0,832506	0,738620
рыба, г	0,411564	0,740954	0,584202
насекомые, г	0,905382	0,905565	0,884012
червяки, г	0,810599	0,812918	0,779456

Communalities: для каждой переменной показывают, какая доля её изменчивости объясняется нашими факторами

Factor Analysis Results: бабуины

Number of variables: 10
Method: Principal components
log(10) determinant of correlation matrix: -4,1096
Number of factors extracted: 10
Eigenvalues: 6,11837 1,80068 ,472888 ,407996 ,317222 .

Quick | Explained variance | Loadings | Scores | Descriptives | Summary

Eigenvalues | Communalities

Scree plot | Goodness of fit test

Reproduced/residual corr.

Highlight residuals greater than: .10

Residual Correlations (бабуины)						
Extraction: Principal components						
(Marked residuals are > ,100000)						
Variable	апельсины, г	бананы, г	яблоки, г	помидоры, г	огурцы, г	мясо, г
апельсины, г	0,31	-0,10	-0,07	-0,01	-0,08	0,08
бананы, г	-0,10	0,18	-0,06	-0,01	0,01	0,01
яблоки, г	-0,07	-0,06	0,24	-0,06	-0,05	0,01
помидоры, г	-0,01	-0,01	-0,06	0,11	-0,02	-0,02
огурцы, г	-0,08	0,01	-0,05	-0,02	0,23	0,03
мясо, г	0,08	0,01	0,01	-0,02	0,03	0,30
курица, г	0,02	-0,02	0,02	-0,01	-0,06	-0,10
рыба, г	0,01	0,03	0,04	-0,03	-0,05	-0,13
насекомые, г	-0,02	-0,02	-0,02	0,01	-0,02	-0,04
червяки, г	-0,06	-0,02	-0,02	-0,00	-0,04	-0,06

Остаточные корреляции между переменными, не объясненные моделью; чем они больше, тем хуже модель.

PCA

Интерпретация компонент (факторов): посмотрим, какие переменные дают в них наибольший вклад.

Variable	Factor Loadings (Unrotated) (бабуны.ста) Extraction: Principal components (Marked loadings are >,700000)	
	Factor 1	Factor 2
апельсины, г	-0,652601	0,514217
бананы, г	-0,756976	0,494770
яблоки, г	-0,745706	0,456680
помидоры, г	-0,941630	-0,021835
огурцы, г	-0,875615	0,051643
мясо, г	-0,576062	-0,604977
курица, г	-0,671289	-0,617962
рыба, г	-0,641532	-0,573925
насекомые, г	-0,951516	0,013513
черви, г	-0,900333	0,048154
Expl. Var	6,118369	1,800682
Prp. Totl	0,611837	0,180068

Factor Analysis Results: бабуны.ста

Number of variables: 10
Method: Principal components
log(10) determinant of correlation matrix: -4,1096
Number of factors extracted: 2
Eigenvalues: 6,11837 1,80068

Quick | Explained variance | **Loadings** | Scores | Descriptives | Summary

Factor rotation: Unrotated

Summary: Factor loadings Highlight factor loadings greater than: .70



Plot of loadings, 2D
Plot of loadings, 3D
Hierarchical analysis of oblique factors

Cancel
Options
By Group

Это loadings – корреляции компонент с исходными переменными

Вращение компонент

Проведём вращение, чтобы улучшить их структуру (метод вращения необходимо указать в публикации).



