Laboratório

Preprocessamento com WEKA Explorer

Faça o download do dataset **test_credit.csv*** , e execute as seguintes tarefas:
1. Use o **Weka Viewer** para ter uma visão geral do dataset original.
2. Substitua os ***missing data*** se houver algum.
3. Verifique se há ***outliers*** ou **valores extremos** no conjunto de dados.
4. Realize **normalização** de duas características.
5. Realize a **discretização** em duas características.
6. Realize a **substituição** em duas características.

*disponível em: www.inf.ufpr.br/menotti/am-231/data.zip

Nas páginas abaixo, encontram-se tutoriais explicando / ilustrando cada passo:

1. Visualização dos dados bruto (raw data)

1. Inicie uma sessão do **Weka** ou execute em linha de comando:
   java –jar weka.jar.

2. Quando a **GUI Chooser** surgir, selecione o **Explorer** a partir das quatro opções do lado direito.

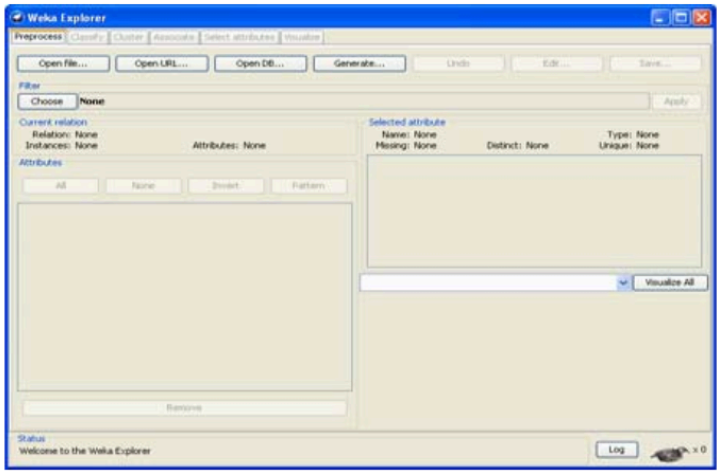

3. A tela acima é a principal do Explorer. Existem 6 guias no topo do aplicativo que representam as operações básicas que o Explorer suporta. Agora, estamos no ***Preprocess***. Clique no botão ***Open file*** para abrir a janela padrão de diálogo através da qual você pode selecionar um arquivo. Escolha o arquivo ***weather.nominal.arff***. Se você tem um arquivo no formato ***CSV***, modifique de "***ARFF*** data files" para "***CSV*** data files" em "Files of type". Quando você especificar um arquivo **.csv** ele é convertido automaticamente para o formato ARFF.

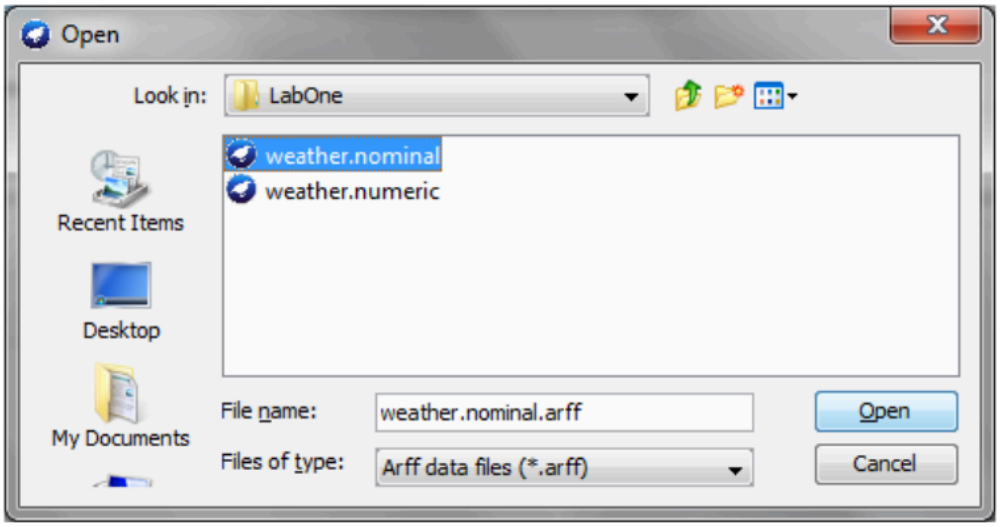

4. Para visualizar todo o dataset, clique no botão **Edit**, e então uma janela de visualização será aberta com o dataset carregado.

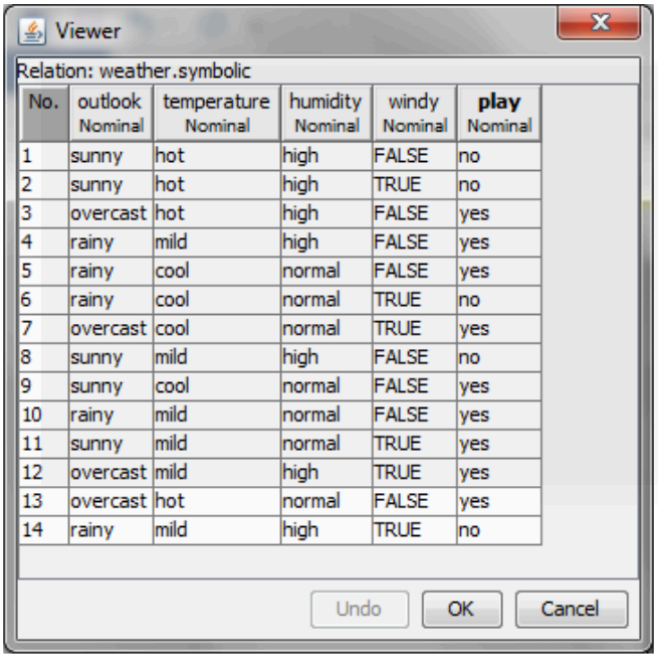

No.	outlook Nominal	temperature Nominal	humidity Nominal	windy Nominal	play Nominal
1	sunny	hot	high	FALSE	no
2	sunny	hot	high	TRUE	no
3	overcast	hot	high	FALSE	yes
4	rainy	mild	high	FALSE	yes
5	rainy	cool	normal	FALSE	yes
6	rainy	cool	normal	TRUE	no
7	overcast	cool	normal	TRUE	yes
8	sunny	mild	high	FALSE	no
9	sunny	cool	normal	FALSE	yes
10	rainy	mild	normal	FALSE	yes
11	sunny	mild	normal	TRUE	yes
12	overcast	mild	high	TRUE	yes
13	overcast	hot	normal	FALSE	yes
14	rainy	mild	high	TRUE	no

5. O primeiro atributo, ***outlook***, é selecionado por default. As características deste atributo são apresentadas. Um histograma no canto inferior direito mostra o quão frequente cada um dos dois valores da classe ***play*** ocorre para cada valor do atributo ***outlook***. Você pode visualizar esta análise para outros atributos bastando realizar a seleção na esquerda.

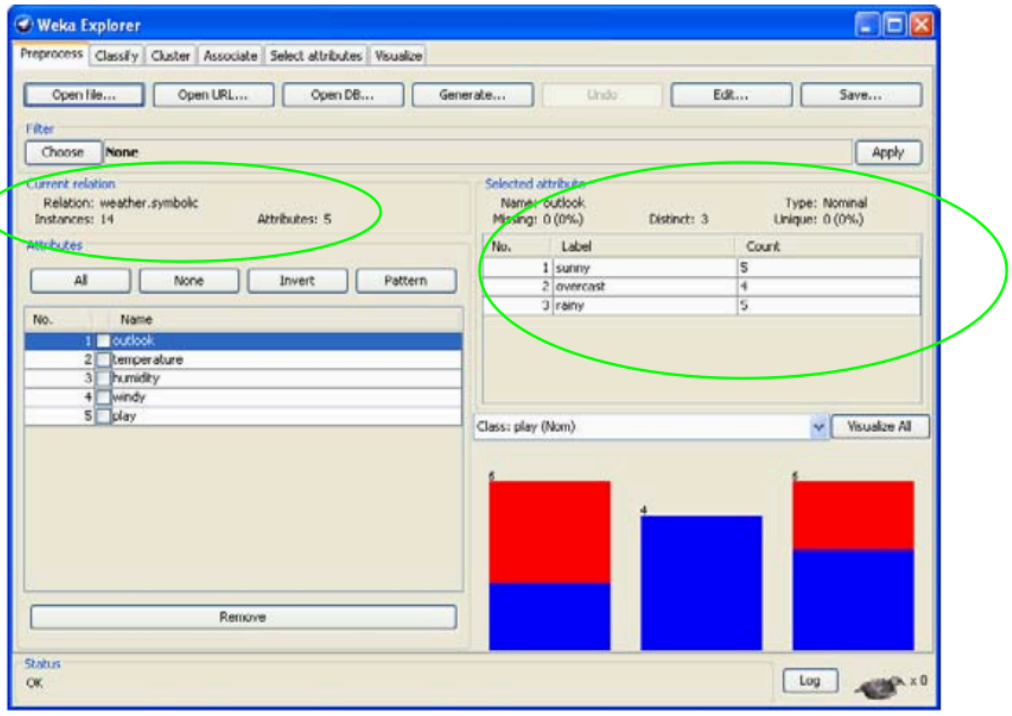

6. Se você abrir o outro arquivo Weather, ***weather.numeric.arff***, a visualização dos atributos é diferente. Selecionando-se o segundo atributo, ***temperature***, você visualiza seus valores máximos e mínimos, bem como a média e o desvio padrão. O histograma apresenta a distribuição da classe como uma função deste atributo.

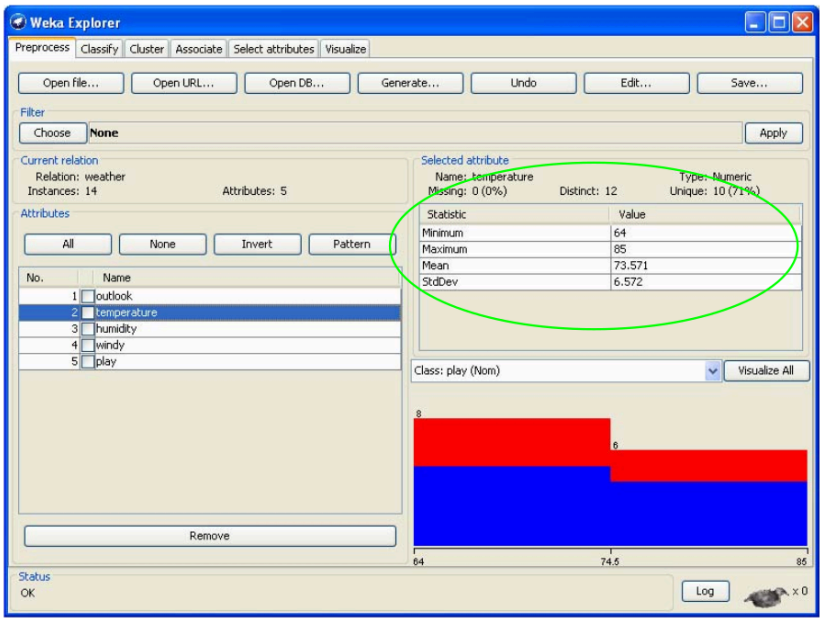

7. Clique na guia **Visualize** para visualizar gráficos 2D do dataset.

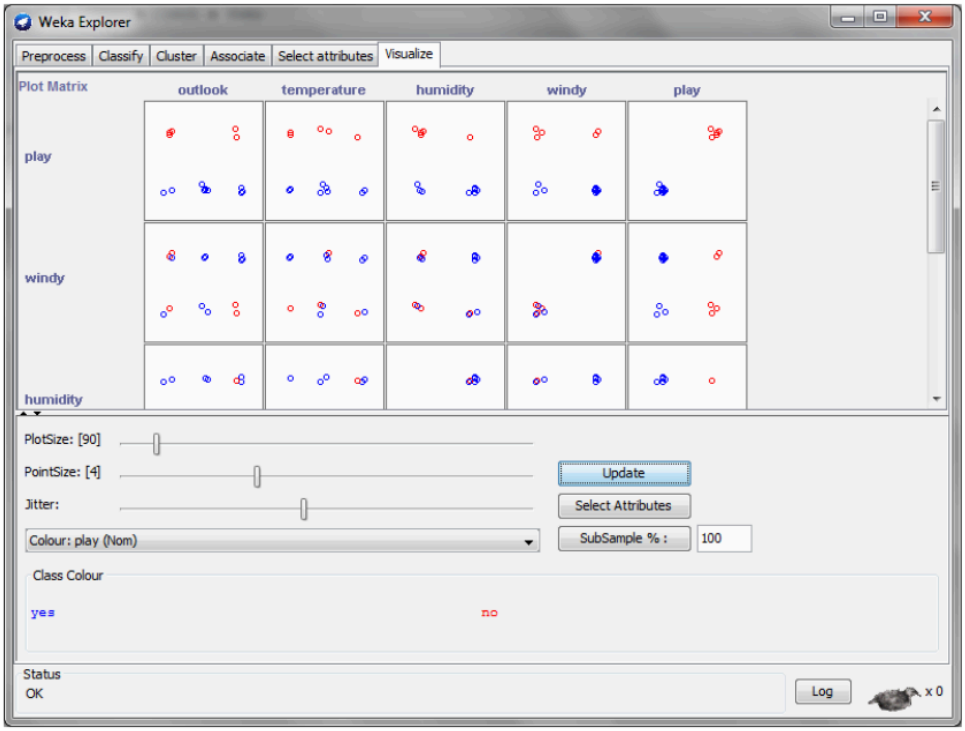

1.1 Usando Filtros para Remover Atributos

Unsupervised Attribute Filter – Remove: Este filtro remove/deleta atributos específicos de um dataset. O mesmo efeito pode ser obtido mais facilmente selecionando-se os atributos relevantes usando as **tick boxes** e então pressionando-se o botão **Remove**.

1. Abra um dataset, tal como o ***weather.nominal*** dataset.

2. Clique no botão **Choose** dentro da caixa **Filter** (acima a esquerda).
   E então clique em: **filters** => **unsupervised** => **attribute** => **Remove**.

