

Referências Bibliográficas

- [1] JANG, Jun-Su; HAN, Kuk-Hyun; KIN, Jong-Hwan. **Face Detection using Quantum-inspired Evolutionary Algorithm**. Congress on Evolutionary Computation, 2004. Pag. 2100-2106, Vol.2.
- [2] ABS DA CRUZ, André Vargas. **Algoritmos Evolutivos com Inspiração Quântica para Problemas com Representação Numérica**. Tese do Departamento de Engenharia Elétrica da Pontifícia Universidade Católica do Rio de Janeiro, 2007.
- [3] KIM, Yehoon; KIN, Jong-Hwan; HAN, Kuk-Hyun. **Quantum-inspired Multiobjective Evolutionary Algorithm for Multiobjective 0/1 Knapsack Problems**. 2006 IEEE Congress on Evolutionary Computation. Vancouver, BC, Canada.
- [4] HAN, Kuk-Hyun; KIN, Jong-Hwan. **Quantum-Inspired Evolutionary Algorithm for a Class of Combinatorial Optimization**. IEE Transactions on Evolutionary Computation, Vol. 6, No. 6, December 2002.
- [5] LI, Zhiyong; RUDOLPH, Günter; LI, Kenli. **Convergence performance comparison of quantum-inspired multi-objective evolutionary algorithms**. Journal of Computers and Mathematics with Applications, Elsevier, 2008.
- [6] TALBI, Hichem; MOHAMED, Batouche; DRAA, Amer. **A Quantum-Inspired Evolutionary Algorithm for Multiobjective Image Segmentation**. International Journal of Mathematical, Physical and Engineering Sciences, Volume 1, Number2.
- [7] MAHDABI, Parvaz; JALILI, Saeed; ABADI, Mahdi. **A Multi-Start Quantum-Inspired Evolutionary Algorithm for Solving Combinatorial Optimization Problems**. GECCO, 2008. Atlanta, Georgia, USA.
- [8] HAN, Kuk-Hyun; KIN, Jong-Hwan. Genetic **Quantum Algorithm and its Application to Combinatorial Optimization Problem**. Congress of Evolutionary Computation, Piscataway, NJ, 2000.

- [9] ARPAIA, Pasquale; MECCARIELLO, Giovanni; RAPONE, Mario; ZANESCO, Antonio. **Quantum-Inspired Evolutionary Classification of Driving Sequences in Vehicle Emission Factor Measurement**. 15th IMEKO TC4, Symposium on Novelties in Electrical Measurements and Instrumentation, Iasi, Romania.
- [10] LACERDA, Estefane; CARVALHO, André C. P. L. F.; BRAGA, Antônio P.; LUDERMIR, Teresa B.. **Evolutionary Radial Basis Functions for Credit Assessment**. Applied Intelligence 22, 167-181, 2005, Springer Science and Business Media, Inc. Manufactured in The Netherlands.
- [11] ZHAN, Lin et al. **ANN-GA Approach of Credit Scoring for Mobile Customers**. 2004 IEEE, Conference on Cybernetics and Intelligent Systems, Singapore, 1-3 December, 2004.
- [12] PEDRAJAS, N. García et al. **Multi-objective cooperative coevolution of artificial neural networks (multi-objective cooperative networks)**. Neural Networks 15 (2002) 1259–1278.
- [13] PEDRAJAS, N. García et al. **Cooperative Coevolution of Artificial Neural Network Ensembles for Pattern Classification**. IEEE Transactions on Evolutionary Computation, Vol. 9, no. 3, June 2005.
- [14] PEDRAJAS, N. García et al. **COVNET: A Cooperative Coevolutionary Model for Evolving Artificial Neural Networks**. IEEE Transactions on Neural Networks, Vol. 14, no. 3, May 2003.
- [15] ABRAHAM, Ajith. **Meta learning evolutionary artificial neural networks**. Neurocomputing 56 (2004) 1 – 38.
- [16] GOMEZ, Faustino et al. **Accelerated Neural Evolution through Cooperatively Coevolved Synapses**. Journal of Machine Learning Research 9 (2008) 937-965.
- [17] BLANCO, A. et al. **A real-coded genetic algorithm for training recurrent neural networks**. Neural Networks 14 (2001) 93-105.
- [18] DELGADO, M.; PEGALAJAR, M.C.. **A multiobjective genetic algorithm for obtaining the optimal size of a recurrent neural network for grammatical inference**. Pattern Recognition 38 (2005) 1444 – 1456.

- [19] PAZ, E. Cantú; KAMATH, Chandrika. **An Empirical Comparison of Combinations of Evolutionary Algorithms and Neural Networks for Classification Problems.** IEEE Transactions on Systems, Man, and Cybernetics - Part B: Cybernetics.
- [20] CAPI, Genci; DOYA, Kenji. **Evolution of recurrent neural controllers using an extended parallel genetic algorithm.** Robotics and Autonomous Systems 52 (2005) 148–159.
- [21] KIM, Kyung-Joong; CHO, Sung-Bae. **Evolutionary ensemble of diverse artificial neural networks using speciation.** Neurocomputing 71 (2008) 1604–1618.
- [22] PEDRAJAS, Nicolás G.; BOYER, Domingo O.. **A cooperative constructive method for neural networks for pattern recognition.** Pattern Recognition 40 (2007) 80 – 98.
- [23] PLATEL, M.D. SCHLIEBS, S. KASABOV, N. **Quantum-Inspired Evolutionary Algorithm: A Multimodel EDA.** IEEE Transactions on Evolutionary Computation. December 2009. Volume 13, Issue 6. Pages 1218-1232.
- [24] MOORE, Mark; NARAYANAN, Ajit. **Quantum-inspired computing.** Department of Computer Science Old Library, University of Exeter, UK, 1995
- [25] MOTTA, S. Valéria et al. **Esfera de Bloch: algumas propriedades.** XXVIII Congresso Nacional de Matemática Aplicada e Computacional, 2005, Santo Amaro, SP.
- [26] MURPHY, C. A.; AHA, D. W. **“UCI repository of machine learning databases”.** Irvine, CA, University of California, 1994.
- [27] PORTUGAL, Renato et al. **Uma Introdução à Computação Quântica.** Notas em matemática aplicada. Sociedade Brasileira de Matemática Aplicada e Computacional, Vitória, ES, Brasil, 2005.
- [28] YAO, Xin. **Evolving Artificial Neural Networks.** IEEE, vol. 87, no. 9, september 1999.
- [29] SEXTON; Randall S. DORSEY, Robert E. **Reliable classification using neural networks: a genetic algorithm and**

