

## Sistema de Previsão Inteligente

Hiran de Melo<sup>1</sup>, José Homero Feitosa Cavalcanti<sup>2</sup>,  
José Felício da Silva<sup>3</sup> e Vicente de Paulo Rodrigues da Silva<sup>4</sup>

<sup>12</sup> Sócio SBA

<sup>12</sup>DEE-CCT/UFPB

<sup>3</sup>DEM-CT/UFPB

<sup>4</sup>DCA-CCT/UFPB

Av. Aprígio Veloso, 882 CEP:58.109-970 Campina Grande, PB

E-mails: <sup>12</sup>{hiran,homero}@dee.ufpb.br, <sup>3</sup>felicio@fumape.ufpb.br, <sup>4</sup>vicente@dca.ufpb.br

### Abstract

*Experimental results obtained from Artificial Neural Network (ANN), Fuzzy Set and Genetic Algorithms of an Intelligent Forecast System that is currently being developed for prediction and analysis of time series.*

### 1. Introdução

Recentemente [1] apresentaram resultados obtidos da Pesquisa & Desenvolvimento (especificamente, Projeto e teste de um Filtro Previsor Neural) de um Sistema Previsão Inteligente (SPI), que utiliza ferramentas baseadas em Rede Neurais Artificiais [2] desenvolvido para previsão de valores futuros de uma série temporal. Eles utilizaram uma Rede Neural Multi Camadas (RNMC) com algoritmo de treinamento de retropropagação ("error backpropagation") do erro. No trabalho já citado, constam as definições básicas acerca de janelas ("windowing") e alguns conceitos necessários para implementação do SPI. Nos testes realizados foi utilizada a série de manchas solares ("sunspots"), 1849-1975 [3], que além de apresentar uma forte componente de ruído, mostra um periodograma que revela que a série apresenta uma periodicidade em torno de 11 anos (10,6 anos). Entretanto, variando de modo considerável em amplitude e fase. Os valores da série de manchas solares (posteriormente ampliada até 1997, dados colhidos no SunSpot Index Data Center, [www.ndg.noaa.gov/stp/SOLAR/SSN/ssn.html](http://www.ndg.noaa.gov/stp/SOLAR/SSN/ssn.html)), além de não serem exatamente periódicos, são irregulares em amplitude. Conjeturou-se [1] que a fuzzyficação desses dados poderia melhorar a previsão. O problema é que não se tinha a idéia do número e nem dos valores dos níveis fuzzy a serem usados.

Partindo deste ponto, os autores do presente trabalho decidiram fazer a "clusterização" ou agrupamento dos dados da série [4], e usar os resultados do agrupamento como níveis fuzzy. Implementado estes novos procedimentos, observou-se, que a RNMC treinada com base no Conjunto de Janelas de Treinamento -

CJT (1;2;3;4;5;6;8;9;10) que é uma fração do conjunto de janelas totais que vai da janela 1 a janela 13 - não conseguia prever adequadamente a janela alvo 7. Embora apresentasse satisfatórias previsões para as demais janelas não utilizadas no CJT: janelas alvos 11, 12 e 13 (vê Fig.1). Conjeturou-se que o problema estava na escolha do CJT. Isto sugeriu o uso do algoritmo genético para a escolha do CJT apropriado, o que possibilitaria a detecção das janelas relevantes do conjunto de treinamento, contornando assim o problema da falta de exatidão da periodicidade, possível causa do comportamento estranho observado na previsão.




Fig.1 – Série das Manchas Solares particionizada em 13 janelas.

Na Fig.1 apresentam-se as curvas da série e da previsão obtidas após o treinamento da RNMC durante 1000 iterações. Observa-se que a previsão nas janelas 11, 12 e 13 acompanham os valores alvos (janelas inferiores mostram as diferenças entre os valores das janelas alvos e os valores da janela produzida pela RNMC). Todavia, a previsão na janela 7 apresenta um relevante distanciamento (amplitude e fase) entre a janela alvo e a janela produzida pela RNMC (curva apontada pela letra A). Na parte inferior é mostrada a curva do função erro, definida como:  $(\text{valores da janela alvo}) - (\text{valores da janela previsão})$ .