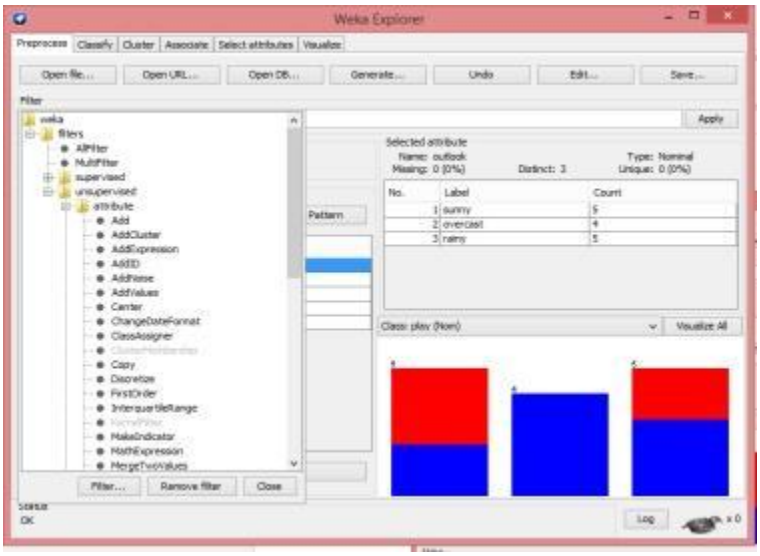

3. Clique com o botão **Direito** sobre a caixa **Remove**, e então escolha **Show Properties**.

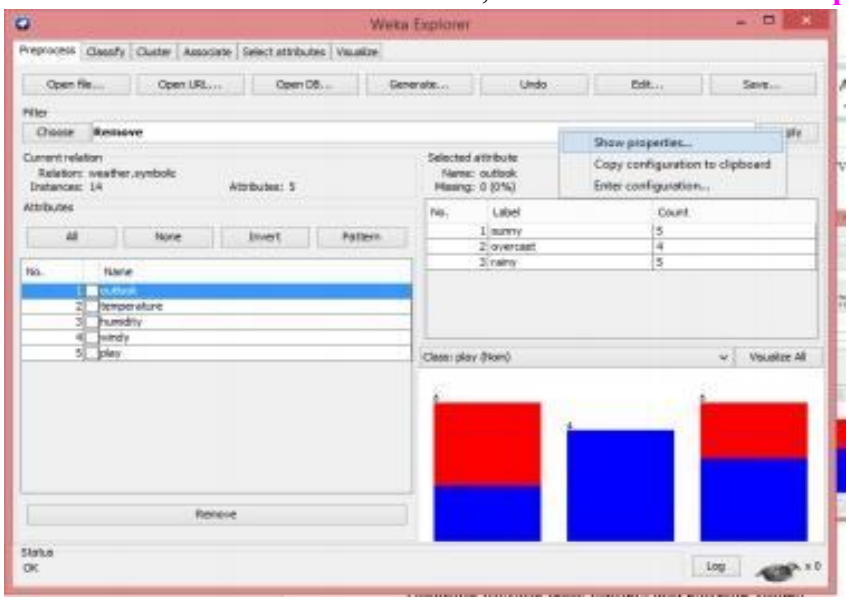

4. Existem duas opções para o filtro **Remove**. Uma opção é **attributeIndices** que especifica a faixa de atributos a ser removida. (No exemplo, os índices ***1,2*** – **outlook** and **temperature** - foram escolhidos). A outra opção é **invertSelection** que determina se o filtro seleciona ou deleta os atributos (Foi selecionado ***False*** (*default*), que indica para remover ao invés de selecioná-los). E então você clica em **OK**.

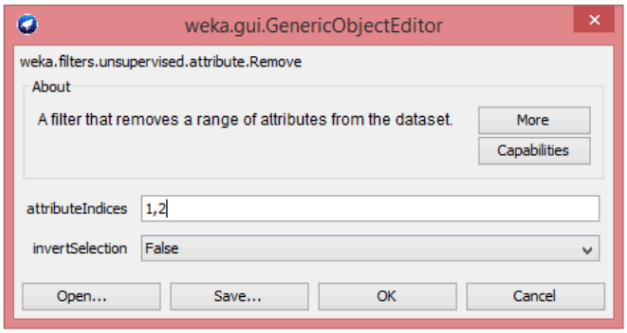

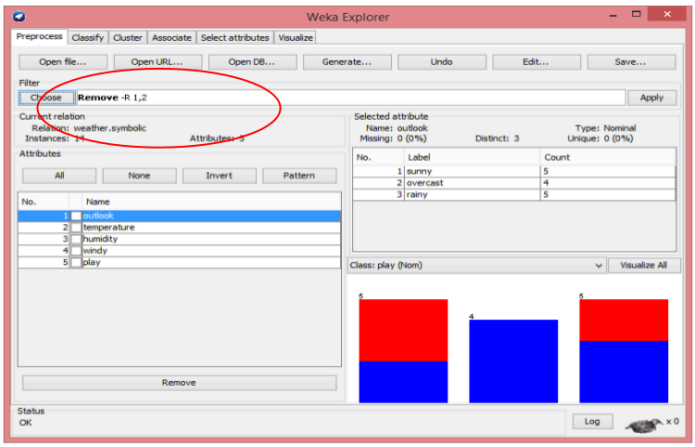

5. Clique no botão **Apply** próximo da caixa do filtro **Remove**, e então os dois primeiros atributos são removidos do dataset, e apenas três sobram. Você pode clicar no botão **Undo** para desfazer a operação de filtragem e restaurar o dataset original. Você pode também clicar no botão **Save** para gravar o dataset processado.

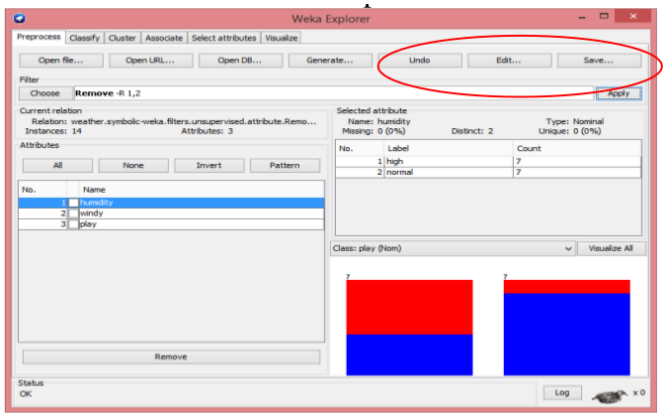

2. Manipulando *missing data*

Unsupervised Attribute Filter – ReplaceMissingValues: Estes filtro substitui todos os valores faltantes (*missing values*) para atributos nominais e numéricos com a moda para atributos nominais e a média para atributos numéricos com base nos dados de treinamento.

1. Abra o dataset – **weather.numeric.arff**. Clique no botão **Edit** para visualizar os dados brutos. Você pode verificar que dois dos atributos têm ***missing values***.

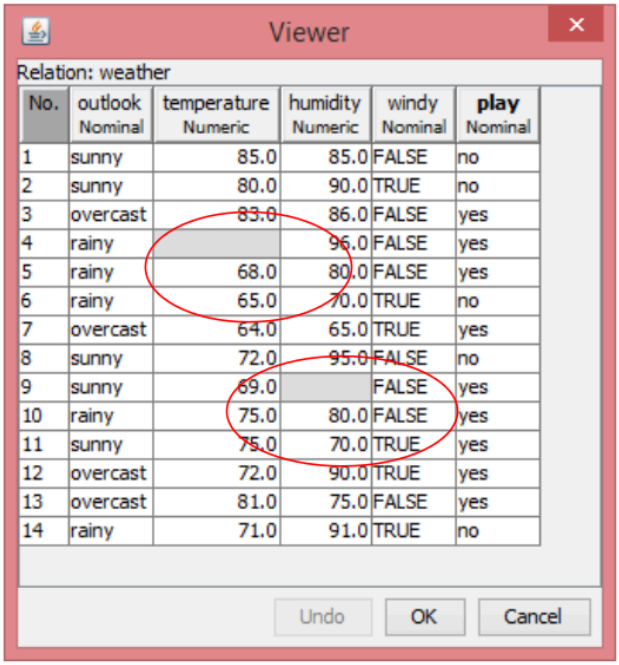

2. Clique no botão **Choose** dentro da caixa **Filter**. Clique no botão **Filter** na parte de baixo da janela *drop-down*.

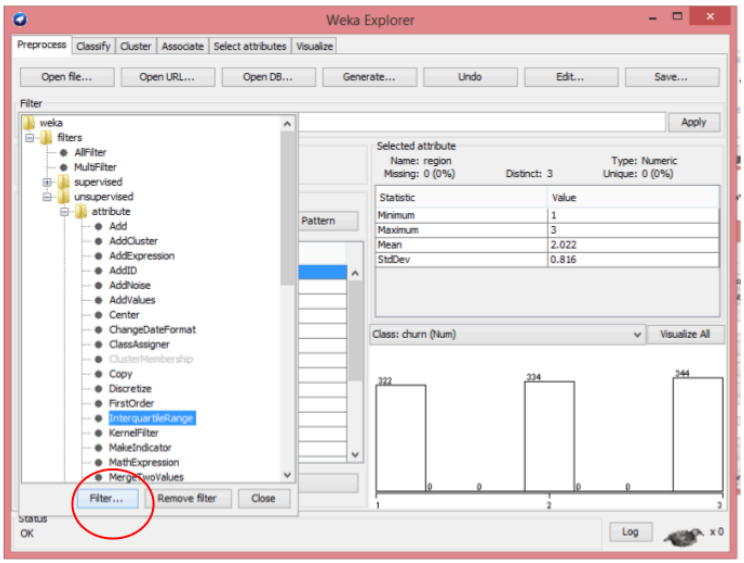

3. Uma janela chamada Filtering Capabilities se abrirá. Esta janela mostra qual tipo de atributos os filtros suportam. Certifique-se de que apenas os tipos **Numeric Attributes**, **Missing values** e **Numeric Class** estejam selecionados. E então clique em **OK**.

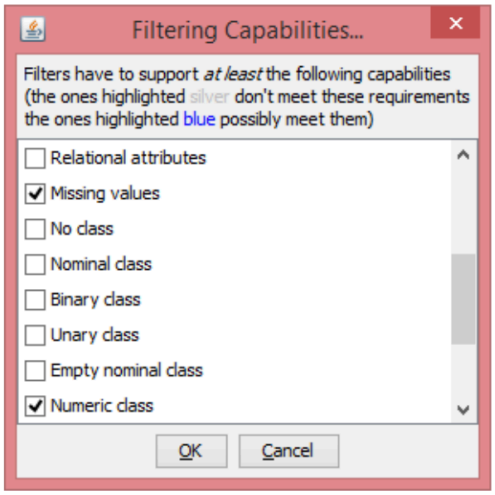

4. Escolha o filtro **ReplaceMissingValues** a partir da lista *drop-down*
   Para isso clique em: **filters** => **unsupervised** => **attribute** => **ReplaceMissingValues**.
   E então clique na caixa Filter para mostrar a janela de propriedade do filtro selecionado.

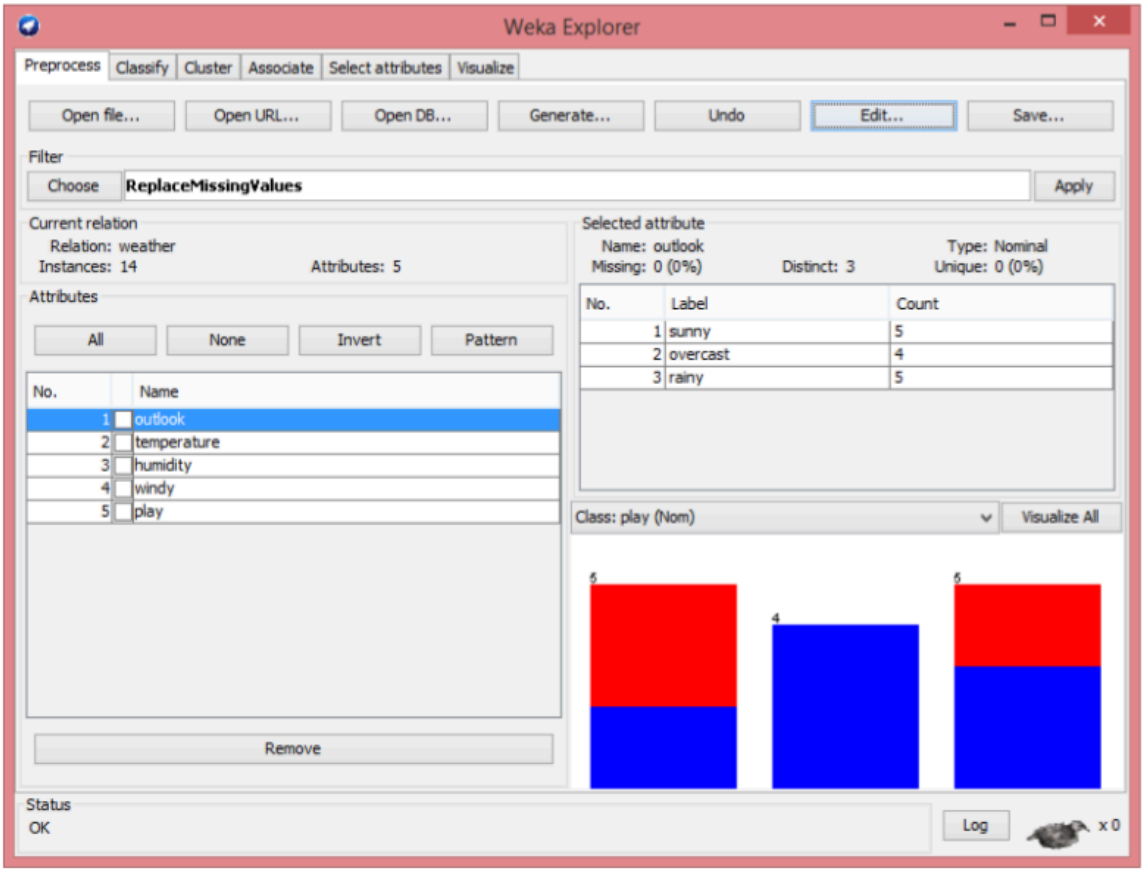

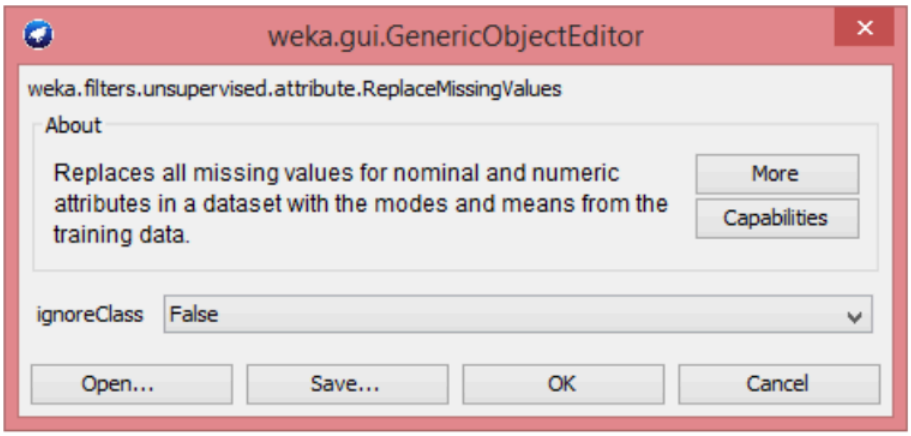

5. Clique no botão **Apply** dentro da caixa **Filter**. Então clique no botão **Edit** para verificar se o dataset foi processado – você verá que os *missing values* foram preenchidos. Grave os dados modificados (clique no botão **Save** na tela principal). Escolha um nome diferente para salvá-lo de forma que o dataset original seja mantido - **weather.numeric.nomissing.arff**

