

6

Conclusões e Trabalhos Futuros

Em muitas aplicações reais de processamento de sinais, as observações do fenômeno em estudo chegam seqüencialmente no tempo. Conseqüentemente, a tarefa de análise destes dados envolve estimar quantidades desconhecidas em cada observação concebida do fenômeno.

Tipicamente estas quantidades desconhecidas são modeladas como os estados de um processo Markoviano e expressados num formato matemático comum, usando a abstração do MEE. Em seguida, os estados são estimados através de alguma estratégia de aprendizado, como por exemplo a estratégia Bayesiana, a qual usa o conhecimento prévio disponível sobre o fenômeno em estudo para formular uma distribuição *a priori* dos estados e para formular uma função de verossimilhança que relacione os estados com as observações do fenômeno. Dentro desta configuração, a *inferência Bayesiana* dos estados é baseada na distribuição *a posteriori*, que é obtida através do teorema de Bayes. Infelizmente, nem sempre é possível obter uma solução analítica exata para esta distribuição *a posteriori*. Graças ao advento de um formidável poder computacional a baixo custo, em conjunto com os recentes desenvolvimentos na área de simulações estocásticas, este problema tem sido superado, uma vez que esta distribuição *a posteriori* pode ser aproximada numericamente através de uma distribuição discreta, formada por um conjunto de amostras.

Neste contexto, este trabalho abordou o campo de simulações estocásticas sob a ótica da genética Mendeliana e do princípio evolucionário da “sobrevivência dos mais aptos”. Neste enfoque, o conjunto de amostras que aproxima a distribuição *a posteriori* pode ser visto como uma população de indivíduos que tentam sobreviver num ambiente Darwiniano, sendo o indivíduo mais forte, aquele que possui maior probabilidade. Com base nesta analogia, no capítulo 4 foram concebidos o Filtro de Partículas Genéticas (FPG) e o Filtro Evolutivo (FE) que são algoritmo de aprendizado *online/batch* evolucionários. Também, foi mostrado uma equivalência entre o teorema de Bayes e o princípio evolucionário

permitindo, assim, concepção de um novo mecanismo de cálculo dos estados do MEE, denominado de *inferência evolucionária*. Além disso, foi estabelecido a equivalência entre o FPG e os métodos SMC (ambos métodos aproximam distribuições variantes no tempo), assim como o FE com os métodos MCMC (ambos métodos aproximam distribuições invariantes no tempo). Finalmente, foi mostrado também que FE é em essência um AG, pois além da sua capacidade de convergência a distribuições de probabilidade, o FE converge também a sua moda global. Em consequência, a fundamentação teórica do FE mostra, analiticamente, a convergência dos AGs em espaços contínuos, resultado este de grande interesse da comunidade de pesquisadores de computação evolucionária.

Historicamente, os AGs têm emergido como uma tecnologia de otimização prática com aplicações nos mais diversos campos [65-68]. Apesar de evidências empíricas mostrando o bom desempenho dos AGs, eles têm sido muitas vezes criticados pela falta de uma plataforma teórica comum capaz de suportar o estudo analítico de suas propriedades de convergência. O próprio John Holland, ciente deste problema, desenvolveu uma plataforma teórica baseada numa representação binária dos *chromossomas* e no *Teorema de Schema* que mostra basicamente que “*schematas* curtos e de baixa ordem tendem a se proliferar ou desaparecer nas gerações seguintes, de acordo com sua aptidão média” [38-40]. Embora este teorema mostre a maneira como os AGs funcionam, o teorema possui limitações ao não explicar muitos aspectos complexos dos AGs e ao não avaliar sua convergência. Recentemente, esta teoria vem sendo estendida com resultados promissores [41-43]. Outra plataforma teórica dos AGs também foi desenvolvida na representação binária dos *chromossomas* e na teoria finita das cadeias de Markov [44-50] e na teoria das cadeias não estacionárias de Markov [69]. Infelizmente, a representação binária tradicional, não é adequada para problemas multidimensionais numéricos de alta precisão [39], onde é conveniente usar uma representação em ponto flutuante. Neste contexto, a fundamentação teórica do FE apresentada nesta tese propõe uma nova plataforma teórica baseada na representação em ponto flutuante (espaços contínuos). Esta plataforma pode ainda ser generalizada para espaços abstratos e, com isto, se tornar uma candidata a uma fundamentação teórica geral dos AGs.

Por outro lado, este trabalho mostrou também que o princípio Darwiniano da “sobrevivência dos mais aptos” não somente pode ser aplicado a problemas de

otimização, mas também ao mecanismo de aprendizado no cálculo dos estados do MEE, mostrando desta forma sua extraordinária generalidade. Finalmente, com base na análise teórica de convergência dos algoritmos de aprendizado baseados na *inferência evolucionária* e nos resultados dos experimentos numéricos, conclui-se que esta abordagem se aplica a problemas reais de processamento de sinais, uma vez que permite analisar sinais complexos caracterizados por comportamentos não-lineares, não-gaussianos e não-estacionários.

Como trabalhos futuros, sugere-se adaptar a plataforma teórica desenvolvida neste trabalho para mostrar a convergência dos AGs em espaços discretos, isto é, para *cromossomas* com representação binárias e baseados em ordem. Além disso, recomenda-se aplicar a inferência evolucionária como método de aprendizado em modelos como redes neurais e sistemas neuro-fuzzy, testando-os em problemas reais.