
Capítulo 1

Introdução Geral

1. Optimização multi-objectivo

O conceito de optimização está associado à determinação de uma ou mais soluções admissíveis, as quais correspondem aos valores extremos de um ou mais objectivos. Os métodos de optimização são de grande importância na resolução de problemas práticos, em particular no domínio da engenharia, das experiências científicas e da tomada de decisões em geral.

Quando um problema de optimização modela um sistema real envolvendo apenas uma função objectivo, a tarefa de determinar a solução óptima é denominada de *optimização mono-objectivo*. Desde a II Guerra Mundial, a maioria dos esforços feitos no campo da optimização foi para desenvolver e aplicar métodos de optimização mono-objectivo, utilizando, por exemplo, técnicas de pesquisa baseadas em gradientes ou em heurísticas. Além dos princípios de pesquisa determinística envolvida num algoritmo, também existem princípios de pesquisa estocástica usados em algoritmos de optimização para determinar, com mais segurança, soluções óptimas globais. Para estender a aplicação de um algoritmo de optimização a domínios de diferentes problemas, os princípios naturais e físicos são imitados para desenvolver algoritmos de optimização poderosos, como é o caso dos algoritmos evolucionários.

Os problemas complexos que surgiram no seio das sociedades modernas tecnologicamente desenvolvidas envolvem aspectos de avaliação múltiplos, conflituosos e incomensuráveis para determinar o mérito dos planos de acção alternativos. Assim, os

modelos matemáticos de apoio à decisão tornam-se mais representativos do contexto da decisão real, se esses aspectos de avaliação forem explicitamente tidos em conta, em vez de os agregar num único indicador de custo ou benefício.

Em modelos de programação multi-objectivo esses aspectos de avaliação são traduzidos pelas funções objectivo a otimizar, sujeitas a um conjunto de restrições. Os modelos multi-objectivo permitem compreender a natureza conflituosa dos objectivos e dos compromissos¹ a serem construídos para identificar as soluções satisfatórias, estabelecendo uma base para racionalizar a comparação entre as soluções não dominadas. Uma solução não dominada (eficiente, óptima de Pareto) é uma solução admissível para a qual não é possível melhorar simultaneamente todas as funções objectivo; isto é, a melhoria numa função objectivo apenas pode ser alcançada aceitando piorar, pelo menos, uma outra função objectivo.

Para além de contribuir para a construção de um modelo mais realista perante problemas reais, uma abordagem multi-objectivo possui ainda intrinsecamente um papel importante na modelação dos processos de decisão, suportando a reflexão e a criatividade dos Agentes de Decisão (AD) face a um extenso universo de potenciais soluções, tendo em mente a sua implementação prática, uma vez que não existe uma solução melhor do que todas as outras em todos os aspectos de avaliação.

O estudo de um problema de optimização multi-objectivo envolve geralmente a caracterização do conjunto de soluções não dominadas, através da realização de um cálculo exaustivo destas soluções ou então calculando uma amostra representativa daquele conjunto. Desta forma, em optimização multi-objectivo não se pretende determinar uma solução óptima (como em optimização mono-objectivo), mas sim determinar um conjunto de soluções não dominadas (frente não dominada, frente óptima de Pareto ou simplesmente frente de Pareto).

Os métodos para resolver problemas de optimização multi-objectivo devem obedecer ao seguinte princípio: determinar um conjunto de soluções de compromisso, de forma a caracterizar o mais extensamente possível as gamas de valores alcançáveis para cada função objectivo.

2. Optimização evolucionária multi-objectivo

A capacidade de trabalhar em cada geração com uma população de potenciais soluções faz com que as abordagens evolucionárias se ajustem bem aos problemas de optimização multi-objectivo, particularmente a problemas de natureza combinatória

¹ Tradução da palavra inglesa "tradeoffs".

complexos, nos quais deve ser identificado um conjunto de soluções não dominadas em vez de uma única solução óptima.

