
Universidade Federal de São Carlos - UFSCar
Departamento de Computação - DC
Programa de Pós-Graduação em Ciência da Computação - PPGCC

Resultados com o WEKA



Aluno: Pablo Freire Matos
Orientador: Dr. Ricardo Rodrigues Ciferri
Coorientador: Dr. Thiago Alexandre S. Pardo
Área: Banco de Dados

Roteiro

- **Testes Realizados na Classificação de Sentenças**
 - **MOVER x WEKA**

Configuração Usada no Mover

- Tipo de treinamento
 - *frequency measure (orig)*
 - *chi-squared (chi)*
 - *information gain (ig)*
- Todas *features* utilizadas
 - *all #used features*
 - *all #features output cut*
 - *all #orig features used*
- Otimização e n-gramas
 - *2 #max stored limit for optimize flow*
 - *5 #max cluster size used to generate features*

Sentenças

- Para cada sentença de treinamento foi excluído:
 - Ponto final
 - Vírgula
 - Parênteses

Todas as palavras de cada sentença de treinamento devem ser **Minúsculas**

Sentença


- Cada sentença tem um número informando a que artigo ele pertence, e.g.:
 - “8 the storage of frozen sperm was offered to mature boys”
 - Significa que a sentença “the storage of frozen...” foi extraída do artigo 8

Categorias de Treinamento

- A pasta “*training*” contém 3 categorias para treinamento:
 - 1_complication
 - 2_benefit
 - 5_other

Cada categoria contém várias sentenças identificadas manualmente

Quantidade de sentença por classe com 4 artigos



Medida de Utilidade no Mover

Stratified Cross-Validation	Precisão do Teste Aleatório	Desvio Padrão	Medida de Utilidade
5 Folds	65,93%	+ ou - 8,45%	IG (Ganho de Informação)
5 Folds	65,93%	+ ou - 8,45%	QUI (Qui-Quadrado)
5 Folds	65,93%	+ ou - 8,45%	ORIG (Frequência)

■ WEKA:

- Ganho de Informação e Qui-Quadrado **também** geram o mesmo resultado

Passos para a Classificação no WEKA

1. Carregar os dados
2. Aplicar pré-processamento
 1. Gerar matriz atributo-valor
 1. Frequência, n-gramas, stopwords, stemmer ...
 2. Converter numérico para nominal
 3. **RemoveMisclassifiedTest**
 4. **Randomize**
 5. Seleção de atributo
3. Selecionar Classificador

Resultado Mover x Weka

Perda de 5,59%

- Naïve Bayes
- Ganho de Informação (**com** ou **sem**)
- Matriz atributo-valor
 - **Frequência mínima = 1**
 - **1-grama**

Cross-Validation	Mover (Stratified CV)	Weka (CV)
3 Folds	64,24%	56,29%
5 Folds	68,15%	61,48%
10 Folds	70,77%	63,70% 59,25% (com stopword) 62,22% (com stemmer IteratedLovins) 62,96% (com stemmer Lovins) 63,70% (com stemmer snowball) 65,18% (stopword e snowball)

Resultado Mover x Weka

Ganho de 3,3%

- Naïve Bayes
- Ganho de Informação (**com** ou **sem**)
- Matriz atributo-valor
 - Frequência mínima = 2 e 3
 - 1-grama

Cross-Validation	Mover (Stratified CV)	Weka (CV)
3 Folds	64,24%	67,40%
5 Folds	68,15%	72,60%
10 Folds	70,77%	74,07% 72,59% (com stopword) 71,11% (com stemmer IteratedLovins) 72,59% (com stemmer Lovins) 70,37% (com stemmer Snowball) 73,33% (stopword e, Lovins ou Snowball)

Resultado Mover x Weka

Ganho de 7,74%

- Naïve Bayes
- Ganho de Informação (com ou sem)
- Matriz atributo-valor
 - Frequência mínima = 2
 - 1 a 3 gramas

Cross-Validation	Mover (Stratified CV)	Weka (CV)
3 Folds	64,24%	68,14%
5 Folds	68,15%	76,30%
10 Folds	70,77%	78,51% 75,55% (com stopword) 74,81% (com stemmer IteratedLovins) 76,29% (com stemmer Lovins) 75,55% (com stemmer Snowball) 75,55% (stopword e Snowball)

Filter

- weka
 - filters
 - AllFilter
 - MultiFilter
 - supervised
 - unsupervised
 - attribute
 - instance
 - NonSparseToSparse
 - Normalize
 - Randomize**
 - RemoveFolds
 - RemoveFrequentValues
 - RemoveMisclassified
 - RemovePercentage
 - RemoveRange
 - RemoveWithValues
 - Resample
 - ReservoirSample
 - SparseToNonSparse
 - SubsetByExpression

