

SINTONIA DE PARÂMETROS DE ALGORITMOS GENÉTICOS MULTIOBJETIVOS PARA SOLUÇÃO DO TREINAMENTO DE MÁQUINA DE VETOR SUPORTE TRANSDUTIVA

JÉSUS J. S. SANTOS*, CIDINEY J. SILVA†, ELIZABETH F. WANNER‡

**Departamento de Engenharia Elétrica, Universidade Federal de Minas Gerais*

†*Departamento de Engenharia Elétrica, Universidade Federal de Minas Gerais*

‡*Departamento de Matemática, Universidade Federal de Ouro Preto*

Emails: souzasantos@gmail.com, cidiney@gmail.com, efwanner@iceb.ufop.com.br

Resumo— Existe disponível na literatura uma grande variedade de Algoritmos Genéticos (AGs) para otimização multiobjetivo. Os AGs multiobjetivos se propõem a determinar um conjunto de soluções não-dominadas, denominado conjunto Pareto-ótimo. Os AGs necessitam de alguns parâmetros externos que são, a princípio, definidos pelo usuário: e.g., taxas de cruzamento e mutação, tamanho da população. Tais parâmetros podem influenciar na velocidade de convergência e na qualidade dos resultados obtidos. Essa influência pode variar de acordo com o problema, o que leva a se procurar um melhor ajuste de parâmetros para cada problema a ser resolvido pelos AGs. Nesse artigo será estudado o impacto da variação de parâmetros em Algoritmos Genéticos multiobjetivos na qualidade da estimativa do conjunto Pareto-ótimo e o esforço computacional necessário em cada cenário de parâmetros. A qualidade das soluções retornadas pelo algoritmo será verificada através do compromisso entre distância do ponto escolhido pelo decisor e o número de avaliações da função objetivo correspondente. O problema de otimização utilizado como exemplo envolve o treinamento transdutivo de uma rede do tipo SVM.

Palavras-chave— Algoritmos Evolucionários, Algoritmos Genéticos Multiobjetivos, Medida de Desempenho, Integrate Sphere Counting, Sintonia de Parâmetros

Abstract— There is available in the literature a variety of Genetic Algorithms (AG) for multiobjective optimization. The AG multiobjective aim to determine a set of non-dominated solutions called Pareto-optimal set. These algorithms need some external parameters those are, in principle, defined by the user. These parameters can influence the speed of convergence and the quality of the results. This influence may vary with the kind of problem, what lead to a needing of a set of parameters for each problem to be solved by the algorithm. In this paper we will study the impact of changes in parameters of Genetic Algorithms in the quality of estimation of all Pareto-optimal and the computational effort required in each setting of parameters. The quality of solutions returned by the algorithm is verified by the distance of the point chosen by the decisor and the amount of evaluations of objective functions. The optimization problem used as example involves the transductive training of a SVM network.

Keywords— Evolutionary Algorithms, Multiobjective Genetic Algorithms, Performance Measure, Integrate Sphere Counting, Tuning of parameters

1 Introdução

Algoritmos evolucionários (AEs) têm se tornado uma importante ferramenta para resolver problemas de otimização multiobjetivo, devido a sua capacidade de lidar com funções genéricas avaliando, a cada execução, um conjunto de estimativas de soluções para o problema em questão (Coello, 1999; Fonseca and Fleming, 1995). Um importante representante da classe dos algoritmos evolucionários é o Algoritmo Genético (AG) (Back, 1996). Os AGs são caracterizados pela existência de pelo menos três operadores genéticos: um operador de cruzamento que combina a informação contida em dois ou mais indivíduos para gerar outros indivíduos; um operador de mutação que utiliza a informação contida em um indivíduo para, estocasticamente, gerar outro indivíduo; e um operador de seleção que é utilizado para gerar a nova população através de réplicas de alguns indivíduos e eliminação de outros. Um AG pode ser construído a partir desses três operadores ou pode conter ope-

radores adicionais tais como elitismo, nicho, busca local, etc. A escolha dos tipos de operadores que serão utilizados para compor um AG, bem como o ajuste dos parâmetros associados a eles, deve ser feita levando-se em conta a classe de problemas que se pretende resolver. Portanto, o desempenho de um AG é bastante influenciado pelos operadores que o compõem e pelos valores dos parâmetros a eles associados.