Neste artigo inicialmente, apresenta-se o SPI, uma pequena descrição dos seus blocos e uma breve

descrição da série temporal. Em seguida, propõe-se o “Diagrama de Aglomeração” das amostras da série temporal, para ser usado para a escolha do número de níveis fuzzy. A seguir, descreve-se sucintamente Algoritmo Genético e apresentam-se resultados experimentais. Por último, conclui-se o trabalho com comentários sobre os resultados obtidos e citam-se os novos problemas a serem superados no intuito da implementação plena do SPI.

### 1.1. O SPI

As séries temporais tem sido estudadas por diversas perspectivas, das quais destaca-se a análise paramétrica e a análise espectral [5]. O objetivo principal destas análises constitui-se, em linhas gerais, na determinação de algumas “regularidades”, tais como tendência, periodicidade e sazonalidade, e/ou na estimativa de valores futuros da série. Um atual e interessante trabalho enfatizando a previsão da tendência de uma série temporal, usando redes neurais artificiais, pode ser encontrado em [10]. Outro estimulante trabalho explorando a eficiência da RNMC na previsão de séries temporais é apresentado por [11] que utiliza o conceito de janela (window) objetivando simplificar a tarefa de previsão.

Uma nova abordagem para a solução deste antigo e estimulante problema pode ser encontrada no campo de Sistemas Inteligentes. O termo Inteligente significa buscar, identificar e emular a forma de processamento da informação executada pelo cérebro humano em situações complexas. Nestas situações não se usa conceitos explicitados em equações matemática, mas, sim a experiência adquirida mediante um processo específico de aprendizagem.

Usando a abordagem dos Sistemas Inteligentes baseada em redes neurais artificiais (RNA), Lógica Fuzzy [6] e Algoritmo Genético [7], desenvolveu-se um aplicativo denominado Sistema de Previsão Inteligentes (SPI).

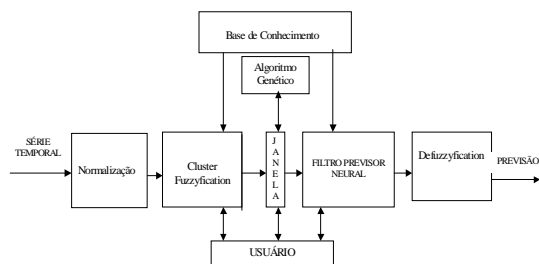


Fig.2 - Sistema de Previsão Inteligente

O Diagrama de Blocos do SPI é mostrado na Fig.2, onde as amostras de uma série temporal são normalizadas e, antes de serem processadas, podem ser fuzzyficadas e/ou agrupadas pelo “Bloco Cluster/Fuzzyfication” visando encontrar o número e as classes representativas dos dados da série temporal. A seguir, utilizando-se as classes já detectadas, as amostras da série temporal são

convertidas em variáveis linguísticas fuzzy, as quais serão agrupadas no “Bloco Janela” usando para tanto o conhecimento existente sobre a série no “Bloco Base do Conhecimento”.

A fase de definição do CJT poderá ser executada automaticamente pelo “Bloco Algoritmo Genético - AG”, ou de uma forma supervisionada pelo “Bloco Usuário” em interação com o “Bloco Janela”. No “Bloco Defuzzyfication” as variáveis linguísticas produzida pelo “Bloco Filtro Previsor Neural - FPN” são convertidas em variáveis numéricas. O FPN, devidamente treinado utilizando o CJT fornecido pelo “Bloco Usuário” ou pelo AG, executará previsões de futuras Janelas Alvos.

O Filtro Previsor Neural estudado em [1] é emulado por uma RNMC, a qual é provavelmente a arquitetura ideal para desempenhar a tarefa de prevê valores futuros de uma seqüência de observações [12]. Um estudo comparativo, realizado por [13], conclui que o método de retropropagação do erro é a melhor escolha para o treinamento da RNMC.

