AKADEMIA GÓRNICZO-HUTNICZA
IM. STANISŁAWA STASZICA W KRAKOWIE

Biblioteka rattle pakietu R

mgr inż. Beata Śpiewak

spiewak@agh.edu.pl

Wydział Geodezji Górniczej i Inżynierii Środowiska
Katedra Geomatyki

Kraków, 21.12.2015 r.

The R Analytical Tool To Learn Easily

Pakiet Rattle to narzędzie do eksploracji danych, które zbiera w jednym miejscu większość najważniejszych funkcji z obszaru data mining dzięki czemu może konkurować z oprogramowaniami komercyjnymi, tj. Statistica czy Matlab.

Author Graham Williams [aut, cph, cre],

- Mark Vere Culp [cph],
- Ed Cox [ctb],
- Anthony Nolan [ctb],
- Denis White [cph],
- Daniele Medri [ctb],
- Akbar Waljee [ctb] (OOB AUC for Random Forest),
- Brian Ripley [cph] (Author of original print.summary.nnet),
- Jose Magana [ctb] (Contributed the ggpairs plots).

Data mining

- Eksploracja danych to „proces automatycznego odkrywania nietrywialnych, dotychczas nieznanych, potencjalnie użytecznych reguł, zależności, wzorców, schematów, podobieństw lub trendów w dużych repozytoriach danych”[Ważniak].
- Korzenie eksploracji danych wywodzą się ze statystyki.

Data mining w Rattle

- Wczytanie danych
- Eksploracja danych
- Wykonanie testów statystycznych
- Transformacja danych w celu dopasowania do modelu
- Budowanie modelu
- Przegląd otrzymanych wyników

Dane

RGui

File Edit View Misc Packages Windows Help

R Console

	age	sex	chest_pain	trestbps	chol	fbs	restecg	thalach	exang	disease
1	31	male	asympt	120	270	f	normal	153	yes	positive
2	33	female	asympt	100	246	f	normal	150	yes	positive
3	34	male	typ_angina	140	156	f	normal	180	no	positive
4	35	male	atyp_angina	110	257	f	normal	140	no	positive
5	36	male	atyp_angina	120	267	f	normal	160	no	positive
6	37	male	asympt	140	207	f	normal	130	yes	positive
7	38	male	asympt	110	196	f	normal	166	no	positive
8	38	male	asympt	120	282	f	normal	170	no	positive
9	38	male	asympt	92	117	f	normal	134	yes	positive
10	41	male	asympt	110	289	f	normal	170	no	positive
11	43	male	asympt	150	247	f	normal	130	yes	positive
12	46	male	asympt	110	202	f	normal	150	yes	positive
13	46	male	asympt	118	186	f	normal	124	no	positive
14	46	male	asympt	120	277	f	normal	125	yes	positive
15	47	male	non_anginal	140	193	f	normal	145	yes	positive
16	47	male	asympt	150	226	f	normal	98	yes	positive
17	48	male	asympt	120	260	f	normal	115	no	positive
18	48	male	asympt	160	268	f	normal	103	yes	positive
19	49	female	non_anginal	160	180	f	normal	156	no	positive
20	49	male	non_anginal	115	265	f	normal	175	no	positive
21	49	male	asympt	130	206	f	normal	170	no	positive
22	50	female	non_anginal	140	288	f	normal	140	yes	positive
23	50	male	asympt	145	264	f	normal	150	no	positive
24	51	female	asympt	160	303	f	normal	150	yes	positive

- Age – wiek
- Sex – płeć
- Chest pain – ból zamostkowy
- Fbs – poziom cukru
- Rest cg – wynik EKG
- Thalach – puls
- Exang – objawy w trakcie wysiłku
- Disease - choroba