Neste trabalho será estudado de forma preliminar uma metodologia para sintonia baseada no desempenho de algoritmos genéticos multiobjetivos (Santos et al., 2008), caracterizados pela presença dos mesmos operadores de mutação, cruzamento e seleção, porém com valores diferentes dos parâmetros associados a eles. O trabalho aqui apresentado trata-se de uma extensão, para o caso multiobjetivo, da metodologia proposta em (Takahashi et al., 2003). Como problema exemplo para aplicação, será utilizado o treinamento multiobjetivo (Silva et al., 2008), (Silva et al., 2009) de uma Máquina de Vetor Suporte com o SPEA II como

objeto de sintonia (no caso, os parâmetros do SPEA). Os parâmetros que serão variados serão: tamanho da população, probabilidade de cruzamento, probabilidade de mutação e raio de mutação do operador mutação gaussiana.

Entende-se aqui como um “algoritmo” cada AG multiobjetivo com um determinado conjunto de parâmetros. O estudo aqui apresentado, seguindo a formulação apresentada em (Takahashi et al., 2003), faz a comparação entre algoritmos utilizando uma análise de dominância que considera os fatores de mérito: (i) um índice de desempenho relacionado com a qualidade da solução encontrada; e (ii) um índice de desempenho relacionado com o esforço computacional requerido para determinação da solução.

A medida de desempenho, chamada *Integrated Sphere Counting* (ISC), proposta em (Silva et al., 2007), será utilizada na comparação entre os diversos algoritmos obtidos. A ISC é uma medida de desempenho simples cujo custo computacional não é significativamente afetado nem pelo número de soluções no conjunto não-dominado e nem pelo número de funções-objetivo do problema, e fornece uma medida de quão bem amostrado se encontra o conjunto Pareto-ótimo, através das soluções obtidas. Essa medida de desempenho será aqui utilizada com dois propósitos diferentes: (i) avaliar a qualidade da estimativa do Pareto-ótimo a cada geração do AG e (ii) permitir a definição de um critério de parada razoável do AG multiobjetivo, a partir da estabilização dos valores da medida ISC. É importante mencionar que, dentre as demais figuras de mérito disponíveis na literatura para medir a qualidade da solução obtida para problemas do tipo multiobjetivo (Coello et al., 2001; Knowles and Corne, 2002; Zitzler et al., 2003), algumas são demasiado simples, não conduzindo a medidas razoáveis da qualidade do conjunto Pareto-ótimo, enquanto outras são demasiado complexas, envolvendo um esforço computacional que não seria adequado para ser despendido a cada iteração de um AG. Dessa forma, o critério ISC torna-se fundamental para permitir o desenvolvimento da metodologia aqui proposta.

Este trabalho está organizado da seguinte forma: a seção 2 descreve, em linha gerais, os algoritmos genéticos multiobjetivos escolhidos para os testes; na seção 3 é apresentado o problema de treinamento de uma SVM, que será o problema de otimização multiobjetivo tratado; as medidas de desempenho, em particular a *Integrated Sphere Counting*, são abordadas na seção 4; a metodologia de avaliação dos algoritmos é apresentada na seção 5; a seção 6 mostra os resultados obtidos; e finalmente, são apresentadas as conclusões.

2 Algoritmos Genéticos Multiobjetivos

Os algoritmos genéticos são caracterizados por operadores de cruzamento e mutação dos indivíduos da população, e um mecanismo probabilístico de seleção que favorece as melhores soluções em uma dada iteração do algoritmo. No contexto da otimização multiobjetivo, a diferença básica entre um algoritmo genético multiobjetivo e sua versão para otimização escalar reside na forma de atribuir a aptidão dos indivíduos.

Descreveremos, brevemente, o algoritmo genético multiobjetivo que será utilizado nesse trabalho.

