

6 – REFERÊNCIAS BIBLIOGRÁFICAS

Armstrong, J. S. & Collopy, F. *Error Measures For Generalizing About Forecasting Methods: Empirical Comparisons*. International Journal of Forecasting, 8 (1992), 69-80.

Barros, M.; Souza, R.C. *Regressão Dinâmica*. Núcleo de Estatística Computacional. PUC-Rio, 1995.

Barros, M. Processos Estocásticos. Rio de Janeiro. Papel Virtual, 2004.

Bakirtzis, A. G., Theocharis, J. B., Kiartzis, S. J., Satsios, K. J. (1995). *Short-term load using fuzzy neural network*. IEEE Transactions on Power Systems. 10(3), 1518-1524.

Bunn, D. W., Farmer, E. D., *Comparative models for electrical load forecasting*, Wiley, Belfast, 1985.

Campos, L. C. D., *Uma nova abordagem evolucionária para a determinação de um conjunto independente máximo de um grafo*. Dissertação de Mestrado, COPPE-UFRJ, 2003.

Cancelo, J. R., Espasa, A. (1996). *Modelling and Forecasting Daily Series of Electricity Demand*. Investigaciones Economicas. 20 (3), 359 – 376.

Cancelo, J. R., Espasa, A., Grafe, R. (2007). *Eighteen-years' experience in data adjustment and forecasting daily and hourly electricity consumption*. 4th International Institute of Forecasters' Workshop, Rio de Janeiro – Brasil.

Carvalho, A. C. P. L. F., Braga, A. P., Ludermir, T. B. *Fundamentos de Redes Neurais Artificiais*, NCE/UFRJ, Rio de Janeiro. (1998)

Cipra, T., Trujillo, J. & Rubio, A. (1995). Holt-Winters Meted with Missing Observations. Management Science, 41 (1), 174 – 178.

Darbellay, G. A., Slama, M. (2000). *Forecasting the short-term demand for electricity – Do neural networks stand a better chance?*, International Journal of Forecasting, 16, 71-83.

Davis, Lawrence. *Handbook of Genetic Algorithms*, Van Nostrand Reinhold, USA, 1991.

Engle, R. F., Mustafa, C., Rice, J. (1992). *Modelling Peak Electricity Demand*. Journal of Forecasting, 11(3), 241 – 251.

Esteves, G. R.T., *Modelos de Previsão de Carga de Curto Prazo*, dissertação de mestrado, DEE, PUC-Rio, abril 2003.

Gardner, E. S. (2006). *Exponential smoothing: The state of the art – Part II*. International Journal of Forecasting, 22 – 637 – 666.

Goldberg, D. E. *Genetic Algorithms in Search, Optimization and Machine Learning*. Addison-Wesley Reading, MA, 1989.

Grubb, H., Mason, A. (2001). Long lead-time forecasting of UK air passengers by Holt-Winters methods with damped trend. International Journal of Forecasting, 17 (1), 71 – 82.

Haykin, S., *Neural Networks: A Comprehensive Foundation*. New Jersey, Prentice Hall, 2o Edição, 1999.

Hippert, H. S., Pedreira, C. E., Souza, R. C. (2001). *Neural Networks for Short-Term Load Forecasting: A Review and Evaluation*, IEEE Transactions on Power Systems, 16 (1), 44-55.

Holland, J. H. *Adaptation in Natural and Artificial Systems*. MIT Press, 1975.

Holt, C. C. (2004a). *Forecasting seasonals and trends by exponentially weighted moving averages*. International Journal of Forecasting, 20, 5 – 10.

Holt, C. C. (2004b). *Author's retrospective on 'Forecasting seasonals and trends by exponentially weighted moving averages'*. International Journal of Forecasting, 20, 11-13.

Jang, J.-S.R. (1993). *ANFIS: Adaptive-Neuro-Fuzzy Inference System*, IEEE Transactions on Systems, Man and Cybernetics, 23(3), 665-685.

Laing, W. D., Smith, D. G. C. (1987). *A comparison of time series forecasting methods for predicting the CEGB demand*. Proceedings of the Ninth Power Systems Computation Conference.