- backpropagation comparison.** Decision Support Systems 30 (2000) 11–22.
- [30] PINHO, A. Guimarães; VELLASCO, Marley; CRUZ, A. Vargas Abs. **A New Model for Credit Approval Problems: A Neuro-Genetic System with Quantum Inspiration and Binary-Real Representation.** NABIC 2009, Coimbatore, India.
- [31] MICHALEWICZ, Zbigniew. **Genetic Algorithms + Data Structures = Evolution Programs.** 3rd edition. Berlin, Germany: Springer, 1999.
- [32] LINDEN, Ricardo. **Algoritmos Genéticos.** 2nd edição. Rio de Janeiro, Brazil: Brasport, 2008.
- [33] QUINLAN, J. R. **Simplifying Decision Trees.** Massachusetts Institute of Technology, Artificial Intelligence Laboratory, 1986.
- [34] BRAGA, Ana Cristina da Silva. **Curvas ROC: Aspectos Funcionais e Aplicações.** Tese de Doutorado. Universidade do Minho Braga: Dezembro, 2000.
- [35] KWEDLO, Wojciech; KRETOWSKI, Marek. **Discovery of Decision Rules from Databases: An Evolutionary Approach.** Institute of Computer Science, University of Bialystok, Bialystok, Poland.
- [36] RATANAMAHATANA, Chotirat; GUNOPULOS, Dimitrios. **Scaling up the Naïve Bayesian Classifier: Using Decision Trees for Feature Selection.** Computer Science Department, University of California, Riverside, CA.
- [37] EGGERMONT, Jeroen; KOK, Joost N.; KOSTERS, Walter A. **Genetic Programming for Data Classification: Partitioning the Search Space.** SAC`04, March 14-17, 2004.
- [38] JIANG, Yuan; ZHOU, Zhi-Hua. **Editing Training Data for kNN Classifiers with Neural Network Ensemble.** National Laboratory for Novel Software Technology, Nanjin University, Nanjin 210093, China.
- [39] ZHONG, Ping; FUKUSHIMA, Masao. **A Regularized Nonsmooth Newton Method for Multi-class Support Vector Machines.** Scientific Research Grant-in-Aid, Japan Society, April of 2006.

- [40] DY, Jennifer G.; BRODLEY, Carla E. **Feature Selection for Unsupervised Learning.** Journal of Machine Learning Research 5 (2004) 845-889.
- [41] RIDDER, Dick de et al. **Supervised locally linear embedding.** Artificial Neural Networks and Neural Information Processing — ICANN/ICONIP 2003. Lecture Notes in Computer Science, Volume 2714/2003, 175.
- [42] POTTER, Ryan. **Comparison of Classification Algorithms Applied to Breast Cancer Diagnosis and Prognosis.** University of Washington, Tacoma, WA 98402, USA.
- [43] MANGASARIAN, O. L.; STREET, Nick W. **Breast Cancer Diagnosis and Prognosis via Linear Programming.** AAI Technical Report SS-94-01, 1994.
- [44] BOUCHACHIA, Abdelhamidi. **RBF Networks for Learning from Partially Labeled Data.** 22st ICML Workshop on Learning with Partially Classified Training Data, Bonn, Germany, August 2005.
- [45] FISCHER, Igor. **Amplifying the Block Matrix Structure for Spectral Clustering.** Technical Report No. IDSIA, January 31, 2005, Switzerland.
- [46] JAGIELSKA, Ilona et al. **A Study in Experimental Evaluation of Neural Network and Genetic Algorithm Techniques for Knowledge Acquisition in Fuzzy Classification Systems.** IEEE, 1997.
- [47] GOLDBERG, David Edward. **Genetic algorithms in search, optimization, and machine learning.** Addison-Wesley, 1989, 412p., ISBN 0201157675.
- [48] BUSSAB; Wilton de Oliveira. MORETTIN; Pedro Alberto. **Estatística Básica.** 5ª edição. São Paulo: editora Saraiva, 2006.
- [49] HAYKIN, Simon. **Neural Networks: A Comprehensive Foundation (2nd Edition).** Porto Alegre: Bookman, 2001.
- [50] BOSE, Indranil; CHEN, Xi. **Quantitative models for direct marketing.** European Journal of Operational Research 195 (2009) 1-16.

- [51] YOBAS, M. B.; CROOK, J. N.; ROSS, P.. **Credit scoring using neural and evolutionary techniques**. IMA Journal of Mathematics Applied in Business and Industry 11 (2000) 111-125.
- [52] SAKPRASAT, Sum; SINCLAIR, Mark C.. **Classification Rule Mining for Automatic Credit Approval using Genetic Programming**. 2007 IEEE Congress on Evolutionary Computation.
- [53] YU, Lean; WANG, Shouyang; LAI, Kin Keung. **Credit risk assessment with a multistage neural network ensemble learning approach**. Expert Systems with Applications 34 (2008) 1434-1444, Elsevier.
- [54] CHEN, Mu-Chen; HUANG, Shih-Hsien. **Credit scoring and rejected instances reassigning through evolutionary computation techniques**. Expert Systems with Applications 24 (2003) 433-441, Elsevier.
- [55] HUANG, Jih-Jeng; TZENG, Gwo-Hshiung; ONG, Chorng-Shyong. **Two-stage genetic programming (2SGP) for credit scoring model**. Applied Mathematics and Computation (2005), Elsevier.
- [56] PIRAMUTHU, Selwyn. **Financial credit-risk evaluation with neural and neurofuzzy systems**. European Journal of Operational Research 112 (1999) 310-321.
- [57] HUANG, Zan et al. **Credit rating analysis with support vector machines and neural networks: a market comparative study**. Decision Support Systems 37 (2004) 543-558, Elsevier.
- [58] HUANG, Zan et al. **Statistical Classification Methods in Consumer Credit Scoring: a Review**. Journal of Royal Statistical Society 160 (1997) 523-541.
- [59] JOHNSON, Richard A.; WICHERN, Dean W. **“Applied Multivariate Statistical Analysis”**. 3rd ed., Prentice Hall, Englewood Cliffs, New Jersey.
- [60] CHELLAPILLA, Kumar; FOGEL, David. **Evolution, Neural Networks, Games, and Intelligence**. IEEE, vol. 87, no. 9, september 1999.

