

5

Conclusões e Trabalhos Futuros

Este trabalho apresentou a proposta de um novo modelo de otimização, inspirado nos conceitos da física quântica de superposição de estados e funções de onda, capaz de oferecer: uma maneira de representar variáveis numéricas de forma direta; melhor desempenho na otimização; escalabilidade; capacidade de armazenamento de conhecimento sobre regiões do espaço de busca; e capacidade de aprendizado compartilhado. Foi apresentado um algoritmo evolutivo com inspiração em física quântica que usa uma representação para números reais (AEIQ- \mathbb{R}), em contrapartida ao algoritmo apresentado em (Han04) que usa uma representação binária para um algoritmo evolutivo com inspiração quântica.

Também foi apresentado um modelo neuro-evolutivo, utilizando o AEIQ- \mathbb{R} para o treinamento dos pesos de uma rede neural recorrente. Este modelo permite, não só o treinamento da rede, como também a otimização da topologia da mesma, através da variação do número de processadores e da distribuição destes processadores em camadas, fazendo-se a manipulação dos pesos da rede neural.

Com relação à capacidade de representar variáveis numéricas de forma direta mostrou-se que, através do uso de funções de onda, foi possível construir uma analogia contínua ao modelo quântico de estados discretos. Também foi apresentado um modelo físico hipotético capaz de simular o funcionamento do AEIQ- \mathbb{R} .

Com relação a maior velocidade de convergência foram apresentados, no capítulo 4, diversos estudos de caso de otimização numérica. Estes estudos de caso mostraram a importância de se usar uma representação específica para números reais ao se tratar problemas de otimização numérica. A comparação de resultados com o AEIQ- \mathbb{R} na otimização deste tipo de problemas mostrou a melhor capacidade deste algoritmo no tratamento desta classe de problemas. Além disso, quando comparado a outros algoritmos de otimização, o AEIQ- \mathbb{R} mostrou ser consistente na otimização de problemas e mostrou ser capaz de produzir bons resultados em diversos tipos de funções, com diferentes características.

Para demonstrar a escalabilidade do algoritmo foram mostrados diversos resultados que mostram a capacidade do algoritmo AEIQ- \mathbb{R} em otimizar problemas com até 1000 variáveis sem, no entanto, ter um crescimento exponencial no esforço computacional necessário para se atingir um determinado resultado. Apesar de não

serem testes conclusivos, estes sugerem a necessidade de uma investigação mais detalhada já que, um algoritmo com complexidade não-exponencial é interessante para a otimização de problemas com grande dimensionalidade.

Para explicar o desempenho do algoritmo foram apresentadas diversas hipóteses, em particular, a hipótese de que a população quântica se comporta como uma representação direta dos melhores *schemata* que representam os melhores indivíduos da população. Uma outra hipótese apresentada sugere que o armazenamento de conhecimento normativo, sob a forma de funções densidade de probabilidade ou funções de onda pode, indiretamente, determinar valores aproximados de avaliação para diferentes regiões do espaço de busca e, assim, ser responsável pelo melhor desempenho do algoritmo. Além disso, este tipo de conhecimento pode, eventualmente, ser compartilhado em um sistema de aprendizado multi-agentes e uma investigação mais detalhada precisa ser realizada nesta área.

Como trabalhos futuros é possível destacar alguns pontos importantes, que podem trazer novas possibilidades de aplicação para o algoritmo:

- Implementação de outros operadores de algoritmos genéticos clássicos com o objetivo de tentar melhorar a capacidade de otimização do AEIQ-R ;
- Testes de desempenho usando-se outros tipos de função densidade de probabilidade, diferentes de um pulso quadrado (por exemplo, distribuições normais);
- Testes do modelo neuro-evolutivo para classificação de padrões;
- Novos testes em previsão de séries usando neuro-evolução;
- Novos experimentos em problemas de controle, principalmente com relação à capacidade de generalização da rede neural encontrada pelo algoritmo;
- Investigação mais detalhada da complexidade computacional do algoritmo proposto;
- Investigação mais detalhada da capacidade de se usar a população quântica como uma forma de conhecimento compartilhado.