Lazo, J. G. L., *Sistema híbrido genético-neural para montagem e gerenciamento de carteiras de ações*, dissertação de mestrado, DEE, PUC-Rio, agosto 2000.

Lazo, J. G. L., Yvan, T. V., Souza, R. C., Barros, M., Miranda, C. V. C., Projeto P&D – Eletropaulo - SPCI, Relatório Final, Rio de Janeiro - RJ, 2006.

Lourenço, P. M., *Um Modelo de Previsão de Curto Prazo de Carga Elétrica Combinando Métodos Estatísticos e Inteligência Computacional*, PUC-Rio, Tese de Doutorado, 1998.

McMenamin, J. S., Monforte, F. A. (1998), *Short-term energy forecasting with neural networks*, Energy Journal, 19(4), 43-61.

Medeiros, M. C., *Técnicas de Pesquisa em Economia*, Notas de Aula, 2005.

Mendel, J. M., *Fuzzy Logic Systems for Engineering: A Tutorial*, Proceedings of the IEEE, Vol. 83, Nº 3, pp. 345-377, Março 1995.

Michalewicz, Zbigniew. *Genetic Algorithms + Data Structures = Evolution programs*, Springe-Verlag, USA, 1996.

Mitchell, M. *An Introduction to Genetic Algorithms*. MIT Press, 1996.

Montgomery, D.C., Johnson, L.A. *Forecasting and Time Series Analysis*, New York, McGraw-Hill Book Co., 2 ed., 1990.

Mori, H., Kobayashi, H. (1996). *Optimal fuzzy inference for short-term load forecasting*, IEEE Transactions on Power Systems, 11(1), 390-396.

Papadakis, S. E., Theocharis, J. B., Kiartzis, S. J., Bakirtzis, A. G. (1998). *A novel approach to short-term load forecasting using fuzzy neural networks*. IEEE Transactions on Power Systems, 13(2), 480-492.

Papalexopoulos, A. D., Hesterberg, T. C. (1990). *A regression-based approach to short-term system load forecasting*. IEEE Transactions on Power Systems, 5 (4). 1535-1547.

Quadrelli, G., *Modelos Comparativos de Previsão de Carga Elétrica de Curto Prazo*, dissertação de mestrado, DEE, PUC-Rio, abril 1998.

Ramanathan, R., Engle, R., Granger, C. W. J, Araghi, F. V., Brace, C. (1997). *Short-run forecasts of electricity loads and peaks*. International Journal of Forecasting, 13 161 – 174.

Rizzo, G. M., *Previsão de Carga de Curtíssimo Prazo no Novo Cenário Elétrico Brasileiro*, dissertação de mestrado, DEE, PUC-Rio, fevereiro 2001.

Sobral, A. P. B., *Modelo de Previsão Horária de Carga Elétrica para Light*, dissertação de mestrado, DEE, PUC-Rio, março 1999.

Souza, R. C., *Métodos Automáticos de Amortecimento Exponencial para Previsão de Séries Temporais*, Monografia GSM-10/83, maio 1983.

Souza, R. C., *Modelos Estruturais para Previsão de Séries Temporais: Abordagens Clássica e Bayesiana*, 17º Colóquio Brasileiro de Matemática, IMPA, 1989.

Souza, R. C., Camargo, M. E., *Análise e Previsão de Séries Temporais : Os Modelos ARIMA*. 2ª Ed., 2004.

Taylor, J. W. (2003a). *Short-term electricity demand forecasting using double seasonal exponential smoothing*. Journal of Operational Research Society, 54, 799-805.

Taylor, J. W. (2003b). *Exponential Smoothing with a Damped Multiplicative Trend*. International Journal of Forecasting, 19, 715-725.

Taylor, J. W., Buizza, R. (2003). *Using weather ensemble predictions in electricity demand forecasting*. International Journal of Forecasting, 19, 57 – 70.

Taylor, J. W., & Majithia, S. (2000). *Using combined forecasts with changing weights for electricity demand profiling*. Journal of the Operational Research Society, 51, 72 – 82.

Taylor, J. W., Menezes, L. M. de, McSharry, P. E. (2006). *A comparison of univariate methods for forecasting electricity demand up to a day ahead*. International Journal of Forecasting, 22, 1 – 16.