- [61] ZHANG , Zhibing. **An Efficient Neuro-Fuzzy-Genetic Data mining Framework Based On Computational Intelligence**. 2009 Ninth International Conference on Hybrid Intelligent Systems.
- [62] BRADLEY, Andrew P. **The use of the Area Under the Roc Curve in the Evaluation of Machine Learning Algorithms**. Pattern Recognition, Vol. 30, No. 7, pp, 1145-1159, 1997.
- [63] CARDILLO, G. **ROC curve: compute a Receiver Operating Characteristics curve**. <http://www.mathworks.com/matlabcentral/fileexchange/19950>.
- [64] MONTGOMERY, Douglas C. **Design and Analysis of Experiments**. 6a edition. Wiley edition, 2004.

Anexos

Testes Estatísticos

Teste Kolmogorov Smirnov para normalidade dos dados

Seja uma amostra $X_1, X_2, X_3, \dots, X_n$ de uma população P . Designa-se por $f(x)$ a função densidade e por $F(x)$ a função distribuição acumulada de X . Estimar $f(x)$ é equivalente a estimar $F(x)$. Sendo assim, nosso objetivo é testar se a amostra observada vem de uma distribuição de probabilidades especificada, ou seja:

$$H_0 : F(x) = F_0(x), \text{ para todo } x. \quad (8-1)$$

A hipótese alternativa pode ser definida como:

$$H_1 : F(x) \neq F_0(x), \text{ para algum } x. \quad (8-2)$$

O teste é feito comparando-se a distribuição observada $F(x)$ com um bom estimador. Seja então a função $F_e(x)$ uma função em “escada”, com saltos de probabilidades para cada incremento de X_i da ordem de $1/n$, o estimador de $F(x)$. Neste caso, ambas as distribuições devem estar bem próximas, caso contrário, se terá evidências para acreditar na hipótese alternativa.

Os probabilistas russos Kolmogorov e Smirnov propuseram uma estatística para o teste, obtida através do máximo dos valores absolutos das diferenças $F(x_i) - F_e(x_i)$, $i=1, \dots, n$. Formalmente, tem-se que a estatística a ser usada no teste será:

$$D_{\max} = \max_{1 \leq i \leq n} |F(x_i) - F_e(x_i)|. \quad (8-3)$$

Ao nível de significância α , com n menor ou igual a 100, o valor D_{\max} deve ser comparado com uma tabela de distribuição de D , proposta por Kolmogorov-Smirnov. Para n maior do que 100, o valor de D pode ser obtido diretamente por:

$$D = \sqrt{\frac{-\ln\left(\frac{\alpha}{2}\right)}{2n}}. \quad (8-4)$$

Em ambos os casos de D , tabelado ou calculado diretamente de (8-4), rejeita-se a hipótese de normalidade se $D_{\max} > D$. Caso contrário, as amostras em análise seguem uma distribuição normalmente distribuída.

Teste F para comparação de duas variâncias de duas populações normais

Suponha duas amostras independentes, de tamanhos n_1 e n_2 , retiradas de duas populações normais com a mesma variância σ^2 . Seja os estimadores de σ^2 dados por S_1^2 e S_2^2 , para as duas amostras respectivamente. Pode-se provar que:

$$U = \frac{(n_1-1)S_1^2}{\sigma^2} \sim X^2(n_1-1),$$

$$V = \frac{(n_2-1)S_2^2}{\sigma^2} \sim X^2(n_2-1),$$

e portanto a v.a.

$$\frac{S_1^2}{S_2^2} = \frac{\frac{U}{n_1-1}}{\frac{V}{n_2-1}} \sim F(n_1-1, n_2-1). \quad (8-5)$$

Considere uma amostra $X_1, X_2, X_3, \dots, X_n$ de uma população com distribuição $N(\mu^2_1, \sigma^2_1)$ e uma $Y_1, Y_2, Y_3, \dots, Y_n$ de uma população com distribuição $N(\mu^2_2, \sigma^2_2)$. Suponha também independência entre X e Y . Nossas hipóteses a serem testadas podem ser definidas da seguinte forma:

$$H_0 : \sigma_1^2 = \sigma_2^2 = \sigma^2, \quad (8-6)$$

$$H_1 : \sigma_1^2 \neq \sigma_2^2.$$

Chama-se de S_1^2 e S_2^2 as variâncias amostrais respectivas. Sob a hipótese H_0 e sobre (8-5), vem-se que:

$$W = S_1^2 / S_2^2 \sim F(n-1, m-1). \quad (8-7)$$

Seja α um nível de significância desejado, e f_1 e f_2 dois valores da distribuição $F(n-1, m-1)$ de modo que $P(W < f_1) = \alpha/2 = P(W > f_2)$, se terá evidências para rejeitar a hipótese nula em caso de:

$$P(W \in RC) = P(W < f_1 \text{ ou } W > f_2) = \alpha. \quad (8-8)$$

Caso contrário, se aceita H_0 , a igualdade das variâncias ao nível de significância de α .

Teste t-student para comparação de duas médias de duas populações normais

Seja P_1 com distribuição $N(\mu_1^2, \sigma_1^2)$ e P_2 com distribuição $N(\mu_2^2, \sigma_2^2)$, deseja-se testar a hipótese de:

$$H_0 : \mu_1 = \mu_2,$$

contra

$$H_1 : \mu_1 \neq \mu_2. \quad (8-9)$$

Para cada amostra de P_1 e P_2 pode-se calcular os estimadores da média e da variância:

$$\begin{aligned} \bar{X} &= \frac{1}{n} \sum_{i=1}^n X_i, S_1^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2; \\ \bar{Y} &= \frac{1}{m} \sum_{i=1}^m Y_i, S_2^2 = \frac{1}{m-1} \sum_{i=1}^m (Y_i - \bar{Y})^2. \end{aligned} \quad (8-10)$$

Sob a hipótese H_0 , isto é, $\mu_1 = \mu_2$,

$$\begin{aligned} E(\bar{X} - \bar{Y}) &= 0, \\ \text{Var}(\bar{X} - \bar{Y}) &= \text{Var}(\bar{X}) + \text{Var}(\bar{Y}) = \frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{m}. \end{aligned} \quad (8-11)$$

Como os estimadores de média de X e Y tem distribuição normal, se as variâncias fossem conhecidas, a estatística

$$Z = \frac{\bar{X} - \bar{Y}}{\sqrt{\frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{m}}}. \quad (8-12)$$

Teria distribuição normal padrão, sob a hipótese nula H_0 , e poderia ser usada para testar H_0 contra H_1 . Contudo, em situações práticas as variâncias não são conhecidas, devendo ser substituídas por estimativas convenientes.