2.1 *Strength Pareto Evolutionary Algorithm 2*

O SPEA 2 (Zitzler et al., 2002) utiliza um arquivo contendo soluções não-dominadas previamente encontradas. A cada geração, soluções não-dominadas são armazenadas nesse arquivo, substituindo as antigas. Para cada indivíduo nesse arquivo, um valor de *força* (strength) é calculado. Esse valor de *força* é similar à classificação dos indivíduos adotada pelo MOGA (Fonseca and Fleming, 1998), uma vez que ele é proporcional ao número de soluções que um determinado indivíduo domina. A função de aptidão de cada indivíduo é calculada de acordo com as *forças* de todas as soluções não-dominadas do arquivo que domina esse determinado indivíduo e por todas as soluções que o indivíduo domina. O processo do cálculo da aptidão do SPEA 2 considera ao mesmo tempo proximidade do conjunto Pareto real e distribuição das soluções. Desta forma, no lugar de técnicas de nicho baseadas em distância, o critério de dominância é usado para garantir que as soluções estejam distribuídas ao longo do conjunto de Pareto real.

3 Problema Abordado: Aprendizado de Máquina de Vetor Suporte Transdutivo

Geralmente podemos obter classificadores perfazendo uma superfície de tomada de decisão que separa os pontos de distintas classes. Esta separação pode ser realizada por algumas máquinas de aprendizado, como as *Multi-Layer Perceptrons* (MLPs), as Funções de Base Radial (*Radial Basis Functions* - RBFs) e as Máquinas de Vetor Suporte (*Support Vector Machines* - SVMs). Cada uma dessas máquinas de aprendizado tem sua própria maneira de obter a superfície de separação. Geralmente, elas tomam dois ou três tipos de dados para se treinarem: o **conjunto de treinamento** (*training set*), que é o conjunto principal de dados composto por pontos pré-classificadas; o **conjunto de validação** (*validation set*), que é um conjunto

usado para validar a adequação de um classificador através de dados anteriormente não vistos; e o conjunto de trabalho (*working set*), que é composta por pontos sem classificação.

Máquinas de Vetor Suporte se propõem a efetuar uma separação linear (ver figura 1) entre pontos de classes distintas.




Figure 1: Um Hiperplano de Separação

Mas os problemas são caracterizadas por pontos não podem ser separados por um hiperplano devido a não-linearidades, dados ruidosos ou outras características intrínsecas do problema considerado. Portanto, o conceito de **funções de kernel** é aplicável aqui. Os pontos são transformados para um outro espaço de maior dimensão (denominado espaço de característica), de forma que os pontos transformados podem ser separados por um hiperplano nesse espaço.

Usualmente, os algoritmos de treinamento utilizam pontos previamente classificados. Mas existe um outro tipo de algoritmo de treinamento que considera pontos não classificados ou dados desbalanceados, os **algoritmos transdutivos**.

Existem vários tipos de SVMs, de acordo com o modo como os seus algoritmos as treinam. Neste trabalho, iremos treinar uma Máquina de Vetor Suporte Transdutiva (*Transductive Least Squares Support Vector Machine* (Silva et al., 2008)). Este SVM tentar encontrar a melhor superfície de separação que, ao mesmo tempo, separa os pontos do **conjunto de treinamento** e encontra uma boa inferência sobre a classificação dos pontos do **conjunto de trabalho**.

3.1 Problema de Otimização Associado

O problema de otimização associado ao treinamento da TLSSVM consiste em determinar um conjunto de soluções Pareto-ótimas que minimize (f_1, f_2) , onde f_1 é o erro do conjunto de treinamento e f_2 é a norma dos pesos. Cada ponto da solução Pareto-ótima fornece um vetor de parâmetros que será um classificador diferente, sendo as-

sim para construir o classificador é necessário escolher um ponto no Pareto. Para isso é implementado um decisor que seleciona o ponto que possui a menor distância a origem do espaço.

4 Medida de Desempenho para Algoritmos Multiobjetivos

A proliferação de algoritmos evolucionários multiobjetivos levanta a questão da importância das medidas de comparações entre eles. Na ausência de um critério de comparação bem estabelecido, não é possível dizer que um conjunto de estimativas Pareto-ótimas provenientes de um determinado algoritmo seja melhor que algum outro conjunto de estimativas provenientes de outro algoritmo.

Usualmente, a qualidade do conjunto Pareto-ótimo pode ser medida através de três aspectos:

- o número de soluções Pareto-ótimas no conjunto de estimativas;
- a proximidade das soluções obtidas em relação ao verdadeiro conjunto de Pareto;
- a distribuição e o espalhamento das soluções.