Taylor, J. W. McSharry, P. E., *Short-Term Load Forecasting Methods: An Evaluation Based on European Data*. 4th International Institute of Forecasters' Workshop, Rio de Janeiro – Brasil, 2007.

Valor, E., Meneu, V., Caselles, V. (2001). *Daily Air Temperature and Electricity Load in Spain*. Journal of Applied Meteorology, 40, 1413 – 1421.

Williams, T. M. (1987). *Adaptative Holt-Winters Forecasting*. The Journal of the Operational Research Society, 38 (6), 553 – 560.

Williams, D. W. and Miller, D. (1999). *Level-adjusted exponential smoothing for modeling planned discontinuities*. International Journal of Forecasting, 15, 273-289.

Winters, P. R. (1960). *Forecasting sales by exponentially weighted moving averages*. Management Science, 324 – 342.

Yan, Y.Y. (1998). *Climate and Residual electricity consumption in Hong Kong*. Energy, 23, 17 – 20.

Zanini, A., *Redes Neurais e Regressão Dinâmica: Um Modelo Híbrido para Previsão de Curto Prazo da Demanda de Gasolina Automotiva no Brasil*, PUC-Rio, Dissertação de Mestrado, 2000.

Anexo A – Algoritmo Genético

Os algoritmos genéticos começaram a ser pesquisados por volta de 1975, contudo, sua eficiência na solução de problemas complexos iniciou-se em torno de 1985, onde ocorreram os principais avanços (Goldberg, 1989).

Seu princípio é baseado na idéia da evolução e da seleção natural, como proposto por Darwin em “A Origem das Espécies”. Assim, na década de 70 vários autores começaram a imitar esse mecanismo da evolução para resolver problemas de várias ordens de complexidade, o que resultou em várias abordagens algorítmicas, compondo então a computação evolucionária, cujos principais tópicos são: as estratégias evolucionárias, a programação evolucionária e os algoritmos genéticos (Goldberg, 1989 e Mitchell, 1996).

Algoritmos genéticos são métodos de busca e otimização estocástica que procuram soluções para problemas complexos ou que tenham espaço de soluções (Espaço de Busca) muito grande. Geralmente, esses problemas são difíceis de serem modelados e solucionados através dos métodos convencionais de otimização.

Assim, baseados nos processos genéticos de organismos biológicos, os algoritmos genéticos procuram soluções ótimas ou sub-ótimas. Isso ocorre da seguinte forma: cada possível solução do problema é codificada, formando uma estrutura denominada cromossomo, que é formada por uma cadeia de bits ou caracteres. Esses cromossomos representam os indivíduos que evoluem através das gerações de acordo com os princípios de seleção natural e sobrevivência dos mais aptos (Lazo, 2000).

Dessa forma, os algoritmos genéticos manipulam uma população formada por indivíduos, na qual cada um representa uma solução candidata para o problema em questão. O espaço de busca ou região viável é a denominação dada ao espaço que engloba todas as soluções candidatas (Campos, 2003).

Ainda baseando-se na evolução da natureza, a cada indivíduo da população é dado um valor de adaptação que se refere à sua aptidão, indicando assim a qualidade da solução deste indivíduo frente às outras soluções dessa população para resolver o problema em questão. Os indivíduos mais aptos têm a

