

метрики  
расстояний  
метрики расстояний  
heatmap

методы  
кластеризации  
k-means  
hierarchical  
проблемы  
дендограммы  
валидация кластеров

деревья  
решений

# Матрицы расстояний, кластеризация и деревья решений

Г. Мороз

# Матрицы расстояний

**Матрица расстояний** — это матрица  $n \times n$ , которая содержит значения меры расстояния/сходства между объектами в метрическом пространстве. Существует уйма мер расстояния/сходства, выбор из которых зависит от типа данных. К сожалению, не существует универсального алгоритма выбора метода, так что это остается на откуп исследователям. Кроме того, схожие методы, зародившиеся в биологии, называют *string metric*: они определяют расстояния между строками (расстояние Хэмминга, расстояние Левинштейна и т. п.)

# Бинарные данные: коэффициент Жаккара

Компаративисты сравнивают языки на основе количества общих когнатов в списке Сводеша. Таким образом, для стословника составляются бинарные матрицы, которые отражают, какой когнат в каком идиоме встретился.

```
df <- data.frame( Lithuanian = c(1, 1, 1, 1, 0),  
                  Latvian = c(1, 1, 1, 0, 0),  
                  Prussian = c(1, 1, 0, 0, 0),  
                  ChurchSlavonic = c(0, 0, 0, 0, 1))
```

Для каждой пары языков строим таблицу сопряженности:

		идиом i	
		1	0
идиом j	1	a	b
	0	c	d

Коэффициент Жаккара рассчитывается по формуле:

$$s(i,j) = \frac{a}{a + b + c} \qquad d(i,j) = \frac{b + c}{a + b + c}$$

В работе [Gower and Legendre 1986] есть и другие методы (14 шт.).

Большинство из них есть в функции `dist.binary()` пакета `ade4`.

# Бинарные данные: коэффициент Жаккара

```
df <- data.frame( Lithuanian = c(1, 1, 1, 1, 0),  
                  Latvian = c(1, 1, 1, 0, 0),  
                  Prussian = c(1, 1, 0, 0, 0),  
                  ChurchSlavonic = c(0, 0, 0, 0, 1))  
  
df <- t(df)          # кластеризации любят держать признаки в строках  
dm <- dist(df, method = "binary")  
  
dm                         # матрица расстояний  
Lithuanian    Latvian     Prussian  
Latvian        0.2500000  
Prussian       0.5000000  0.3333333  
ChurchSlavonic 1.0000000  1.0000000  1.0000000  
round(100*(dm))           # удобнее смотреть  
                           Lithuanian  Latvian  Prussian  
Latvian                   25  
Prussian                  50      33  
ChurchSlavonic            100     100      100
```

# Небинарные категории: в бинарные

На основе WALS.

```
df <- data.frame(  
  order = c("SVO", "SOV", "SVO", "VOS"),  
  gender = c("3", "0", "0", "0"),  
  future = c("non.inflect", "inflect", "non.inflect", "non.inflect"),  
  row.names = c("English", "Turkish", "Estonian", "Malagasy"))
```

df

	order	gender	future
English	SVO	3	non.infl
Turkish	SOV	0	infl
Estonian	SVO	0	non.infl
Malagasy	VOS	0	non.infl

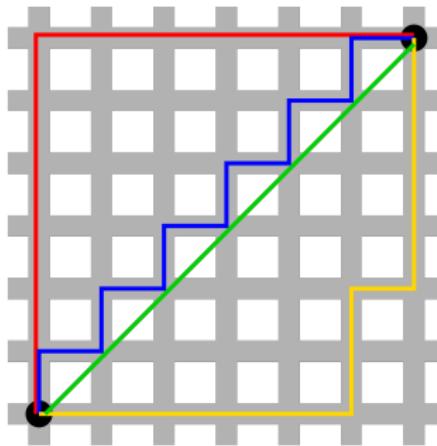
```
model.matrix(~. -1, data=df)
```

	orderSOV	orderSVO	orderVOS	gender3	futurenon.infl
English	0	1	0	1	1
Turkish	1	0	0	0	0
Estonian	0	1	0	0	1
Malagasy	0	0	1	0	1

# Числовые категории

Если категории числовые, то чаще всего используют:

- евклидово расстояние                                  `method = "euclidean"`
- расстояние городских кварталов                    `method = "manhattan"`



Картина из Википедии: зеленое — евклидово, остальные — манхэттенское.

презентация доступна: <http://goo.gl/F6pC3o>

# Смешанные категории

Для данных содержащих как числовые, так и категориальные данные используется алгоритм предложенный в работе [Gower 1971]. В целом, если в данных нет пропущенных значений, эта мера достаточно близка к евклидову расстоянию. В R она реализована функцией `daisy` пакета `cluster`. Вот пример на основе данных по количеству согласных и наличию абруптивных (график):

```
df <- read.csv("http://goo.gl/919qoS", row.names = 1)
df <- df[sample(1:27, 5),] # выборка из данных

library(cluster)
dm <- daisy(df); dm # строит матрицу и вызывает ее
```

Dissimilarities :

	Japanese	Hawaiian	Lakota	Pomo
Hawaiian	0.15909091			
Lakota	0.84090909	1.00000000		
Pomo	0.75000000	0.90909091	0.09090909	
Turkish	0.20454545	0.36363636	0.63636364	0.54545455

Metric : mixed ; Types = I, N

Number of objects : 5

# Метрики расстояний для строк

Для решения ряда проблем NLP было создано несколько метрик для измерения расстояний между строками. Для подсчета этих метрик в R есть несколько пакетов, я приведу примеры использования [пакета stringdist](#). Наиболее популярные в лингвистике расстояния:

- Хэмминга # method = "h"
- Левенштейна ([см. визуализацию](#)) # method = "lv"
- косинусное # method = "c"

```
library(stringdist)
str1 <- "мама"
str2 <- "папа"
stringdist(str1, str2, method = "h")
[1] 2

str3 <- "мама"
str4 <- c("папа", "рампа", "лада", "рама")
stringdist(str3, str4, method = "lv")
[1] 2 2 2 1
```

# Способы уменьшения размерностей?

- регрессионный анализ
- кластеризация
- многомерное шкалирование (multidimensional scaling)
- компонентный анализ (principal component analysis)

метрики  
расстояний

метрики расстояний  
heatmap

методы  
кластеризации

k-means

hierarchical

проблемы

дendrogramмы

валидация кластеров

деревья  
решений

# heatmap

Как обычно, есть несколько способов визуализации:

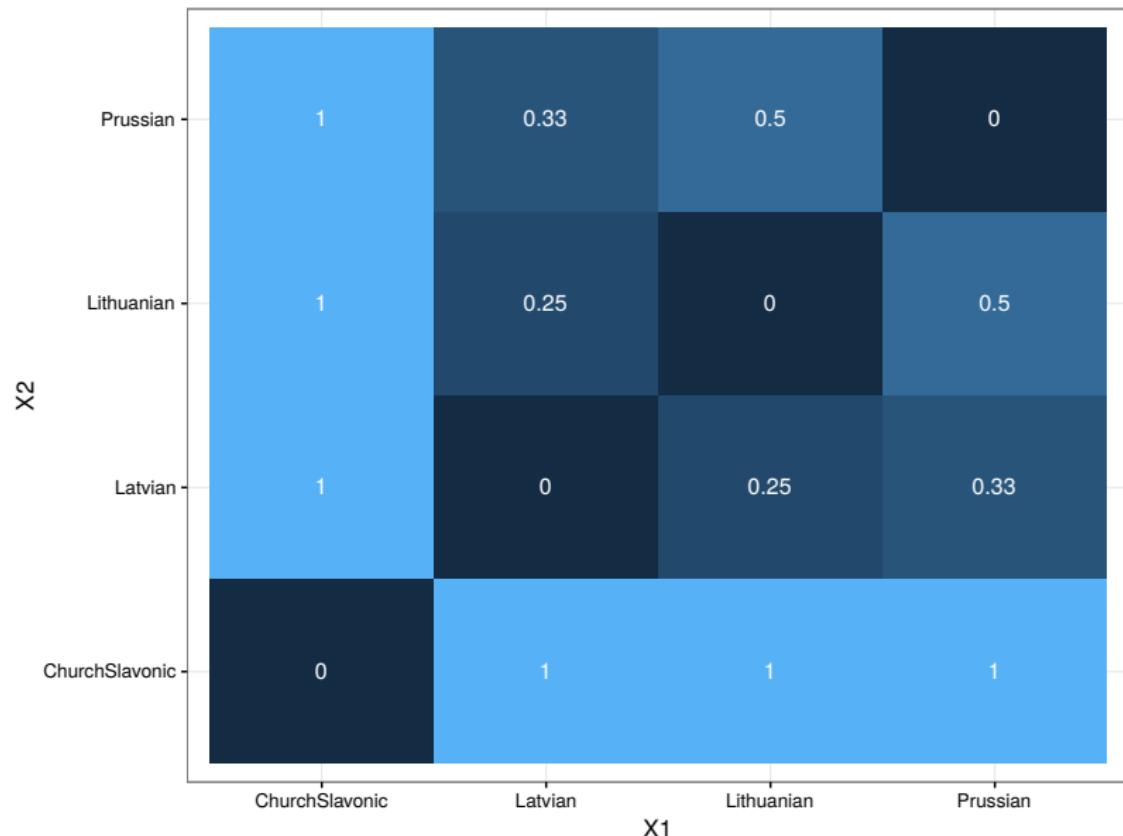
- в Rbase есть функция `heatmap()`, но ее настройка — сплошное мучение
- в `ggplot2` есть `geom_tile()`

Обе функции принимают на вход матрицы, так что результат работы функции `dist()` надо трансформировать:

```
df <- data.frame( Lithuanian = c(1, 1, 1, 1, 0),
                   Latvian = c(1, 1, 1, 0, 0),
                   Prussian = c(1, 1, 0, 0, 0),
                   ChurchSlavonic = c(0, 0, 0, 0, 1))
df <- t(df)           # кластеризации любят держать признаки в строках
dm <- as.matrix(dist(df, method = "binary"))
```

# heatmap: ggplot

метрики  
расстояний  
метрики расстояний  
heatmap  
методы  
кластеризации  
k-means  
hierarchical  
проблемы  
дendrogramмы  
валидация кластеров  
деревья  
решений



# heatmap: ggplot

метрики  
расстояний  
метрики расстояний  
heatmap  
  
методы  
кластеризации  
k-means  
hierarchical  
проблемы  
дendrogramмы  
валидация кластеров  
  
деревья  
решений

```
df <- data.frame( Lithuanian = c(1, 1, 1, 1, 0),  
                  Latvian = c(1, 1, 1, 0, 0),  
                  Prussian = c(1, 1, 0, 0, 0),  
                  ChurchSlavonic = c(0, 0, 0, 0, 1))  
df <- t(df)          # кластеризации любят держать признаки в строках  
dm <- as.matrix(dist(df, method = "binary"))      # считает расстояния  
  
library(reshape)  
dm.m <- melt(dm)           # преобразования матрицы для ggplot  
  
library(ggplot2)  
ggplot(dm.m, aes(X1, X2, fill=value)) +  
  geom_tile() +                      # делает heatmap  
  geom_text(aes(X1, X2, label = round(value, 2)), # пишет значения  
            color = "white", size = 4)
```

# Кластеризация

Кластеризация — это не метод, а задача, для решения которой придумано множество алгоритмов. Не существует "правильных" методов кластеризации, так как "clustering is in the eye of the beholder" [Estivill-Castro 2002]. В презентации рассказывается о представителях двух семейств алгоритмов:

- метод  $k$ -средних ( $k$ -means)
- иерархическая кластеризация (hierarchical clustering)

# Алгоритм $k$ -means

Алгоритм  $k$ -means был разработан в статье [Lloyd 1982]:

- на вход алгоритму подаются данные и  $k$  — количество кластеров, на которые эти данные надо поделить;
- произвольно выбираются  $k$  точек (центроидов) и рассчитываются ближайшие расстояния (евклидово) от данных точек до центроидов, точки которые ближе всего к некоторому центроиду образуют кластер;
- на основе точек вошедших в кластер строится новый центроид, так чтобы расстояние от всех точек до нового центроида было минимально;
- часть точек становится ближе к новому центроиду и входят в его кластер, а часть от центроида отдаляется и начинают входить в другой/другие кластер/кластеры;
- ... все это повторяется, пока на некоторой итерации не происходит изменение положения центроидов.

Naftali Harris сделал [визуализация  \$k\$ -means](#).  
презентация доступна: <http://goo.gl/F6pC3o>