Filter... Remove filter Close

Apply

Selected attribute

Name: class Type: Nominal
Missing: 0 (0%) Distinct: 2 Unique: 0 (0%)

No.	Label	Count	Weight
-----	-------	-------	--------

weka.gui.GenericObjectEditor

weka.filters.unsupervised.instance.Randomize

About

Randomly shuffles the order of instances passed through it. [More](#) [Capabilities](#)

randomSeed 42

Open... Save... OK Cancel

Resultado Mover x Weka

Sem Ganho

- Naïve Bayes
- Ganho de Informação (com ou sem)
- Matriz atributo-valor
 - Frequência mínima = 2
 - 1 a 3 gramas
- Randomize

Cross-Validat ion	Mover (Stratified CV)	Weka (CV)	Weka (CV) (Randomize)
3 Folds	64,24%	68,14%	69,62%
5 Folds	68,15%	76,30%	74,81%
10 Folds	70,77%	78,51%	75,55%

Naïve Bayes no WEKA

- Mesmos resultados
 - Naïve Bayes
 - Naïve BayesUpdateable
 - Naïve BayesSimple

- Naïve BayesMultinomial
- Naïve BayesMultinomialUpdateable

Resultado no Weka com 135 exemplos

- Ganho de Informação
- Matriz atributo-valor
 - Frequência mínima = 2
 - 1 a 3 gramas

Valores dos parâmetros padrão

Classificador	10-Fold Cross-Validation	Tempo (segundos)	10-Fold Cross-Validation (Randomize)	Tempo (segundos) (Randomize)
Naïve Bayes	78,51%	0,22	75,55%	0,11
OneR	71,85%	0,22	71,85%	0,11
Prism	71,85%	0,22	71,85%	1,8
J48	71,85%	0,22	71,85%	0,94
ID3	54,07%	0,67	56,29%	0,7
SVM	71,85%	0,55	71,85%	0,66

Randomize influencia o NB
Randomize NÃO influencia o SVM

Classifier

Choose **NaiveBayes**

Test options

- Use training set
 - Supplied test set
 - Cross-validation Folds
 - Percentage split %
-

(Nom) class

Result list (right-click for options)

- 21:26:59 - bayes.NaiveBayes

Classifier output

```

Correctly Classified Instances      127      94.0741 %
Incorrectly Classified Instances    8        5.9259 %
Kappa statistic                    0.9089
Mean absolute error                 0.0467
Root mean squared error             0.1895
Relative absolute error             10.666 %
Root relative squared error         40.5048 %
Total Number of Instances          135

```

=== Detailed Accuracy By Class ===

	TP Rate	FP Rate	Precision	Recall	F-Measure	ROC Area	Class
	0.886	0	1	0.886	0.94	0.998	1_C
	0.917	0	1	0.917	0.957	0.999	2_F
	1	0.1	0.873	1	0.932	1	5_C
Weighted Avg.	0.941	0.041	0.948	0.941	0.941	0.999	

=== Confusion Matrix ===

```

a  b  c  <-- classified as
39  0  5 | a = 1_Complication_44
 0 33  3 | b = 2_Benefit_36
 0  0 55 | c = 5_Other_55

```

Status

OK

Aplicar Filtro: Remove Misclassified

The screenshot shows the Weka Explorer application window. The 'Filter' tab is active, and the 'instance' folder is selected in the left-hand tree view. The 'Remove Misclassified' filter is highlighted in blue. The main area displays the filter's configuration, including the command line: `weka.filters.unsupervised.instance.RemoveMisclassified -C -1 -F 0 -T 0.1 -I 0`. Below this, the 'Selected attribute' section shows the 'class' attribute with 3 distinct values and 0 missing values. A table displays the distribution of the 'class' attribute:

No.	Label	Count	Weight
1	1_Complication_44	44	44.0
2	2_Benefit_36	36	36.0
3	5_Other_55	55	55.0


Below the table, the 'Class: younger than 2 (Nom)' is selected, and a bar chart visualizes the distribution of the 'class' attribute. The bars are blue, and the counts are labeled above each bar: 44, 36, and 55.

Status 23/09/09

OK

Resultados com o WEKA

Log



Preprocess Classify Cluster Associate Select attributes Visualize

Open file... Open URL... Open DB... Generate... Undo Edit... Save...