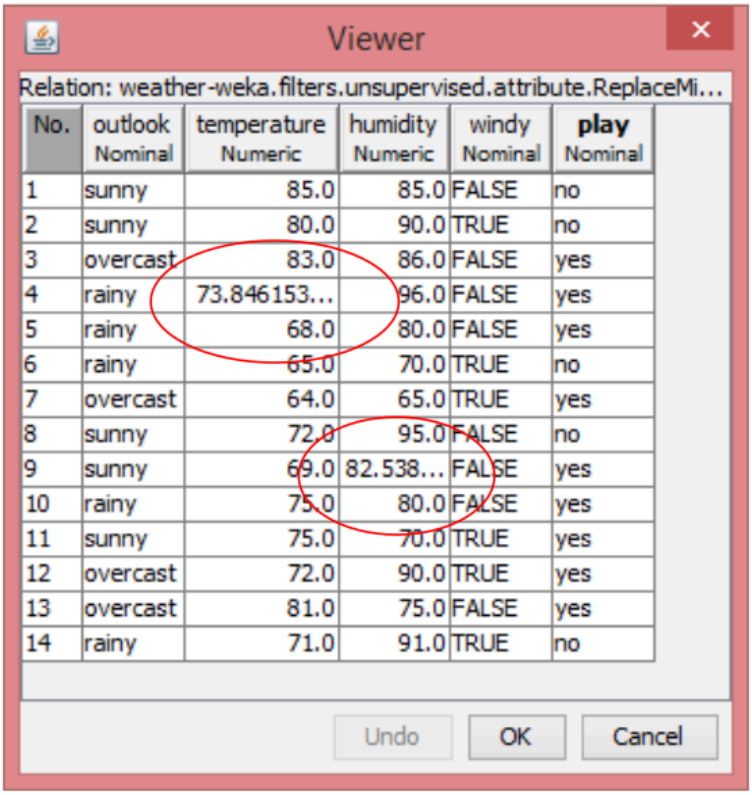

No.	outlook Nominal	temperature Numeric	humidity Numeric	windy Nominal	play Nominal
1	sunny	85.0	85.0	FALSE	no
2	sunny	80.0	90.0	TRUE	no
3	overcast	83.0	86.0	FALSE	yes
4	rainy	73.846153...	96.0	FALSE	yes
5	rainy	68.0	80.0	FALSE	yes
6	rainy	65.0	70.0	TRUE	no
7	overcast	64.0	65.0	TRUE	yes
8	sunny	72.0	95.0	FALSE	no
9	sunny	69.0	82.538...	FALSE	yes
10	rainy	75.0	80.0	FALSE	yes
11	sunny	75.0	70.0	TRUE	yes
12	overcast	72.0	90.0	TRUE	yes
13	overcast	81.0	75.0	FALSE	yes
14	rainy	71.0	91.0	TRUE	no

3. Usando Filtros para detectar/manipular *outliers* e *extreme values*

Unsupervised Attribute Filter – InterquartileRange: Este filtro adiciona novos **atributos** que indicam se valores de **instâncias** podem ser considerados **outliers** ou ***extreme Values***.

1. Abra o dataset – **small_telco.csv**. Realize o passo de substituição de *missing values* com o filtro – **ReplaceMissingValues**. Observe que há um total de 22 atributos neste dataset.

2. Então clique no botão **Choose** dentro da caixa Filter. Clique no botão **Filter** na parte de baixo da janela *drop-down*.

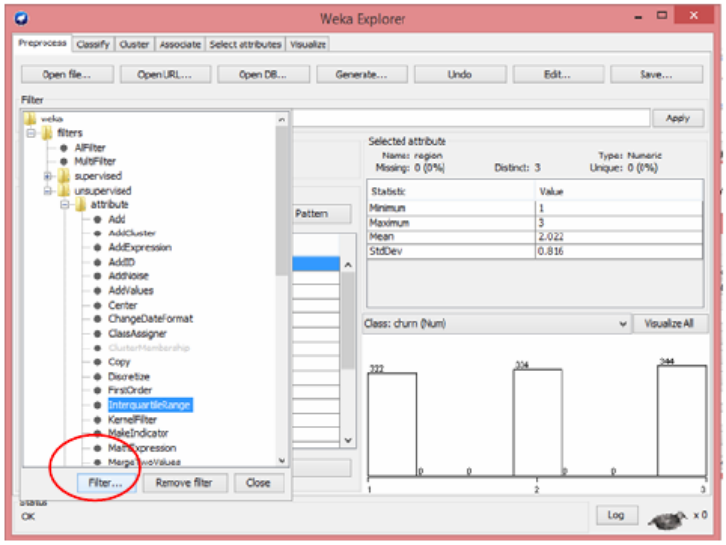

3. Uma janela chamada Filtering Capabilities se abrirá. Esta janela mostra qual tipo de atributos the os filtros suportam. Certifique-se de que apenas os tipos **Numeric Attributes** e **Numeric Class** estejam selecionados. E então clique em **OK**.

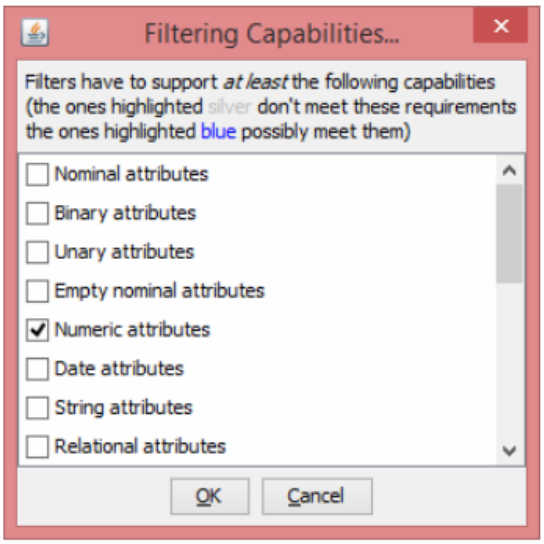

4. Escolha o filtro **InterquartileRange** a partir da lista drop-down list de filtros não supervisionado para atributos. Para isso clique em: **filters** => **unsupervised** => **attribute** => **InterquartileRange**.

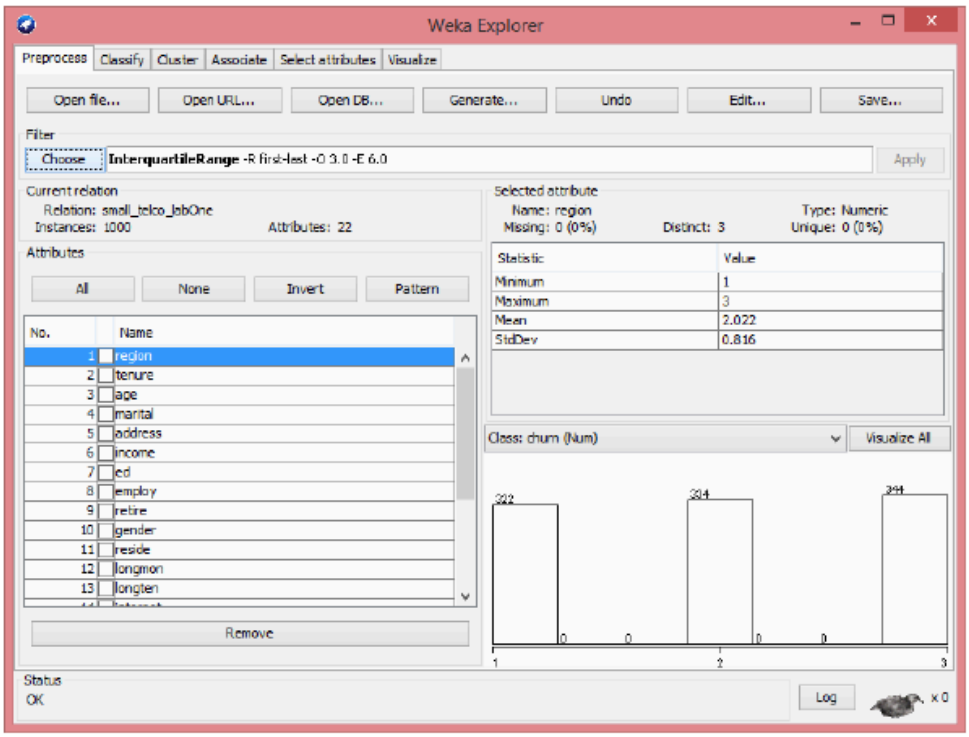

5. Clique (com o botão **Esquerdo**) dentro da caixa **Filter**, e então a janela de propriedades é apresentada. Clique no botão More para mostrar mais informações sobre este filtro.

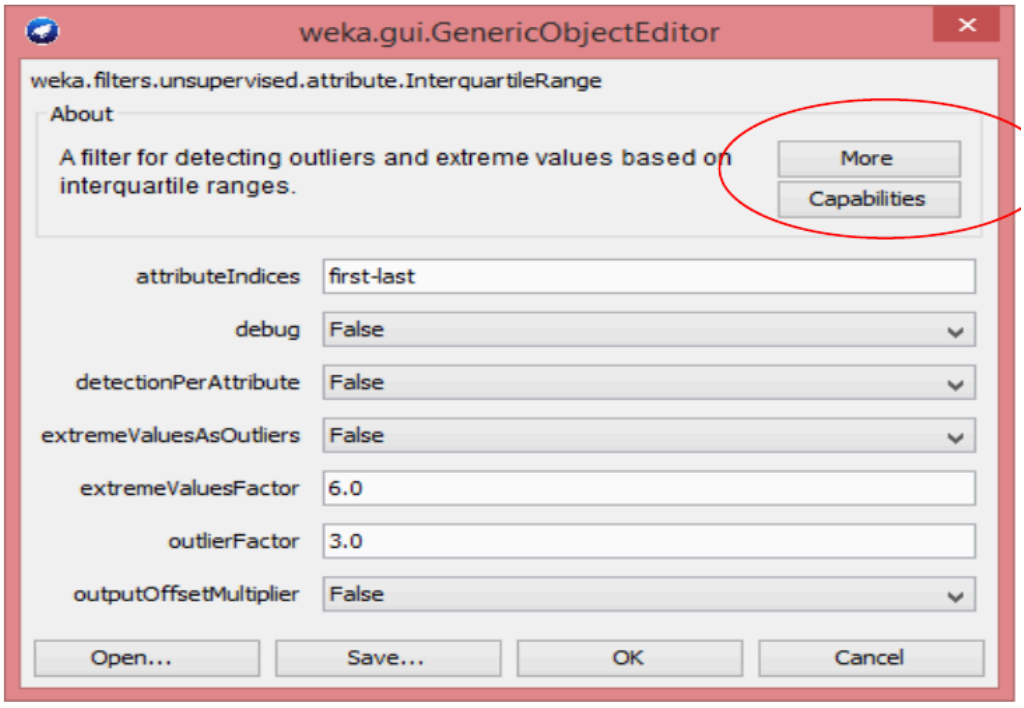

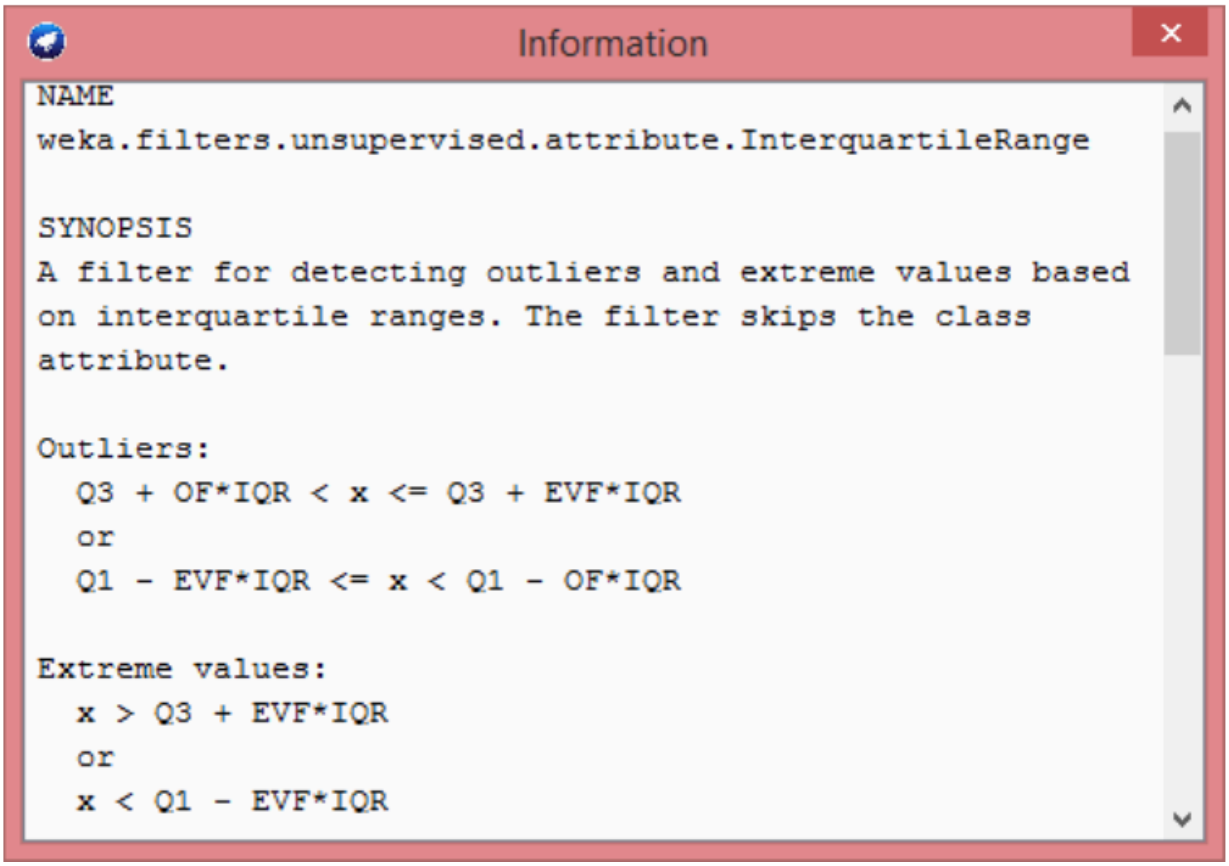

Os fatores são usados para definir os ***extreme values*** e ***outliers*** de acordo com a definição de Q1, Q3 e IQR (veja ilustração abaixo).

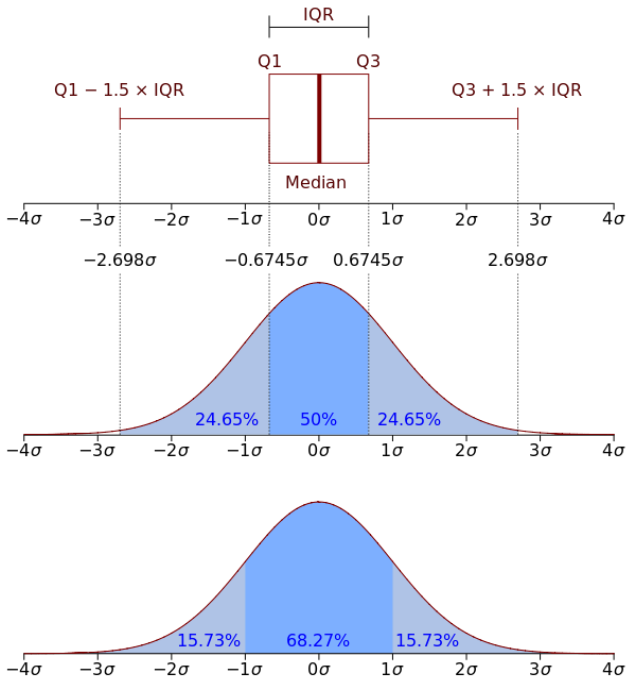

6. Clique no botão **Apply** dentro da caixa **Filter**. Você encontrará dois atributos extras/novos que foram gerados. Estes dois atributos marcam uma instância como um ***outlier*** ou um ***extreme value*** se qualquer um dos seus valores de seus atributos são tidos como ***outlier*** ou ***extreme value***.