Suponha que, ao se testar a hipótese de variância pelo teste F, esta seja aceita, ou seja, $\sigma_1^2 = \sigma_2^2 = \sigma^2$. Porém, como esta variância comum é desconhecida. E como S_1^2 e S_2^2 são dois estimadores não-viesados de σ^2 , pode-se combiná-los em um único estimador não viesado de σ^2

$$S_p^2 = \frac{(n-1)S_1^2 + (m-1)S_2^2}{n+m-2}. \quad (8-13)$$

E ainda, cada parcela de (8-13) quando dividida por σ^2 , terá distribuição qui-quadrado, com (n-1) e (m-1) graus de liberdade, respectivamente. Vem-se então que

$$\frac{(n+m-2)S_p^2}{\sigma^2} \sim X^2(n+m-2). \quad (8-14)$$

Desta forma, é possível provar que

$$T = \frac{\frac{\bar{X} - \bar{Y}}{\sigma\sqrt{1/n+1/m}}}{S_p/\sigma} = \frac{\bar{X} - \bar{Y}}{S_p\sqrt{1/n+1/m}} \quad (8-15)$$

Terá uma distribuição t de Student, com (n+m-2) graus de liberdade, sob H_0 , isto é, se $\mu_1 = \mu_2$. Neste caso, se aceitaria a hipótese alternativa, ou seja, μ_1 diferente de μ_2 , em caso de T observado em (8-15) for maior que um t da distribuição t-student com (n+m-2) graus de liberdade, *em caso de variâncias consideradas estatisticamente iguais*.

Para o caso de variâncias desiguais ou desconhecidas, deve-se usar a estatística

$$T = \frac{\bar{X} - \bar{Y}}{\sqrt{S_1^2/n + S_2^2/m}}. \quad (8-16)$$

Pode-se provar que, sob a veracidade de H_0 , a v.a. T aproxima-se de uma distribuição t de Student, com o número de graus de liberdade dado aproximadamente por

$$v = \frac{(A+B)^2}{A^2/(n-1) + B^2/(m-1)}, \quad (8-17)$$

onde

$$A = s_1^2/n, \quad B = s_2^2/m. \quad (8-18)$$

Sendo assim, em caso de variâncias estatisticamente desiguais ou desconhecidas, se rejeitaria H_0 em caso de T em (8-16) for maior que um t de student com v graus de liberdade. Ou seja, a hipótese de diferenças de médias entre μ_1 e μ_2 seria aceita.

Teste Wilcoxon (ou Mann-Whitney) para comparação de duas médias de duas populações não-normais

O teste de Wilcoxon, ou de Mann-Whitney, pertence a uma categoria de procedimentos chamados não-paramétricos ou livres de distribuição, e, portanto, não fazem suposições a respeito da forma das distribuições P_1 e P_2 , a não ser que estas tenham uma escala de medida pelo menos ordinal. Da mesma forma, deseja-se saber se uma população tende a ter valores maiores que outra, ou se elas têm a mesma mediana, ou média.

Este teste se baseia nos postos dos valores obtidos combinando-se as duas amostras. Primeiro ordena-se os valores de duas amostras, do menor para o maior, em uma única lista. A estatística de teste é a soma dos postos associados aos valores amostrados de uma população, P_1 , por exemplo. Se esta soma for grande, isto seria um indicativo de que os valores da população P_1 tendem a ser maior que o da P_2 . Neste caso, rejeitar-se-ia a hipótese de igualdade de médias.

Sejam duas amostras independentes, X_1, \dots, X_n , de P_1 , e Y_1, \dots, Y_m , de P_2 . Seja $N=n+m$ e combinam-se as duas amostras numa só, ordenam-se os N valores do menor para o maior e chamemos $S_1 < S_2 < \dots < S_m$ os postos dos Y_i (tratamentos) e $R_1 < R_2 < \dots < R_n$ os postos de X_i (controles). Supondo que não hajam empates, pode-se definir

$$W_S = S_1 + S_2 + \dots + S_m \quad (8-19)$$

a soma dos postos dos tratamentos.

Sejam as hipóteses de teste

$$\begin{aligned} H_0 : \mu_1 &= \mu_2, \\ H_1 : \mu_1 &\neq \mu_2, \end{aligned} \quad (8-20)$$

é possível provar que

$$\begin{aligned} E(W_S) &= \frac{m(N+1)}{2}, \\ \text{Var}(W_S) &= \frac{nm(N+1)}{12}, \end{aligned} \quad (8-21)$$

e que, a distribuição W_S pode ser aproximada pela distribuição normal, quando n e m tendem ao infinito. Ou seja:

$$Z = \frac{W_S - E(W_S)}{\sqrt{\text{Var}(W_S)}} \sim N(0,1) \quad (8-22)$$

Neste caso, ao nível de significância de α , rejeita-se H_0 caso a $P(W_S < W_{\text{Observado}})$ seja menor que α . Caso contrário, aceita-se a igualdade de médias.

Resultados Outros Algoritmos

Algoritmos	MPPCE	DPPCE	Fonte	Ano Publicação
Original Decision Tree	20,6%	0,6%	[33]	1986
Cost-Complexity Pruning	15,8%	1,9%	[33]	1986
Reduced Error Pruning	15,2%	3,2%	[33]	1986
Pessimistic Pruning	16,1%	0,4%	[33]	1986
Production Rule Form	16,5%	1,8%	[33]	1986
Production Rule Form	16,5%	1,8%	[33]	1986
Composite Rule Sets	14,4%	1,9%	[33]	1986
MLP-Backprop	17,1%	1,8%	[10]	2005
Cascade correlation	18,0%	3,0%	[10]	2005
Tower	14,7%	3,2%	[10]	2005
Pyramid	16,9%	2,1%	[10]	2005
SVM	16,7%	2,6%	[10]	2005
RBF - Batch	16,7%	3,9%	[10]	2005
RBF - DF	16,3%	2,5%	[10]	2005
RBF - IO	17,8%	4,0%	[10]	2005
RBF - DFIO	16,7%	4,3%	[10]	2005
RBF - IOFDF	17,3%	4,4%	[10]	2005
RBF - On line	16,9%	4,4%	[10]	2005
RBF - Optimal	15,9%	4,7%	[10]	2005
RBF - GA	14,0%	3,5%	[10]	2005
C4.5 Rules	15,5%	-	[10]	2005
C4.5 Trees	15,1%	-	[10]	2005
Foil trad.1	17,8%	-	[10]	2005
Foil trad.2	17,4%	-	[10]	2005
Foil trad.3	17,0%	-	[10]	2005
Foil exd.1	18,0%	-	[10]	2005
Foil exd.2	16,4%	-	[10]	2005
Foil exd.3	16,4%	-	[10]	2005
EDRL	13,9%	0,4%	[35]	1998

Tabela 5.1 – Melhores resultados por algoritmo e por autor para o problema Australian Credit.