## Задача

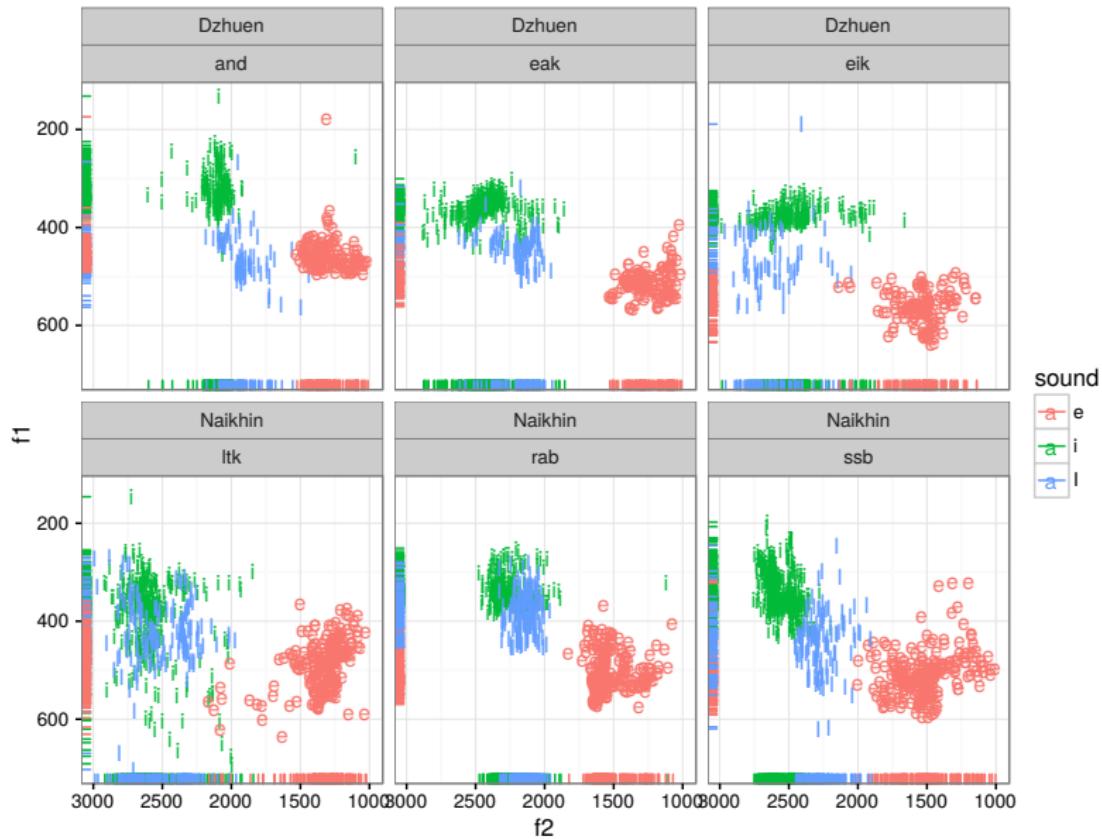
В описании нанайского языка есть гласные *i*, *ɪ* и *ə* (в данных закодированы *i*, *I*, *e* соответственно), однако совсем не понятно, одинаково ли произносят гласные *i* и *ɪ* современные носители. В датасет записаны F<sub>1</sub> и F<sub>2</sub> этих трех гласных, произнесенных в нанайских словах шестью нанайцами из двух селений Найхин и Джуен. Если F<sub>1</sub> и F<sub>2</sub> достаточно для описания разницы между этими гласными, то тогда они должны кластеризоваться.

метрики  
расстояний  
метрики расстояний  
heatmap  
методы  
кластеризации  
k-means  
hierarchical  
проблемы  
дendrogramмы  
валидация кластеров  
деревья  
решений

# Задача

метрики  
расстояний  
метрики расстояний  
heatmap  
методы  
кластеризации  
k-means  
hierarchical  
проблемы  
дendrogramмы  
валидация кластеров

деревья  
решений



## *k-means*

Нашим примером будет носитель ssb:

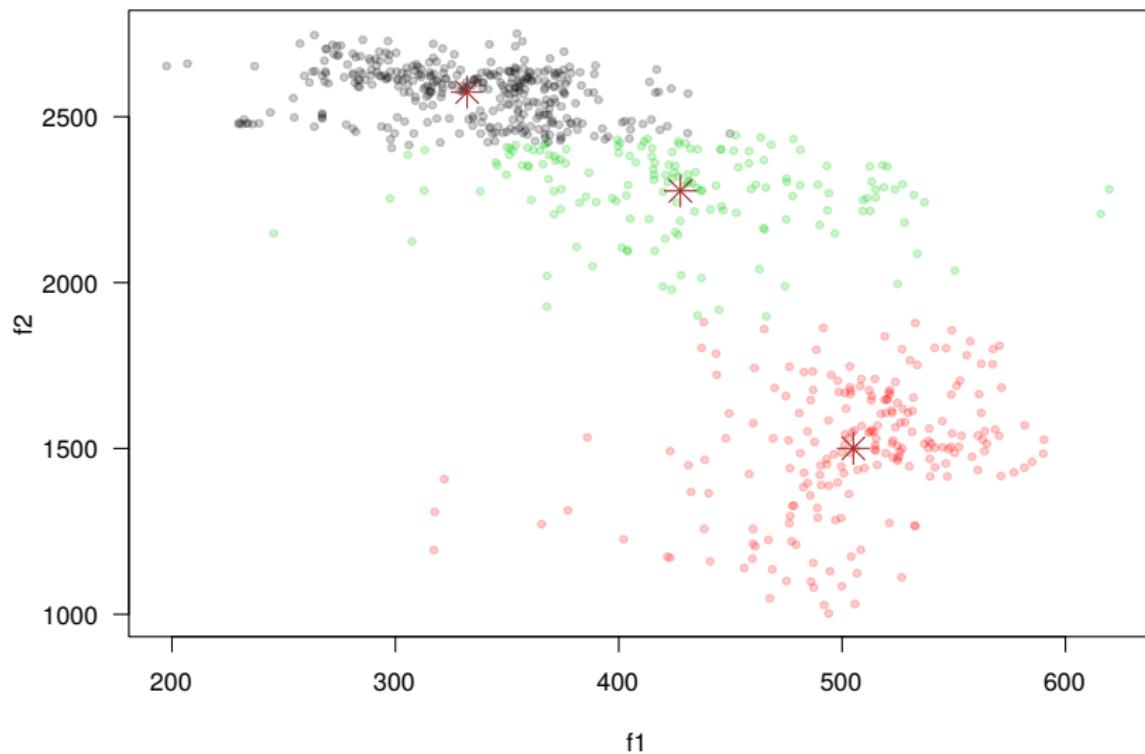
```
n <- read.csv("http://goo.gl/YPMyI2", sep = ";")  
n <- n[n$dictor == "ssb",]
```

```
dm <- dist(n[, c(5,6)])  
set.seed(5) # устанавливаем определенное значение рандомизатора  
n.cl <- kmeans(dm, centers = 3) # датафрейм, к  
n.cl$cluster # кластер каждой точки  
n.cl$centers # координаты центроидов
```

метрики  
расстояний  
метрики расстояний  
heatmap  
методы  
кластеризации  
k-means  
hierarchical  
проблемы  
дendrogramмы  
валидация кластеров  
деревья  
решений