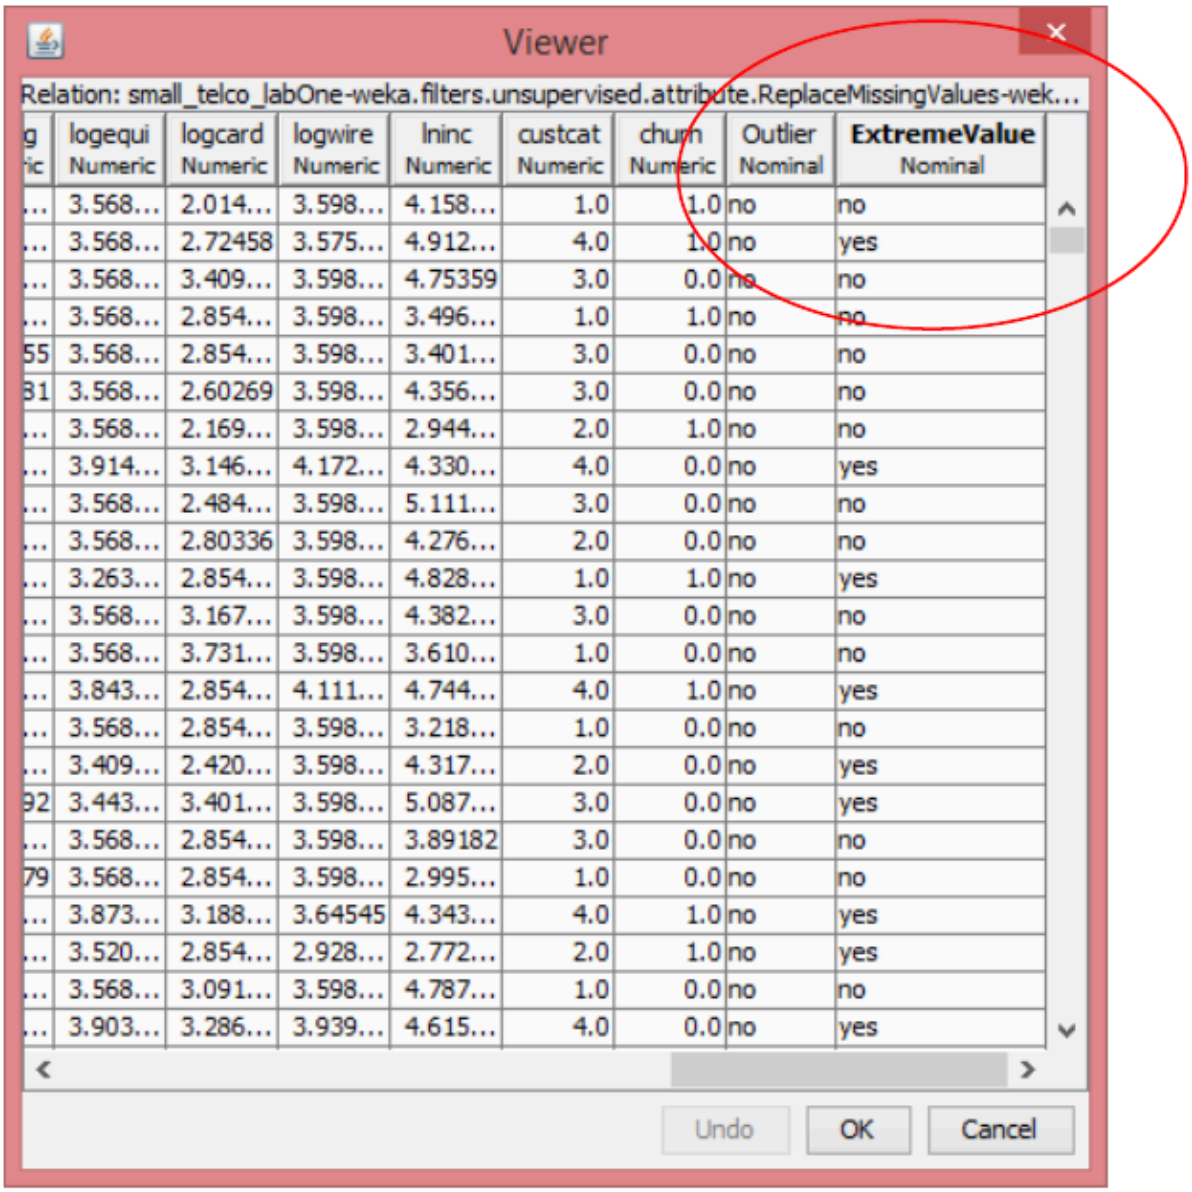

g ic	logequi Numeric	logcard Numeric	logwire Numeric	lninc Numeric	custcat Numeric	churn Numeric	Outlier Nominal	**ExtremeValue** Nominal
...	3.568...	2.014...	3.598...	4.158...	1.0	1.0	no	no
...	3.568...	2.72458	3.575...	4.912...	4.0	1.0	no	yes
...	3.568...	3.409...	3.598...	4.75359	3.0	0.0	no	no
...	3.568...	2.854...	3.598...	3.496...	1.0	1.0	no	no
55	3.568...	2.854...	3.598...	3.401...	3.0	0.0	no	no
31	3.568...	2.60269	3.598...	4.356...	3.0	0.0	no	no
...	3.568...	2.169...	3.598...	2.944...	2.0	1.0	no	no
...	3.914...	3.146...	4.172...	4.330...	4.0	0.0	no	yes
...	3.568...	2.484...	3.598...	5.111...	3.0	0.0	no	no
...	3.568...	2.80336	3.598...	4.276...	2.0	0.0	no	no
...	3.263...	2.854...	3.598...	4.828...	1.0	1.0	no	yes
...	3.568...	3.167...	3.598...	4.382...	3.0	0.0	no	no
...	3.568...	3.731...	3.598...	3.610...	1.0	0.0	no	no
...	3.843...	2.854...	4.111...	4.744...	4.0	1.0	no	yes
...	3.568...	2.854...	3.598...	3.218...	1.0	0.0	no	no
...	3.409...	2.420...	3.598...	4.317...	2.0	0.0	no	yes
92	3.443...	3.401...	3.598...	5.087...	3.0	0.0	no	yes
...	3.568...	2.854...	3.598...	3.89182	3.0	0.0	no	no
79	3.568...	2.854...	3.598...	2.995...	1.0	0.0	no	no
...	3.873...	3.188...	3.64545	4.343...	4.0	1.0	no	yes
...	3.520...	2.854...	2.928...	2.772...	2.0	1.0	no	yes
...	3.568...	3.091...	3.598...	4.787...	1.0	0.0	no	no
...	3.903...	3.286...	3.939...	4.615...	4.0	0.0	no	yes

7. Se nós mudamos a opção **detectionPerAttribute** do filtro **InterquartileRange**, de False para True, um par indicador **outlier-extreme** para cada atributo é gerado.

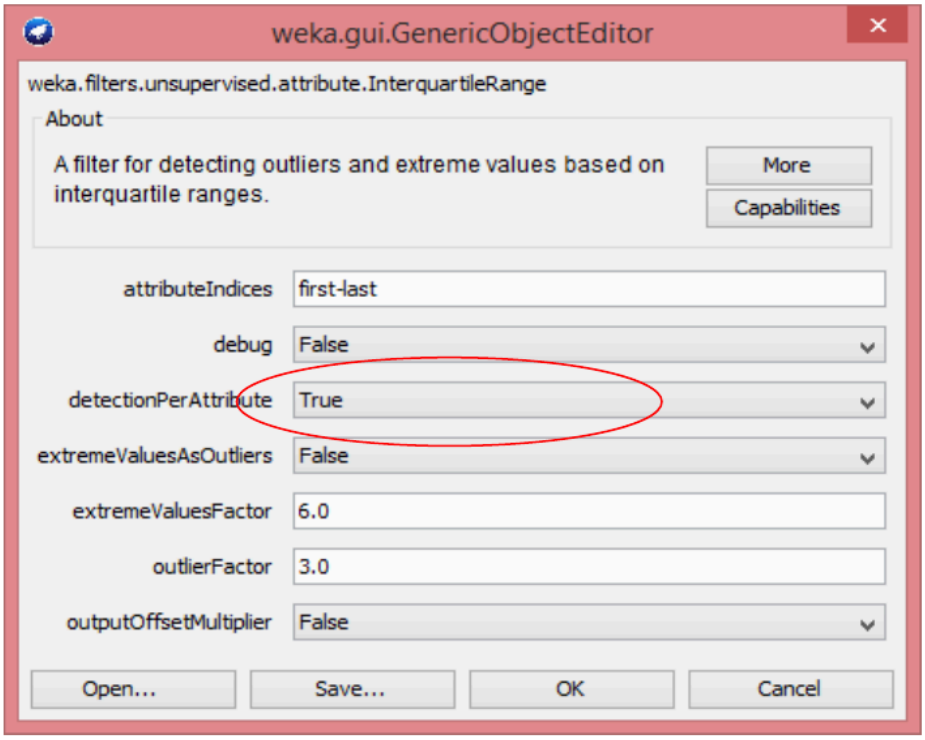

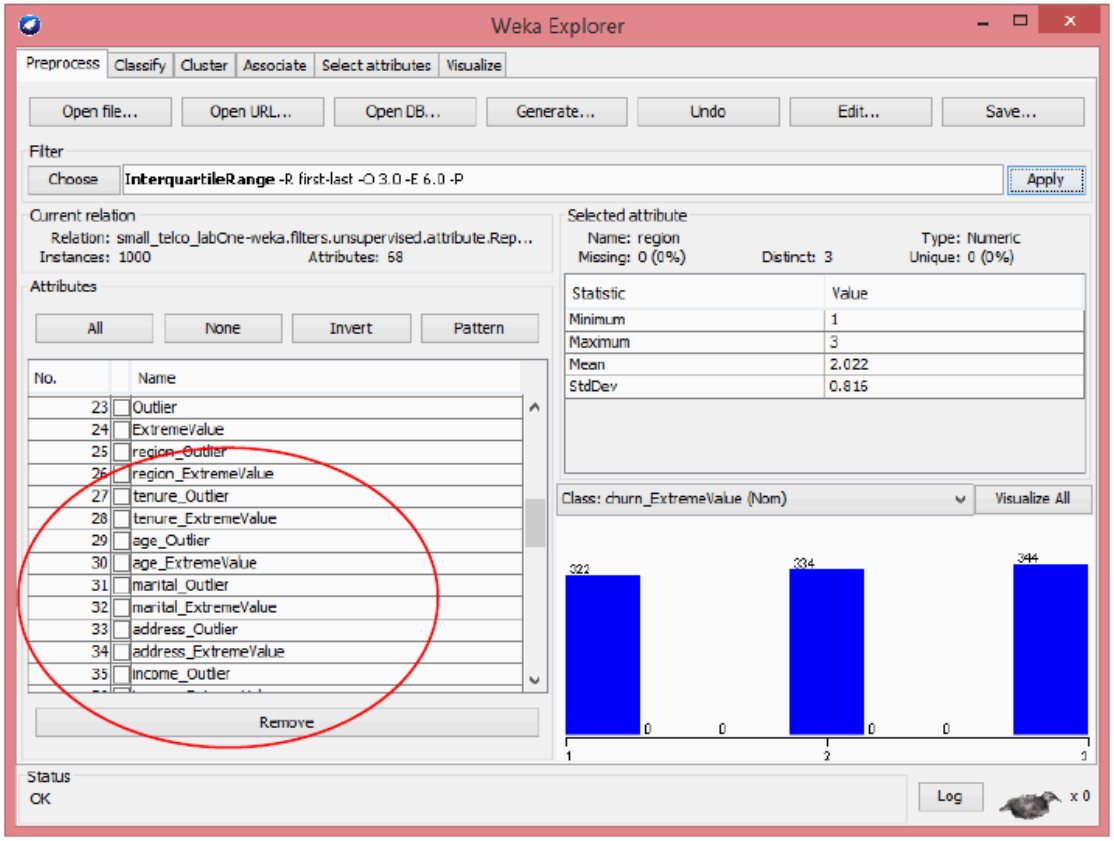

8. Você pode clicar em cada atributo gerado para verificar se existem valores ***outlier*** ou ***extreme value*** para atributos originais. Você pode remover aqueles atributos indicadores que não tenham nenhum ***outlier*** ou ***extreme value*** com o botão **Remove**. Salve os dados resultantes como **small_telco.processed.arff**.

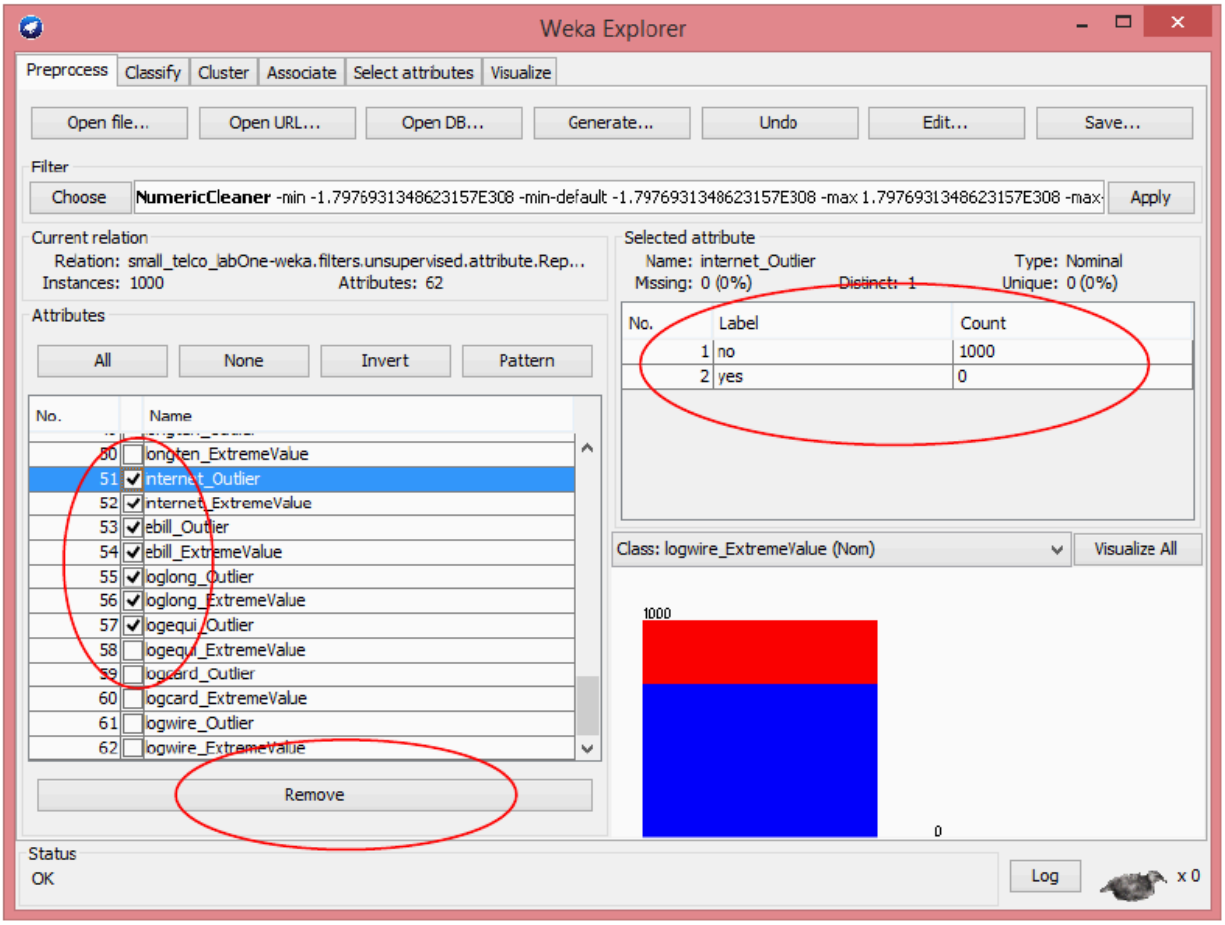

3.1. Removendo instâncias com *outliers* e *extreme values*

Unsupervised Instance Filter – RemoveWithValues: Este filtro remove instâncias de acordo com valores de um atributo.