Nakładka graficzna Rattle

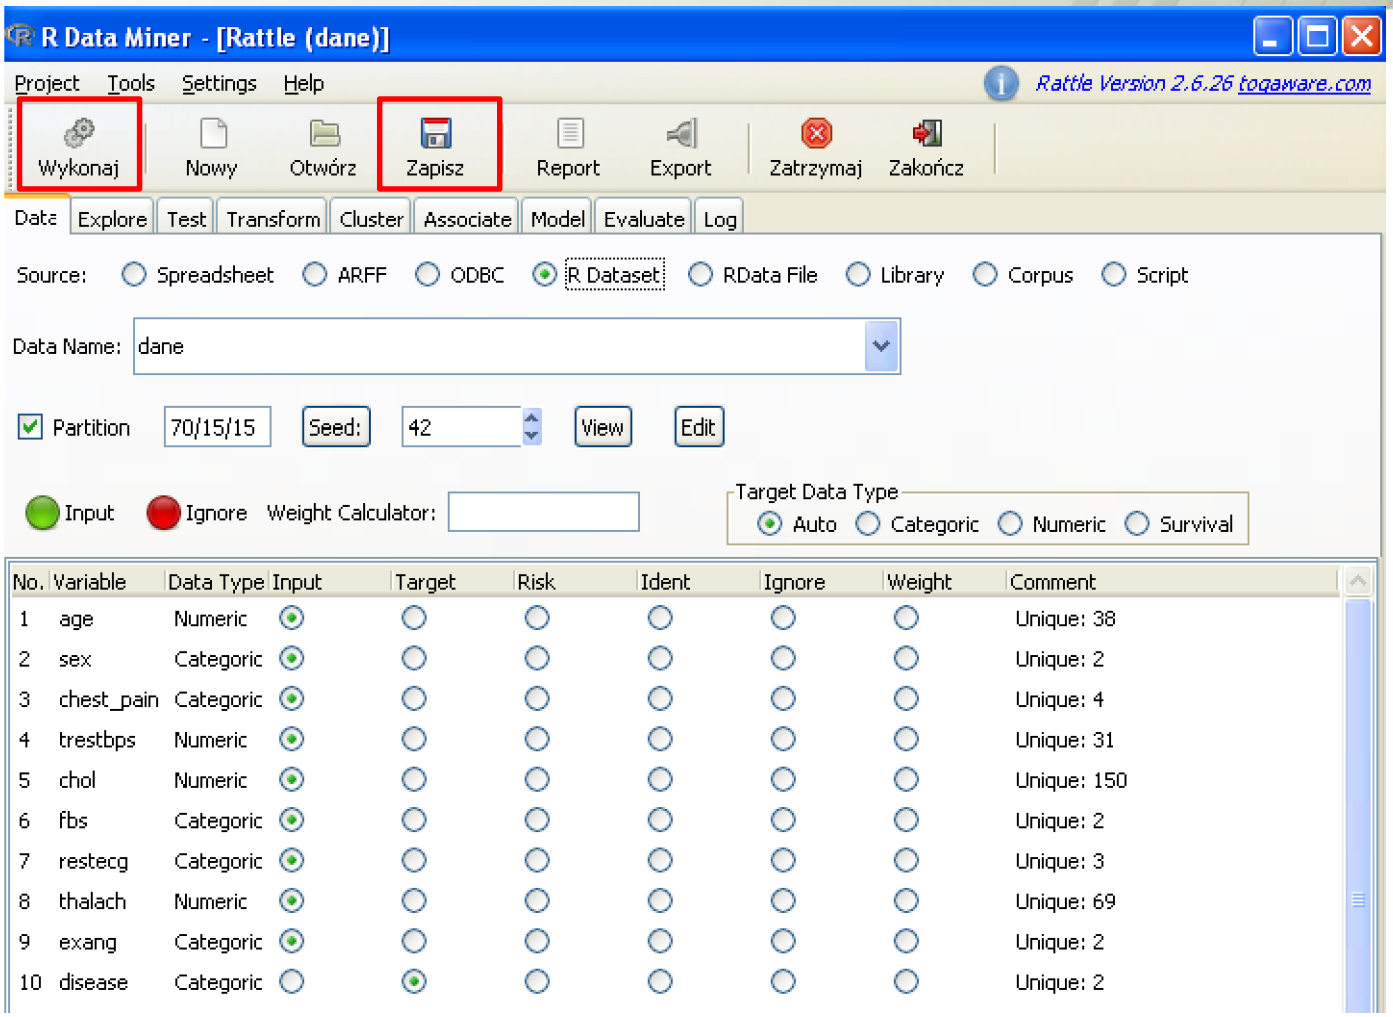

Summary

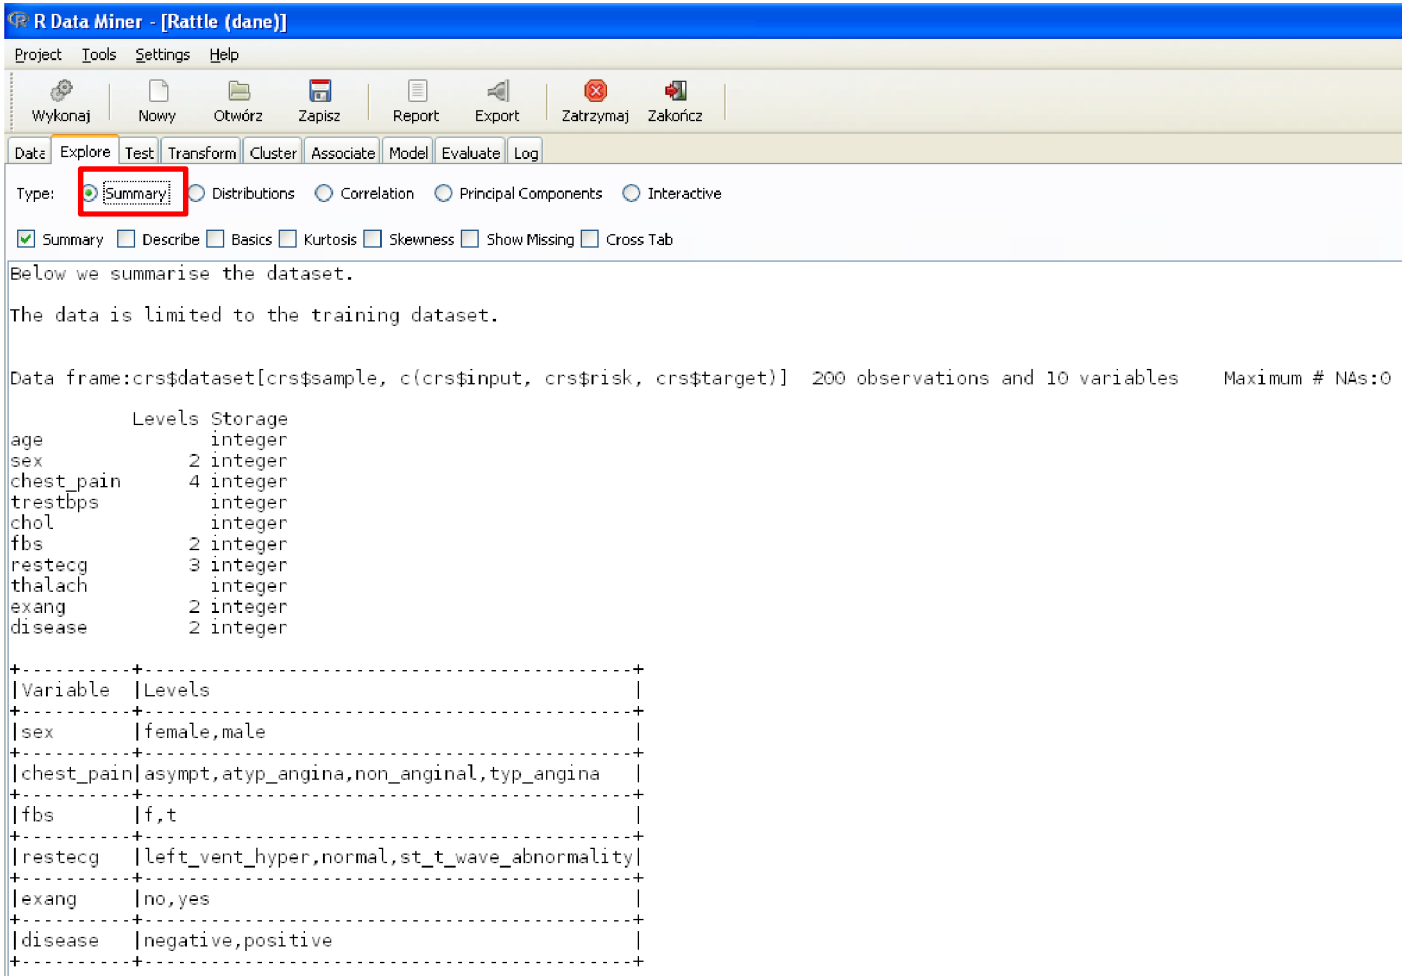
R Data Miner - [Rattle (dane)]
Project Tools Settings Help
Wykonaj Nowy Otwórz Zapisz Report Export Zatrzymaj Zakończ
Data Explore Test Transform Cluster Associate Model Evaluate Log
Type: Summary Distributions Correlation Principal Components Interactive
Summary Describe Basics Kurtosis Skewness Show Missing Cross Tab
Below we summarise the dataset.
The data is limited to the training dataset.
Data frame:crs$dataset[crs$sample, c(crs$input, crs$risk, crs$target)] 200 observations and 10 variables Maximum # NAs:0
Levels Storage
age integer
sex 2 integer
chest_pain 4 integer
trestbps integer
chol integer
fbs 2 integer
restecg 3 integer
thalach integer
exang 2 integer
disease 2 integer
+----------+--+
|Variable |Levels |
+----------+--+
|sex |female,male |
+----------+--+
|chest_pain|asympt,atyp_angina,non_anginal,typ_angina |
+----------+--+
|fbs |f,t |
+----------+--+
|restecg |left_vent_hyper,normal,st_t_wave_abnormality|
+----------+--+
|exang |no,yes |
+----------+--+
|disease |negative,positive |
+----------+--+