# Визуализация k-means: R-base

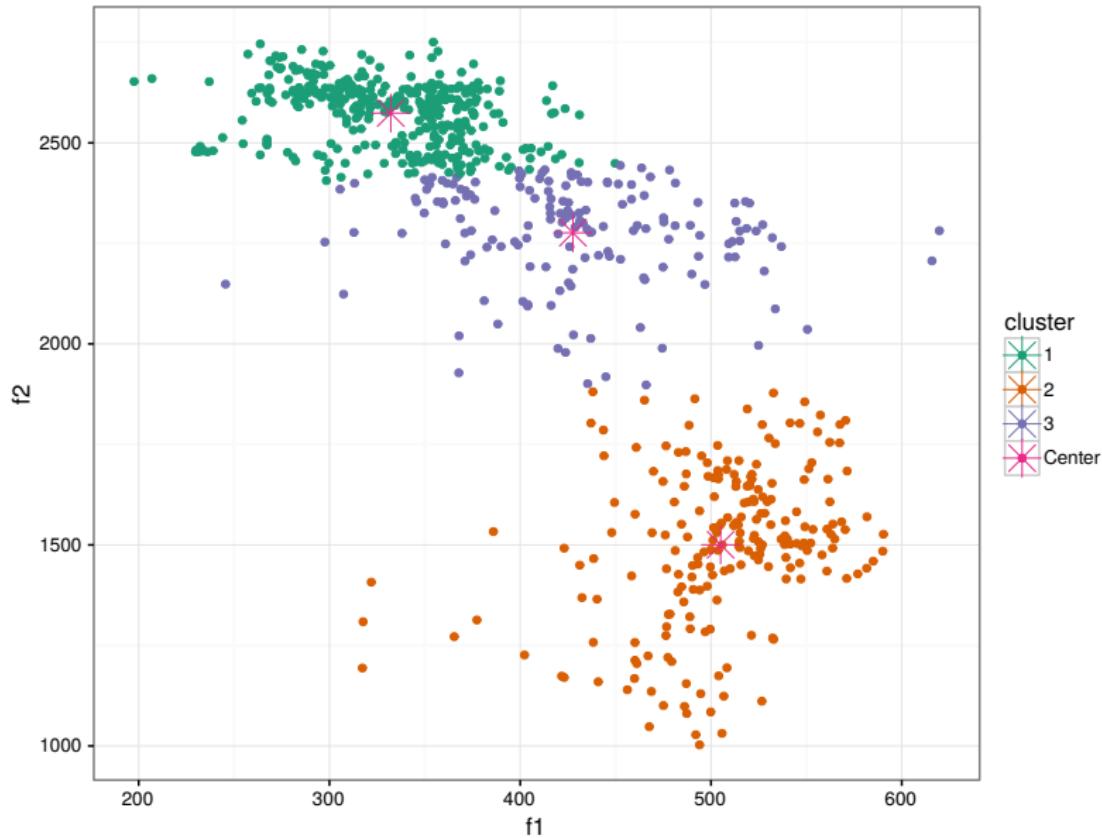
метрики  
расстояний  
метрики расстояний  
heatmap  
методы  
кластеризации  
k-means  
hierarchical  
проблемы  
дендограммы  
валидация кластеров  
деревья  
решений



```
plot(n[, c(5,6)],  
     col = n.cl$cluster) # данные  
points(n.cl$centers, col = "brown", pch = 8, cex = 2) # раскрашиваем по кластеру  
# центроиды  
презентация доступна: http://goo.gl/F6pC3o
```

# Визуализация $k$ -means: ggplot2

метрики  
расстояний  
метрики расстояний  
heatmap  
методы  
кластеризации  
**k-means**  
hierarchical  
проблемы  
дендограммы  
валидация кластеров  
деревья  
решений



# Визуализация $k$ -means: ggplot2

```
n$cluster <- factor(n.cl$cluster)      # добавляет кластеризацию в дф
centers <- as.data.frame(n.cl$centers)    # создает дф с центроидами

library(ggplot2)
ggplot(data=n, aes(x=f1, y=f2, color=cluster)) +
  geom_point() +
  geom_point(data=centers, aes(x=f1,y=f2, color='Center'),
             shape = 8, size = 5)
```

метрики  
расстояний  
метрики расстояний  
heatmap

методы  
кластеризации

k-means

hierarchical

проблемы

дendrogramмы

валидация кластеров

деревья  
решений

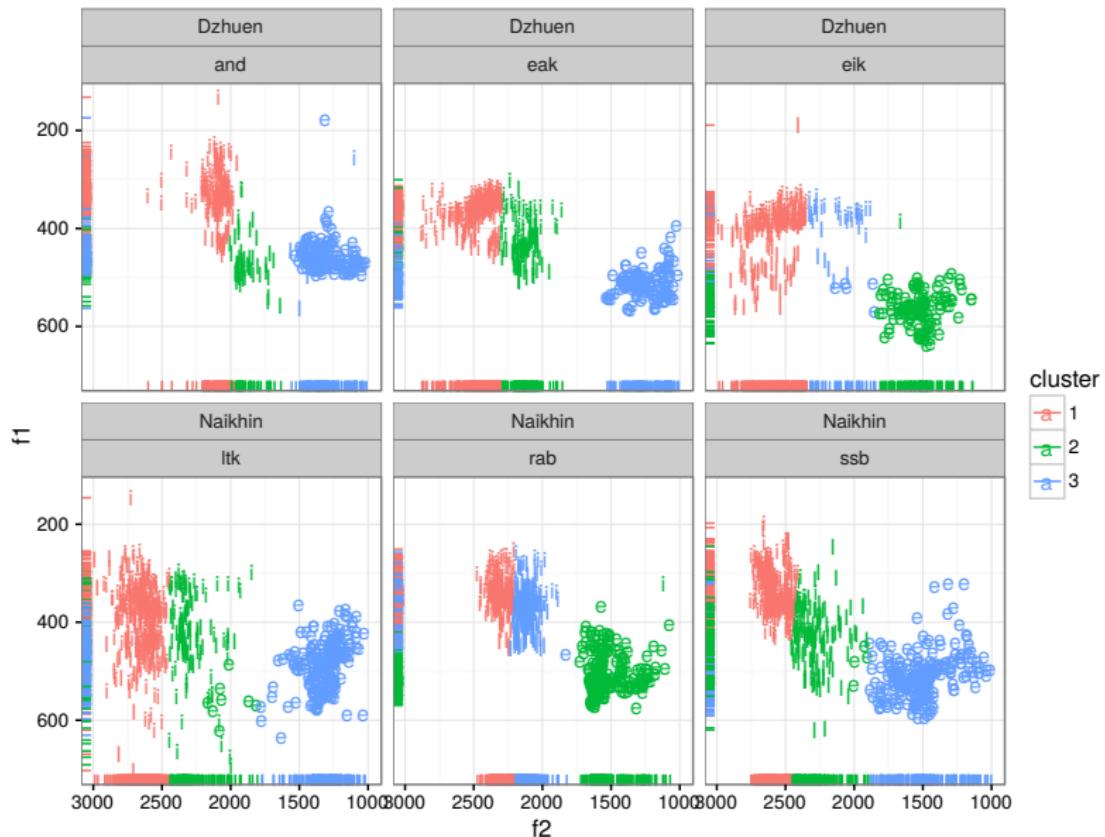
## *k*-means: продолжение

И что дальше? В наших данных есть информация о произнесениях, так что можно сравнить (следующий слайд) результат работы *k*-means (обозначено цветом) с тем, что ожидалось в данных словах (обозначено буквой) и посмотреть сколько раз *k*-means ошибся (слайд через один):

	and	eak	eik	ltk	rab	ssb
correct	393	426	278	515	549	682
mistaken	27	61	99	148	102	43
	and	eak	eik	ltk	rab	ssb
correct	0.94	0.87	0.74	0.78	0.84	0.94
mistaken	0.06	0.13	0.26	0.22	0.16	0.06