Dado que no contexto da optimização evolucionária, em particular, e das meta-heurísticas, em geral, normalmente apenas é possível determinar se uma solução é dominada após o cálculo de uma outra que a domina, as soluções não dominadas deveriam em rigor designar-se por soluções potencialmente não dominadas. No entanto, para simplificação da linguagem utilizar-se-à a designação de solução não dominada com este último sentido, quer corresponda ou não a uma solução realmente não dominada.

Os algoritmos evolucionários são uma classe das técnicas de optimização estocástica, que consistem em imitar alguns dos mecanismos da evolução natural de populações de espécies no contexto de problemas de optimização. Estes métodos são iterativos, não garantindo a convergência para as melhores soluções, uma vez que se baseiam em heurísticas. Apesar de existirem vários tipos de algoritmos evolucionários, os mais usados são as Estratégias Evolucionárias (Rechenberg (1964), Rechenberg (1973)), a Programação Evolucionária (Fogel et al. (1966)) e os Algoritmos Genéticos (Holland (1975)). As Estratégias Evolucionárias caracterizam-se por originalmente considerarem apenas o operador genético mutação na geração de novas soluções, apesar de versões mais recentes (Schwefel (1995)) considerarem também o operador genético cruzamento. A Programação Evolucionária caracteriza-se por a representação das soluções ser livre e seguir a natureza do problema, e por o operador mutação ser o único responsável pela geração de descendentes. Os Algoritmos Genéticos (AGs) caracterizam-se por envolver todas as componentes do processo evolucionário (isto é, selecção, cruzamento, mutação e substituição). Destes três tipos de algoritmos, os AGs são os utilizados no trabalho que serviu de base a esta dissertação.

Os AGs usados para determinar a frente óptima de Pareto em problemas de optimização multi-objectivo são caracterizados pelo tipo de função de aptidão utilizado para avaliar as soluções obtidas, pelo tipo de mecanismo que usam na preservação da diversidade na frente de Pareto e pelo uso, ou não, de estratégias elitistas. Relativamente ao tipo de função de aptidão, o mais utilizado é baseado na dominância de Pareto introduzida por Goldberg (1989). Os mecanismos de preservação da diversidade, que garantem a diversificação das soluções e contribuem para a obtenção de uma distribuição uniforme das soluções, podem ser baseados nas técnicas de partilha² do valor de aptidão, de multidões³, de agrupamentos⁴, etc.. As estratégias elitistas utilizam, na sua maioria,

² Tradução da palavra inglesa "sharing".

³ Tradução da palavra inglesa "crowding".

⁴ Tradução da palavra inglesa "clustering".

uma população externa na qual guardam as melhores soluções que vão sendo obtidas pelo AG.

Os AGs podem ser classificados de acordo com a utilização ou não de estratégias elitistas. Do grupo dos AG que não usam estratégias elitistas, destacam-se os seguintes: VEGA (Schaffer (1984)), WBGA (Hajela e Lin (1992)), MOGA (Fonseca e Fleming (1993)), NSGA (Srinivas e Deb (1994)) e NPGA (Horn et al. (1994)). Do grupo dos AGs que utilizam uma estratégia elitista, destacam-se os seguintes: SPEA (Zitzler e Thiele (1998)), NSGA-II (Deb et al. (2000)) e SPEA 2 (Zitzler et al. (2001)).

Na resolução de um problema de optimização multi-objectivo, através de um destes algoritmos, pretende-se então determinar uma frente óptima de Pareto, a qual deve, por um lado, convergir o mais possível para a frente óptima de Pareto real e, por outro, garantir uma boa diversidade das soluções que a compõem. No entanto, algumas destas soluções, que poderão ser de interesse para um AD como soluções de compromisso aceitáveis no sentido que apresentam um equilíbrio satisfatório entre os aspectos de avaliação operacionalizados pelas funções objectivo, podem ser muito sensíveis a perturbações. Isto é, quando uma dada solução não dominada, seleccionada usando uma qualquer abordagem, é implementada na prática, algumas alterações relativamente aos valores estimados para os dados do modelo (coeficientes e parâmetros das funções objectivo, coeficientes e parâmetros das restrições, limites das variáveis de decisão, etc.) podem levar a uma importante degradação no desempenho das funções objectivo. Desta forma, surge a necessidade de oferecer ao AD soluções que sejam relativamente insensíveis às alterações dos dados do modelo; isto é, os algoritmos devem procurar soluções robustas.