Filter Choose **RemoveMisclassified** -W "weka.classifiers.bayes.NaiveBayes" -C -1 -F 0 -T 0.1 -I 0 Apply

Current relation Selected attribute
Relation: C:\Documents and Settings\Public\Me... 438 documentos UNID
Instances: 135 Name: class Type: Nominal
Missing: 0 (0%) Distinct: 3 Unique: 0 (0%)

Índice da classe = 0

Attributes All None Invert

No.	Name
1	<input type="checkbox"/> class
2	<input type="checkbox"/> 1
3	<input type="checkbox"/> 1 of
4	<input type="checkbox"/> 1 recurrent
5	<input type="checkbox"/> 1 recurrent stroke
6	<input type="checkbox"/> 13
7	<input type="checkbox"/> 2
8	<input type="checkbox"/> 2 the
9	<input type="checkbox"/> 2 treatment
10	<input type="checkbox"/> 2 treatment was
11	<input type="checkbox"/> 2 years
12	<input type="checkbox"/> 2 years of
13	<input type="checkbox"/> 3

Remove

GenericObjectEditor

weka.filters.unsupervised.instance.RemoveM

About
A filter that removes instances which classified.

Capabilities

classIndex

classifier Choose **NaiveBayes**

invert

maxIterations

numFolds

threshold

Open... Save... OK Cancel

**Neste caso:
Mudar para zero**

Open file... Open URL... Open DB... Generate... Undo Edit... Save...

Filter
 Choose **RemoveMisclassified** -W "weka.classifiers.bayes.NaiveBayes" -C 0 -F 0 -T 0.1 -I 0 Apply

Current relation
 Relation: C:_Documents and Settings_Pablo Mes_660...
 Instances: 109 Sum of weights: 109

Selected attribute
 Name: class Type: Nominal
 Missing: 0 (0%) Distinct: 3 Unique: 0 (0%)


Attributes

Instâncias inicial = 135
Redução de 19,25%

	Label	Count	Weight
1	1_Complication_44	38	38.0
2	2_Benefit_36	16	16.0
3	5_Other_55	55	55.0

No.	Name
1	<input type="checkbox"/> class
2	<input type="checkbox"/> 1
3	<input type="checkbox"/> 1 of
4	<input type="checkbox"/> 1 recurrent
5	<input type="checkbox"/> 1 recurrent stroke
6	<input type="checkbox"/> 13
7	<input type="checkbox"/> 2
8	<input type="checkbox"/> 2 the
9	<input type="checkbox"/> 2 treatment
10	<input type="checkbox"/> 2 treatment was
11	<input type="checkbox"/> 2 years
12	<input type="checkbox"/> 2 years of
13	<input type="checkbox"/> 3

Class: younger than 2 (Nom)



Classifier Choose **AttributeSelectedClassifier** -E "weka.attributeSelection.InfoGainAttributeEval" -S "weka.attributeSelection.Ranker -T -1.7976931348623157E308 -f

Test options

Use training set

Supplied test set

Cross-validation Folds

Percentage split %

(Nom) class

- Result list (right-click for options)
- 21:26:59 - bayes.NaiveBayes
 - 21:32:47 - meta.AttributeSelectedClassifier
 - 21:39:26 - meta.AttributeSelectedClassifier
 - 21:40:17 - meta.AttributeSelectedClassifier

Classifier output

Correctly Classified Instances	109	100	%
Incorrectly Classified Instances	0	0	%
Kappa statistic	1		
Mean absolute error	0.0181		
Root mean squared error	0.0752		
Relative absolute error	4.4957	%	
Root relative squared error	16.7837	%	
Total Number of Instances	109		

=== Detailed Accuracy By Class ===

	TP Rate	FP Rate	Precision	Recall	F-Measure	ROC Area	Class
	1	0	1	1	1	1	1_0
	1	0	1	1	1	1	2_1
	1	0	1	1	1	1	5_0
Weighted Avg.	1	0	1	1	1	1	

=== Confusion Matrix ===

```

a b c <-- classified as
38 0 0 | a = 1_Complication_44
0 16 0 | b = 2_Benefit_36
0 0 55 | c = 5_Other_55

```

Resultado no Weka (109 exemplos-NB)

- Pré-processamento

- Matriz atributo-valor
 - Frequência mínima = 2
 - 1 a 3 gramas

- RemoveMisclassifiedTest do Naïve Bayes (NB)

Valores dos parâmetros padrão

Classificador	10-Fold Cross-Validation (Resultado Anterior)	Tempo (segundos) (Resultado Anterior)	10-Fold Cross-Validation	Tempo (segundos)
Naïve Bayes	78,51%	0,22	↓ 76,14%	0,11
OneR	41,48%	0,09	↑ 52,29%	0,09
Prism	45,92%	1,47	↑ 51,37%	0,91
J48	50,37%	0,91	↑ 66,05	0,52
ID3	54,07%	0,67	↑ 75,22%	0,47
SVM	71,85%	0,55	↑ 78,89%	↓ 0,33