Esses três aspectos não podem ser adequadamente medidos usando-se uma única medida de desempenho: várias medidas de desempenho têm sido propostas com o objetivo de se avaliar o desempenho de diferentes tipos de algoritmos multiobjetivos. Algumas dessas medidas necessitam do conhecimento do verdadeiro conjunto de Pareto; outras fornecem uma medida absoluta que sintetiza a qualidade do conjunto de soluções não-dominadas sem a necessidade de um conjunto de referência; outras medidas podem ainda comparar dois ou mais conjuntos de soluções não-dominadas. Uma revisão detalhada das medidas de desempenho pode ser encontrada em (Coello et al., 2001; Knowles and Corne, 2002; Zitzler et al., 2003).

Neste trabalho, usaremos a medida de desempenho chamada *Integrate Sphere Counting* (ISC) (Silva et al., 2007). A ISC é uma medida de desempenho que associa a cada conjunto de aproximação um número que reflete um determinado aspecto qualitativo. Quanto maior o valor dado pela ISC, melhor a distribuição do conjunto de Pareto.

4.1 Critério de Parada Baseado na Qualidade do Pareto

Neste trabalho, é utilizado como critério de parada do AG a estabilização do valor obtido pela métrica

Table 1: Parâmetros utilizados

Parâmetro	Valor
N_{pop}	20, 40 e 80 indivíduos
p_c	0.4, 0.8
p_m	0.1, 0.2 e 0.3

ISC, em um intervalo de n gerações, calculada a cada geração do algoritmo. Desta forma permite-se que o algoritmo evolua as soluções do conjunto Pareto-ótimo enquanto a qualidade destas soluções, dada pela distribuição dos pontos da fronteira de Pareto, não estabilize, evitando a subestimação ou a superestimação do número de gerações necessárias para a obtenção do Pareto, reduzindo o custo computacional com interações desnecessárias. Considera-se estabilizado caso não ocorra uma variação do valor da ISC de 5% durante 10 gerações consecutivas.

5 Metodologia de Avaliação de Parâmetros

Dada uma classe específica de problemas e um conjunto de parâmetros para determinados operadores, neste caso o treinamento da TLSSVM, queremos determinar os melhores algoritmos com relação aos seguintes critérios:

- distância do ponto escolhido pelo decisor a origem, que caracteriza a qualidade da solução, e
- o número de avaliações das funções-objetivo gasto no processo, que caracteriza o esforço computacional associado aos algoritmos.

Utilizando os parâmetros escolhidos, tamanho da população (N_{pop}), probabilidade de cruzamento (p_c) e probabilidade de mutação (p_m), a tabela 1 mostra o conjunto de valores de cada parâmetro que será usado com os algoritmos multiobjetivos. Considerando esses valores, temos 18 conjuntos de parâmetros diferentes (ver Figura 2) e, que serão avaliadas 21 vezes cada, a fim de determinar as combinações de parâmetros que levam a melhores desempenhos.

6 Resultados

A figura 4 mostra a relação entre número de avaliações da função objetivo e a distância do ponto escolhido à origem para cada um dos 18 conjunto de parâmetros, sendo que o melhor conjunto de parâmetros é aquele que satisfaz simultaneamente a condição de menor distância (qualidade) e o

Conjunto de Parâmetros	Probabilidade de Cruzamento		População
	Probabilidade de Mutação	Probabilidade de Mutação	
1	0.4	0.1	20
2	0.8	0.1	20
3	0.4	0.2	20
4	0.8	0.2	20
5	0.4	0.3	20
6	0.8	0.3	20
7	0.4	0.1	40
8	0.8	0.1	40
9	0.4	0.2	40
10	0.8	0.2	40
11	0.4	0.3	40
12	0.8	0.3	40
13	0.4	0.1	80
14	0.8	0.1	80
15	0.4	0.2	80
16	0.8	0.2	80
17	0.4	0.3	80
18	0.8	0.3	80

Figure 2: Tabela de parâmetros que determinam os algoritmos

menor número de avaliações possível (custo computacional). Desta forma obtemos um classificador que proporciona uma boa qualidade da classificação com um desempenho computacional eficiente, um exemplo de classificação pode ser visto na figura 3.




Figure 3: Exemplo de Classificação obtida

Um Pareto médio das 21 execuções é apresentado na figura 4 onde os melhores parâmetros são mostrados na tabela 2.