A modelação de muitos problemas de optimização multi-objectivo (e também mono-objectivo) depende de informação que, em geral, não se conhece com exactidão, normalmente porque envolve previsões ou estimativas de fenómenos naturais, económicos ou sociais. Em alguns casos esta incerteza é simplesmente ignorada (trabalha-se com a melhor estimativa dos dados), mas é comum a construção de modelos que procuram incorporar a incerteza (baseados em cenários, probabilísticos, difusos, etc.). Sobre estes modelos aplicam-se normalmente regras ou paradigmas de optimização com carácter decisivo, que nem sempre incorporam devidamente as preferências do AD.

Desta forma, os modelos construídos para resolver problemas multi-objectivo devem incorporar explicitamente a incerteza, a qual não resulta apenas da constante variabilidade dos fenómenos mencionados, mas também da imprecisão e das variações associadas aos dados do problema, das inevitáveis imprecisões na fase de modelação, ou do desenvolvimento da estrutura de preferências do AD durante o processo interactivo de

decisão. A análise da robustez das soluções de compromisso consideradas satisfatórias pelo AD é uma questão de grande importância, devendo constituir uma componente fundamental de ferramentas computacionais interactivas de apoio à decisão.

3. Análise de robustez em optimização

A incerteza é uma característica intrínseca dos problemas reais surgindo de múltiplas origens e possuindo natureza distinta. A incerteza emerge da cada vez maior complexidade das interacções no interior dos sistemas sociais, económicos e técnicos, caracterizados por uma rápida evolução tecnológica, alterações nas estruturas de mercado e de novas relações sociais. Geralmente, é impraticável que os modelos de apoio à decisão possam capturar todos os fenómenos interrelacionados relevantes presentes, chegar até toda a informação necessária e também dar conta das alterações e/ou hesitações relacionadas com a expressão das preferências de quem decide.

O tratamento da incerteza inclui construir, primeiro, os modelos que incorporem a incerteza e, depois, os métodos para determinar as soluções destes modelos. Os modelos mais usados para tratar a incerteza em problemas de optimização são essencialmente de quatro tipos: probabilísticos, difusos, intervalares e usando cenários. Relativamente aos métodos para efectuar o tratamento da incerteza em programação matemática, existem, essencialmente, cinco classes: programação difusa, programação intervalar, análise de sensibilidade, programação estocástica e programação robusta.

Além da incerteza estrutural, relacionada com o conhecimento global acerca do sistema a ser modelado, também os dados do problema podem sofrer de imprecisões, de imperfeições ou estarem sujeitos a alterações. Neste contexto, é importante fornecer ao AD soluções robustas. Apesar da definição de robustez não estar uniformizada na literatura, uma solução robusta está geralmente ligada a um certo grau de "imunidade" em relação à incerteza dos dados, a uma capacidade de adaptabilidade ou flexibilidade relativamente a um futuro incerto ou a preferências mal especificadas, garantindo um desempenho aceitável mesmo sob alteração das condições (tais como os dados do modelo flutuando sobre os "dados nominais").

Segundo Vincke (2003), existem quatro conceitos diferentes de robustez: decisão robusta (Gupta e Rosenhead (1968)), solução robusta (Mulvey et al. (1995) e Kouvelis e Yu (1997)), conclusão robusta (Roy (1998) e Dias e Clímaco (1999)) e método robusto (Vincke (1999-a) e Vincke (1999-b)).

O primeiro foi aplicado a problemas de decisão, em que uma decisão é robusta se continuar, o mais possível, receptiva a "bons" planos no futuro. O segundo foi aplicado em problemas de optimização, em particular combinatória, onde robustez significa "boa

em todos ou na maioria dos cenários” (um cenário é um conjunto de valores possíveis para os dados do modelo), onde usaram a definição de pior cenário, o qual foi definido de acordo com os critérios *min-max* ou *min-max regret*. No terceiro caso, uma conclusão robusta significa “válida em todos ou na maioria dos cenários” (um cenário é um conjunto de valores aceitáveis para os dados do modelo). No último caso, um método robusto significa “que fornece resultados válidos em todos ou na maioria dos cenários” (um cenário é um conjunto de valores possíveis para os dados do modelo e para os parâmetros do método).