Factor Analysis Results: бабуины

Number of variables: 10
Method: Principal components
log(10) determinant of correlation matrix: -4,1096
Number of factors extracted: 2
Eigenvalues: 6,11837 1,80068

Quick | Explained variance | Loadings | Scores | Descriptives | Summary

Factor rotation: Varimax raw

Summary: Factor loadings | Highlight factor loadings greater than: .70

Plot of loadings, 2D

Plot of loadings, 3D

Hierarchical analysis of oblique factors

Varimax raw – самый распространённый способ поворота КОМПОНЕНТ

После вращения факторов их структура становится более ясной:

Factor Loadings (Varimax raw) (бабуины)

Variable	Factor Loadings (Varimax raw) (бабуины)	
	Factor 1	Factor 2
апельсины, г	0,830623	-0,019320
бананы, г	0,902408	0,058905
яблоки, г	0,870524	0,082595
помидоры, г	0,739857	0,582885
огурцы, г	0,731191	0,484489
мясо, г	0,097371	0,829676
курица, г	0,165722	0,897242
рыба, г	0,168370	0,844159
насекомые, г	0,768988	0,560555
червяки, г	0,748861	0,502121
Expl. Var	4,561544	3,357507
Prp. Totl	0,456154	0,335751

Фактор 1 в основном связан с растительной пищей, фактор 2 – с животной.

Итак, пищевые предпочтения павианов составлены из двух основных факторов – отношением к животной и растительной пище.

Если вращение компонент не улучшило интерпретируемость компонент, лучше оставить исходные компоненты

В публикацию

Посмотрим, как исходные переменные расположились в пространстве новых факторов

Number of variables: 10
 Method: Principal components
 log(10) determinant of correlation matrix: -4,1096
 Number of factors extracted: 2
 Eigenvalues: 6,11837 1,80068

Quick | Explained variance | Loadings | Scores | Descriptives | Summary


Factor rotation: Varimax raw

Summary: Factor loadings Highlight factor loadings greater than: .70

Plot of loadings, 2D

Plot of loadings, 3D


Hierarchical analysis of oblique factors



РСА

Если мы хотим проводить дальнейший анализ связи питания павианов с другими переменными, мы можем заменить 10 переменных на полученных два фактора.

Коэффициенты показывают вклад переменных в компоненту.



Factor Scores (бабуины)

Rotation: Varimax raw
Extraction: Principal components

Case	Factor 1	Factor 2
1	0,77326	-0,59909
2	-1,95924	-0,42839
3	-1,31803	-0,13560
4	0,17915	-0,70837
5	0,08277	-1,64135
6	-1,42460	0,42254
7	-0,19411	-0,39425
8	0,95212	-1,13020
9	0,03346	-0,20582
10	-0,70690	-0,41079
11	-0,18579	-1,75809
12	0,23559	1,19109
13	-1,09461	1,24608
14	-0,57400	-0,37563
15	0,17399	-0,08925
16	-0,57290	1,27404
17	-2,53492	-0,89944
18	0,53181	-1,11260
19	-0,27819	-0,00231

Factor Score Coefficients (бабуины) | Fac

Они не коррелируют между собой (удобно в анализе), их легко интерпретировать

Для публикаций



В методы: использовали метод главных компонент; применяли к ним вращение Varimax raw. Иногда весть PCA идёт в раздел методов, когда с его помощью получают новые переменные.

“To reduce the dimensionality in the data set and to simplify the analysis, we applied principal components analysis (PCA) on variables ...

All variables were standardized, and two principal components were extracted after Varimax raw rotation.”


В результаты: собственные значения выделенных компонент; доля изменчивости, которую они объясняют; расшифровка, какие исходные переменные они отражают (не забыть указать увеличивается или уменьшается переменная с ростом компоненты).

“...The two components explained 86% of the variance in the spatiotemporal distribution of males and females. PC1 reflected an increase in the number of adult males within 100 m...”

РСА

Замечание:


На протяжении всей процедуры РСА не было протестировано **НИ ОДНОЙ** статистической гипотезы.



- ✓ Из обычного РСА нельзя сделать **никаких качественных ВЫВОДОВ** (что-то равно чему-то, А зависит от Б, и проч.);
- ✓ исследование структуры многомерных данных в РСА – **описательная** процедура;
- ✓ часто РСА - **предварительный этап** анализа; полученные компоненты идут как переменные в другие статистические процедуры;
- ✓ **случайные ошибки**, аутлаеры могут радикально изменить структуру и значения компонент, их интерпретацию, и никто этого не заметит.