Além desses testes, também se inclui nos próximos passos a inserção de novas formas de conhecimento similares aos usados em algoritmos culturais (como por exemplo o conhecimento topográfico) e a utilização do AEIQ-R para a resolução de outros tipos de problemas, descritos nas seções a seguir.

5.1 Aprendizado Online

Sistemas de aprendizado online são aqueles onde a tarefa que se deseja aprender ou otimizar é não-estacionária, ou seja, a configuração do problema varia com o tempo (Saad98). A idéia por trás do uso de algoritmos evolutivos para aprendizado *online* é usar as melhores soluções, encontradas até o momento anterior a esta mudança de configuração do problema, para alimentar a população inicial que será usada durante o aprendizado da nova configuração do problema. A expectativa é que as pequenas mudanças provocadas na configuração do problema provoquem também pequenas mudanças nas soluções consideradas ótimas. O uso do AEIQ-R para aprendizado *online* tem, deste modo, um potencial promissor: os pulsos que formam o indivíduo quântico representam, ao invés de apenas pontos no espaço de busca, toda uma região promissora do espaço de buscas. Ao usar estas regiões como realimentação para o AEIQ-R, espera-se conseguir um aprendizado *online* mais eficiente.

Para se experimentar este modelo, propõe-se utilizar um simulador de dinâmica de vôos chamado JSBSim (Jsbsim). O objetivo é fazer com que o sistema seja capaz de controlar em tempo real um foguete sem estabilizadores verticais, como o mostrado na figura 5.1.

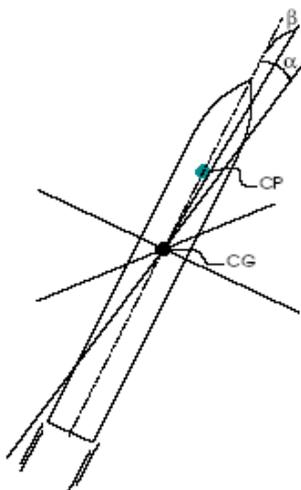


Figura 5.1: Diagrama de um foguete sem estabilizadores.

Nesta figura, CG é o centro de gravidade do foguete, CP é o centro de pressão e α e β representam os ângulos de inclinação do foguete com o eixo horizontal.

Neste tipo de foguete existem apenas duas forças atuando sobre o mesmo: o empuxo gerado pelos propulsores do foguete e o arrasto exercido pela atmosfera sobre o centro de pressão do foguete. O controle deste tipo de foguete oferece um grande desafio, devido ao fato da ausência dos estabilizadores verticais fazer com que o centro de pressão do foguete fique localizado acima do seu centro

de gravidade, tornando o sistema naturalmente instável, de maneira similar ao problema do pêndulo invertido. No entanto, ao contrário do pêndulo invertido, este problema oferece um grau de complexidade muito maior pois, à medida que o foguete se movimenta, diversas variáveis relacionadas à configuração do ambiente se alteram (como, por exemplo, a densidade do ar, o peso do foguete, etc), exigindo que o sistema se adapte rapidamente à nova configuração do ambiente.

5.2

Sistemas Multi-Agentes

De acordo com (Franklin96), um agente autônomo é um sistema que está situado e é parte de um ambiente, e que é capaz de perceber este ambiente e agir sobre ele no decorrer do tempo em busca de um determinado objetivo. O mesmo artigo cita quatro pontos-chaves que diferenciam um agente de um programa:

- Reação ao ambiente: o agente é capaz de reagir a mudanças no ambiente;
- Autonomia: exerce controle sobre suas próprias ações;
- Orientado a um objetivo: suas ações não são simples respostas ao ambiente;
- Temporalmente contínuo: um agente é um processo em contínua execução.