# Кластеры k-means

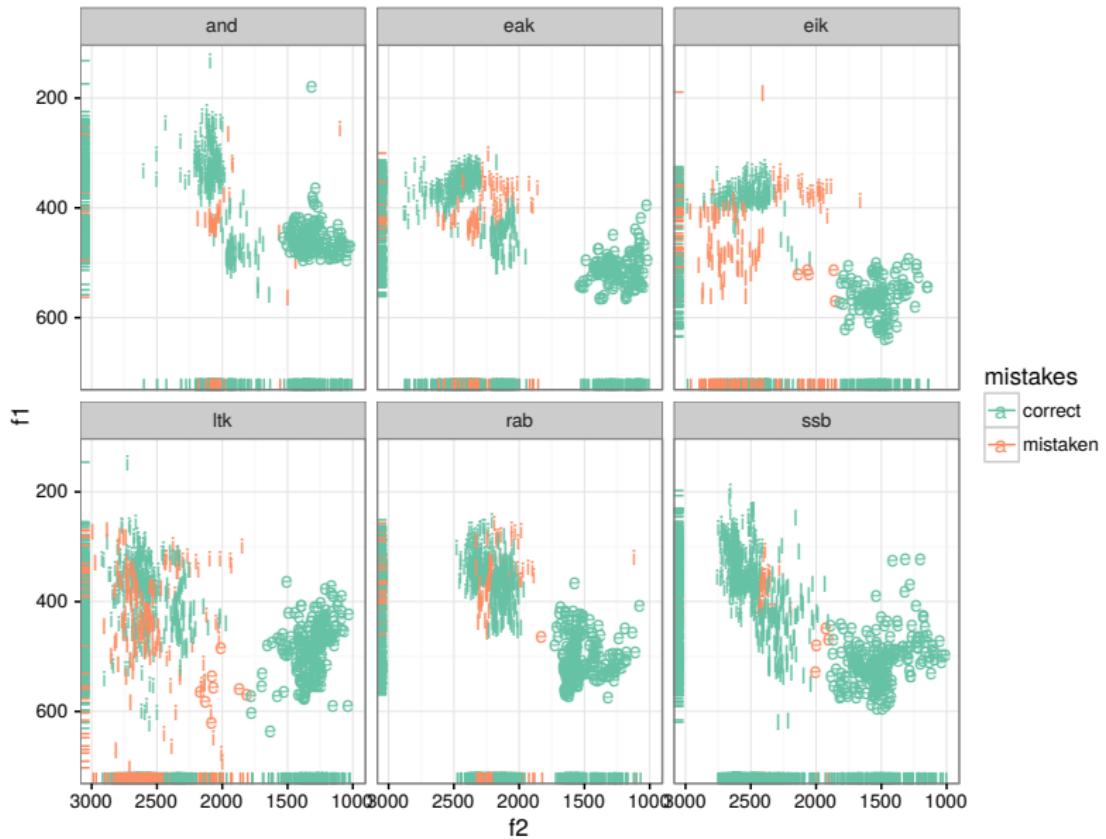
метрики  
расстояний  
метрики расстояний  
heatmap  
методы  
кластеризации  
k-means  
hierarchical  
проблемы  
дендограммы  
валидация кластеров  
деревья  
решений



# Ошибки алгоритма $k$ -means

метрики  
расстояний  
метрики расстояний  
heatmap  
методы  
кластеризации  
 $k$ -means  
hierarchical  
проблемы  
дendrogramмы  
валидация кластеров

деревья  
решений



# Иерархическая кластеризация

Иерархические кластеризации имеют два типа:

- **снизу вверх (agglomerative)**: каждое наблюдение в начальной позиции является кластером, дальше два ближних кластера соединяются в один, а дендограмма отображает порядки таких соединений.
- **сверху вниз (divisive)**: все наблюдения в начальной позиции являются кластером, который дальше делится на более мелкие, а дендограмма отображает порядки таких разъединений.

Алгоритмы иерархической кластеризации требуют на вход матрицы расстояний. Алгоритмов кластерного анализа очень много, так что имеет смысл заглянуть в работу [Gordon 1987] и [на страницу CRAN](#).

# Иерархическая кластеризация

Нашим примером снова будет носитель ssb:

```
n <- read.csv("http://goo.gl/YPMyI2", sep = ";")  
n <- n[n$dictor == "ssb",]
```

Функция `hclust` принимает на вход матрицу расстояний:

```
hc <- hclust(dist(n[,c(5,6)]))  
plot(hc) # agglomerative clustering  
plot(hc, labels = F) # график получившихся кластеров  
rect.hclust(hc, k=3) # график без подписей  
# выделить k кластеров
```

Функция `cutree` возвращает вектор номеров кластеров в соответствии с данными, так что можно строить все предыдущие графики:

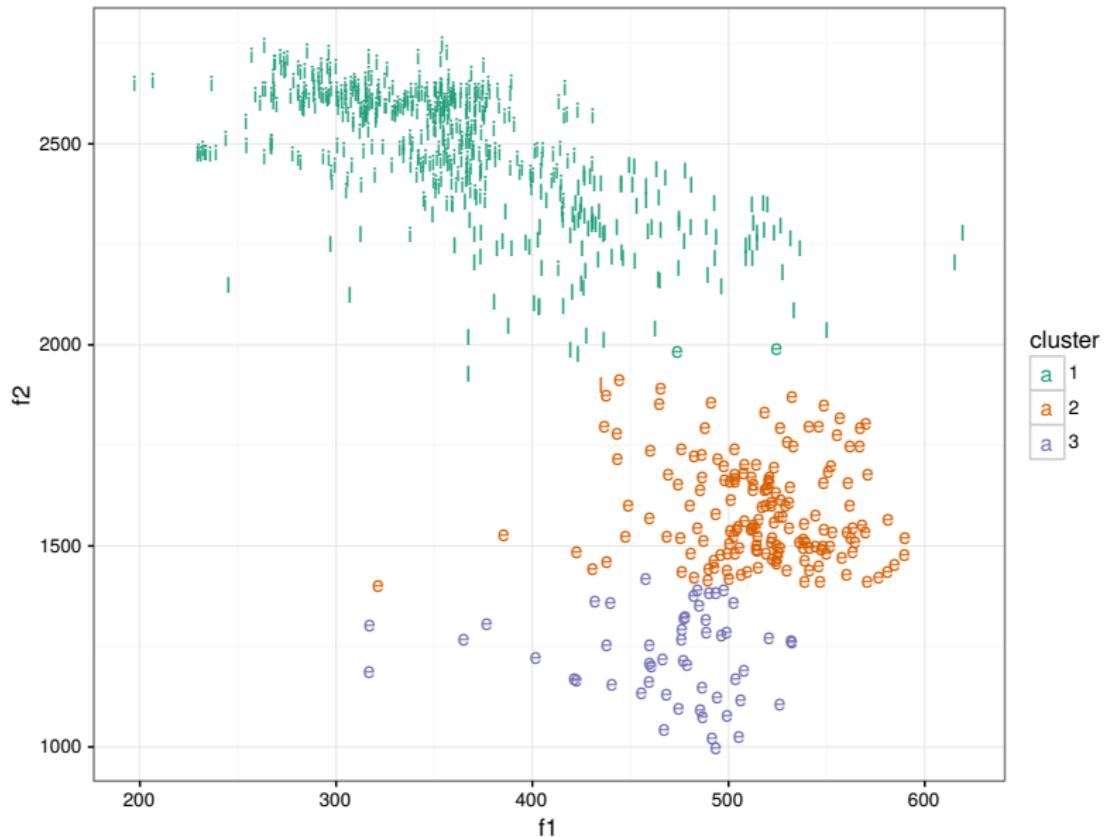
```
cluster <- cutree(hc, k=3)
```

	and	eak	eik	ltk	rab	ssb
correct	393	345	234	478	494	439
mistaken	27	142	143	185	157	286

	and	eak	eik	ltk	rab	ssb
correct	0.94	0.71	0.62	0.72	0.76	0.61
mistaken	0.06	0.29	0.38	0.28	0.24	0.39