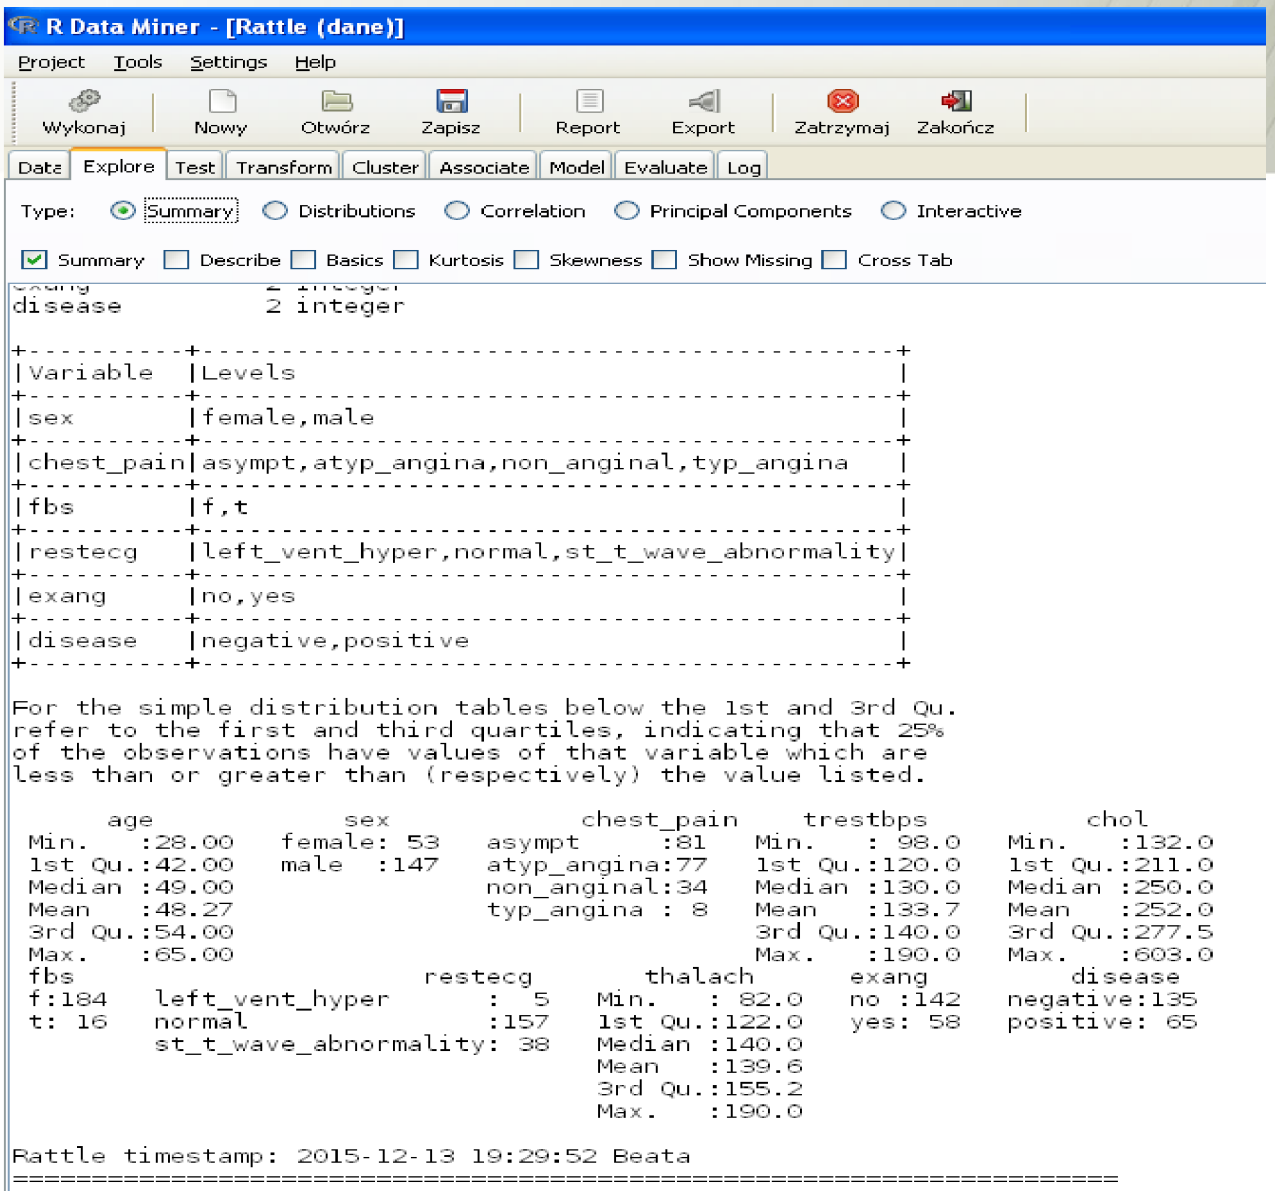
R Data Miner - [Rattle (dane)]
Project Tools Settings Help
Wykonaj Nowy Otwórz Zapisz Report Export Zatrzymaj Zakończ
Data Explore Test Transform Cluster Associate Model Evaluate Log
Type: Summary Distributions Correlation Principal Components Interactive
Summary Describe Basics Kurtosis Skewness Show Missing Cross Tab
disease 2 integer
+----------+--+
|Variable |Levels |
+----------+--+
|sex |female,male |
+----------+--+
|chest_pain|asympt,atyp_angina,non_anginal,typ_angina |
+----------+--+
|fbs |f,t |
+----------+--+
|restecg |left_vent_hyper,normal,st_t_wave_abnormality|
+----------+--+
|exang |no,yes |
+----------+--+
|disease |negative,positive |
+----------+--+
For the simple distribution tables below the 1st and 3rd Qu.
refer to the first and third quartiles, indicating that 25%
of the observations have values of that variable which are
less than or greater than (respectively) the value listed.
age sex chest_pain trestbps chol
Min. :28.00 female: 53 asympt :81 Min. : 98.0 Min. :132.0
1st Qu.:42.00 male :147 atyp_angina:77 1st Qu.:120.0 1st Qu.:211.0
Median :49.00 non_anginal:34 Median :130.0 Median :250.0
Mean :48.27 typ_angina : 8 Mean :133.7 Mean :252.0
3rd Qu.:54.00 3rd Qu.:140.0 3rd Qu.:277.5
Max. :65.00 Max. :190.0 Max. :603.0
fbs restecg thalach exang disease
f:184 left_vent_hyper : 5 Min. : 82.0 no :142 negative:135
t: 16 normal :157 1st Qu.:122.0 yes: 58 positive: 65
st_t_wave_abnormality: 38 Median :140.0
Mean :139.6
3rd Qu.:155.2
Max. :190.0
Rattle timestamp: 2015-12-13 19:29:52 Beata