1. Após encontrarmos instâncias com valores ***outlier*** ou ***extreme value***, nós podemos podemos removê-las completamente do dataset. Escolha o filtro **RemoveWithValues** na lista drop-down de filtros não-supervisionados de instâncias.
   Para isso clique em: **filters** => **unsupervised** => **instance** => **InterquartileRange**.
   Como o atributo *outlier* está indexado com 23 e o último valor é "**yes**", modifique as opções ***atributeIndex*** para **23** e o ***nominalIndices*** para "**last**"

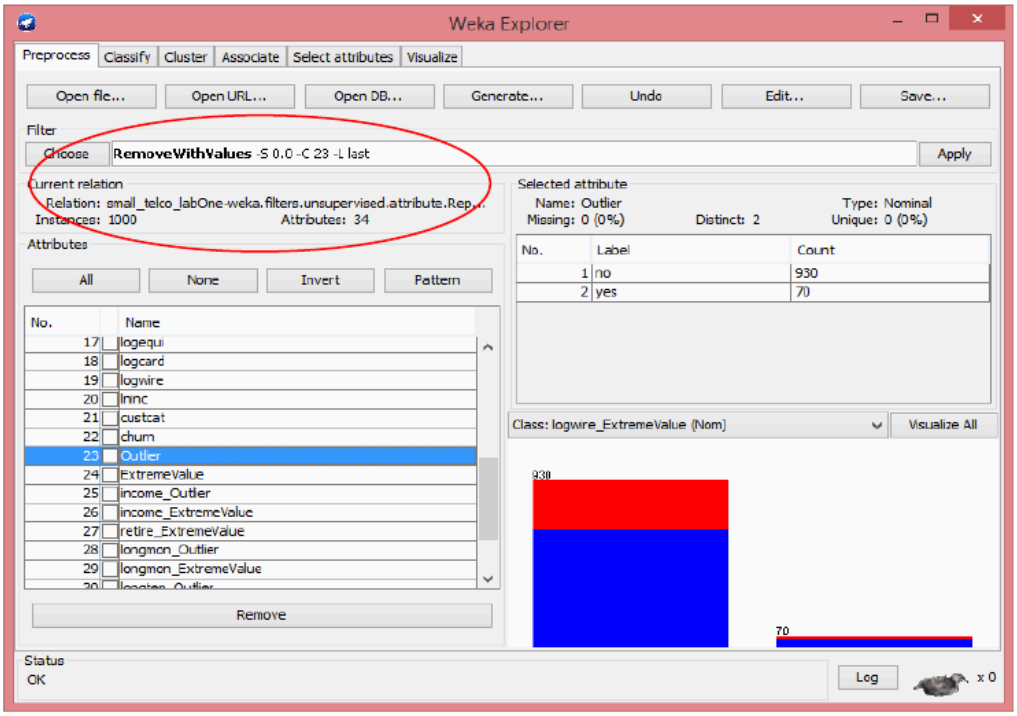

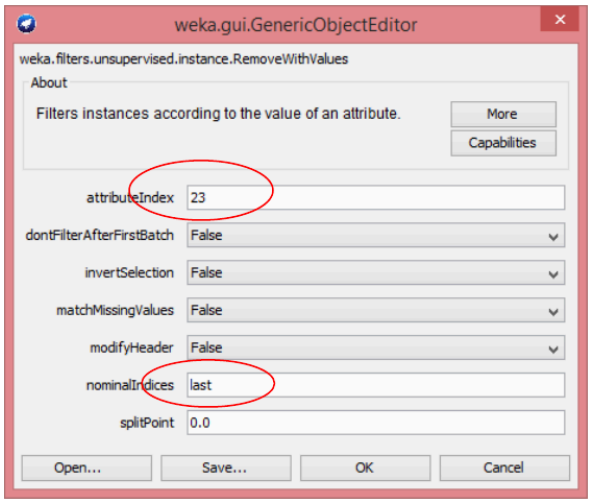

2. Então clique no botão **Apply** depois de confirmar as mudanças. 70 instâncias serão removidas do dataset e o atributo *outlier* não terá instâncias com valor "**yes**".

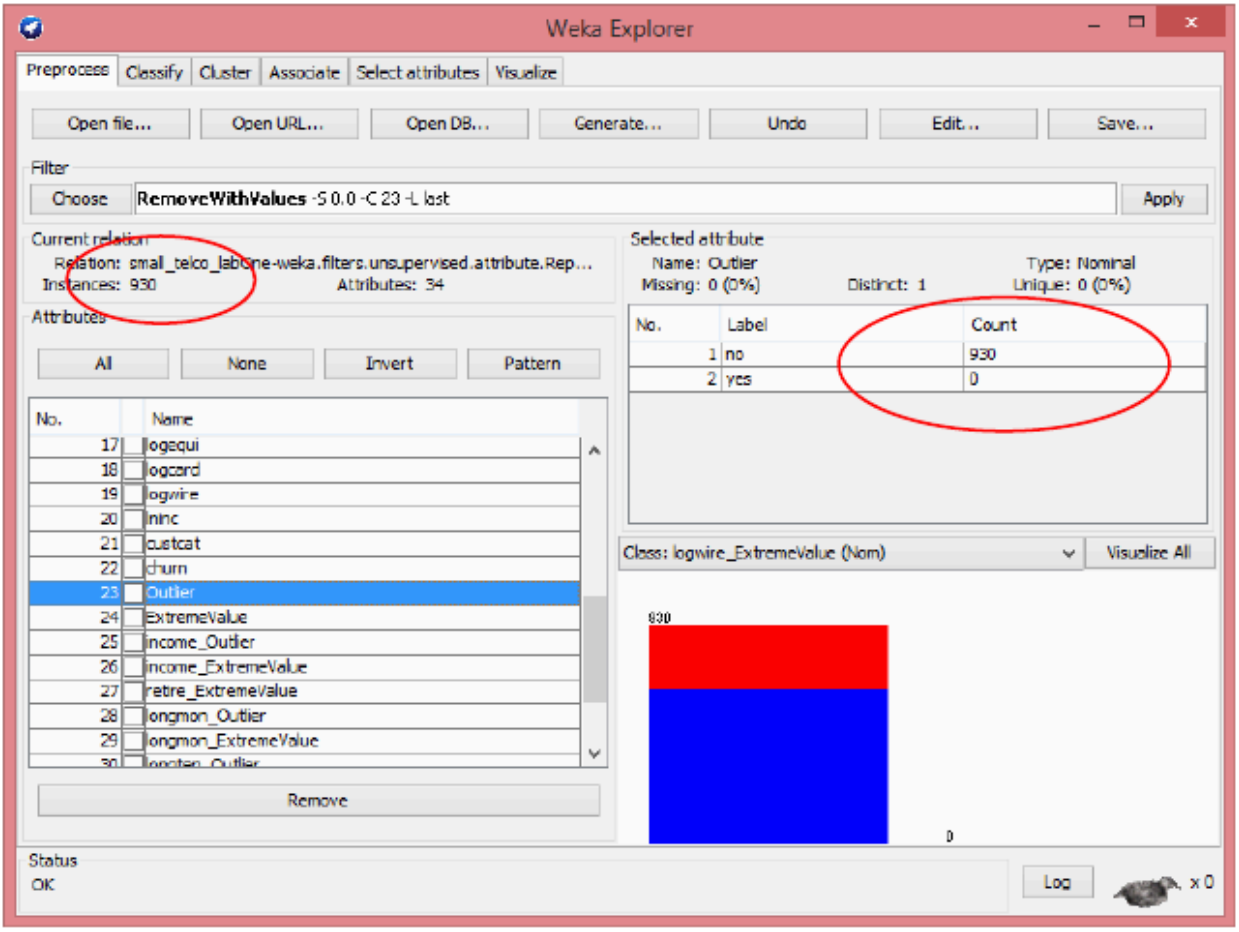

3. Você poderá também remover instâncias por atributo de acordo com pares ***outlier-atributo*** da mesma forma.

4. Usando filtros para executar a normalização

Unsupervised Attribute Filter – Normalize: Este filtro normaliza todos os valores numéricos valores no dataset fornecido para o intervalo padrão de [0,0, 1,0].

1. Abra o dataset **weather.numeric.nomissing.arff** (os valores ausentes já foram substituídos).

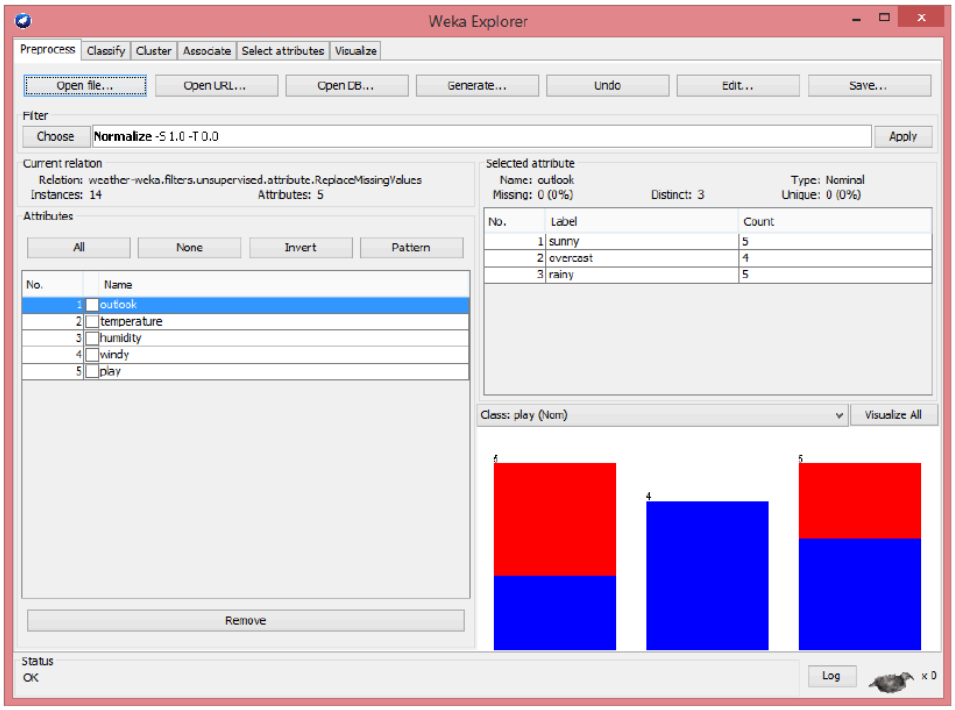

2. Escolha filtro Normalize na lista drop-down de filtros de atributos não supervisionados.
   Para isso clique em: **filters** => **unsupervised** => **attribute** => **Normalize**.
   E, em seguida, clique com o botão **Esquerdo** para abrir sua janela de propriedades. Queremos fazer normalização em todos os atributos numéricos. Clique em **OK** e **Apply**.

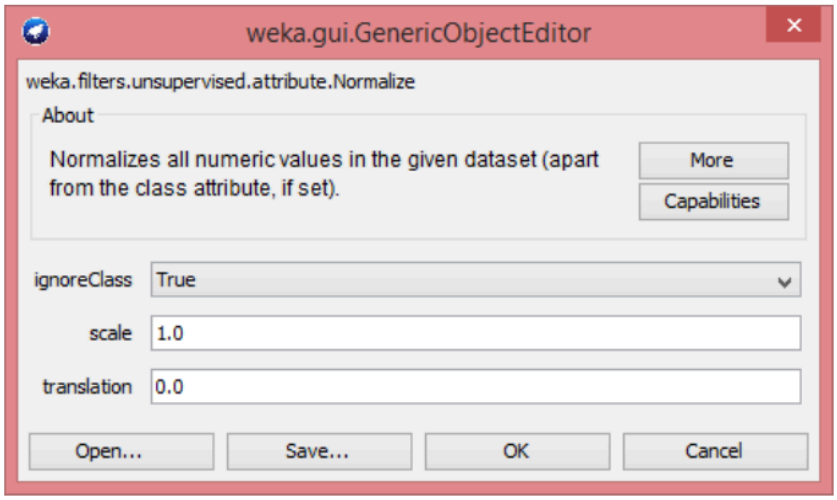

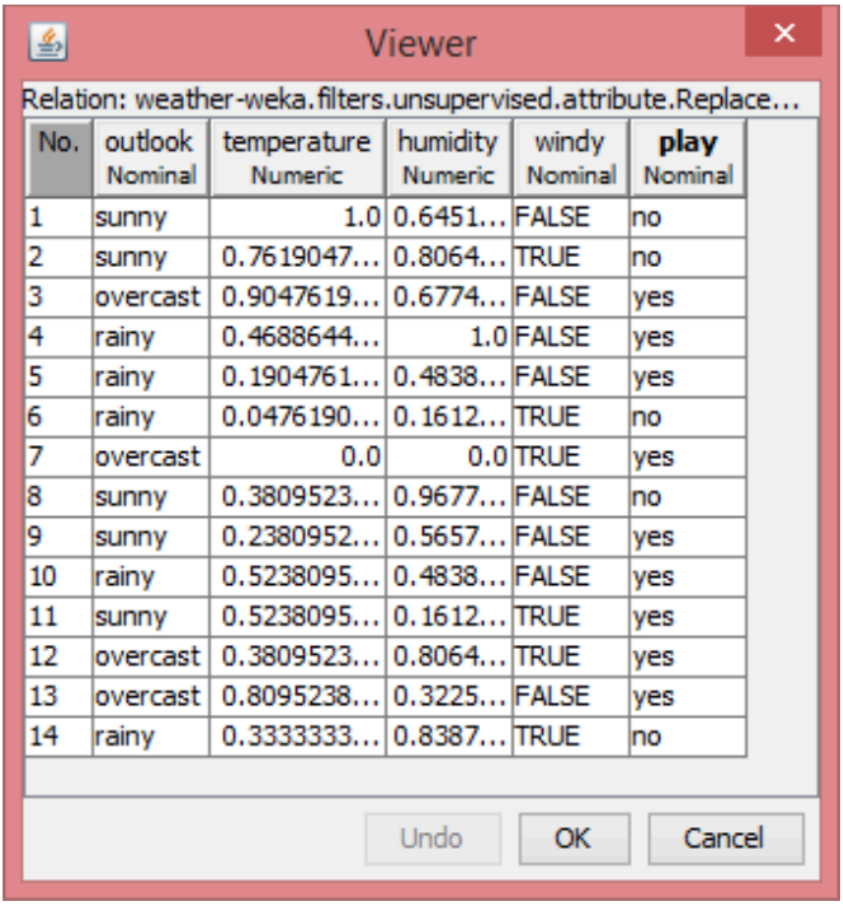

3. Você pode escolher um intervalo diferente definindo fatores de **scale** e **translation**. A **scale** é a diferença entre os valores mínimo e máximo. Se a **scale** ficar em 2 e a **translation** for mantida em 0, o intervalo será [0.0, 2.0].