Требования к выборкам для проведения РСА

1. Связь переменных должна быть **линейной** (это **важно!** Диагностика - осмотр скаттерплотов);
2. многомерное **нормальное** распределение – не критично (оценка – на основе гистограмм; если есть группы – внутри групп);
3. **Трансформация** данных – для линейных связей;
4. Исключение **аутлаеров!** (особенно если они меняют интерпретацию компонент);
5. Рекомендуется, чтобы **размер выборки** был >50 , строго ≥ 25 объектов; оптимальный – ≥ 100 . Чем больше переменных, тем больше должен быть размер выборки.
6. Между переменными должна быть ненулевая корреляция, но коэффициентов корреляции, близких единице, тоже быть не должно.



Расширенный вариант PCA в программе

Данные – структура сообщества животных Африки в разных условиях



Можно выбрать матрицу ковариаций вместо матрицы корреляций (если важно сохранить в модели различия в дисперсии переменных)



PCA



Select variables for analysis, supplementary, active case, and group

8 - Veg_liana 9 - Veg_DBH 10 - Veg_Canopy 11 - Veg_Understory 12 - RA_Apes 13 - RA_Birds 14 - RA_Elephant 15 - RA_Monkeys 16 - RA_Rodent 17 - RA_Ungulate 18 - Rich_AllSpecies	1 - TransectID 2 - Distance 3 - HuntCat 4 - NumHouseholds 5 - LandUse 6 - Veg_Rich 7 - Veg_Stems 8 - Veg_liana 9 - Veg_DBH 10 - Veg_Canopy 11 - Veg_Understory	1 - TransectID 2 - Distance 3 - HuntCat 4 - NumHouseholds 5 - LandUse 6 - Veg_Rich 7 - Veg_Stems 8 - Veg_liana 9 - Veg_DBH 10 - Veg_Canopy 11 - Veg_Understory	1 - TransectID 2 - Distance 3 - HuntCat 4 - NumHouseholds 5 - LandUse 6 - Veg_Rich 7 - Veg_Stems 8 - Veg_liana 9 - Veg_DBH 10 - Veg_Canopy 11 - Veg_Understory
--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------	----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------	----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------	----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------

Variables for analysis: 12-17
Supplementary variables: 6-10
Active cases variable:
Grouping variable: 5

Show appropriate variables only

Principal Components and Classification Analysis Results: sprcies di...

Есть возможность сразу задать набор дополнительных переменных и группирующие переменные

Сразу видно, как меняется качество модели с уменьшением числа компонент; отличные картинки, с дополнительными и группирующими переменными.

No. of active vars: 6 No. of supplementary vars: 5
No. of active cases: 24 No. of supplementary cases: 0

Eigenvalues: 3,05143 1,00845 ,906915 ,706142 ,327046 ...




Number of factors : 3 Quality of representation : 82,8 %

Quick Variables | Cases | Descriptives

- Factor coordinates of variables
- Factor & variable correlations
- Plot var. factor coordinates, 2D
- Communalities (Cosine ?)
- Options for plot of factor coord.
 - Vectors (points to origin)
 - Unit circle
 - Variable names
 - Variable numbers
 - No Names/Numbers
- Contributions of variables
- Eigenvalues
- Scree plot
- Eigenvectors

PCA

Более информативное представление компонент



Возможность представить объекты в пространстве новых компонент с ярлыками групп из группирующей переменной

Связь РСА с MANOVA и регрессионным анализом.

1. Если мы хотим **сравнить группы** объектов, и зависимых переменных много, можно провести MANOVA (преимущество: можно сразу анализировать действие и нескольких группирующих переменных на несколько зависимых одним движением руки), а можно – сначала РСА, а потом – ANOVA (преимущество: возможность исследовать структуру зависимых переменных и выделить несколько компонент).
2. Если мы хотим провести множественный **регрессионный анализ**, а между предикторами присутствуют серьёзные корреляции, можно сначала сделать РСА для независимых переменных (можно даже без сокращения их числа), а потом – регрессионный анализ, и проблема скоррелированности предикторов исчезнет.