4. Análise de robustez em otimização evolucionária

Os algoritmos evolucionários permitem resolver muitos problemas de otimização, cuja modelação de cada um deles foi construída a partir de informação com algum nível de incerteza. Em otimização evolucionária, é usual a incerteza ser representada através da função de aptidão.

Segundo Jin e Branke (2005), os métodos para tratamento da incerteza em otimização evolucionária podem ser categorizados nas seguintes quatro classes: função de aptidão perturbada, função de aptidão aproximada, função de aptidão com variação temporal (ou em ambientes dinâmicos) e análise de robustez.

Relativamente à classe dos métodos para determinar soluções robustas (análise de robustez), que é a que mais interessa no âmbito deste trabalho, os métodos existentes podem ainda ser subdivididos em dois grupos: os que optimizam o valor esperado da função de aptidão e os multi-objectivo. Apesar de existirem reportadas na literatura algumas abordagens evolucionárias para determinar soluções robustas em optimização, mono e multi-objectivo, a maioria das abordagens está vocacionada para resolver problemas de optimização mono-objectivo, ou então converter o problema multi-objectivo original num mono-objectivo.

A maioria das abordagens em optimização multi-objectivo consiste em optimizar a média e o desvio padrão da função de aptidão associada ao problema em estudo, as quais são obtidas através de uma amostra de pontos na vizinhança de uma dada solução. Apenas algumas abordagens tratam o caso como multi-objectivo, mas em que consideram como funções objectivo a optimizar o desempenho e a robustez, e não como um verdadeiro problema multi-objectivo. Poucas abordagens consideram explicitamente o caso multi-objectivo (por exemplo, a apresentada por Deb e Gupta (2005)).

No trabalho realizado no âmbito desta dissertação, é usado o conceito de solução robusta, a qual é avaliada nos espaços dos dados do modelo susceptíveis de conterem um certo grau de incerteza (espaços das soluções, e dos dados associados às funções

objectivo e às restrições) e no espaço dos objectivos. Neste trabalho usa-se o conceito de cenário de referência, o qual corresponde aos valores nominais associados aos dados do modelo que contêm incerteza, isto é, que estão sujeitos a perturbações.

5. Objectivos do trabalho

Pretende-se com este trabalho construir uma metodologia para apoiar a tomada de decisão em problemas de optimização multi-objectivo, cujos valores das variáveis de decisão das soluções e dos dados (associados às funções objectivo e às restrições) do problema, estão sujeitos a perturbações, utilizando a análise de robustez. Para tal, desenvolveram-se duas abordagens evolucionárias envolvendo a análise de robustez em problemas de optimização multi-objectivo, as quais utilizam uma nova definição de robustez, designada por grau de robustez.

Estas abordagens baseiam-se no comportamento das soluções nas respectivas vizinhanças quando sujeitas a perturbações no espaço das variáveis de decisão ou nos espaços dos dados associados às funções objectivo e às restrições do problema, avaliado no espaço dos objectivos (ver também o conceito de solução robusta do tipo II em Deb e Gupta (2004) e Deb e Gupta (2005)).

O conceito de grau de robustez aqui introduzido permite ao AD exercer um controlo sobre o nível de robustez desejado das soluções obtidas. O AD pode especificar o tamanho da vizinhança das soluções, quer no espaço dos dados sujeitos a perturbações, quer no espaço das funções objectivo (normalmente o espaço com que o AD está mais familiarizado).

Na implementação destas abordagens, foram construídos dois algoritmos evolucionários (genéticos), nos quais o conceito de grau de robustez foi embebido no processo evolucionário, em especial na avaliação da aptidão (desempenho) de cada indivíduo. A ideia principal é influenciar o processo evolucionário no sentido de alcançar as soluções não dominadas mais robustas; isto é, soluções para as quais os desempenhos das funções objectivo são mais imunes a perturbações nos valores das variáveis de decisão das soluções, e nos dados associados às funções objectivo e às restrições.