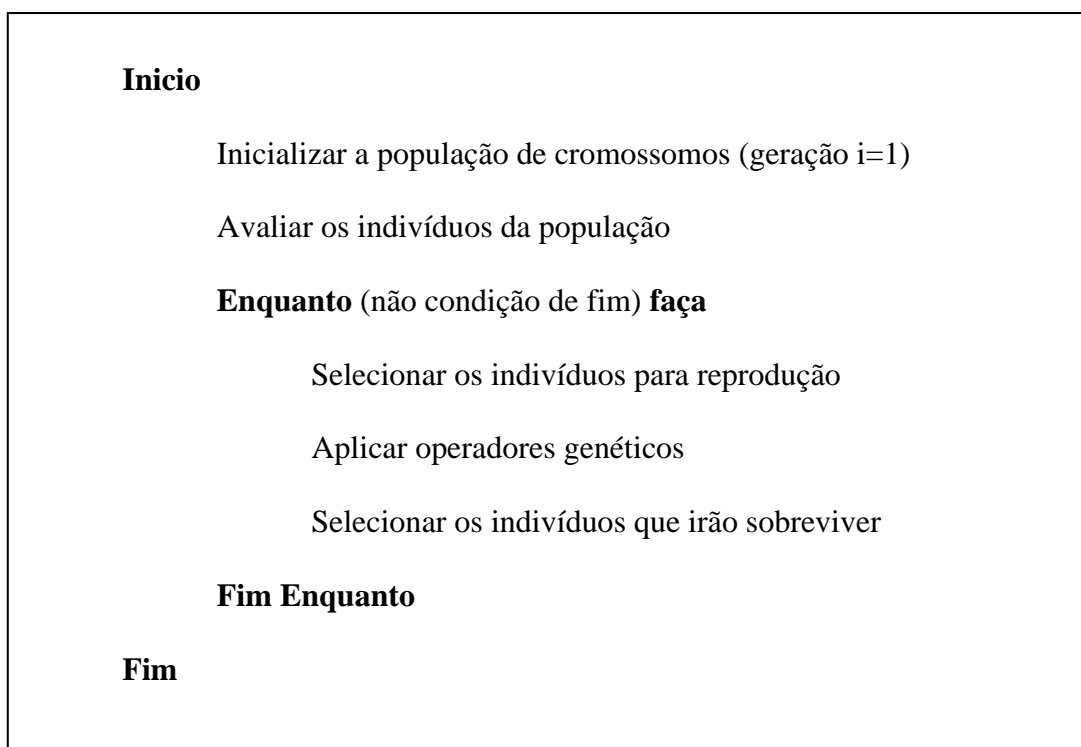
chance de se reproduzirem através de cruzamentos com outros indivíduos da população, gerando, conseqüentemente, descendentes com características de ambos. Novos indivíduos também podem ser introduzidos na população através da mutação, que ocorre de forma aleatória.

Para os problemas de otimização, a função de aptidão equivale à função objetivo do problema, isto é, à função que será otimizada. Assim, os indivíduos ou cromossomos de alta aptidão são aqueles em que a função objetivo a ser minimizada (ou maximizada) possui valores baixos (ou altos).

A evolução começa com a criação aleatória dos indivíduos que irão pertencer à população inicial. Depois os indivíduos são separados para a reprodução (através da seleção baseada na aptidão), criando novas soluções, sendo usado para tal um conjunto de operadores genéticos. Então, será a aptidão do indivíduo quem irá determinar o seu grau de sobrevivência e, conseqüentemente, a chance do cromossomo prosseguir nas próximas gerações. A essência é que os indivíduos gerados possam representar, a cada desenvolvimento, soluções melhores (Lazo, 2000).

A estrutura básica de um algoritmo genético é apresentada na figura A.01 abaixo. Maiores detalhes sobre a implementação de um algoritmo genético podem ser encontrados em Goldberg (1989).

Figura A.01- Estrutura básica de um algoritmo genético



Nas próximas seções será descrito cada um dos procedimentos do algoritmo da figura A.01.

A.1 – Representação

A escolha sobre como representar as possíveis soluções de um algoritmo genético é o primeiro passo a ser definido (a mais comum é a codificação binária) e que tem impacto no desempenho do algoritmo genético, por isso deve ser o mais simples possível, sem perder as características de representação do problema.

É neste estágio que é descrita a estrutura do cromossomo, especificando-se cada gene, de forma que este seja capaz de descrever todo o espaço de busca do problema.

A2 – Codificação e Decodificação

A codificação consiste na formação do cromossomo (cadeia de valores), o qual é representado por um conjunto de parâmetros (genes) e é uma das fases mais importantes na definição do algoritmo genético, sendo um fator que pode significar o sucesso ou o fracasso de um algoritmo genético.