Correspondence analysis

- ✓ Метод анализа сложных таблиц сопряжённости.
- ✓ Анализ взаимосвязи 2-х категориальных переменных.
- ✓ Если у каждой переменной по 2 категории (2x2 таблица) – точный критерий Фишера;
- ✓ >2 категорий – критерий **Chi-квадрат**, но его результат для >4 категорий трудно интерпретировать!
- ✓ Для таких таблиц $n \times p$, где n и p – кол-во категорий в **ДВУХ** качественных переменных, придуман СА.
- ✓ **ЦЕЛЬ** – представить связь между двумя переменными, **уменьшив число категорий** в одной из переменных и потеряв как можно меньше информации;

Примеры:

- ✓ сравнение видового состава в нескольких регионах;
- ✓ сравнение соотношений разных социальных контактов у разных половозрастных групп;
- ✓ соотношение разных фенотипов в разных популяциях...

Correspondence analysis

✓ эти новые категории рассматриваются как **новые «переменные»** (столбцы, категории переменной A); строки таблицы (категории переменной B) рассматриваются как «объекты».

✓ основа – **хи-квадрат** статистика; строится матрица, её элементы содержат разности наблюдаемых и ожидаемых частот.

Переменная A: приверженность к курению;

Переменная B: должность.



Staff Group	Smoking Category				Row Totals
	(1) None	(2) Light	(3) Medium	(4) Heavy	
(1) Senior Managers	4	2	3	2	11
(2) Junior Managers	4	3	7	4	18
(3) Senior Employees	25	10	12	4	51
(4) Junior Employees	18	24	33	13	88
(5) Secretaries	10	6	7	2	25
Column Totals	61	45	62	25	193

Correspondence analysis

- ✓ В результате преобразования матриц получается таблица с **МЕНЬШИМ ЧИСЛОМ СТОЛБЦОВ** (=«переменных» = категорий переменной A);
- ✓ Сумма элементов главной диагонали - **Inertia**=Chi-square/Total N (вместо суммы дисперсии);
- ✓ для каждого столбца получается **eigenvalue** – доля общей Inertia, которая на него приходится
- ✓ В результат строится **картинка**, где «объекты» (строки = категории переменной B) располагаются в пространстве новых категорий переменной A.
- ✓ Чисто **описательная** процедура, хороша для построения картиной и обсуждения данных.

Correspondence analysis

Data: Smoking3 (2v by ...)

	Simple correspondenc	
	1	2
	EMPLOYEE	SMOKIN
1	Sr.Manag	None
2	Sr.Manag	None
3	Sr.Manag	None
4	Sr.Manag	None
5	Sr.Manag	Light
6	Sr.Manag	Light
7	Sr.Manag	Medium
8	Sr.Manag	Medium
9	Sr.Manag	Medium
10	Sr.Manag	Heavy
11	Sr.Manag	Heavy
12	Jr.Manag	None
13	Jr.Manag	None
14	Jr.Manag	None

Statistics Data Mining Graphs Tools Data Window Help

Resume... Ctrl+R

- Basic Statistics/Tables
- Multiple Regression
- ANOVA
- Nonparametrics
- Distribution Fitting
- Advanced Linear/Nonlinear Models
- Multivariate Exploratory Techniques**
 - Cluster Analysis
 - Factor Analysis
 - Principal Components & Classification Analysis
 - Canonical Analysis
 - Reliability/Item Analysis
 - Classification Trees
 - Correspondence Analysis**
 - Multidimensional Scaling
 - Discriminant Analysis
 - General Discriminant Analysis Models
- Industrial Statistics & Six Sigma
- Power Analysis
- Automated Neural Networks
- PLS, PCA, Multivariate/Batch SPC
- Variance Estimation and Precision (VEPAC)
- Statistics of Block Data
- STATISTICA Visual Basic
- Batch (ByGroup) Analysis
- Probability Calculator