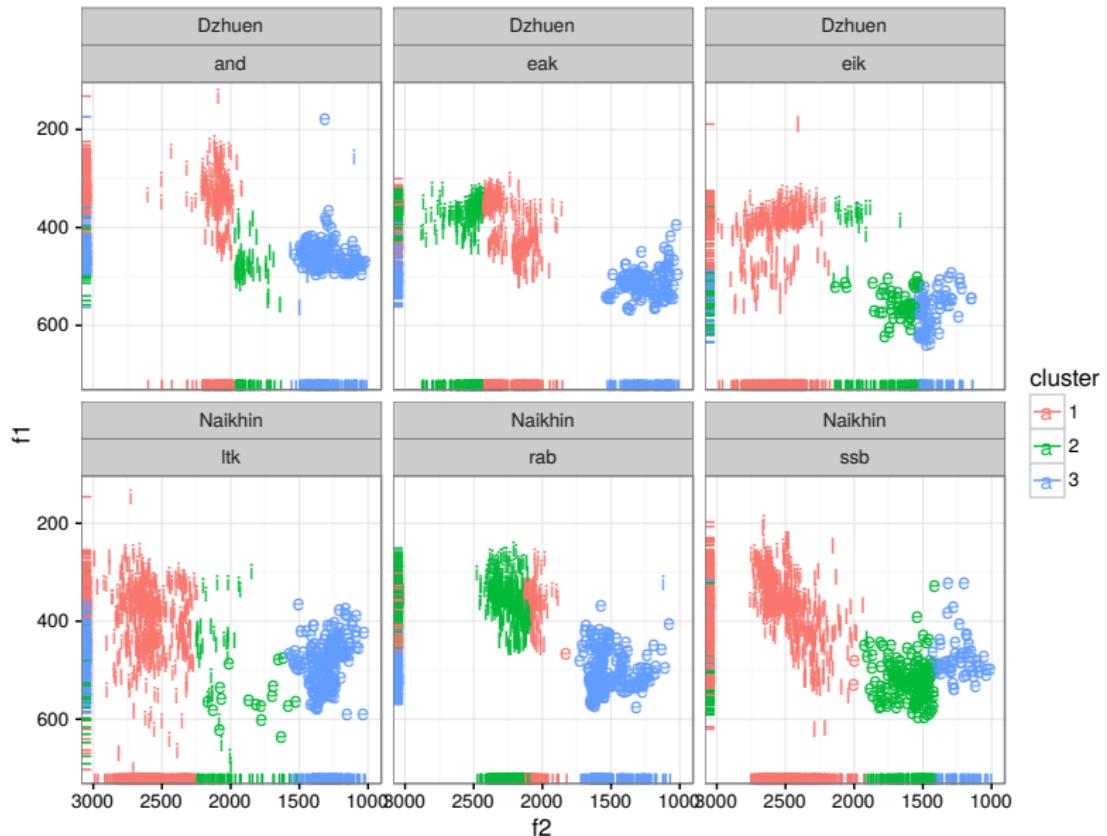
# Иерархическая кластеризация

метрики  
расстояний  
метрики расстояний  
heatmap  
методы  
кластеризации  
k-means  
**hierarchical**  
проблемы  
дендограммы  
валидация кластеров  
деревья  
решений



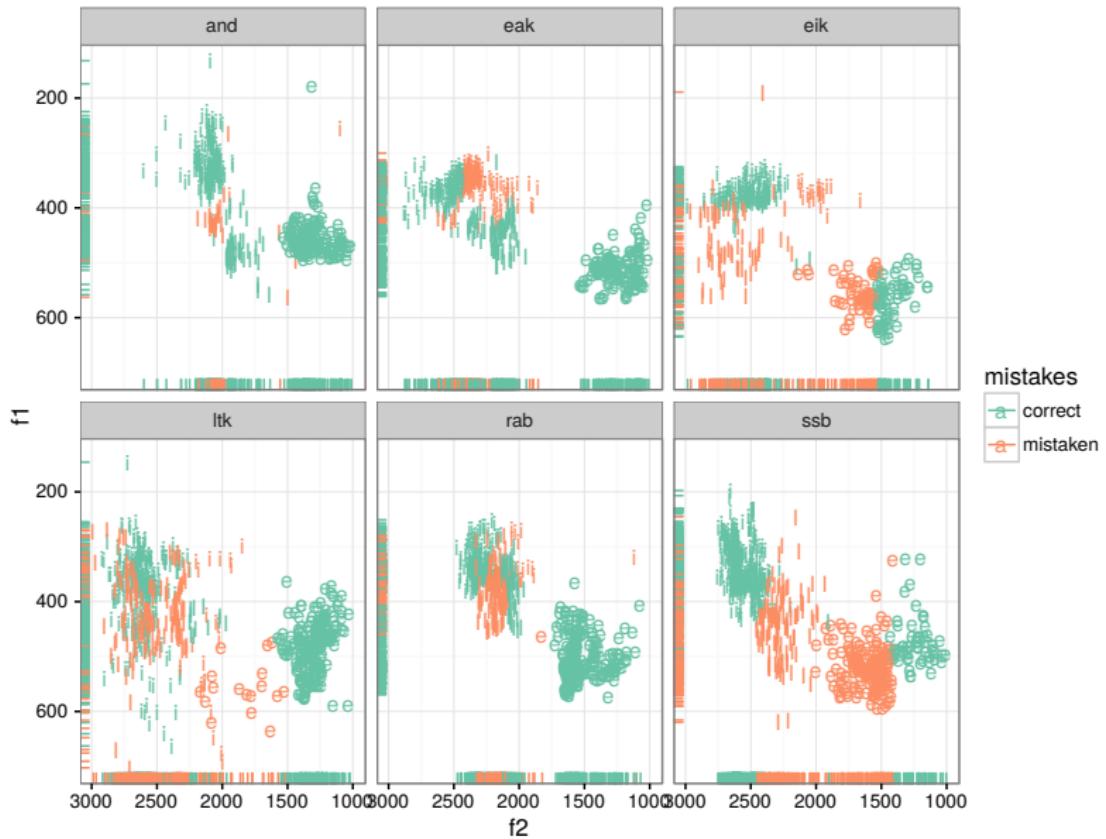
# Кластеры иерархическая кластеризации

метрики  
расстояний  
метрики расстояний  
heatmap  
методы  
кластеризации  
k-means  
hierarchical  
проблемы  
дендограммы  
валидация кластеров  
деревья  
решений



# Ошибки алгоритма иерархической кластеризации

метрики  
расстояний  
метрики расстояний  
heatmap  
методы  
кластеризации  
k-means  
hierarchical  
проблемы  
дендограммы  
валидация кластеров  
деревья  
решений



# Проблемы приведенных методов

- $k$ -means может давать разные результаты на одних и тех же данных
- при использовании  $k$ -means нужно знать  $k$
- иерархическая кластеризация не может исправить ошибки, сделанные на предыдущих шагах: в работе [Hawkins 1982] приводится пример вектора  $c(-2.2, -2, -1.8, -0.1, 0.1, 1.8, 2, 2.2)$ , в котором очевидны три кластера, однако если на первом этапе алгоритм разбьет все на  $c(-2.2, -2, -1.8, -0.1)$  и  $c(0.1, 1.8, 2, 2.2)$ , то дальше это исправлено не будет.