Os cromossomos são codificados por uma seqüência de caracteres do sistema alfabético. A forma mais tradicional é a codificação binária, composta por (0,1) (Holland, 1975), mas já existem codificações com outros alfabetos, por exemplo, com números reais (Michalewicz, 1996) e regras de inferência.

Com a decodificação é possível, a partir de um cromossomo, construir a solução para um problema. Com isso, depois da evolução do algoritmo genético o cromossomo escolhido como melhor indivíduo é transformado na solução.

A.3 – Inicialização da População

A inicialização da população geralmente é feita de forma aleatória, mas também é possível inicializar com alguns indivíduos, caso se conheçam, a priori, algumas soluções aproximadas.

Esta não é uma fase crítica do algoritmo, sendo apenas necessário que os indivíduos sejam diversificados a fim de garantir que a população tenha soluções candidatas distribuídas por todo o espaço de busca.

A.4 – Avaliação


A avaliação consiste em calcular a aptidão de cada indivíduo. Assim é atribuído um valor numérico a cada indivíduo da população, que representa a sua “utilidade” ou “habilidade” para solucionar o problema em questão.

A.5 – Operadores Genéticos

Os principais operadores dos algoritmos genéticos são os de Reprodução, *Crossover* e Mutação.

- Reprodução: é o processo de selecionar e copiar um certo cromossomo para a próxima população de acordo com a sua aptidão. Dessa forma, os cromossomos com maior aptidão têm mais possibilidade de contribuir com os indivíduos da outra população.
- *Crossover*: refere-se à troca de partes dos cromossomos formando novas soluções. Para que seja realizado, primeiro é necessário um sorteio para que sejam escolhidos os cromossomos, depois, de acordo com a taxa de *crossover*, ocorre ou não sua realização. Há várias formas de se fazer o *crossover* (detalhes sobre essas formas podem ser encontrados em Goldberg (1989), Davis (1991) e Campos (2003)), na figura A.02 será representado o *crossover* de um ponto.


Figura A.02 – *Crossover* de um ponto



- Mutação: consiste na troca aleatória do valor do gene de um cromossomo por um valor válido do alfabeto e é utilizada para garantir que nenhuma informação desapareça. Há uma taxa de mutação, a partir da qual define-se, por sorteio, se haverá ou não mutação do gene em questão. Caso ocorra, o bit sorteado será substituído por outro valor pertencente ao alfabeto, como mostrado na figura A.03. Há ainda outros tipos de

mutação, estes podem ser encontrados com mais detalhes em Davis (1991) e Campos (2003).

Figura A.03 - Mutação



A.6 – Parâmetros da Evolução

A seguir será apresentado como alguns parâmetros influenciam no desempenho dos algoritmos genéticos:

- Tamanho da população: neste caso há um *trade-off* que afeta o desempenho e a eficiência do algoritmo genético, pois com uma população pequena o desempenho piora, uma vez que o espaço de busca do problema é menor. Já uma população grande, apesar de evitar convergências erradas para soluções locais ao invés de globais, necessita de mais recursos computacionais.
- Taxa de cruzamento: aqui também há um *trade-off*, uma vez que se esta taxa for alta, mais rápido novas estruturas serão introduzidas na população, mas conseqüentemente estruturas com altas aptidões poderão erroneamente ser retiradas. Já se o valor for muito baixo, o algoritmo pode ficar muito lento.
- Taxa de mutação: a mutação visa garantir que o espaço de estados irá ser melhor explorado, evitando que o algoritmo convirja rapidamente para mínimos locais. A taxa de mutação também é um fator importante pois uma taxa baixa deixa a busca estagnada em um certo valor, já uma taxa alta torna a busca muito aleatória.
- Intervalo de Geração: é o que controla o percentual da população que será substituído na próxima geração. Se tiver um valor alto, grande parte da população será substituída, o que pode acarretar em perdas de estruturas de alta aptidão, se for um valor baixo, o algoritmo pode ficar muito lento.

- Número de Geração: representa o número total de ciclos de evolução, podendo ser um dos critérios de parada do algoritmo genético. Um número pequeno de gerações reduz o desempenho uma vez que não é possível cobrir todo o espaço de busca; já um número grande acarreta em maior tempo para processamento, mas evita a convergência para soluções locais.