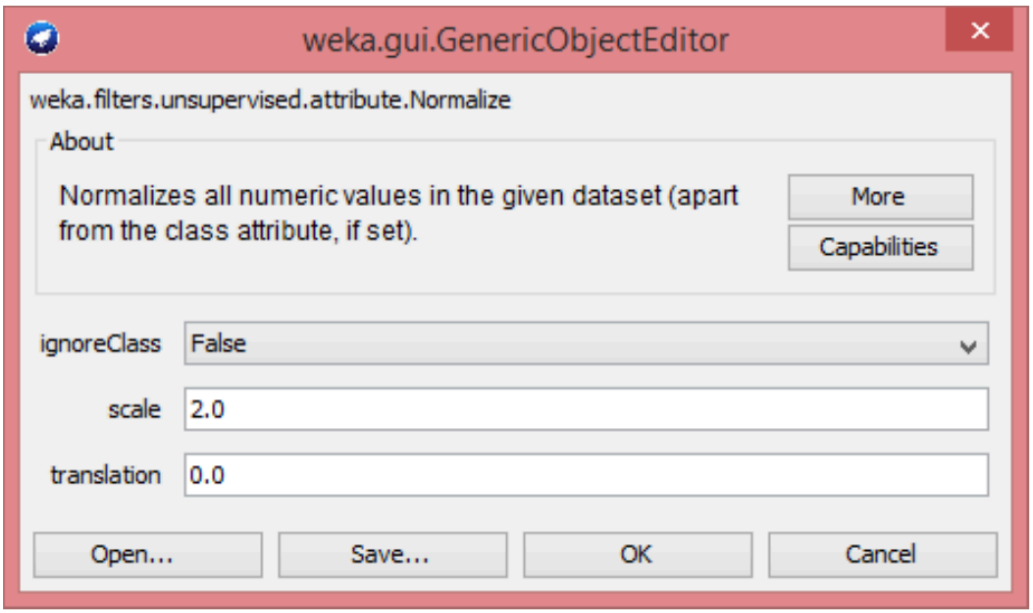

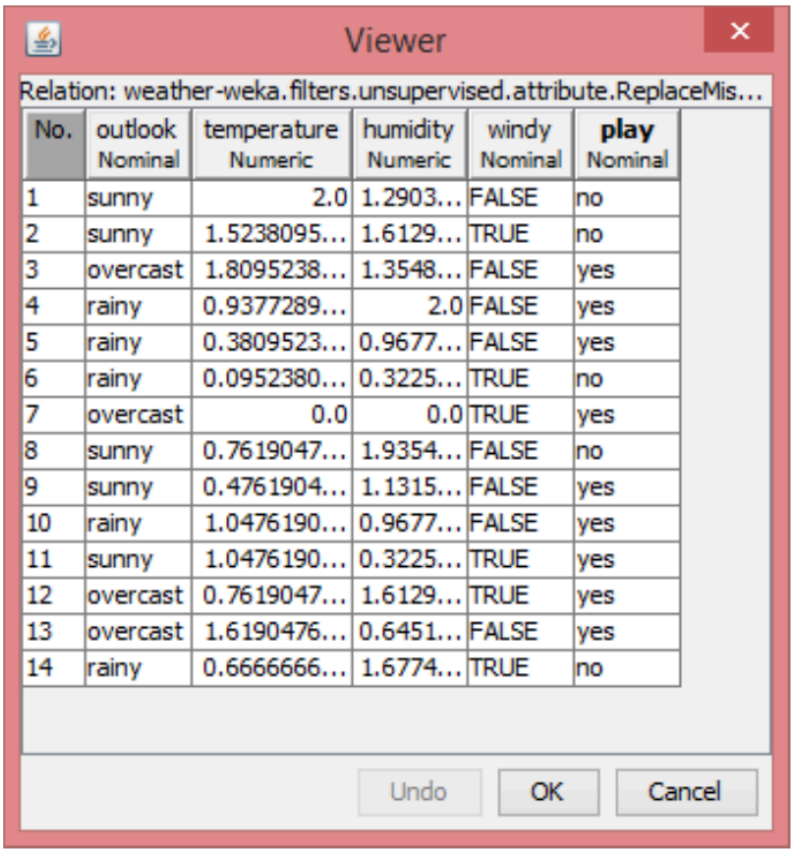

4. A **translation** é a distância entre o mínimo e 0.0. Quando a **scale** é deixada em 2 e a **translation** mantida em -1, o intervalo é [-1.0, 1.0].

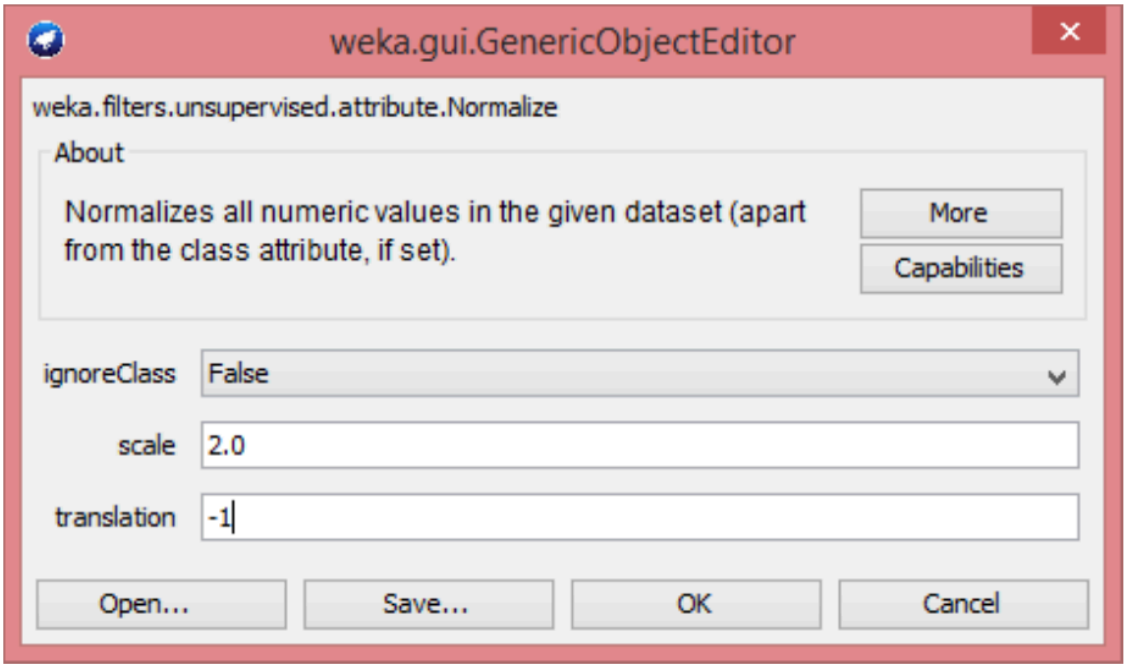

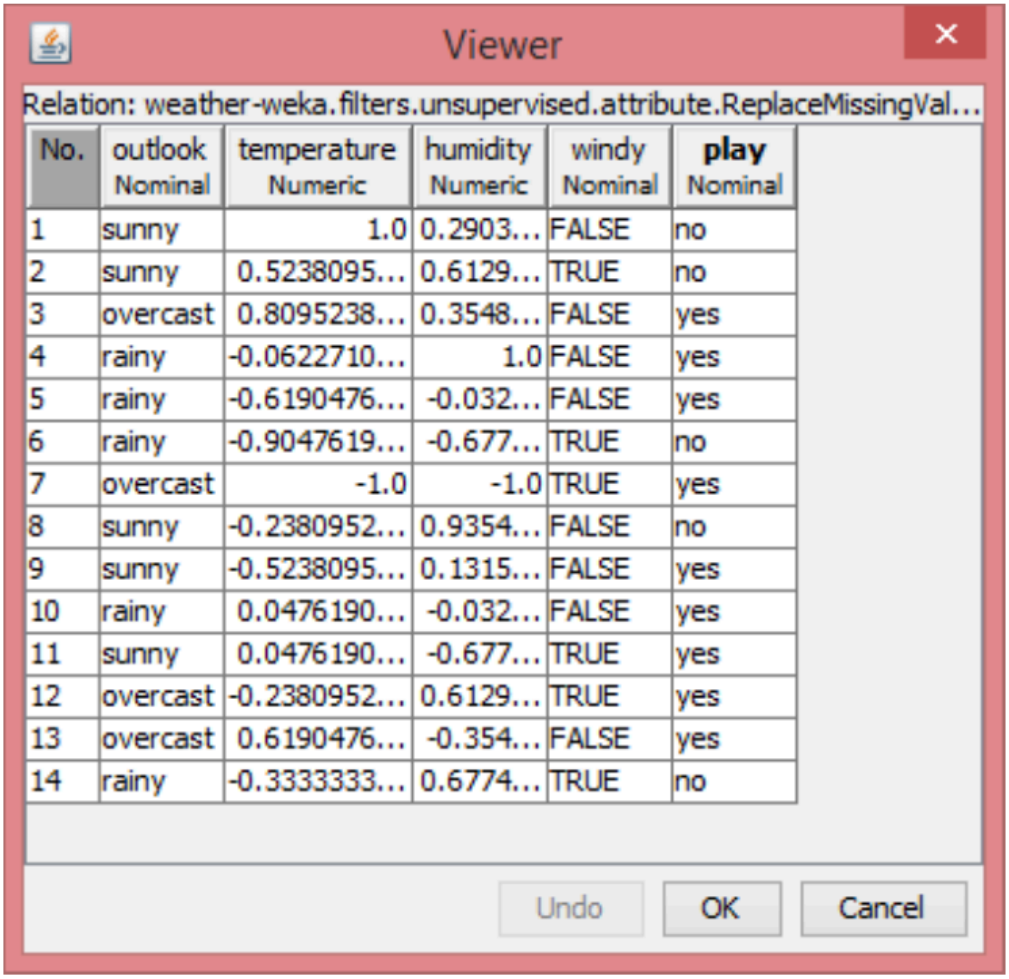

No.	outlook Nominal	temperature Numeric	humidity Numeric	windy Nominal	**play** Nominal
1	sunny	1.0	0.2903...	FALSE	no
2	sunny	0.5238095...	0.6129...	TRUE	no
3	overcast	0.8095238...	0.3548...	FALSE	yes
4	rainy	-0.0622710...	1.0	FALSE	yes
5	rainy	-0.6190476...	-0.032...	FALSE	yes
6	rainy	-0.9047619...	-0.677...	TRUE	no
7	overcast	-1.0	-1.0	TRUE	yes
8	sunny	-0.2380952...	0.9354...	FALSE	no
9	sunny	-0.5238095...	0.1315...	FALSE	yes
10	rainy	0.0476190...	-0.032...	FALSE	yes
11	sunny	0.0476190...	-0.677...	TRUE	yes
12	overcast	-0.2380952...	0.6129...	TRUE	yes
13	overcast	0.6190476...	-0.354...	FALSE	yes
14	rainy	-0.3333333...	0.6774...	TRUE	no

5. Você pode salvar o dataset se estiver satisfeito com os resultados (**weather.numeric.processed.arff**)

5. Discretização com Filtros

Unsupervised Attribute Filter – Discretize: Este filtro converte atributos numéricos em atributos nominais usando discretização ***equal-width*** (largura - default) or ***equal-depth*** (frequência)

1. Abra o dataset **weather.numeric.nomissing.arff**. (sem *missing values*)

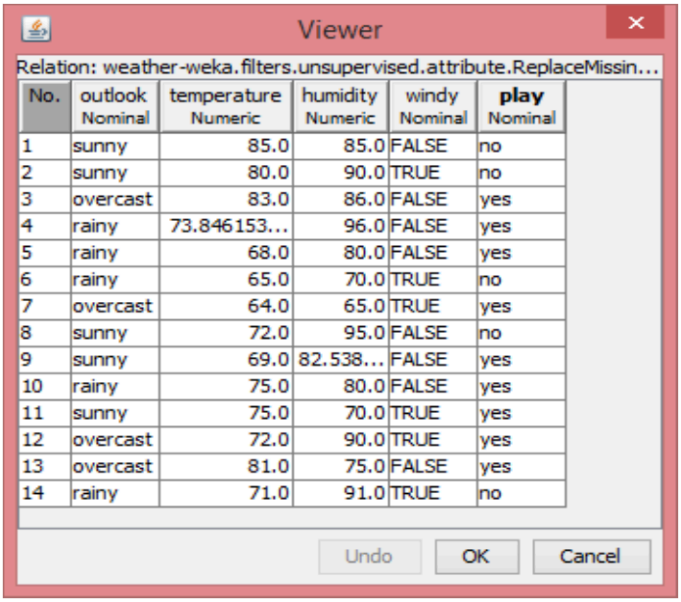

No.	outlook Nominal	temperature Numeric	humidity Numeric	windy Nominal	play Nominal
1	sunny	85.0	85.0	FALSE	no
2	sunny	80.0	90.0	TRUE	no
3	overcast	83.0	86.0	FALSE	yes
4	rainy	73.846153...	96.0	FALSE	yes
5	rainy	68.0	80.0	FALSE	yes
6	rainy	65.0	70.0	TRUE	no
7	overcast	64.0	65.0	TRUE	yes
8	sunny	72.0	95.0	FALSE	no
9	sunny	69.0	82.538...	FALSE	yes
10	rainy	75.0	80.0	FALSE	yes
11	sunny	75.0	70.0	TRUE	yes
12	overcast	72.0	90.0	TRUE	yes
13	overcast	81.0	75.0	FALSE	yes
14	rainy	71.0	91.0	TRUE	no

2. Escolha o filtro **Discretize** a partir da lista drop-down de filtros de atributos não supervisionados.
   Para isso clique em: **filters** => **unsupervised** => **attribute** => **Discretize**.
   E então clique (com o botão **Esquerdo**) para abrir a janela de propriedades. Vamos realizar uma discretização ***equal-width*** (largura) no atributo 2 – **temperature** com 3 *bins*.