метрики  
расстояний  
метрики расстояний  
heatmap  
методы  
кластеризации  
 $k$ -means  
hierarchical  
проблемы  
дendrogramмы  
валидация кластеров  
деревья  
решений

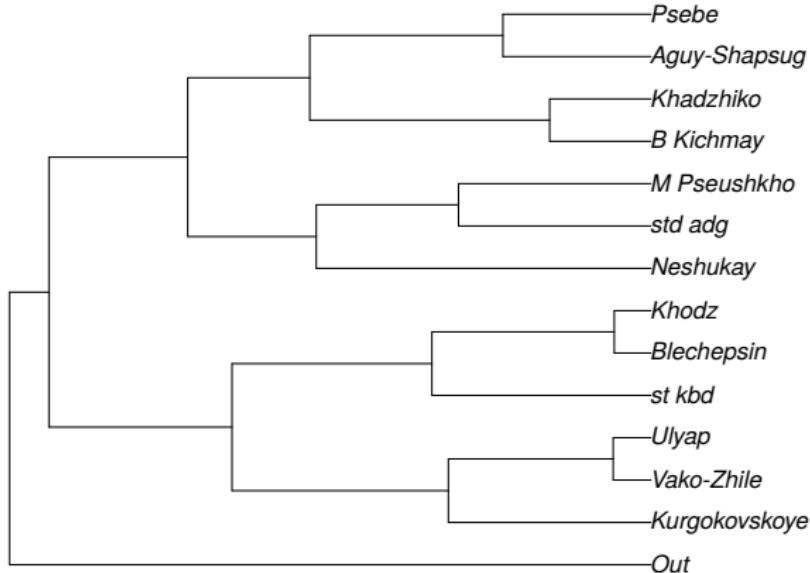
# Дендрограммы

Дендрограммой обычно называют граф, отображающий некоторые расстояния между единицами. Существует достаточно много методов построения графов на основе матрицы расстояний, напрямую связанный с используемым методом кластеризации. Надо отметить, что дендрограмма это всего лишь **семейство визуализаций матрицы расстояний**. Примером для построения дендрограмм послужат данные фонетических особенностей адыгских идиомов:

```
ad <- read.csv("http://goo.gl/Rj92fh")
rownames(ad) <- ad[,1]
ad.d <- dist(ad, method = "binary")
ad.c <- hclust(ad.d)
library(ape)
ad.c <- as.phylo(ad.c)          # этот формат лучше воспринимается
plot(ad.c, type = "phylogram")
```

# Дендрограммы: type = "phylogram"

метрики  
расстояний  
метрики расстояний  
heatmap  
методы  
кластеризации  
k-means  
hierarchical  
проблемы  
дендрограммы  
валидация кластеров  
деревья  
решений



# Дендрограммы: type = "cladogram"

метрики  
расстояний

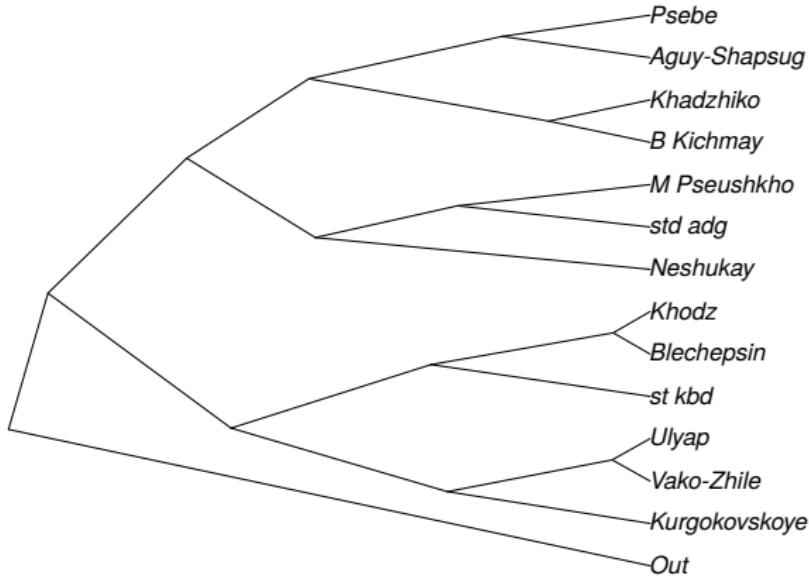
метрики расстояний  
heatmap

методы  
кластеризации

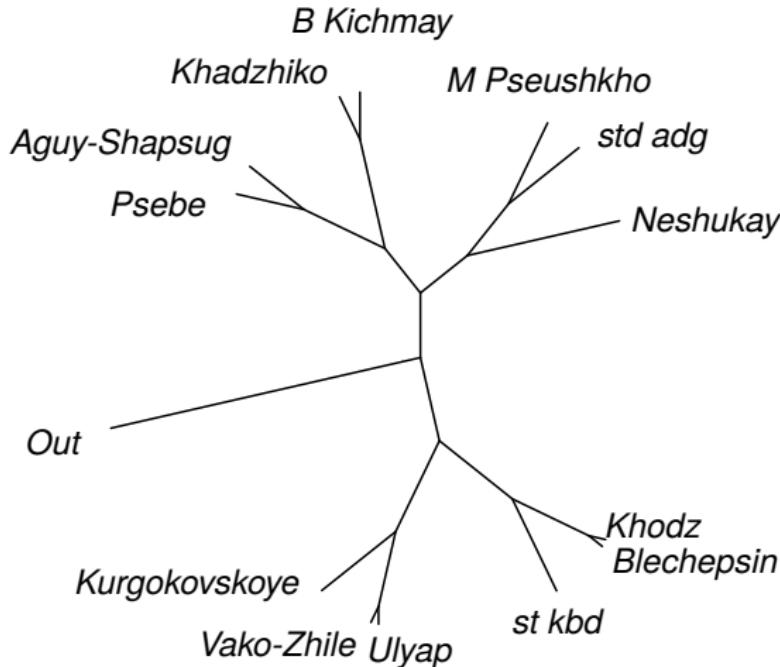
k-means  
hierarchical  
проблемы

дендрограммы  
валидация кластеров

деревья  
решений



# Дендрограммы: type = "unrooted"



Плохо работает, нужно доводить руками.