Algoritmos	MPPCE	DPPCE	Fonte	Ano Publicação
Depuration (3,2)	4,3%	4,8%	[38]	2004
RelabelOnly (3,2)	4,3%	4,8%	[38]	2004
RemoveOnly (3,2)	4,8%	5,1%	[38]	2004
NNEE (5,5)	4,5%	3,3%	[38]	2004
v-K-SVCR	1,3%	-	[39]	2006
FSSEM-TR-STD-1	2,7%	4,4%	[40]	2004
FSSEM-k-TR-STD-1	4,7%	5,2%	[40]	2004
FSSEM-ML-STD-1	7,3%	12,1%	[40]	2004
FSSEM-k-ML-STD-1	3,3%	4,5%	[40]	2004
EM-STD-1	3,3%	5,4%	[40]	2004
EM-k-STD-1	42,0%	14,3%	[40]	2004
FSS-Kmeans-TR-STD-2	2,7%	3,3%	[40]	2004
FSS-Kmeans-k-TR-STD-2	13,3%	9,4%	[40]	2004
FSS-Kmeans-ML-STD-2	2,0%	3,1%	[40]	2004
FSS-Kmeans-k-ML-STD-2	4,7%	4,3%	[40]	2004
Kmeans-STD-2	17,3%	10,8%	[40]	2004
Kmeans-k-STD-2	44,0%	11,2%	[40]	2004
K-means	27,8%	22,2%	[45]	2005
Girolami	10,3%	2,2%	[45]	2005
K-lines (s)	12,3%	5,3%	[45]	2005
LDC	1,7%	2,4%	[41]	2003
LDC-PCA	4,0%	3,1%	[41]	2003
LDC-Fisher	1,7%	2,4%	[41]	2003
LDC-MDS	4,7%	3,6%	[41]	2003
LDC-LLE	1,0%	1,6%	[41]	2003
LDC-1SLLE	12,0%	6,1%	[41]	2003
LDC-alfa-SLLE	1,0%	1,6%	[41]	2003
Clustering GP (k=2)	21,1%	0,3%	[37]	2004
Clustering GP (k=3)	2,1%	0,2%	[37]	2004
Clustering GP (k=4)	5,2%	0,7%	[37]	2004
Clustering GP (k=5)	6,0%	0,8%	[37]	2004
Refined GP Gain (k=2)	29,6%	0,3%	[37]	2004
Refined GP Gain (k=3)	6,3%	0,3%	[37]	2004
Refined GP Gain (k=4)	5,1%	0,7%	[37]	2004
Refined GP Gain (k=5)	6,5%	1,0%	[37]	2004
Refined GP Gain Ratio (k=2)	31,7%	0,9%	[37]	2004
Refined GP Gain Ratio (k=3)	31,7%	0,9%	[37]	2004
Refined GP Gain Ratio (k=4)	31,7%	0,9%	[37]	2004
Refined GP Gain Ratio (k=5)	31,7%	0,9%	[37]	2004
Simple GP	5,6%	1,1%	[37]	2004
C4.5	5,9%	-	[37]	2004
Bagged C4.5	5,0%	-	[37]	2004
Boosted C4.5	5,0%	-	[37]	2004
CEFR-Miner	4,7%	7,1%	[37]	2004
ESIA	4,7%	0,0%	[37]	2004
EDRL	4,0%	0,0%	[35]	1998

Tabela 5.2 – Melhores resultados por algoritmo e por autor para o problema Iris Data.

Algoritmos	MPPCE	DPPCE	Fonte	Ano Publicação
Selective Bayesian Classifier	23,8%	-	[36]	2002
Naive Bayesian Classifier	24,7%	-	[36]	2002
C4.5	26,0%	-	[36]	2002
Augmented Bayesian Classifier	23,9%	-	[36]	2002
Clustering GP (k=2)	27,8%	0,7%	[37]	2004
Clustering GP (k=3)	28,0%	0,8%	[37]	2004
Clustering GP (k=4)	27,9%	0,9%	[37]	2004
Clustering GP (k=5)	28,4%	0,8%	[37]	2004
Refined GP Gain (k=2)	28,1%	0,8%	[37]	2004
Refined GP Gain (k=3)	27,1%	0,8%	[37]	2004
Refined GP Gain (k=4)	28,3%	0,7%	[37]	2004
Refined GP Gain (k=5)	28,2%	0,6%	[37]	2004
Refined GP Gain Ratio (k=2)	28,3%	0,5%	[37]	2004
Refined GP Gain Ratio (k=3)	28,5%	0,6%	[37]	2004
Refined GP Gain Ratio (k=4)	28,6%	0,5%	[37]	2004
Refined GP Gain Ratio (k=5)	28,5%	0,5%	[37]	2004
ESIA	29,5%	0,2%	[37]	2004
EDRL	29,9%	0,8%	[35]	1998

Tabela 5.3 – Melhores resultados por algoritmo e por autor para o problema German Credit.

Algoritmos	MPPCE	DPPCE	Fonte	Ano Publicação
SMO	2,1%	-	[42]	1997
Simple Logistic	3,3%	-	[42]	1997
LMT	2,8%	-	[42]	1997
IBk	3,9%	-	[42]	1997
IB1	3,9%	-	[42]	1997
Logistic	3,0%	-	[42]	1997
MultClassClassifier	3,0%	-	[42]	1997
ThresholdSelector	2,8%	-	[42]	1997
Bagging	10,4%	-	[42]	1997
BayesNet	10,7%	-	[42]	1997
MultlayerPerceptron	2,8%	-	[42]	1997
MSM-T	3,0%	-	[43]	1994

Tabela 5.4 – Melhores resultados por algoritmo e por autor para o problema Diagnostic Breast Cancer.