### 1.2. A Série Temporal : Sunspot

Na Fig.3 é mostrado o gráfico da série temporal das manchas solares (sunspot) registradas entre os anos 1849-1997. Os dados da série estão agrupados em 13 janelas, com sobrepasso igual a 11 e alvo igual a 6 (Apêndice A). Por exemplo, a primeira janela, manchas solares entre os anos 1849-1865, tem como alvo as manchas solares dos anos 1866-1871.

Um interessante resultado obtêm-se excitando o FPN não treinado. Observe-se que a saída é indiferente a janela de entrada. O FPN fornece a mesma saída para as diferentes janelas. Como, por exemplo, aplicando o CJT constituído pelas janelas 1, 2, 3, 4, 5, 6, 8, 9 e 10, denominado CJT(1;2;3;4;5;6;8;9;10), a o FPN não treinado obtêm-se o resultado ilustrado na Fig.3.

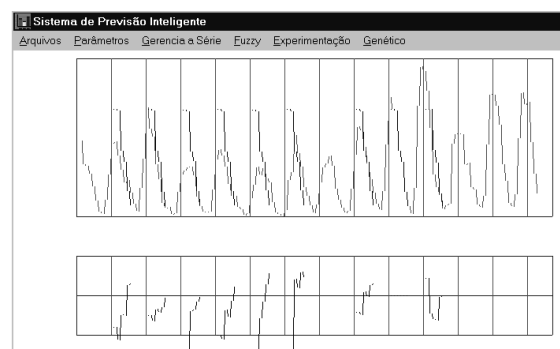


Fig.3 – A saída do FPN excitado pelas janelas do CJT (1;2;3;4;5;6;8;9;10) antes do treinamento.

### 1.3. Agrupamento dos Dados da Série

Objetivando resolver o problema detectado na Fig.1 implementou-se o “Bloco de Cluster/Fuzzification”

baseado nos Conjuntos “Fuzzy” [6]. Estabeleceu-se como ponto de partida que o número de níveis “fuzzy” seria definido pelo usuário do SPI e que o valor de cada nível poderia ser estabelecido pelo usuário ou, alternativamente, encontrado pelo método de cálculo automático conhecido como “Cluster” [4].

Na Fig. 4 é apresentado o resultado da “clusterização” da série em sete níveis fuzzy, indicados pelas variáveis lingüísticas VL1, VL2, ..., VL7, com funções pertinência triangular. Cada linha vertical corresponde a uma amostra da série, e a sua posição na abscissa corresponde ao valor da amostra normalizado entre zero e um. Os autores sugerem que os resultados da “clusterização” apresentados na Fig.5 sejam denominados “Diagrama de Aglomeração”, provavelmente equivalente ao “Dendrogram” [9] proposto pela Análise Estatística Clássica (Hierarchical Cluster Analysis).

#### 1.4. Fuzzyficação da Série

Observando-se a Fig.4, vê-se que o Diagrama de Aglomeração indica que a maioria dos dados se agrupam nos níveis inferiores. Aparentemente, o agrupamento dos dados da série em sete classes não é a melhor escolha. Possivelmente, construindo-se Diagramas de Aglomerações de 2, 3, ...,7 “clusters” e comparando-os, encontre-se o melhor número de níveis para a fuzzificação da série.

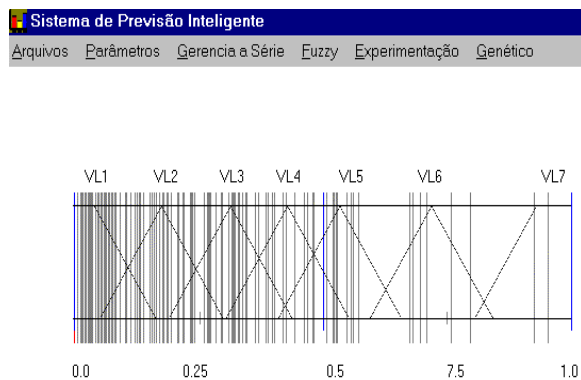


Fig. 4 Diagrama de Aglomeração

Observou-se heurísticamente que, para a série em estudo, quatro níveis seria o número indicado. Todavia, no presente trabalho, a fim de se experimentar o AG do SPI, escolheram-se sete níveis, que provavelmente é a pior escolha.