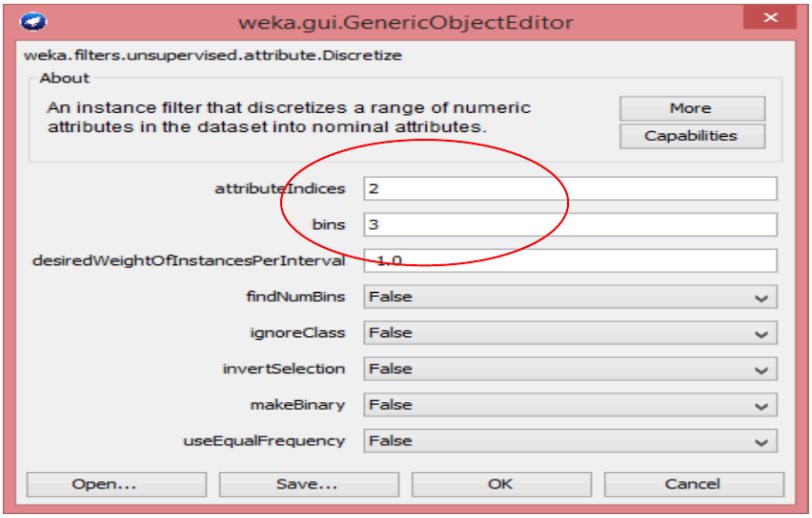

3. Clique no botão **Apply**. E então selecione o atributo **temperature** para verificar os resultados.

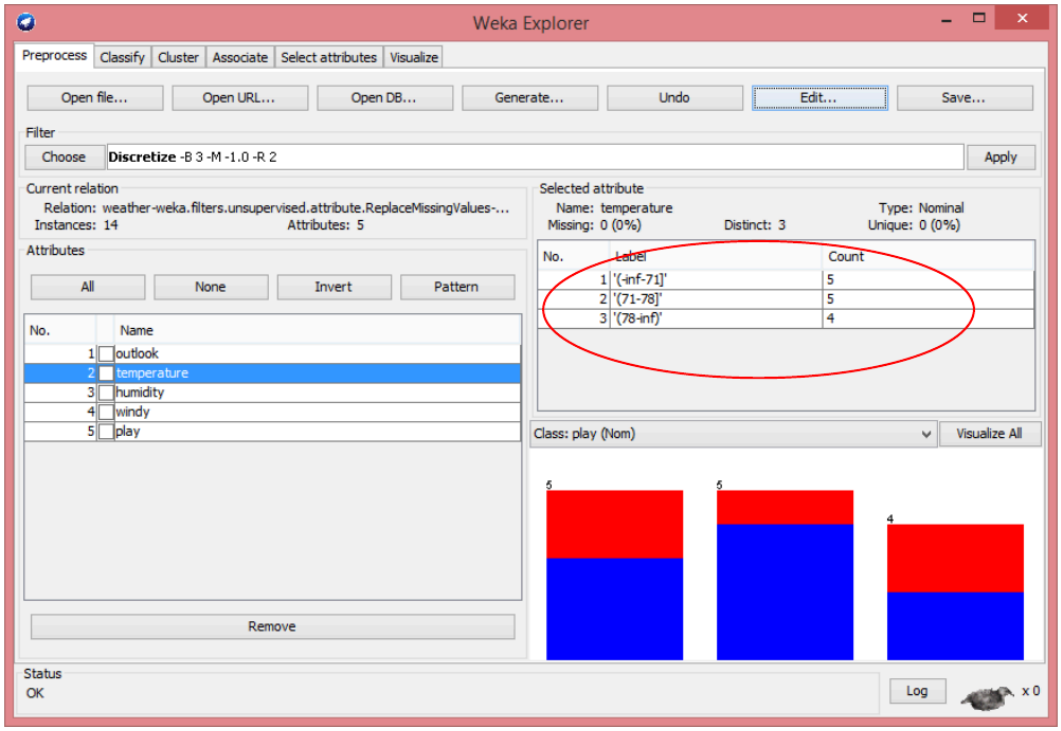

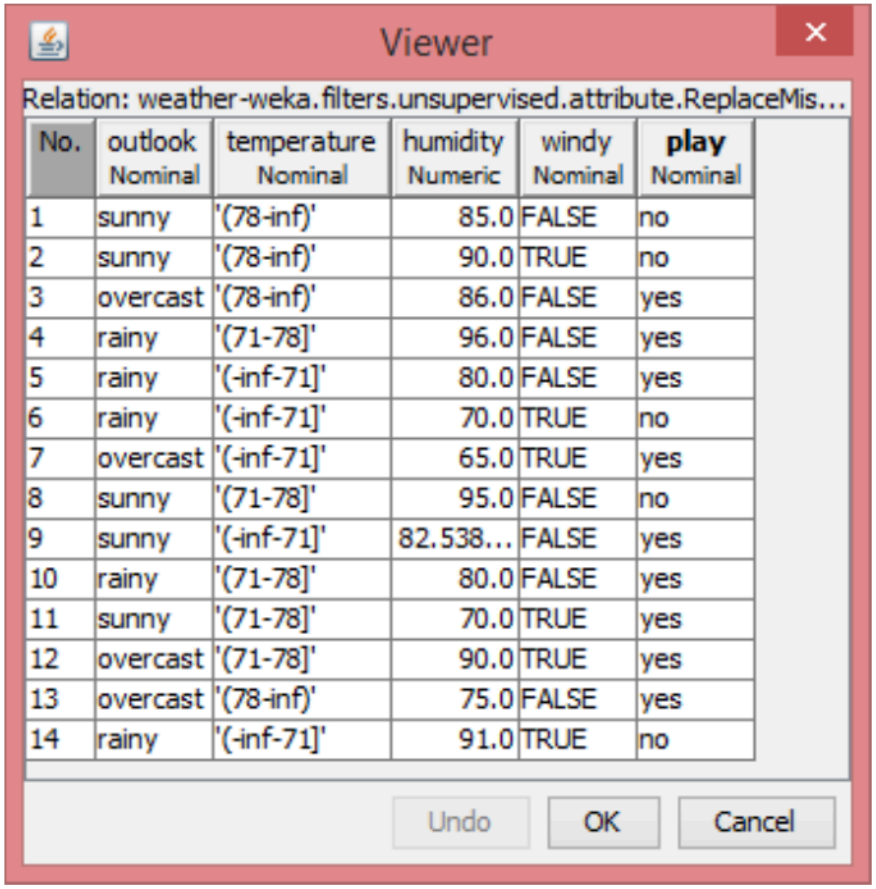

4. Para realizar a discretização ***equal-depth*** (frequência) no atributo 3 - ***humidity***, escolhemos o filtro PKIDiscretize a partir da lista drop-down de filtros de atributos não supervisionados. Para isso clique em: **filters** => **unsupervised** => **attribute** => **PKIDiscretize**.
Este filtro usa a raiz quadrada do número de valores como o número de *bins*.

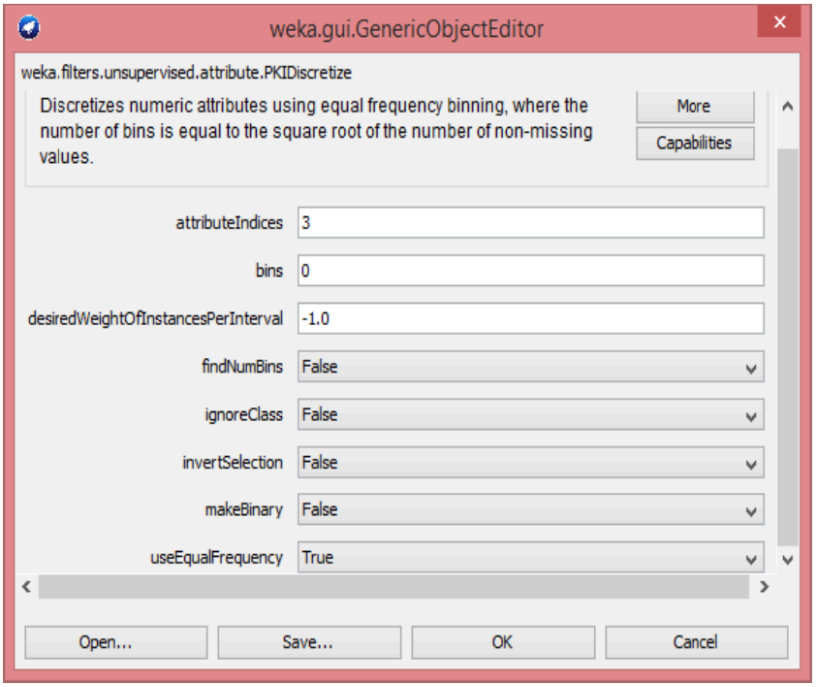

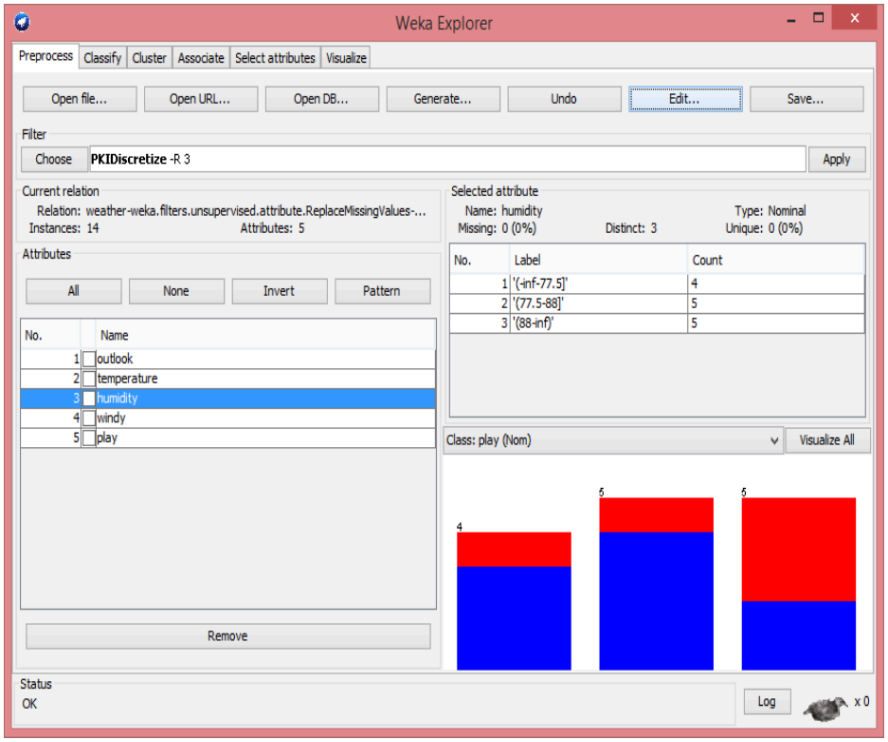

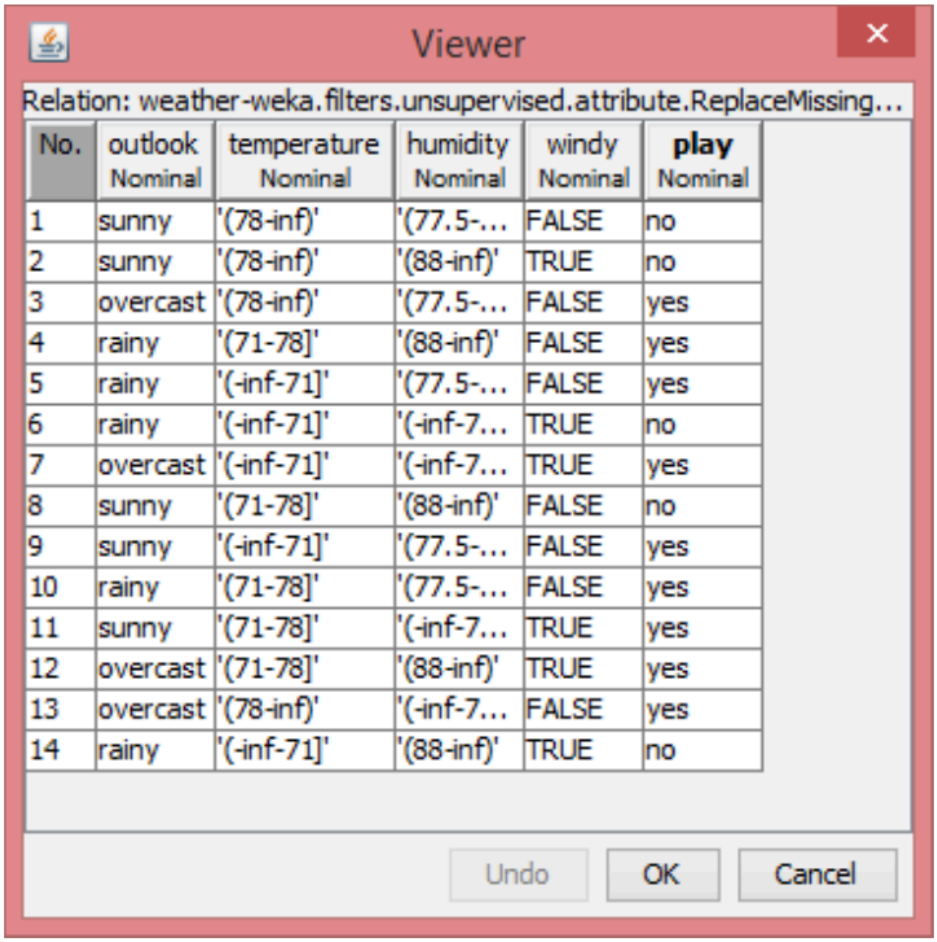
Viewer
Relation: weather-weka.filters.unsupervised.attribute.ReplaceMissing...
No.
outlook Nominal
temperature Nominal
humidity Nominal
windy Nominal
play Nominal
1 sunny '(78-inf)' '(77.5-... FALSE no
2 sunny '(78-inf)' '(88-inf)' TRUE no
3 overcast '(78-inf)' '(77.5-... FALSE yes
4 rainy '(71-78]' '(88-inf)' FALSE yes
5 rainy '(-inf-71]' '(77.5-... FALSE yes
6 rainy '(-inf-71]' '(-inf-7... TRUE no
7 overcast '(-inf-71]' '(-inf-7... TRUE yes
8 sunny '(71-78]' '(88-inf)' FALSE no
9 sunny '(-inf-71]' '(77.5-... FALSE yes
10 rainy '(71-78]' '(77.5-... FALSE yes
11 sunny '(71-78]' '(-inf-7... TRUE yes
12 overcast '(71-78]' '(88-inf)' TRUE yes
13 overcast '(78-inf)' '(-inf-7... FALSE yes
14 rainy '(-inf-71]' '(88-inf)' TRUE no
Undo
OK
Cancel

6. Usando Filtros para Substituir valores

Unsupervised Attribute Filter – NumericCleaner: Este filtro substitui os valores dos atributos numéricos que são muito pequenos ou muito grandes ou muito próximos a um valor particular por valores *default*.

1. Ao invés de remover instâncias com ***outlier*** e ***extreme value***, nós poderíamos substituir os valores dos atributos para valores ***default***. Abra o dataset **small_telco.processed.arff**. Vamos usar o atributo **income** como um exemplo. Clique no atributo **income**, e então suas estatísticas são mostradas na parte direita da janela: o mínimo é 9, o máximo é 1668 e a média é 77.535.