Korelacja pomiędzy zmiennymi

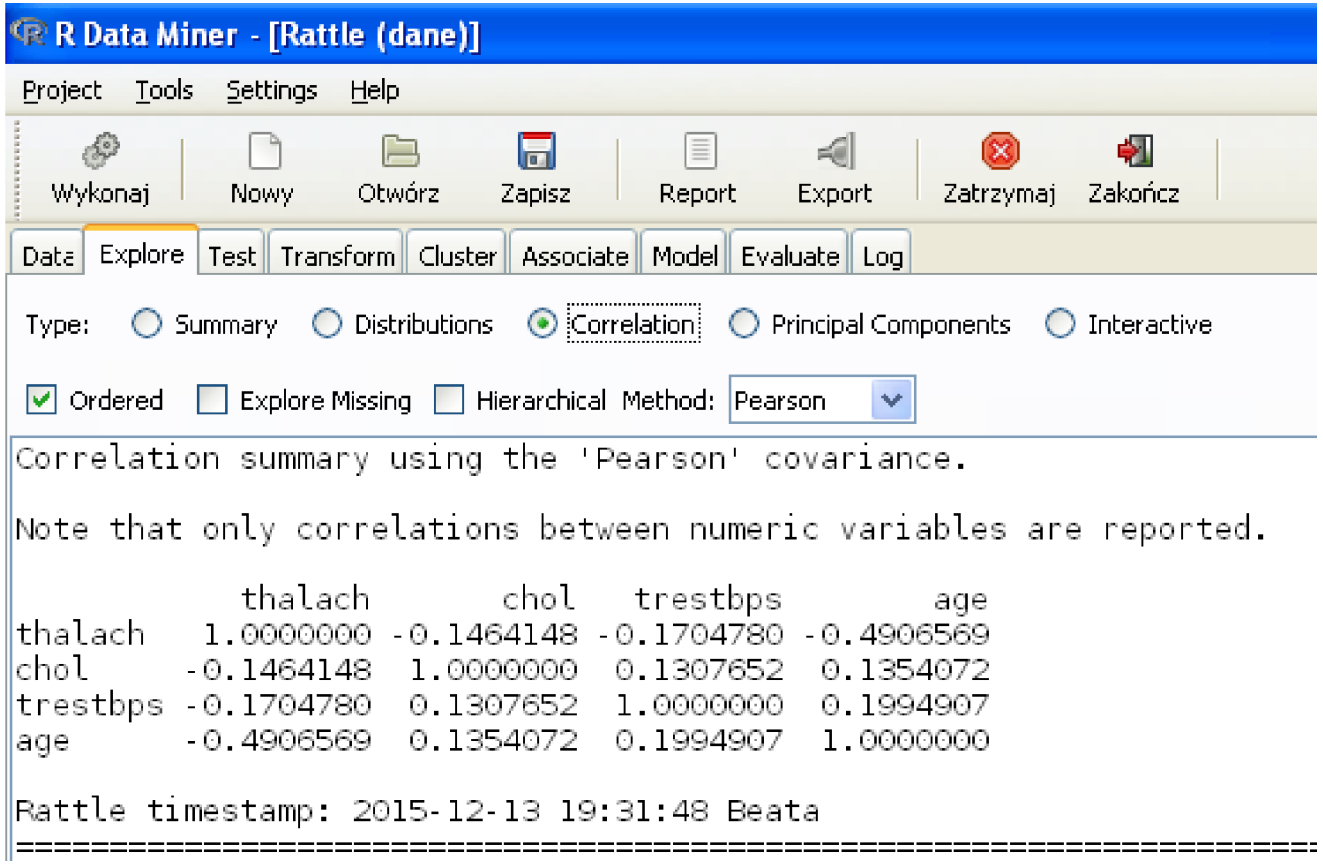

Explore - >Distribution

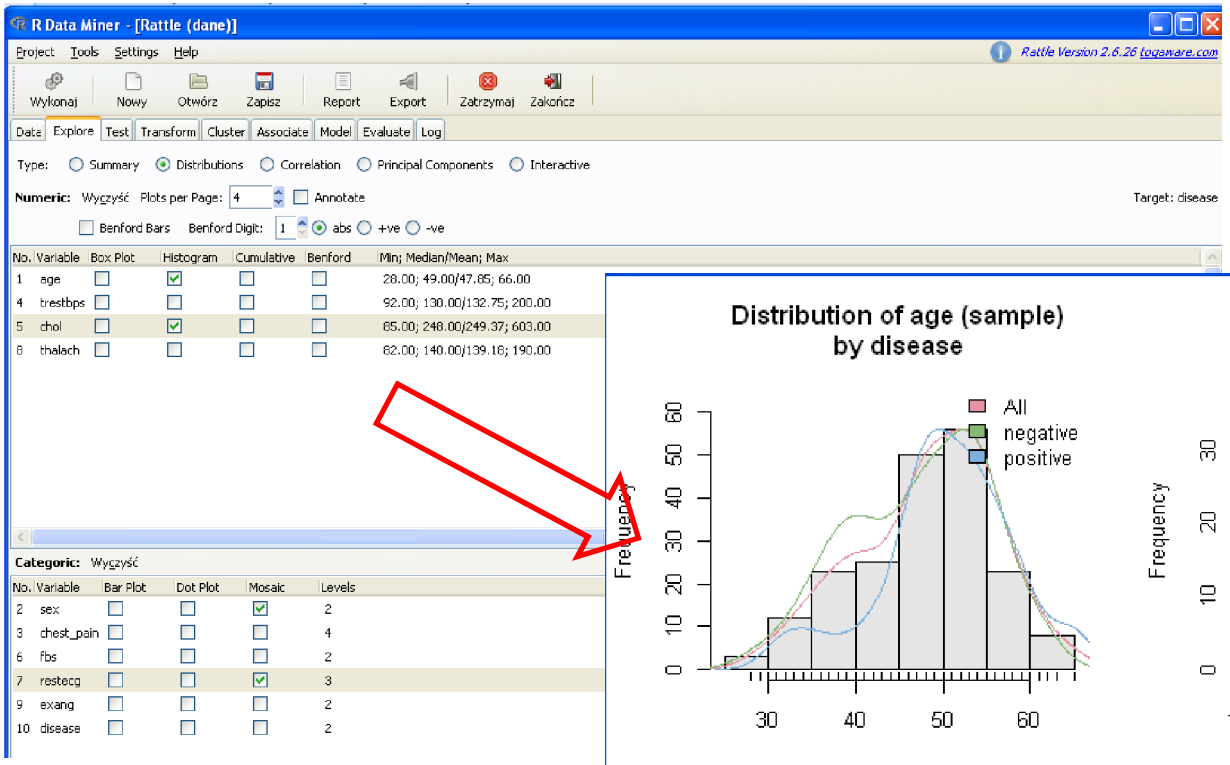