Com a aplicação destes algoritmos evolucionários, pretende-se determinar uma frente óptima de Pareto, cujas soluções, para além de serem as mais robustas, assegurem também uma boa diversidade ao longo desta frente.

6. Organização da tese

Esta dissertação encontra-se dividida em sete capítulos, cada um dos quais referentes a aspectos diferentes do trabalho realizado. Neste primeiro capítulo é feita uma breve descrição do enquadramento do trabalho realizado e dos objectivos propostos.

No capítulo 2 é feita uma descrição mais pormenorizada dos conceitos essenciais (em especial o de dominância) associados à optimização multi-objectivo, passando pelos métodos existentes para resolver problemas deste tipo, dos quais se destacam os algoritmos evolucionários. Neste mesmo capítulo é também apresentada uma descrição dos algoritmos evolucionários, com particular relevo para os Algoritmos Genéticos. Por fim, são descritas as abordagens evolucionárias mais importantes para resolver problemas de optimização multi-objectivo.

O capítulo 3 está reservado ao estado da arte da Análise de Robustez em problemas de optimização, o qual começa por caracterizar os tipos de incerteza, as várias definições de robustez, e a análise de robustez em problemas de optimização (em especial optimização combinatória) e usando meta-heurísticas.

O capítulo 4 é dedicado ao estado da arte da Análise de Robustez em optimização evolucionária multi-objectivo, no qual são apresentadas uma caracterização da optimização evolucionária em ambientes incertos e as abordagens propostas de optimização robusta em ambientes sujeitos a perturbações relativamente aos seus valores nominais, incluindo as definições de grau de robustez em cada uma daquelas abordagens. Neste capítulo são também descritos os aspectos principais dos algoritmos evolucionários usados para testar o desempenho das abordagens propostas.

No capítulo 5 é apresentado um conjunto de testes e de resultados obtidos com um dos algoritmos evolucionários implementados e aplicado a um problema de teste bi-objectivo, que é normalmente usado na literatura da área da programação evolucionária, considerando perturbações nos valores das variáveis de decisão das soluções, servindo para avaliar o desempenho de uma das abordagens propostas neste trabalho.

No capítulo 6 é apresentado um estudo da aplicabilidade de uma das abordagens propostas a um caso real, mais concretamente ao problema da compensação do factor de potência numa rede eléctrica de distribuição do tipo radial. Este problema é bi-objectivo e considera-se que alguns dos dados do modelo associados às funções objectivo e às restrições estão sujeitos a perturbações.

O capítulo 7 está destinado às conclusões do trabalho realizado e às pistas de desenvolvimento a que este pode conduzir no futuro.

7. Contribuições científicas da tese

O trabalho realizado que serviu de base a esta dissertação deu origem a várias publicações nacionais e internacionais:

- dois relatórios de investigação
 - Research Report N.5/2004, INESC – Coimbra (Antunes et al. (2004)),
 - Research Report N.3/2006, INESC – Coimbra (Barrico e Antunes (2006-d));
- quatro conferências internacionais (com arbitragem pelos pares)
 - The 6th Metaheuristics International Conference (MIC2005), Viena, Áustria (Antunes et al. (2005)),
 - II European-Latin-American Workshop on Engineering Systems (SELASI II), Porto, Portugal (Barrico e Antunes (2006-a)),
 - The 7th International Conference on Multi-Objective Programming and Goal Programming (MOPGP 2006), Tours, France (Barrico e Antunes (2006-b)),
 - 2006 IEEE World Congress on Computational Intelligence (WCCI 2006), Vancouver, Canadá (Barrico e Antunes (2006-c));
- um capítulo de livro (com arbitragem pelos pares)
 - Shengxiang Yang, Yew-Soon Ong, Yaochu Jin (Eds.), "Evolutionary Computation in Dynamic and Uncertain Environments", Series on Studies in Computational Intelligence (SCI), Volume 51, Springer (Barrico e Antunes (2007)).