Algoritmos	MPPCE	DPPCE	Fonte	Ano Publicação
ClassificationViaRegression	20,2%	-	[42]	1997
Logistic	20,2%	-	[42]	1997
MultiClassClassifier	20,2%	-	[42]	1997
LogitBoost	20,7%	-	[42]	1997
SimpleLogistic	21,7%	-	[42]	1997
LWL	22,7%	-	[42]	1997
RBF Network	23,7%	-	[42]	1997
AdaBoostM1	23,7%	-	[42]	1997
SimpleCart	23,7%	-	[42]	1997
AttributeSelectedClassifier	23,7%	-	[42]	1997
NaiveBayes	22,2%	-	[42]	1997
NaiveBayesUpdateable	22,2%	-	[42]	1997

Tabela 5.5 – Melhores resultados por algoritmo e por autor para o problema Prognostic Breast Cancer.

Algoritmos	MPPCE	DPPCE	Fonte	Ano Publicação
Depuration (3,2)	5,1%	4,3%	[38]	2004
RelabelOnly (3,2)	5,1%	4,3%	[38]	2004
RemoveOnly (3,2)	5,1%	2,9%	[38]	2004
NNEE (5,5)	5,1%	2,9%	[38]	2004
v-K-SVCR	3,3%	-	[39]	2006
FSSEM-TR-STD-1	44,0%	8,1%	[40]	2004
FSSEM-k-TR-STD-1	12,4%	13,0%	[40]	2004
FSSEM-ML-STD-1	30,6%	21,8%	[40]	2004
FSSEM-k-ML-STD-1	23,6%	14,4%	[40]	2004
EM-STD-1	10,0%	17,3%	[40]	2004
EM-k-STD-1	37,1%	12,6%	[40]	2004
FSS-Kmeans-TR-STD-2	37,3%	14,0%	[40]	2004
FSS-Kmeans-k-TR-STD-2	28,1%	9,6%	[40]	2004
FSS-Kmeans-ML-STD-2	16,1%	9,9%	[40]	2004
FSS-Kmeans-k-ML-STD-2	18,5%	7,2%	[40]	2004
Kmeans-STD-2	0,0%	0,0%	[40]	2004
Kmeans-k-STD-2	33,4%	21,3%	[40]	2004
RBF with Partial Supervision	18,0%	-	[44]	2005
K-means	8,7%	10,5%	[45]	2005
Girolami	3,9%	0,9%	[45]	2005
K-lines (s)	18,9%	6,6%	[45]	2005

Tabela 5.6 – Melhores resultados por algoritmo e por autor para o problema Wine Data.

Apêndices

Resultados para os testes estatísticos de normalidade, variância e media, por variação de parâmetros nas configurações

Variação	Kolmogorov-Smirnov Z	Resultado
Estratégia=1	0,780	Distribuição é Normal
Estratégia=2	0,884	Distribuição é Normal
Estratégia=3	0,726	Distribuição é Normal
Estratégia=4	0,815	Distribuição é Normal
Estratégia=5	0,791	Distribuição é Normal
Estratégia=6	0,741	Distribuição é Normal
Estratégia=7	0,637	Distribuição é Normal
Estratégia=8	0,534	Distribuição é Normal
Estratégia=9	0,577	Distribuição é Normal
Estratégia=10	0,600	Distribuição é Normal
Estratégia=11	0,834	Distribuição é Normal
Estratégia=12	0,873	Distribuição é Normal
TI=20	1,480	Distribuição é Normal
TI=30	1,446	Distribuição é Normal
TI=40	1,396	Distribuição é Normal
N _Q =5	1,036	Distribuição é Normal
N _Q =10	0,915	Distribuição é Normal
N _Q =15	1,480	Distribuição é Normal
N _Q =30	1,446	Distribuição é Normal
N _C =15	1,213	Distribuição é Normal
N _C =30	1,446	Distribuição é Normal
N _C =60	1,024	Distribuição é Normal
N _C =100	0,915	Distribuição é Normal
N _C =200	1,036	Distribuição é Normal
C _{Cb} =0.92	1,015	Distribuição é Normal
C _{Cb} =0.95	1,480	Distribuição é Normal
C _{Cb} =0.98	1,396	Distribuição é Normal
C _{Cb} =0.99	1,006	Distribuição é Normal
C _{Cr} =0.08	1,015	Distribuição é Normal
C _{Cr} =0.05	1,480	Distribuição é Normal
C _{Cr} =0.02	1,396	Distribuição é Normal
C _{Cr} =0.01	1,006	Distribuição é Normal
C _Q =0.10	1,480	Distribuição é Normal
C _Q =0.20	1,446	Distribuição é Normal
C _Q =0.30	1,396	Distribuição é Normal
$\theta=0.020*\pi$	1,396	Distribuição é Normal
$\theta=0.050*\pi$	1,446	Distribuição é Normal
$\theta=0.080*\pi$	1,480	Distribuição é Normal
Função Avaliação=(1)	1,851	Distribuição é Normal
Função Avaliação=(1)/(2)	1,583	Distribuição é Normal

Tabela 5.7 – Teste Kolmogorov-Smirnov para distribuição de MPPCE por variação de parâmetros nas estratégias do NEIQ-BR.

Estratégias	G.L.	Média	Desvio Padrão
1	8	1,875	2,475
2	8	1,375	2,387
3	8	2,000	2,976
4	8	1,750	2,188
5	8	1,500	2,070
6	8	1,250	1,753
7	8	2,500	2,507
8	8	2,250	2,550
9	8	2,500	3,024
10	8	3,125	3,182
11	8	2,375	3,335
12	8	2,375	2,875

Tabela 5.8 – Estatísticas descritivas por variação de estratégias.

Estratégias	1	2	3	4	5	6	7	8	9	10	11
1	-	-	-	-	-	-	-	-	-	-	-
2	0,699	-	-	-	-	-	-	-	-	-	-
3	0,648	0,44	-	-	-	-	-	-	-	-	-
4	0,851	0,799	0,509	-	-	-	-	-	-	-	-
5	0,596	0,936	0,349	0,689	-	-	-	-	-	-	-
6	0,39	0,729	0,215	0,437	0,757	-	-	-	-	-	-
7	0,522	0,31	1	0,308	0,176	0,055	-	-	-	-	-
8	0,788	0,518	1	0,613	0,4	0,221	0,722	-	-	-	-
9	0,529	0,348	0,885	0,391	0,258	0,145	0,846	0,678	-	-	-
10	0,297	0,187	0,62	0,183	0,115	0,051	0,485	0,397	0,721	-	-
11	0,43	0,287	0,738	0,317	0,214	0,126	0,67	0,547	0,836	0,913	-
12	0,378	0,232	0,772	0,227	0,137	0,053	0,652	0,514	0,896	0,777	0,907

Tabela 5.9 – P-valor do teste F por variação de estratégias.