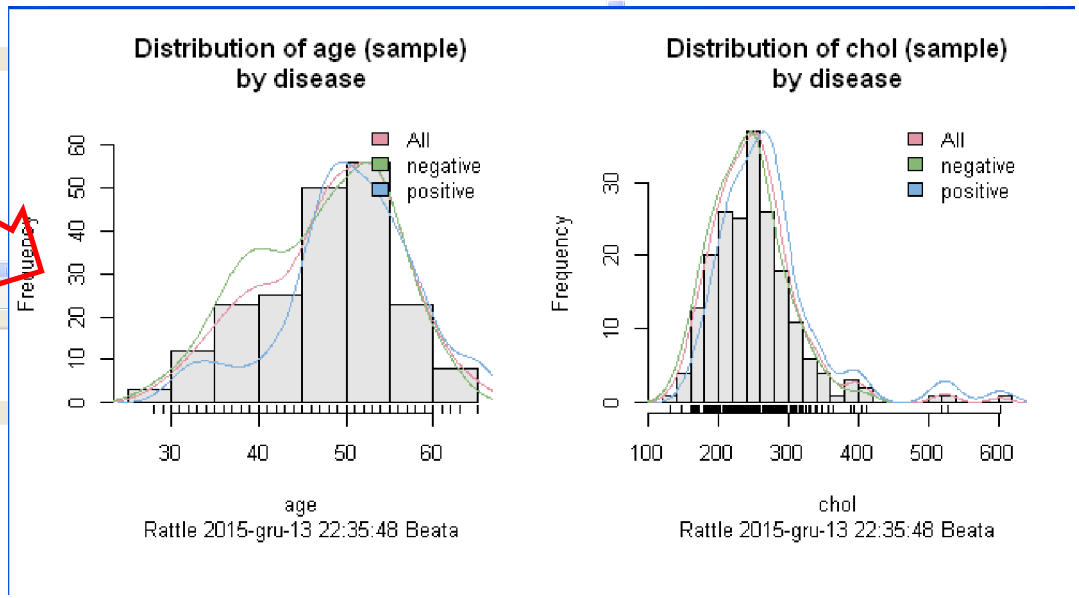

Explore - > Distribution

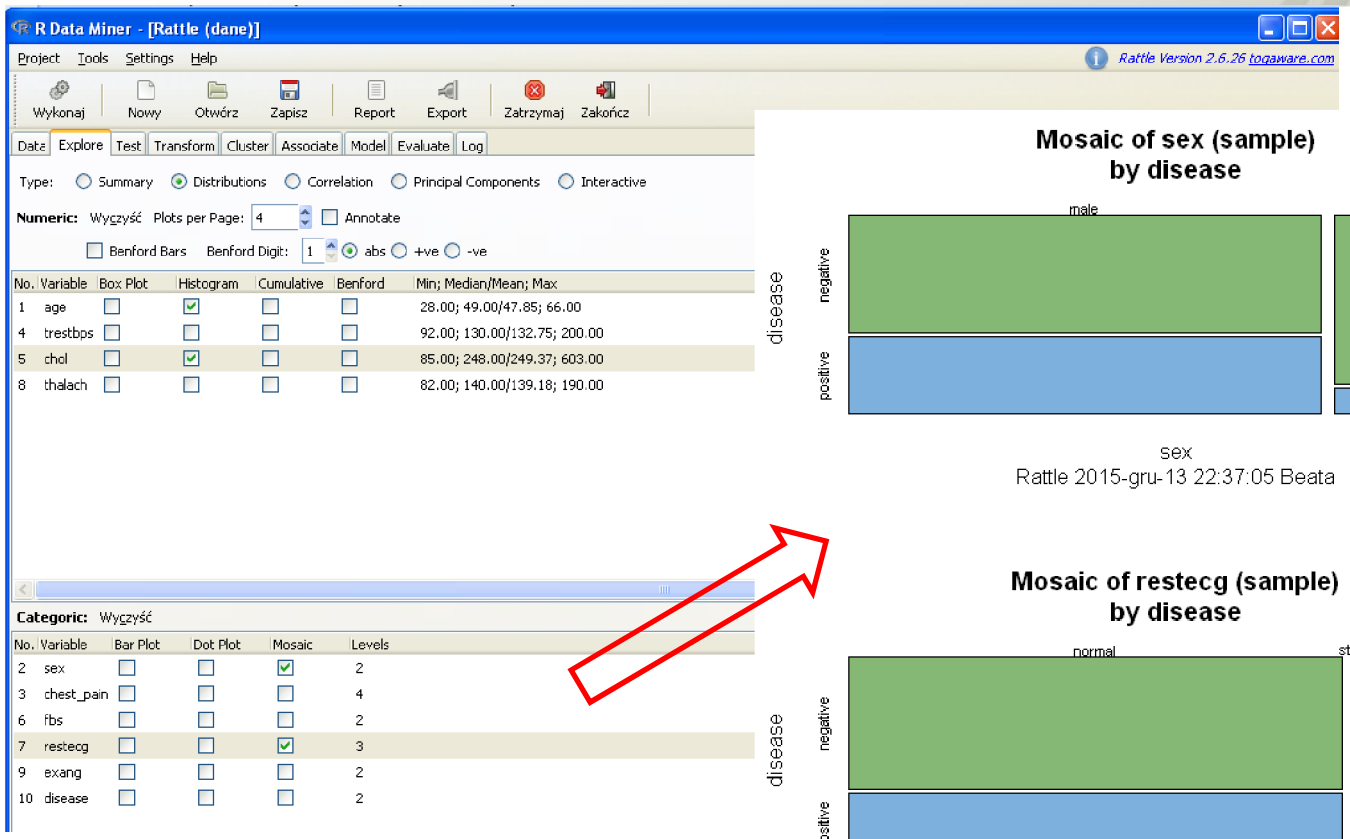

Transform - > Rescale/Order