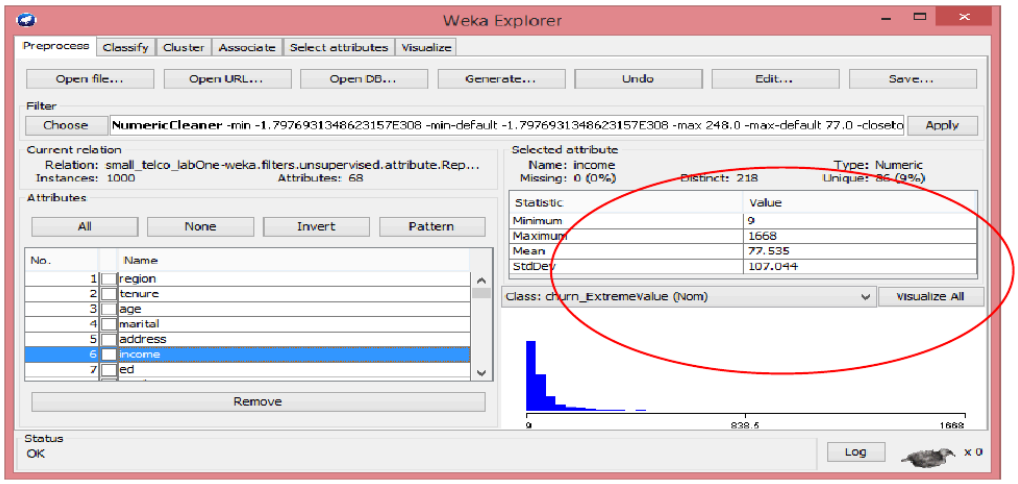

2. Realize uma filtragem **RemoveWithValues** invertida com o atributo **income_Outlier**.

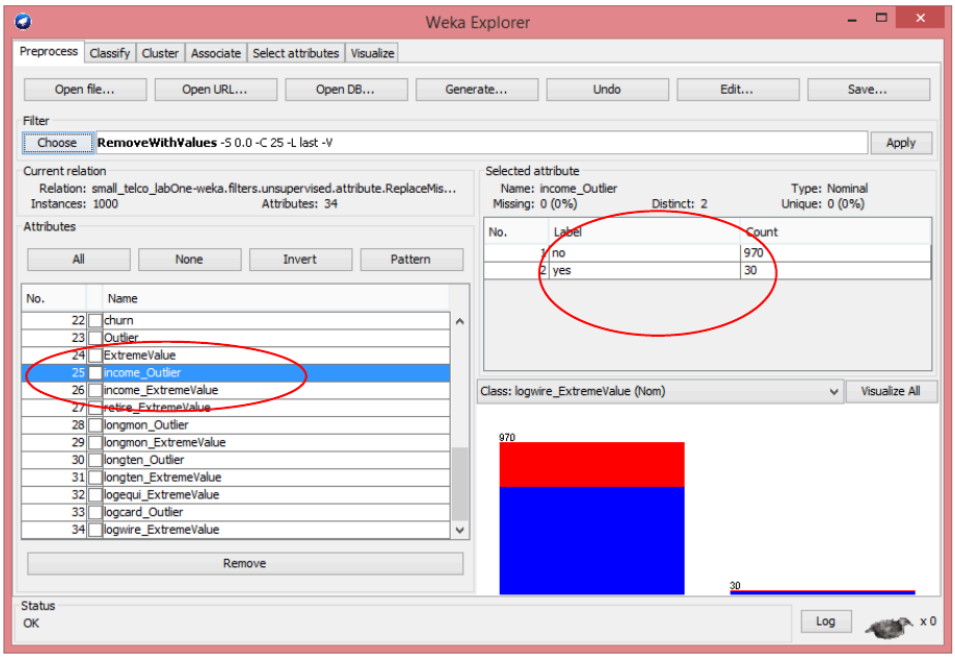

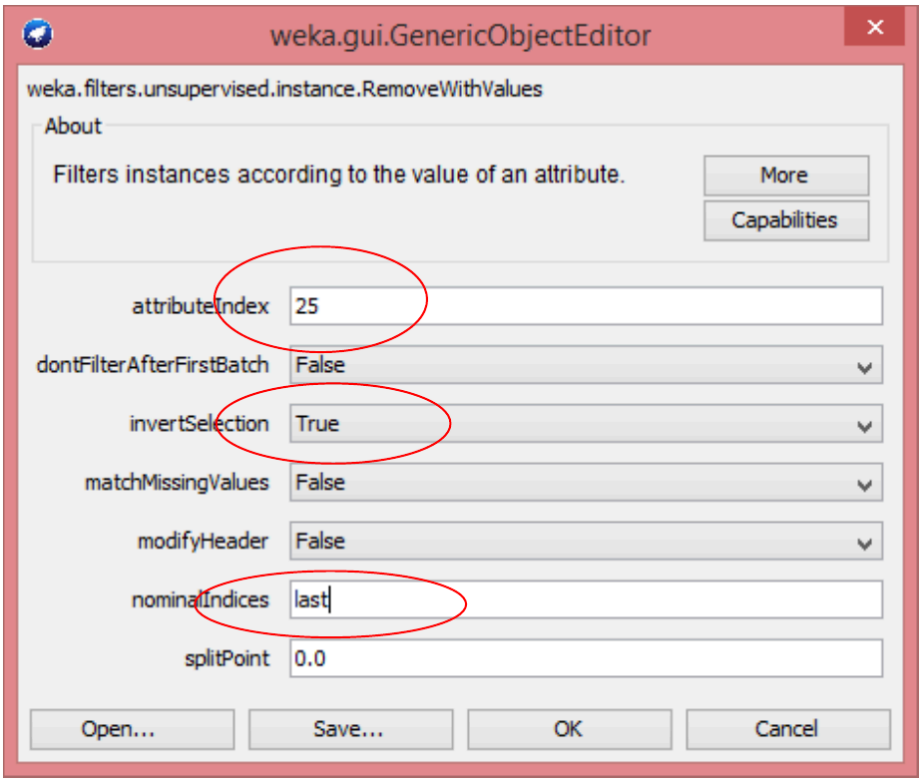

3. Verifique o status do atributo **income** nas 30 instâncias remanescentes. O min. Agora é 248, e o max. é 398.

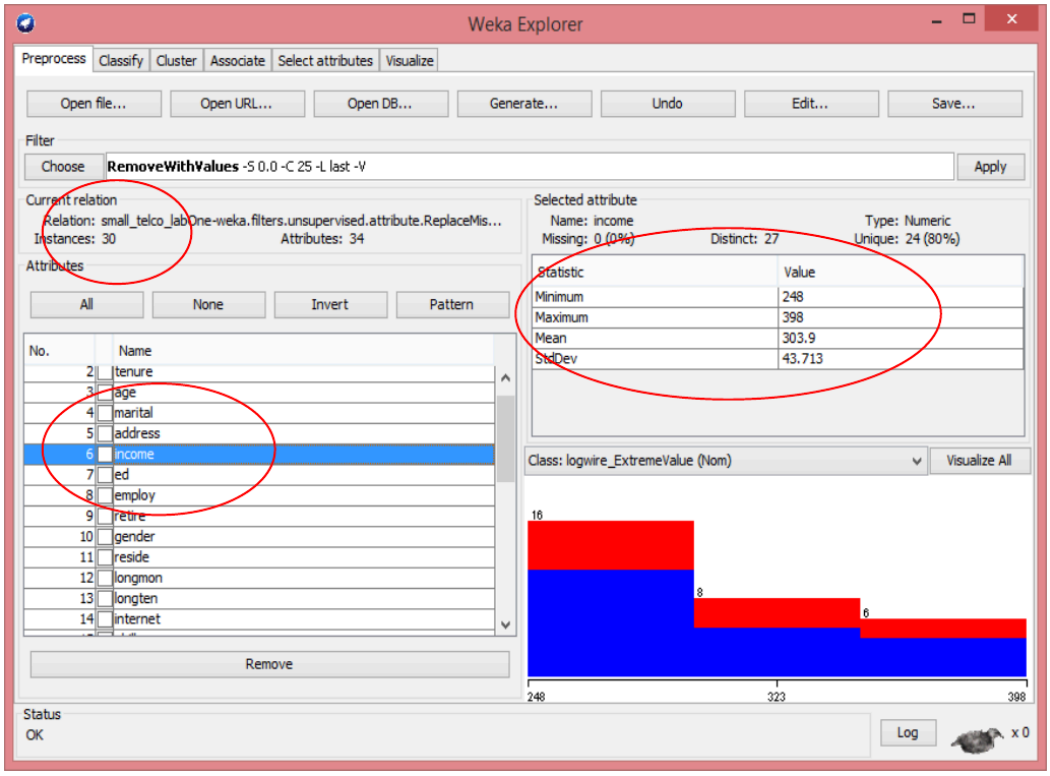

4. Clique no botão **Undo** e repita o passo e repita os passo 2 com o atributo **income_Extremevalue**. Verifique o atributo **income** nas 15 instâncias remanescentes. O min. Ficou em 418, e o max. é 1668.

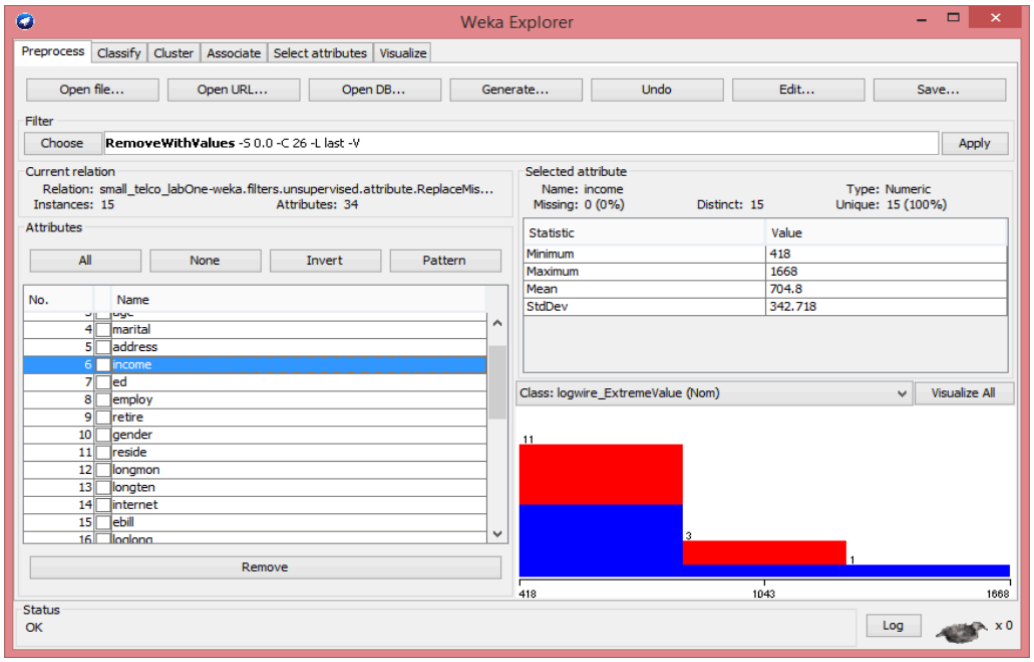

5. Clique no botão **Undo** .

6. Então estamos prontos para realizar o filtro não supervisionado no atributo – **NumericCleaner** em todas as instâncias. Escolha o filtro NumericCleaner na lista drop-down, e então clique com o botão **Esquerdo** na caixa do filtro para mostrar a janela de propriedades.

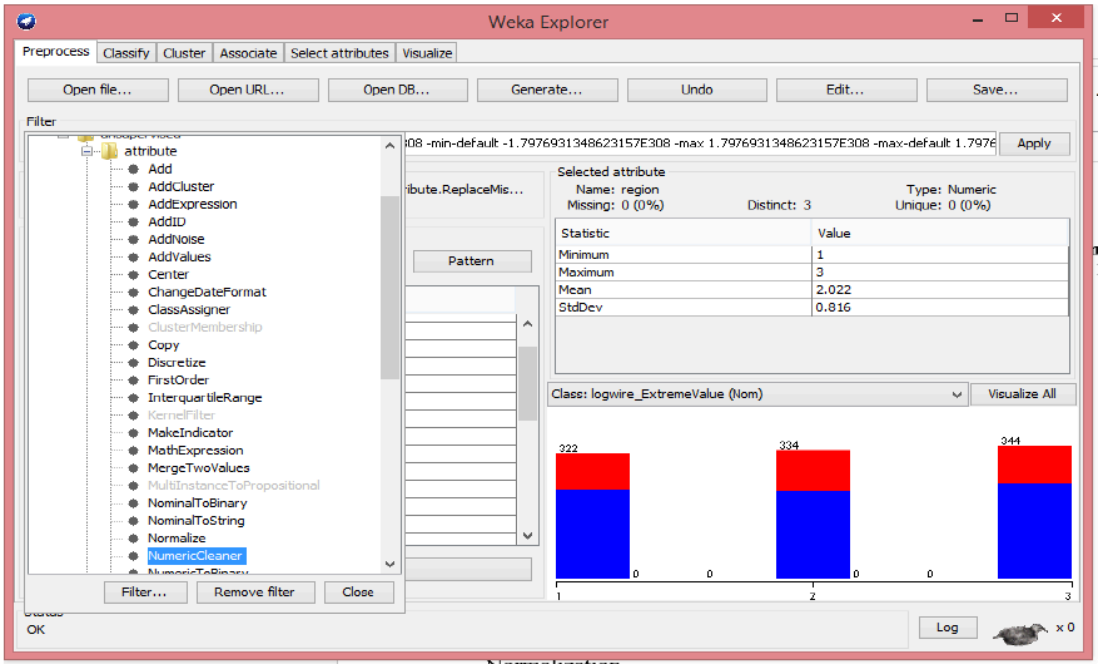

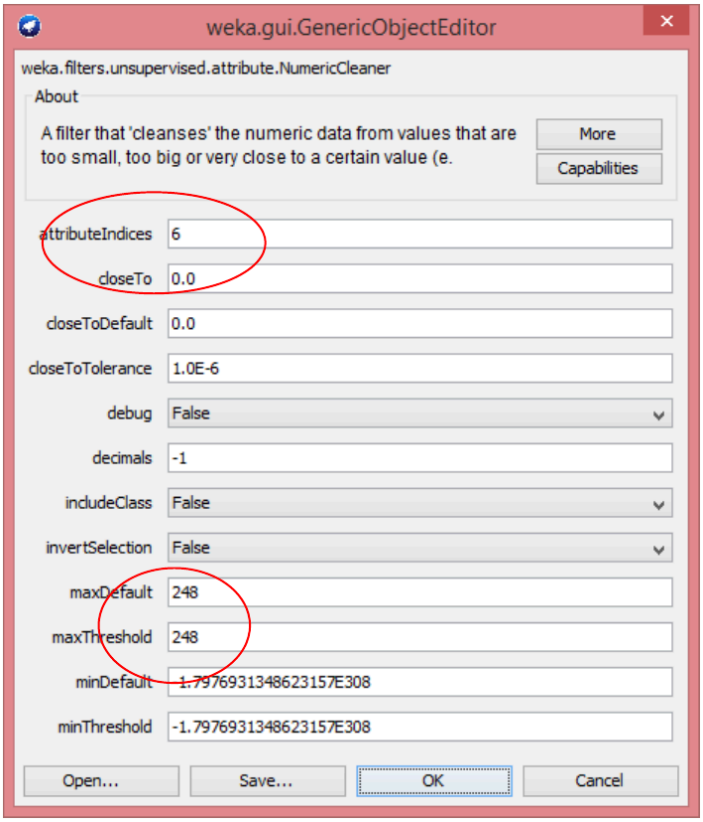

7. Clique no botão Apply para realizar a filtragem, então selecionar o atributo **income** para visualizar as estatísticas do atributo modificado. Se você gostou do resultado, salve o dataset.