#### 1.5. O Algoritmo Genético

Algoritmo Genético (AG) é um procedimento iterativo, que mantém uma população de estruturas (chamadas indivíduos, espécies ou cromossomos) que representam possíveis soluções de um determinado problema [7]. Os AG são sistemas que se baseiam nos mecanismos da

evolução dos seres vivos [8]. O AG tem como característica a geração de um conjunto de soluções ao invés de uma única solução [8]. Possíveis soluções de um problema são combinadas através dos operadores genéticos específicos inspirados na Seleção Natural de Charles Robert Darwin (1809-1882), no Cruzamento e na Mutação. Basicamente, esses operadores modificam as estruturas (ou cromossomos) do problema, e sobrevivem para a próxima geração os mais aptos dentre essa população de indivíduos. Há uma troca aleatória, porém estruturada, de informações entre esses cromossomos (cruzamento), de modo que, a cada geração, um novo conjunto de cromossomos é criado baseado nos mais aptos da geração anterior. As mutações nos genes dos cromossomos são usualmente geradas de forma aleatória, mas os métodos são determinísticos e em geral podem ser considerados como sendo do tipo genético com regras de mutações determinísticas.

No Algoritmo Genético do SPI as janelas representam genes e o conjunto de janelas representa um cromossomo. Cada gene do cromossomo recebe um valor binário indicando a condição de treinamento da RNA. Se o valor do gene for um, indica treinamento, se o valor do gene for zero, indica não treinamento.

O AG caracteriza-se, também, por ser um processo de seleção baseado no desempenho e na população de cromossomos. Os elementos da população são listas fixas de parâmetros a serem otimizadas baseadas em um determinado índice de desempenho (“fitness”). Uma relevante questão consiste precisamente na definição do índice de desempenho apropriado ao problema que se deseja solucioná-lo. Escolheu-se, para o problema em estudo, que a melhor solução seria o cromossomo em que a média da somatória do erro quadrático de previsão de todas as janelas tivesse o menor valor.

O AG, mostrado na Fig.5, possui 5 componentes básicos: 1) Um método para codificação dos cromossomos (por exemplo, o conjunto representando a seqüência de janelas do CJT {1;0;0;0;1;1;0;0;0;1;1}, onde os bits representam genes); 2) Uma função objetivo “fitness” (menor erro médio quadrático); 3) Uma população inicial (50 cromossomos); 4) Uma população dos cromossomos escolhidos (10 cromossomos); 5) Um conjunto de operadores para formarem a evolução entre dois cromossomos de populações consecutivas (mutação e cruzamento), que são usados entre as posições das espécies; 6) Parâmetros de trabalho (por exemplo, 2% de probabilidade de mudança no cromossomo) [8].

Inicialmente, geram-se aleatoriamente uma população de 50 indivíduos. A seguir escolhem-se os cromossomos de 10 CJT que possuem o menor erro médio quadrático, denominado de comprimento. Os cromossomos escolhidos são denominados melhores previsões. Devido as características do SPI, algumas vezes é necessário encontrar as piores previsões, isto é,

encontrar o conjunto de 10 CJT que possuem o maior erro médio quadrático.

Utilizaram-se duas populações de cromossomos: 1) uma população de 50 cromossomos, denominada população principal – PP, em que os cromossomos podem se reproduzir; 2) uma população de 10 cromossomos escolhidos, ou população dos escolhidos – PE, onde são armazenados os 10 melhores cromossomos.



Fig. 5 - Fluxograma do AG

O AG implementado possui dois operadores genético que operam diretamente sobre os cromossomos da PE, a mutação e o cruzamento. Na mutação, escolhe-se aleatoriamente um cromossomo da PE, a seguir, escolhe-se aleatoriamente um gene do cromossomo, é feito a operação lógica OU-EXCLUSIVO com o seu valor, e o resultado é colocado na cópia do cromossomo. No cruzamento, escolhem-se aleatoriamente dois cromossomos da PE, a seguir, escolhe-se aleatoriamente a posição de dois genes dos cromossomos, o conjunto de genes delimitados pelos genes escolhidos são trocados entre os dois cromossomos, gerando dois novos cromossomos. Os cromossomos resultantes da mutação e cruzamento são colocados em locações escolhidas aleatoriamente na PP.