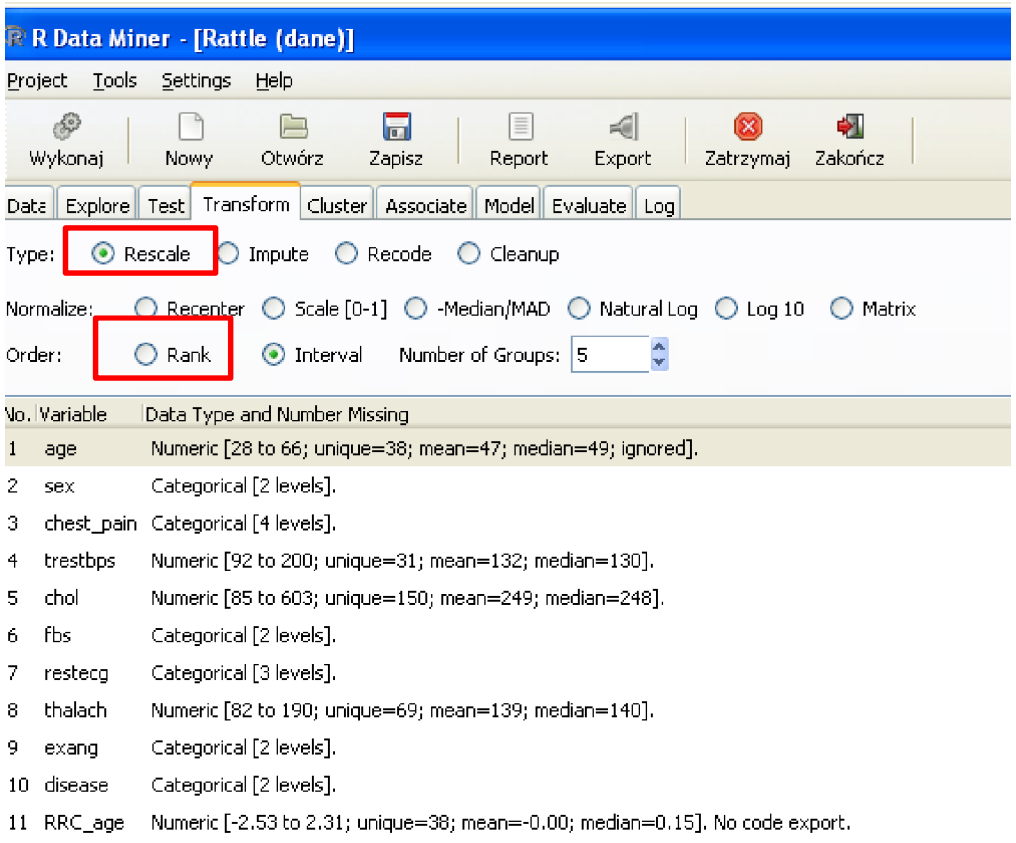

- Przeskalowanie
- Redukcja skośności
- Uzupełnienie brakujących danych
- Zmiana danych ilościowych na jakościowe