Estratégias	1	2	3	4	5	6	7	8	9	10	11
1	-	-	-	-	-	-	-	-	-	-	-
2	0,687	-	-	-	-	-	-	-	-	-	-
3	0,929	0,650	-	-	-	-	-	-	-	-	-
4	0,916	0,748	0,851	-	-	-	-	-	-	-	-
5	0,747	0,912	0,702	0,818	-	-	-	-	-	-	-
6	0,569	0,907	0,549	0,622	0,798	-	-	-	-	-	-
7	0,624	0,374	0,722	0,534	0,399	0,267	-	-	-	-	-
8	0,770	0,490	0,859	0,680	0,529	0,376	0,846	-	-	-	-
9	0,658	0,423	0,744	0,579	0,453	0,329	1,000	0,861	-	-	-
10	0,395	0,234	0,477	0,331	0,246	0,166	0,669	0,554	0,693	-	-
11	0,739	0,502	0,816	0,664	0,539	0,413	0,934	0,934	0,939	0,652	-
12	0,715	0,462	0,801	0,632	0,496	0,361	0,927	0,928	0,934	0,629	1,000

Tabela 5.10 – P-valor do teste t por variação de estratégias.

TI	G.L.	Média	Desvio Padrão
20	32	1,875	2,537
30	32	2,313	2,546
40	32	2,031	2,621

Tabela 5.11 – Estatísticas descritivas por variação de neurônios na camada escondida.

TI	Teste F			Teste T		
	20	30	40	20	30	40
20	-	-	-	-	-	-
30	0,460	-	-	0,494	-	-
40	0,624	0,827	-	0,809	0,665	-

Tabela 5.12 – P-valor do teste de variância e média por neurônios na camada escondida.

N _Q	G.L.	Média	Desvio Padrão
5	16	1,813	2,373
10	16	2,250	2,910
15	32	1,875	2,537
30	32	2,313	2,546

Tabela 5.13 – Estatísticas descritivas por indivíduos quânticos.

N _Q	Teste F				Teste T			
	5	10	15	30	5	10	15	30
5	-	-	-	-	-	-	-	-
10	0,396	-	-	-	0,645	-	-	-
15	0,961	0,392	-	-	0,935	0,648	-	-
30	0,459	0,706	0,460	-	0,515	0,939	0,494	-

Tabela 5.14 – P-valor do teste de variância e média por indivíduos quânticos.

C _Q	G.L.	Média	Desvio Padrão
0.10	32	1,875	2,537
0.20	32	2,313	2,546
0.30	32	2,031	2,621

Tabela 5.15 – Estatísticas descritivas por taxa de cruzamento quântico.

C _Q	Teste F			Teste T		
	0.10	0.20	0.30	0.10	0.20	0.30
0.10	-	-	-	-	-	-
0.20	0,460	-	-	0,494	-	-
0.30	0,624	0,827	-	0,809	0,665	-

Tabela 5.16 – P-valor do teste de variância e média por taxa de cruzamento quântico.

N _c	G.L.	Média	Desvio Padrão
15	16	1,938	2,720
30	32	2,313	2,546
60	16	1,813	2,428
100	16	2,250	2,910
200	16	1,813	2,373

Tabela 5.17 – Estatísticas descritivas por indivíduos clássicos.

N _c	Teste F					Teste T				
	15	30	60	100	200	15	30	60	100	200
15	-	-	-	-	-	-	-	-	-	-
30	0,576	-	-	-	-	0,640	-	-	-	-
60	0,947	0,471	-	-	-	0,892	0,518	-	-	-
100	0,505	0,706	0,409	-	-	0,756	0,939	0,648	-	-
200	0,946	0,459	1,000	0,396	-	0,891	0,515	1,000	0,645	-

Tabela 5.18 – P-valor do teste de variância e média por indivíduos clássicos.

C _{Cr}	G.L.	Média	Desvio Padrão
0.08	16	2,188	2,428
0.05	32	1,875	2,537
0.02	32	2,031	2,621
0.01	16	2,438	2,732

Tabela 5.19 – Estatísticas descritivas por taxa de cruzamento clássico real.

C _{Cr}	Teste F				Teste T			
	0.08	0.05	0.02	0.01	0.08	0.05	0.02	0.01
0.08	-	-	-	-	-	-	-	-
0.05	0,707	-	-	-	0,685	-	-	-
0.02	0,960	0,624	-	-	0,843	0,809	-	-
0.01	0,635	0,423	0,674	-	0,786	0,484	0,620	-

Tabela 5.20 – P-valor do teste de variância e média por taxa de cruzamento clássico real.

C _{cb}	G.L.	Média	Desvio Padrão
0.92	16	2,188	2,428
0.95	32	1,875	2,537
0.98	32	2,031	2,621
0.99	16	2,438	2,732

Tabela 5.21 – Estatísticas descritivas por taxa de cruzamento clássico binária.

C_{Cb}	Teste F				Teste T			
	0.08	0.05	0.02	0.01	0.08	0.05	0.02	0.01
0.92	-	-	-	-	-	-	-	-
0.95	0,707	-	-	-	0,685	-	-	-
0.98	0,960	0,624	-	-	0,843	0,809	-	-
0.99	0,635	0,423	0,674	-	0,786	0,484	0,620	-

Tabela 5.22 – P-valor do teste de variância e média por taxa de cruzamento clássico binária.

θ	G.L.	Média	Desvio Padrão
0.020*pi	32	2,031	2,621
0.050*pi	32	2,313	2,546
0.080*pi	32	1,875	2,537

Tabela 5.23 – Estatísticas descritivas por velocidade de atualização θ .

θ	Teste F			Teste T		
	0.020*pi	0.050*pi	0.080*pi	0.020*pi	0.050*pi	0.080*pi
0.020*pi	-	-	-	-	-	-
0.050*pi	0,827	-	-	0,665	-	-
0.080*pi	0,624	0,460	-	0,809	0,494	-

Tabela 5.24 – P-valor do teste de variância e média por velocidade de atualização θ .