а	высота	Длин	Длин	ч-та соц.	ч-
чере	реза,	а	а	контактов	кон
		тепа	уха		
13,145	0,454545	47,79	1,57	0,59541063	0,6

Correspondence Analysis (CA): Table Specifications: Smoking3

Correspondence Analysis (CA) | Multiple Correspondence Analysis (MCA)

Input

- Raw data (requires tabulation)
- Frequencies with grouping variables
- Frequencies w/out grouping vars

You can tabulate variables with codes, or input a (stacked) table of frequencies, with/out coding variables.

Row and column variable(s) ALL

Codes for grouping variables selected

OK

Cancel

Options

NOTE: If more than one variable is selected in a list, a multi-way table will be analyzed.

Open Data

SELECT CASES

Главная информация – дистанции между рядами («объектами») в пространстве новых компонент;
 Интерпретация компонент – по тому, какие группы они лучше всего разделяют.

Correspondence Analysis Results: Smoking3

Variables and number of categories:
 Row variables: EMPLOYEE (5)
 Column variables: SMOKING (4)
 Eigenvalues: ,0748 ,0100 ,0004
 Total chi-square=16,4416 df=12 p=,1719

Quick [Advanced] Options Review Supplementary points

Row and column coordinates
 Print/report Summary Box
 Eigenvalues Plot
 Unstandardized matrices


Plots of coordinates
 Row, 1D 2D 3D
 Column, 1D 2D 3D
 Row & col., 1D 2D 3D

Plot selected dimensions only
 Truncate labels to 2 chars
 Use identical X/Y/Z scales

Summary
 Cancel
 Options

Взаиморасположение объектов в пространстве новых переменных

В публикацию



Coordinates and Contributions to Inertia (Smoking3)

Row Coordinates and Contributions to Inertia (Smoking3)
 Input Table (Rows x Columns): 5 x 4
 Standardization: Row and column profiles

Row Name	Row Number	Coordin. Dim. 1	Coordin. Dim. 2	Mass	Quality
Sr.Manag	1	-0,065768	0,193737	0,056995	0,892568
Jr.Manag	2	0,258958	0,243305	0,093264	0,991082
Sr.Empl	3	-0,380595	0,010660	0,264249	0,999817
Jr.Empl	4	0,232952	-0,057744	0,455959	0,999810
Secretar	5	-0,201089	-0,078911	0,129534	0,998603

Row Coordinates and Contributions to Inertia (Smoking3) | Column Coordinates and Contributions to Inertia (Smoking3) | Plot of E

Canonical analysis

Концепция очень близка PCA.

- ✓ в рез-те операций над этими матрицами получаются **canonical roots** – пары компонент (по одной из каждого набора) такие, что в первой паре корреляция максимальна, во второй – меньше и т.д.
- ✓ Компоненты, составляющие **roots** - линейные комбинации исходных переменных.
- ✓ **Eigenvalues** – доля изменчивости, объяснённая корреляцией соответствующих компонент.
- ✓ Интерпретация канонических корней: **canonical weights** = **eigenvector**, показывают вклад каждой переменной в данный корень; **factor structure** = **factor loadings**, показывают корреляции корней с исходными переменными.

В примере – корреляция между разными показателями удовлетворения работой и удовлетворения хобби и домашними делами.



Canonical analysis

Statistics Data Mining Graphs Tools Data Window Help

Resume... Ctrl+R

to Report Add to MS Word

Basic Statistics/Tables

Multiple Regression

ANOVA

Nonparametrics

Distribution Fitting

Advanced Linear/Nonlinear Models

Multivariate Exploratory Techniques

Industrial Statistics & Six Sigma

Power Analysis

Automated Neural Networks

PLS, PCA, Multivariate/Batch SPC

Variance Estimation and Precision (VEPAC)