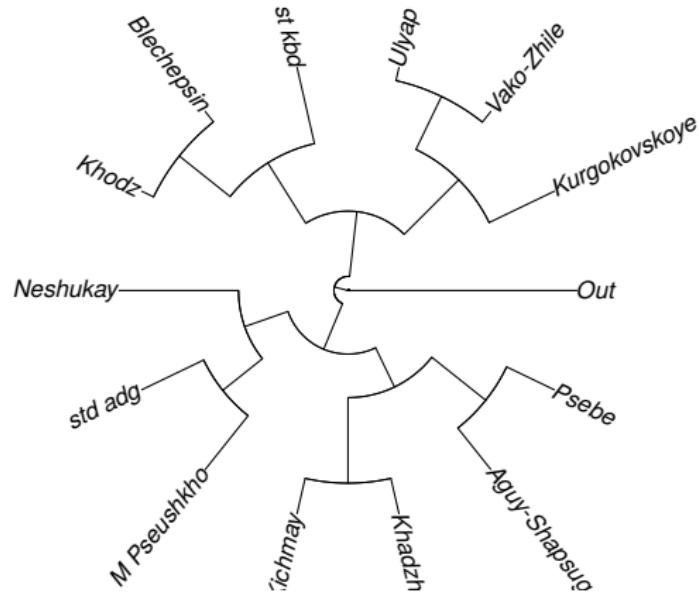
# Дендрограммы: type = "fan"

метрики  
расстояний  
метрики расстояний  
heatmap

методы  
кластеризации  
k-means  
hierarchical  
проблемы

дендрограммы  
валидация кластеров

деревья  
решений



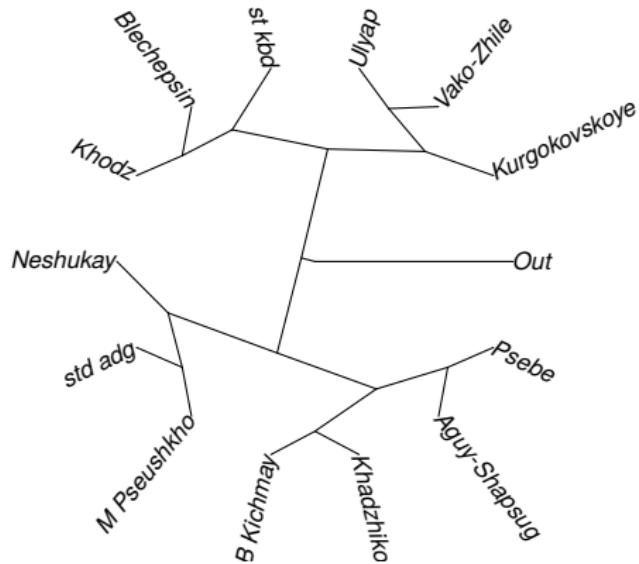
# Дендрограммы: type = "radial"

метрики  
расстояний  
метрики расстояний  
heatmap

методы  
кластеризации  
k-means  
hierarchical  
проблемы

дендрограммы  
валидация кластеров

деревья  
решений



# Деревья решений

Достаточно популярным средством построения моделей является дерево решений. В узлах дерева пишутся условия, ограничивающие предикторы, на ребрах записываются значения предикторов, а на листьях дерева записаны значения предсказываемой переменной. Деревья решений позволяют решать как задачи регрессии, так и классификации.

- |  |  |  |
|--|--|--|
| <p><b>pro</b> ДР легко интерпретировать</p> <p><b>contra</b> Даже незначительные изменения в обучающих данных могут привести к значительной перестройке модели</p> | <p><b>pro</b> ДР могут работать с переменными любого типа</p> <p><b>contra</b> Невысокая предсказательная точность</p> | <p><b>pro</b> ДР автоматически подбирают модель, учитывая взаимодействия</p> |
|--|--|--|

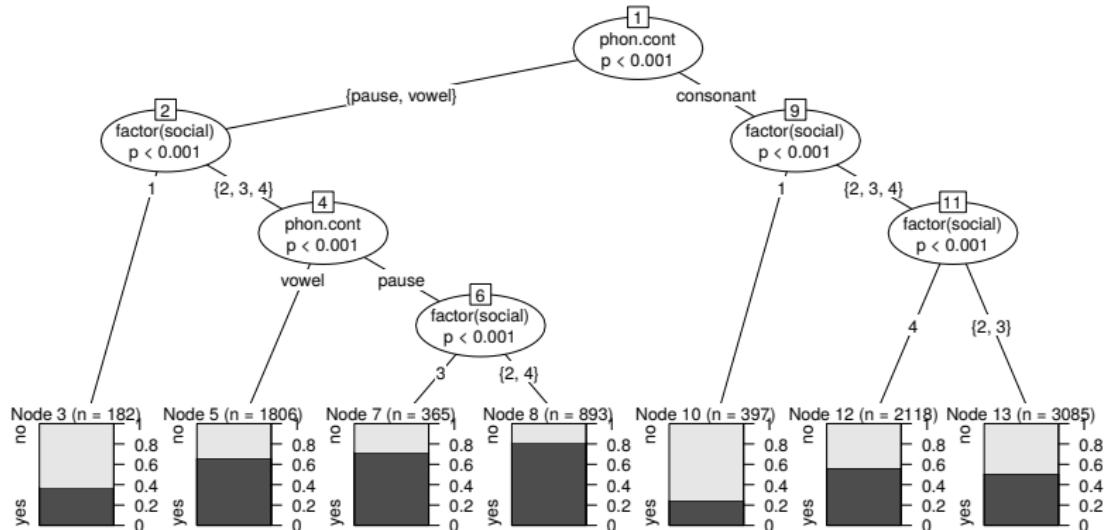
Для преодоления недостатков можно использовать случайные леса (*random forest*) и другие ансамбли деревьев.

презентация доступна: <http://goo.gl/F6pC3o>

# Деревья решений

метрики  
расстояний  
метрики расстояний  
heatmap  
методы  
кластеризации  
k-means  
hierarchical  
проблемы  
дendrogramмы  
валидация кластеров

деревья  
решений



```
df <- read.csv("http://goo.gl/NwbKsN")
df$social <- factor(df$social)      # внимание! числовой vs. номинативный

library(party)
fit <- ctree(deletion~phon.cont+social, data=df)
plot(fit)
```

метрики  
расстояний  
метрики расстояний  
heatmap

методы  
кластеризации  
k-means  
hierarchical  
проблемы  
дendrogramмы  
валидация кластеров

деревья  
решений

# Спасибо за внимание

Пишите письма

[agricolamz@gmail.com](mailto:agricolamz@gmail.com)

# Список литературы

метрики  
расстояний  
метрики расстояний  
heatmap  
  
методы  
кластеризации  
k-means  
hierarchical  
проблемы  
дendrogramмы  
валидация кластеров  
  
деревья  
решений

- Estivill-Castro, V. (2002). Why so many clustering algorithms: a position paper. ACM SIGKDD explorations newsletter 4(1), 65–75.
- Gower, J. C. (1971). A general coefficient of similarity and some of its properties. Biometrics, 857–871.
- Gower, J. C. and P. Legendre (1986). Metric and euclidean properties of dissimilarity coefficients. Journal of classification 3(1), 5–48.
- Hawkins, D. M. (1982). Topics in applied multivariate analysis, Volume 1. Cambridge University Press.
- Lloyd, S. P. (1982). Least squares quantization in pcm. Information Theory, IEEE Transactions on 28(2), 129–137.