Resultado no Weka

- Pré-processamento
 - Matriz atributo-valor
 - Frequência mínima = 2
 - 1 a 3 gramas
 - RemoveMisclassifiedTest de cada classificador

Valores dos parâmetros padrão

Classificador	10-Fold Cross-Validation (Resultado Anterior)	10-Fold Cross-Validation
Naïve Bayes	78,51%	76,14% (109 exemplos)
OneR	41,48%	100% (64 ex)
Prism	45,92%	45,92% (135 ex)
J48	50,37%	65,28 (121 ex)
ID3	54,07%	54,07% (135 ex)
SVM	71,85%	71,85% (135 ex)

Quantidade de sentença por classe com 4 artigos

Other (55)

Total: 135

**Complication e
Benefit (80)**

Resultado Mover x Weka

Ganho de 5,33%

- Naïve Bayes
- Ganho de Informação (com ou sem)
- Pré-processamento
 - Matriz atributo-valor
 - Frequência mínima = 2
 - 1 a 3 gramas
 - RemoveMisclassifiedTest e Randomize

Cross-Validation	Weka (CV) – 2 classes com 135 exemplos	Weka (CV) – 2 classes com 130 exemplos (RemoveMisclassifiedTest)	Weka (CV) – 2 classes com 135 exemplos (Randomize)	Weka (CV) – 2 classes com 130 exemplos (Remove e Randomize)
10 Folds	78,51	82,30%	82,96%	83,84%

Resultado Mover x Weka

Ganho de 5,33%

- Naïve Bayes
- Ganho de Informação (com ou sem)
- Pré-processamento
 - Matriz atributo-valor
 - Frequência mínima = 2
 - 1 a 3 gramas
 - RemoveMisclassifiedTest e Randomize

Cross-Validation	Mover (Stratified CV)	Weka (CV) – 3 classes com 135 exemplos	Weka (CV) – 3 classes com 109 exemplos (Remove)	Weka (CV) – 2 classes com 135 exemplos	Weka (CV) – 2 classes com 130 exemplos (Remove e Randomize)
10 Folds	70,77%	78,51%	76,14%	78,51	83,84%

Considerações Finais

■ Pré-processamento

1. Gerar matriz atributo-valor
 1. Frequência, n-gramas, stopwords, stemmer ...
 2. **IDF e TF transform, lematização**
2. Converter numérico para nominal
3. Randomize
4. RemoveMisclassifiedTest
5. **Igualar os exemplos (over e under sampling)**
6. Seleção de atributo

Considerações Finais

- Pré-processamento
 - Matriz atributo-valor
 - Frequência mínima = 2
 - 1 a 3 gramas
 - sem stopword
 - sem stemmer
 - testar lematização
 - Randomize e RemoveMisclassifiedTest
 - com 2 classes (Other, Complication e Benefit)
 - RemoveMisclassifiedTest
 - Com 3 classes (Complication, Benefit e Other)

Referências

- ANTHONY, L.; LASHKIA, G. V. Mover: a machine learning tool to assist in the reading and writing of technical papers. **IEEE Transactions on Professional Communication**, v. 46, n. 3, p. 185-193, 2003.
- BURSTEIN, J.; MARCU, D.; KNIGHT, K. Finding the WRITE stuff: automatic identification of discourse structure in student essays. **Intelligent Systems**, IEEE, v. 18, n. 1, p. 32-39, 2003.
- BATISTA, G. E. A. P. A.; PRATI, R. C.; MONARD, M. C. A study of the behavior of several methods for balancing machine learning training data. **SIGKDD Explorations Newsletter**, v. 6, n. 1, p. 20-29, 2004.
- HEY, D. F.; FELTRIM, V. D. Uma investigação sobre a aplicação de algoritmos de aprendizado à classificação de papéis retóricos. In: VIII Fórum de Informática e Tecnologia de Maringá, XI Mostra de Trabalhos de Informática, 2008, Maringá. **Anais...** Universidade Estadual de Maringá, 2008. p. 94-104.

Referências (Cont.)

- WITTEN, I. H.; FRANK, E. **Data mining**: practical machine learning tools and techniques with Java implementations. 2nd ed. San Francisco, CA: Morgan Kaufmann, 2005. 525 p.

Universidade Federal de São Carlos - UFSCar
Departamento de Computação - DC
Programa de Pós-Graduação em Ciência da Computação - PPGCC

Resultados com o WEKA



Aluno: Pablo Freire Matos
Orientador: Dr. Ricardo Rodrigues Ciferri
Coorientador: Dr. Thiago Alexandre S. Pardo
Área: Banco de Dados