Resultados para modelagem manual dos problemas da cooperativa de crédito por redes neurais e algoritmo de retropropagação

Neurônios Camada Escondida	SSE		MPPCE		
	Treino	Teste	Normal	Excedeu	Total
$(n^{\circ} \text{ atributos} + n^{\circ} \text{ classes}) / 2 = 16$	2,896	0,867	64,0%	73,4%	69,4%
$n^{\circ} \text{ atributos} = 29$	2,819	0,837	64,8%	74,1%	70,1%
$n^{\circ} \text{ classes} = 2$	2,972	0,843	61,0%	75,6%	69,5%
$n^{\circ} \text{ atributos} + n^{\circ} \text{ classes} = 31$	2,863	0,856	68,4%	70,4%	69,6%
4 neurônios	2,921	0,849	69,3%	69,6%	69,5%
6 neurônios	2,874	0,838	68,3%	71,7%	70,3%
8 neurônios	2,876	0,853	67,2%	71,2%	69,5%

Tabela 5.25 – MPPCE por variação de neurônios na camada escondida, problema crédito de limite especial.

Neurônios Camada Escondida	SSE		DPPCE		
	Treino	Teste	Normal	Excedeu	Total
$(n^{\circ} \text{ atributos} + n^{\circ} \text{ classes}) / 2 = 16$	0,126	0,070	8,7%	7,3%	0,6%
$n^{\circ} \text{ atributos} = 29$	0,077	0,083	4,4%	2,1%	2,0%
$n^{\circ} \text{ classes} = 2$	0,106	0,067	2,3%	3,6%	2,0%
$n^{\circ} \text{ atributos} + n^{\circ} \text{ classes} = 31$	0,075	0,047	0,7%	0,8%	0,2%
4 neurônios	0,066	0,059	1,2%	0,8%	0,1%
6 neurônios	0,096	0,080	1,3%	2,1%	1,8%
8 neurônios	0,100	0,067	2,3%	1,4%	0,3%

Tabela 5.26 – DPPCE por variação de neurônios na camada escondida, problema crédito de limite especial.

Duração da Fase de Treinamento	SSE		MPPCE		
	Treino	Teste	Normal	Excedeu	Total
25	2,865	0,842	65,4%	73,8%	70,2%
50	2,821	0,841	65,8%	72,9%	69,9%
100	2,898	0,857	65,1%	73,9%	70,2%
200	2,875	0,842	68,2%	71,1%	69,9%
400	2,854	0,835	67,0%	72,6%	70,2%
800	2,918	0,853	66,7%	71,8%	69,6%

Tabela 5.27 – MPPCE por variação de fase de treinamento, problema crédito de limite especial.

Duração da Fase de Treinamento	SSE		DPPCE		
	Treino	Teste	Normal	Excedeu	Total
25	0,064	0,066	4,3%	6,3%	1,9%
50	0,081	0,081	3,1%	4,4%	1,3%
100	0,088	0,068	2,4%	0,5%	1,1%
200	0,101	0,051	0,5%	0,2%	0,2%
400	0,095	0,064	1,0%	2,7%	1,1%
800	0,030	0,063	3,4%	1,4%	0,8%

Tabela 5.28 – DPPCE por variação de fase de treinamento, problema crédito de limite especial.

Neurônios Camada Escondida	SSE		MPPCE		
	Treino	Teste	Adimplente	Inadimplente	Total
$(n^{\circ} \text{ atributos} + n^{\circ} \text{ classes}) / 2 = 17$	0,090	1,283	93,2%	82,1%	93,2%
$n^{\circ} \text{ atributos} = 32$	0,096	1,076	94,7%	72,9%	94,5%
$n^{\circ} \text{ classes} = 2$	0,111	1,328	94,3%	72,1%	94,2%
$n^{\circ} \text{ atributos} + n^{\circ} \text{ classes} = 34$	0,084	1,379	93,2%	78,4%	93,1%
4 neurônios	0,119	1,219	94,0%	81,6%	93,9%
6 neurônios	0,078	1,427	92,1%	87,9%	92,1%
8 neurônios	0,063	1,523	91,7%	87,1%	91,7%

Tabela 5.29 – MPPCE por variação de neurônios na camada escondida, problema empréstimos financeiros.

Neurônios Camada Escondida	SSE		DPPCE		
	Treino	Teste	Adimplente	Inadimplente	Total
$(n^{\circ} \text{ atributos} + n^{\circ} \text{ classes}) / 2 = 17$	0,026	0,363	1,6%	6,2%	1,5%
$n^{\circ} \text{ atributos} = 32$	0,053	0,272	1,9%	16,5%	1,8%
$n^{\circ} \text{ classes} = 2$	0,070	0,450	2,7%	20,3%	2,6%
$n^{\circ} \text{ atributos} + n^{\circ} \text{ classes} = 34$	0,050	0,195	1,5%	13,0%	1,5%
4 neurônios	0,124	0,550	3,2%	7,4%	3,1%
6 neurônios	0,049	0,369	3,1%	6,2%	3,0%
8 neurônios	0,046	0,366	1,3%	2,5%	1,3%

Tabela 5.30 – DPPCE por variação de neurônios na camada escondida, problema empréstimos financeiros.

Duração da Fase de Treinamento	SSE		MPPCE		
	Treino	Teste	Adimplente	Inadimplente	Total
25	0,097	1,422	93,5%	76,8%	93,4%
50	0,074	1,436	92,8%	82,3%	92,8%
100	0,100	1,266	94,3%	82,4%	94,2%
200	0,121	1,058	95,2%	76,8%	95,1%
400	0,076	1,413	92,4%	80,0%	92,3%
800	0,103	1,186	94,9%	74,4%	94,7%

Tabela 5.31 – MPPCE por variação de fase de treinamento, problema empréstimos financeiros.

Duração da Fase de Treinamento	SSE		DPPCE		
	Treino	Teste	Adimplente	Inadimplente	Total
25	0,056	0,254	1,5%	12,9%	1,4%
50	0,045	0,418	2,6%	5,3%	2,6%
100	0,055	0,176	2,0%	9,7%	1,9%
200	0,066	0,145	2,1%	12,9%	2,0%
400	0,030	0,406	2,4%	9,4%	2,3%
800	0,042	0,223	1,6%	16,5%	1,5%

Tabela 5.32 – DPPCE por variação de fase de treinamento, problema empréstimos financeiros.