### 1.6. Resultados Experimentais

Foram feitas diversas experimentações com o AG. Decidiu-se encontrar um CJT constituído de seis janelas que gerasse as piores previsões e um outro CJT que gerasse as melhores previsões. A experimentação foi feita com NJA=6 (Vê Apêndice A) e o Bloco AG

forneceu o CJT(3;4;5;7;8;9) para as piores previsões e o CJT(4;5;6;9;10;11) para as melhores.

As Fig. 6 e Fig.7 mostram as previsões nas demais janelas após um treinamento constituído de 1000 iterações.

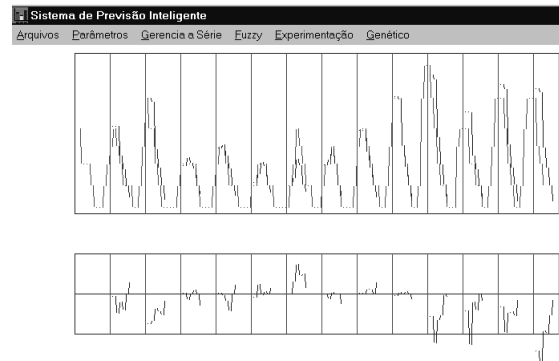


Fig.6 Treinamento e Previsões com o CJT(3;4;5;7;8;9)

Observe-se que a previsão é polarizada na média dos valores da série. Nota-se, também, que a RNA não está completamente treinada, todavia os resultados de previsão são melhores devido a maior capacidade de generalização da rede. Para o FPN treinado com o CJT(3;4;5;7;8;9) temos os seguintes erros médios quadráticos 0,0183 e 0,0750, respectivamente para as janelas alvos 12 e 13. Já para o FPN treinado com o CJT(4;5;6;9;10;11) temos os seguintes erros médios quadráticos 0,0016 e 0,0100, respectivamente para as janelas alvos 12 e 13.

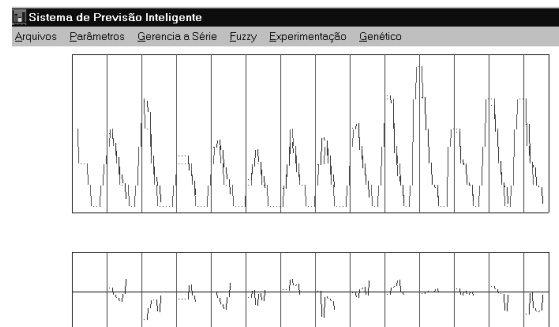


Fig.7 Treinamento e Previsões com o CJT(4;5;6;9;10;11).

### 1.7. Conclusões e Perspectivas

Muitas observações feitas durante o processo de treinamento do RNA tem orientado a pesquisa e o desenvolvimento do SPI, outras permanecem sem respostas satisfatórias.

Por exemplo: para um pequeno número de iterações algumas janelas do CJT apresentavam um comportamento surpreendente. Os erros médios quadráticos na janela alvo, inicialmente diminui e, logo após cresce, e com o aumento do número de iterações

ele tende a zero. A RNA aprende em poucas iterações as características de algumas janelas do CJT, enquanto outras janelas exigem um número maior de iterações. Será que essas observações indicam perturbações na série temporal? Ou elas estariam associadas ao tamanho das janelas de entradas? Ou, ainda, elas dependem do tamanho das janelas alvos?

Por outro lado, temos que pequenas variações nos valores próximos ao ponto de transição entre duas funções de pertinência, levam a valores fuzzificados que se diferenciam por um nível, o que resulta em um grande erro de previsão.

Durante a experimentação com os CJTs dos melhores e piores resultados observou-se que algumas janelas participavam dos dois conjuntos. Além disso, constatou-se que se for conhecido o grupo das melhores janelas, descartando as demais, consegue-se uma excelente previsão nas últimas janelas. Infelizmente este resultado não é conclusivo, pois não foram ainda realizados os exaustivos testes para os CJTs tendo um número de componentes diferentes de 6. Assim, não se garante que as últimas janelas façam parte do grupo das melhores. Como também não se garante que 6 seja o número ótimo de componentes da CJT.