Quando diversos agentes interagem de forma colaborativa ou competitiva, os mesmos podem formar um sistema multi-agente. Em geral, os agentes que formam este tipo de sistema não têm disponíveis todos os dados ou todos os métodos necessários para se alcançar um objetivo e, deste modo, precisam colaborar entre si para alcançá-lo. Além disso, existe pouco ou nenhum controle central nestes sistemas responsável por gerenciar os agentes (nos casos de interações competitivas, não existe nenhum tipo de controle central entre os agentes que estão competindo).

O aprendizado de sistemas multi-agentes constitui um importante aspecto desta área de pesquisa. O uso do AEIQ-IR para este aprendizado pode ser feito baseado no modelo mostrado na figura 5.2.

A idéia é que o indivíduo quântico funcione como um espaço que armazene conhecimento normativo sobre o aprendizado e que este conhecimento seja compartilhado entre os agentes. Além disso, a população clássica é dividida em subpopulações e cada uma dessas subpopulações evolui o conhecimento de cada um dos agentes. A expectativa é que o compartilhamento do conhecimento e a separação das subpopulações seja capaz de produzir a especialização dos agentes e a capacidade de cooperação dos mesmos na realização da tarefa.

Para a experimentação deste modelo, propõe-se utilizar um sistema chamado Robocode (Robocode). Este sistema consiste em uma arena onde um conjunto de robôs, similares a tanques de combate, simulam uma disputa. Cada vez que um dos

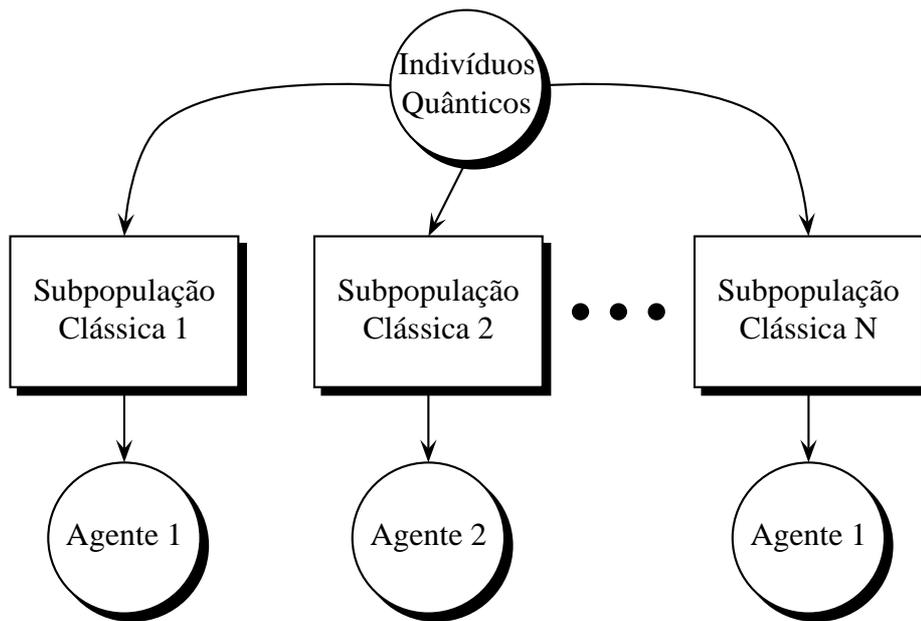


Figura 5.2: Modelo de aprendizado multi-agentes usando o AEIQ-IR .

robôs é atingido por outro, o mesmo é eliminado da competição. O último robô a ficar na arena é o vencedor da disputa. O sistema permite a definição de times e os agentes que formam os times devem colaborar entre si para ganhar a disputa. Além disso, existem diversos algoritmos disponíveis, desenvolvidos para o controle dos robôs (inclusive algoritmos desenvolvidos com o uso de programação genética), que permitem a comparação dos resultados diretamente.