7 Conclusões

Uma metodologia para sintonia de algoritmos genéticos multiobjetivos foi apresentada aqui, baseada na análise de dominância em relação aos critérios de custo computacional e qualidade da solução.

Table 2: Valores do melhor conjunto de parâmetros

Parâmetro	Valor
N_{pop}	20 indivíduos
p_c	0.8
p_m	0.2




Figure 4: Número de Avaliações da função Objetivo Vs. Distância do ponto escolhido à origem

Através dessa metodologia é possível verificar que o ajuste dos parâmetros em algoritmos genéticos multiobjetivos afeta o desempenho e o custo computacional dos mesmos. Além disso, para o problema de treinamento de SVM utilizado, espera-se que os algoritmos derivados do SPEA 2, ajustados com parâmetros corretos, seriam adequados para tratar problemas do tipo daquele que foi aqui estudado.

É importante salientar que sem a utilização do critério de parada baseado na estabilidade da qualidade (índice ISC) das soluções fornecidas pelos AGs, não seria possível avaliar a influência dos parâmetros da forma que foi proposta. Tal critério de parada tem grande potencial para ser utilizado como parte integrante de algoritmos evolutivos multiobjetivos.

Agradecimentos

O autor agradece o apoio das agências de fomento à pesquisa: FAPEMIG e CNPq.

References

Back, T. (1996). *Evolutionary Algorithms in Theory and Practice*, Oxford University Press.

Coello, C. A. C. (1999). A comprehensive survey of evolutionary-based multiobjective optimization techniques, *Knowledge and Information Systems* **1**(3): 269–308.

Coello, C. A. C., Veldhuizen, D. V. and Lamont, G. (2001). *Evolutionary Algorithms for Solving Multi-objective Problems*, Kluwer.

Fonseca, C. M. and Fleming, P. J. (1995). An overview of evolutionary algorithms in multiobjective optimization, *Evolutionary Computation* **7**(3): 205–230.

Fonseca, C. M. and Fleming, P. J. (1998). Multiobjective optimization and multiple constraint handling with evolutionary algorithms-part i: a unified formulation, *IEEE Trans. on System, Man and Cybernetics-Part A: Systems and Humans* **28**(1): 26–37.

Knowles, J. and Corne, D. (2002). On metrics for comparing nondominated sets, *Proceedings of the Conference on Evolutionary Computation*, IEEE, pp. 711–216.

Santos, J. J. S., Silva, C., Wanner, E. F., Neto, O. M. and Takahashi, R. H. C. (2008). Avaliação do impacto na variação de parâmetros em algoritmos genéticos multiobjetivo, *Anais do XVII Congresso Brasileiro de Automática*, Sociedade Brasileira de Automática, Juiz de Fora.

Silva, C., Santos, J. J. S. and Wanner, E. F. (2008). Proposal of a transductive least squares support vector machine, *Anais do XVII Congresso Brasileiro de Automática*, Sociedade Brasileira de Automática, Juiz de Fora.

Silva, C., Santos, J. J. S., Wanner, E. F., Carrano, E. G. and Takahashi, R. H. C. (2009). Semi-supervised training of least squares support vector machine using a multiobjective evolutionary algorithm, *Proceedings of IEEE Congress on Evolutionary Technology*, IEEE, Norway.

Silva, V. L. S., Wanner, E. F., Cerqueira, S. A. A. G. and Takahashi, R. H. C. (2007). A new performance metric for multiobjective optimization: The integrate sphere counting, *Proc. IEEE Congress on Evolutionary Computation*, Singapore.

Takahashi, R. H. C., Vasconcelos, J. A., Ramirez, J. A. and Krahenbuhl, L. (2003). A multiobjective methodology for evaluation genetic operators, *IEEE Trans. on Magnetics* **39**: 1321–1324.

Zitzler, E., Laumanns, M. and Thiele, L. (2002). SPEA 2: Improving the Strength Pareto Evolutionary Algorithms, *EUROGEN 2001. Evolutionary Methods for Design, Optimization and Control with Applications to Industrial Problems*, pp. 95–100.

Zitzler, E., Thiele, L., Laumanns, M., Fonseca, C. M. and da Fonseca, V. G. (2003). Performance assessment of multiobjective optimizers: An analysis and review, *IEEE Trans. on Evolutionary Computation* **7**(2): 117–132.