Finalmente, nota-se a necessidade de definir um novo índice de desempenho para o AG e de dotar o SPI de um controle sobre o número de janelas do CJT que será produzido pelo AG.

O atual estágio da pesquisa e do desenvolvimento do SPI tem propiciado aos autores uma forte convicção que estão lidando com algo novo e que certamente se constituirá num avanço na concepção de sistemas inteligentes.

## Referências

- [1] - Melo, Hiran de & Cavalcanti, José Homero Feitosa, Filtro Previsor Neural, XII Brazilian Automatic Control Conference-XII CBA'98, setembro de 1998, Uberlândia MG, pp.319-324.
- [2] - Humelhart, D. E. e Hinton, G.E. & Williams, R.J. (1986). Learning Internal Representations by Error Propagation, Parallel Distributed Processing: Explorations in the Microstructures of Cognition, Vol.1, D.E.Humelhart & J.L.McClelland, Cambridge, MA: MIT Press, pp.318-362.
- [3] - Morettin, P. A ., Toloi, C.M.C., Gait, N. e Mesquita, A. R., 1989, , Analysis of the Relationships Between Some Natural Phenomena: Atmospheric Precipitation, Mean Sea Level and Sunspots. Relatório Técnico do Departamento de Estatística da USP, pp.2-35.
- [4] - Chen, C. H. & Bezdek, James C. - Fuzzy Logic and Neural Network Handbook - Mc Graw-Hill, Capítulo 2. 1996.
- [5] - Priestley, M. B., Spectral Analysis and Time Series, Academic Press Inc, 1996.
- [6] - Zadeh, L. A. (1993). Fuzzy Sets, Information and Control, 1965, 8, pp.28-44.
- [7] - Holland, John H. Adaptation in Natural and Artificial Systems. MIT Press/Bradford Books edition. 1992

[8] - Fogel, D.B. & Fogel, L.J., Evolutionary Computation, Special Issue ON Evolutionary Computation, Transactions on Neural Networks, Vol.5, No.1, January 1994, pp.1-147.

[9] - SPSS Inc. SPSS Base 8.0 - Applications Guide - Cluster Analysis 1998, pp. 287-308. SPPI Inc. Hall, 1998.

[10] - Saad, Emad W., Prokhorov, Danil V., Wunsch, Donald C. II, Comparative Study of Stock Trend Prediction Using Time Delay, Recurrent and Probabilistic Neural Networks, IEEE Transactions on Neural Networks, Volume 9, nº 5, September, 1998, pp. 1456-1470.

[11] - Geva, Amir B. Scale Net - Multiscale Neural Network Architecture for Time Series Prediction, IEEE Transactions on Neural Networks, Volume 9, nº 5, September, 1998, pp. 1471-1482.

[12] - Ungar, Lyle H., Forecasting, The Handbook of Brain Theory and Neural Networks, Edited by Michael A. Arbib, The Mit Press, England, 1995, pp. 399-403.

[13] - Weigend, Andreas S. e Gershenfeld, Neil A., "Results of the Time Series Prediction Competition at the Santa Fe Institute". Neural Networks Theory, Technology, and Applications, 1996, pp. 529-536..

## APÊNDICE A - Conceitos Básicos

**Definição 1** - Janela é um conjunto de amostras consecutivas de uma série temporal.

**Definição 2** - O conjunto das amostras da Janela a serem usados como excitação da RNA é denominado Janela Entrada.

**Definição 3** - O conjunto das amostras da Janela a serem usados como alvo para treinamento da RNA é denominado Janela Alvo.

**Definição 4** - Define-se Sobrepasso como a diferença entre os pontos iniciais de duas janelas consecutivas. (Fig. 8)




Fig.8 Conjunto de Janelas para Treinamento - CJT com sobrepasso 11.

**Definição 5** - Um Conjunto de Janelas consecutivas usadas para Treinamentos denomina-se CJT.

**Definição 6** - Define-se NJA (Número de Janelas Ativas) como o número de janelas do CJT que devem ser treinadas.