Transform - > Rescale

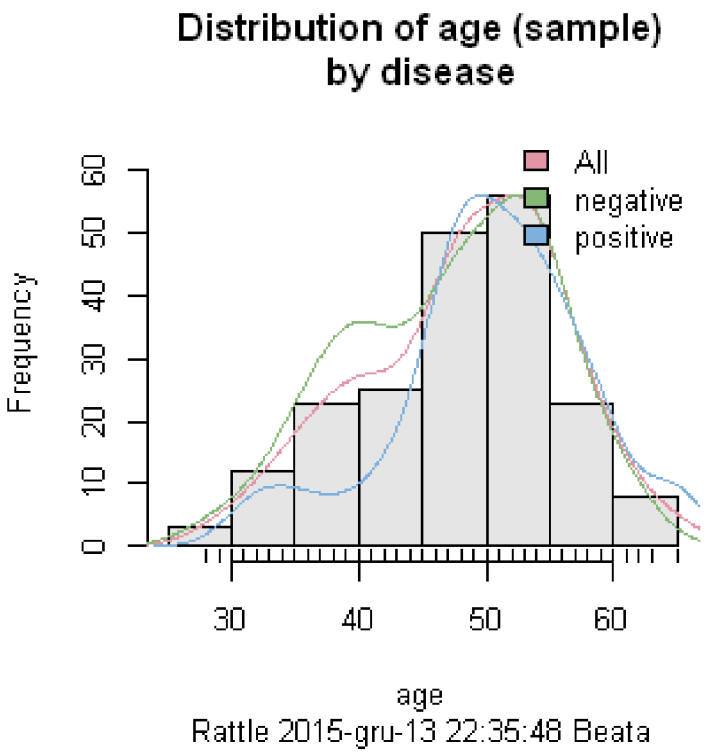

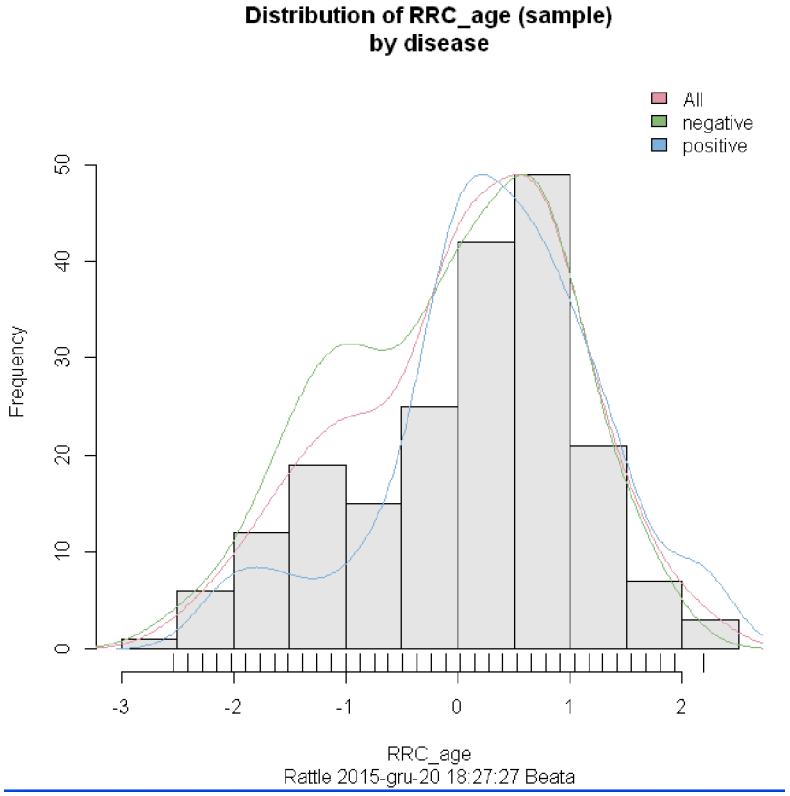

Cluster – GRUPOWANIE forma automatycznego

łączenia (grupowania) obiektów, które są do siebie podobne według określonych kryteriów

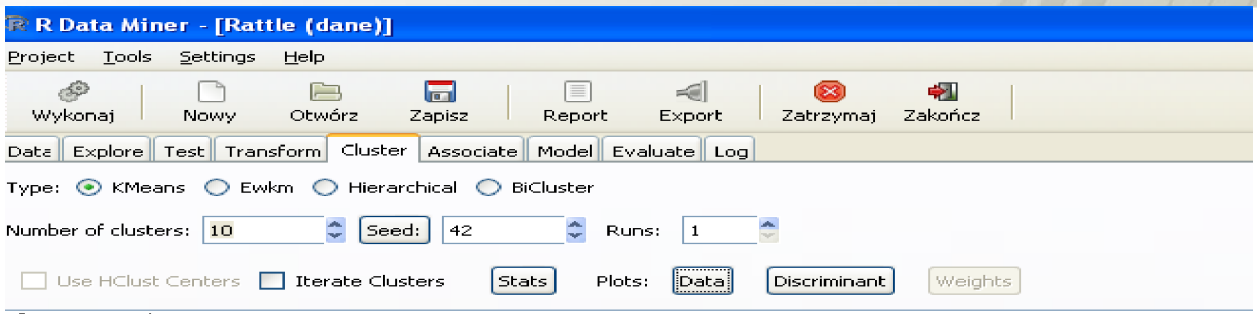


```
Cluster sizes:

[1] "13 8 37 26 13 30 3 23 36 11"

Data means:

    trestbps          chol      thalach       RRC_age
133.65500000 252.00500000 139.61000000   0.05466617

Cluster centers:

   trestbps      chol  thalach      RRC_age
1  144.6154 174.0000 154.3077 -0.10786151
2  121.0000 163.1250 179.8750 -1.20731348
3  122.2973 210.9189 147.1892 -0.20088212
4  145.3462 211.0000 114.9615  0.55401593
5  150.7692 364.6923 128.2308  0.52950195
6  135.0000 270.5000 111.6667  0.66122374
7  131.0000 550.0000 128.3333 -0.19284330
8  135.7391 304.5217 153.9565 -0.13003067
9  122.8889 256.4167 144.8333 -0.01933881
10 148.1818 254.8182 171.3636 -0.67569441

Within cluster sum of squares:

 [1]  7740.733  2601.825 16769.370 19519.001 21442.779 24632.884  4661.682
 [8] 16915.788 13562.898  4762.522

Time taken: 0.06 secs

Rattle timestamp: 2015-12-20 21:43:06 Beata
================================================================================
```

Podsumowanie

- Powszechnie dostępne narzędzie
- Nie wymaga umiejętności programowania
- Graficzny interfejs ułatwiający korzystanie z pakietu
- Pozwala na ulepszanie swoich możliwości przez zaawansowanych użytkowników

Bibliografia

- https://cran.r-project.org/web/packages/rattle/index.html
- https://cran.r-project.org/web/packages/rattle/rattle.pdf
- http://eric.univ-lyon2.fr/~ricco/tanagra/fichiers/heart_for_rattle.txt
- http://rattle.togaware.com/

Dziękuje za uwagę!