Statistics of Block Data

STATISTICA Visual Basic

Batch (ByGroup) Analysis

Probability Calculator

Cluster Analysis

Factor Analysis

Principal Components & Classification

Canonical Analysis

Reliability/Item Analysis

Classification Trees

Correspondence Analysis

Multidimensional Scaling

Discriminant Analysis

General Discriminant Analysis

а	высота	Длин	Длин	4-та с
чере	резца,	а	а	контакт
		тепа	уха	
13,145	0,454545	47,79	1,57	0,5954

Canonical Analysis: Factor

Quick

Variables: ALL

Input File: Raw Data

Review descriptive statistics and correlation matrix

Cancel

Options

Open Data

SELECT CASES

MD deletion

Casewise

Mean substitution

Review Descriptive Statistics: Factor

missing data casewise deleted

100 cases selected, 0 with missing data

100 valid cases accepted

Quick Advanced Matrix

Means & standard deviations

Box & whisker plot of vars

Correlations

Matrix plot of correlations

Covariances

SD=Sums of Squares/N



OK

Cancel

Options

Первый шаг – анализ исходных корреляций между переменными

Canonical analysis



Eigenvalues (Factor.sta)			
Root	Root 1	Root 2	Root 3
Value	0,782703	0,073484	0,038957

Eigenvalues – показывают, какую долю общей изменчивости в наборах объясняет данная корреляция компонент (корень).

Chi-Square Tests with Successive Roots Removed (Factor.sta)						
Root Removed	Canonial R	Canonial R-sqr.	Chi-sqr.	df	p	Lambda Prime
0	0,884705	0,782703	153,5785	21	0,000000	0,193486
1	0,271080	0,073484	10,8516	12	0,541689	0,890422
2	0,197374	0,038957	3,7153	5	0,591097	0,961043



Значимость корреляций между наборами переменных для каждого корня; измеряется сначала для всех корней, потом после удаления 1-го корня и т.п.

Canonical analysis

Variable	Factor Structure, left set (Factor.sta)		
	Root 1	Root 2	Root 3
WORK_1	0,796461	-0,575348	0,186075
WORK_2	0,952643	0,100725	-0,286926
WORK_3	0,875390	0,217192	0,431880

Корреляции корней с исходными переменными (loadings)

Variable	Canonical Weights, left set (Factor.sta)		
	Root 1	Root 2	Root 3
WORK_1	0,217021	-1,35890	0,24350
WORK_2	0,592485	0,37139	-1,38770
WORK_3	0,300124	0,83222	1,28861

Вклад каждой переменной в соответствующий корень (eigenvectors)

Redundancy – доля изменчивости, которая объясняется данной корреляцией

Canonical Analysis Results: Factor


Canonical R: ,8847051
 Chi-Square: 153,5785 df = (21) p = 0,000000
 Number of valid cases: 100

	No. of vars.	Variance extracted	Total redundancy given the other set
Left set:	3	100,00000000%	61,566122215%
Right set:	7	54,127096948%	33,297287915%

Quick | Canonical factors | Factor structures | Canonical scores | Summary

Correlations within & between sets
 Lineplot of canonical correlations
 Scatterplot of canonical correlations
 Factor structures & redundancies

Cancel
 Options
 By Group



Требования к выборкам для канонического анализа

1. Внутри переменных должно быть многомерное *нормальное распределение* (оценка – на основе гистограмм);
2. Связь переменных должна быть *линейной*;
3. Размер выборки не должен быть меньше 50, оптимальный – от 20 x число переменных.
4. Важно исключить аутлаеры
5. коэффициентов корреляции, близких *единице*, быть не должно.

Для публикаций

В методы: использовали канонический анализ; переменные соответствовали условиям нормального распределения.



В результаты:

- ✓ собственные значения полученных корней;
- ✓ значимость корреляций для каждого корня (Chi-square test): Canonical R, Chi-square, df, p;
- ✓ доля изменчивости, которую объясняет модель в каждом наборе (variance extracted);
- ✓ Интерпретация корней: какие исходные переменные отражают (loadings = factor structure для каждого набора).