

FUZZYFUTURE: FERRAMENTA DE PREVISÃO DE SÉRIES TEMPORAIS BASEADA EM SISTEMA HÍBRIDO FUZZY-GENÉTICO

Victor Barboza Brito
Marley Vellasco
Ricardo Tanscheit

Departamento de Engenharia Elétrica
Pontifícia Universidade Católica do Rio de Janeiro (PUC-Rio)
e-mails: victorbb@gmail.com; marley@ele.puc-rio.br; ricardo@ele.puc-rio.br
Rua Marquês de São Vicente, 225, Gávea
22451-900, Rio de Janeiro, RJ, Brasil

Resumo – A previsão de séries temporais está presente em diversas áreas, como os setores elétrico, financeiro, econômico e industrial. Em todas essas áreas, as previsões são fundamentais para a tomada de decisões no curto, médio e longo prazo. As técnicas estatísticas são as mais utilizadas em problemas de previsão de séries, principalmente por apresentarem um maior grau de interpretabilidade, garantido pelos modelos matemáticos gerados. No entanto, técnicas de inteligência computacional têm sido cada vez mais aplicadas em previsão de séries temporais, com destaque para as Redes Neurais Artificiais (RNA) e os Sistemas de Inferência Fuzzy (SIF). Muitos são os casos de sucesso de aplicação de RNAs, porém os sistemas desenvolvidos são do tipo “caixa preta”, inviabilizando uma melhor compreensão do modelo final de previsão. Já os SIF são interpretáveis, entretanto sua aplicação é comprometida pela dependência de criação de regras por especialistas e pela dificuldade em ajustar os diversos parâmetros como o número e formato de conjuntos. Além disso, a falta de pessoas com o conhecimento necessário para o desenvolvimento e utilização de modelos baseados nessas técnicas também contribui para que estejam pouco presentes na rotina de planejamento e tomada de decisão na maioria das organizações. Este trabalho apresenta o desenvolvimento de uma ferramenta computacional, capaz de realizar previsões de séries temporais, baseada em um modelo híbrido fuzzy-genético, onde a previsão é realizada através de um Sistema de Inferência Fuzzy cujos parâmetros são otimizados por Algoritmos Genéticos, oferecendo uma interface gráfica intuitiva e amigável.

Palavras-chave – Séries temporais; previsão; lógica fuzzy; algoritmos genéticos; ferramenta.

1 Introdução

A previsão de séries temporais está presente em diversas áreas. No setor elétrico, por exemplo, as previsões de carga são indispensáveis tanto na operação eficiente e segura do sistema quanto na tomada de decisão sobre a expansão e o planejamento da operação. Em outros setores, como o financeiro, prever o valor futuro de ações é de extremo interesse não só de investidores em bolsas de valores, como também de pesquisadores acadêmicos que buscam entender o comportamento do mercado de ações. Na economia, bancos centrais necessitam de previsões de inflação para controlar os instrumentos que afetam o comportamento da economia. No setor industrial, previsões de demanda fundamentam o planejamento de curto e longo prazo de marketing, logística, produção e finanças. Entre as diversas técnicas de previsão de séries temporais existentes, certamente as técnicas estatísticas são as mais utilizadas, principalmente por apresentarem um maior grau de interpretabilidade, garantido pelos modelos matemáticos gerados.

No entanto, técnicas de inteligência computacional têm sido cada vez mais aplicadas em problemas de previsão de séries temporais, com destaque para as Redes Neurais Artificiais (RNA) e os Sistemas de Inferência Fuzzy (SIF). Muitos são os casos de sucesso de aplicação de Redes Neurais em previsão de séries (Kong & Martin, 1995; Yip et al., 1997; Thiesing & Vomberger, 1997; Zhang & Kline, 2007) porém os sistemas desenvolvidos são do tipo “caixa preta”, inviabilizando uma melhor compreensão do modelo final de previsão. Por outro lado, os Sistemas de Inferência Fuzzy são interpretáveis, mas sua aplicação em previsão de séries temporais é comprometida pela dependência de criação de regras por especialistas. Mesmo com o uso de técnicas de extração de regras a partir de dados, como o procedimento proposto em (Wang & Mendel, 1992), ainda permanecem as dificuldades referentes ao ajuste de parâmetros como o número de conjuntos, o formato dos mesmos e o tamanho da janela. Além disso, a falta de pessoas com o conhecimento necessário para o desenvolvimento e utilização de modelos baseados nessas técnicas também contribui para que estejam pouco presentes na rotina de planejamento e tomada de decisão na maioria das organizações. Assim, este trabalho tem como objetivo desenvolver uma ferramenta computacional amigável, baseada na teoria de sistemas de inferência fuzzy, capaz de realizar previsões de séries temporais em diferentes horizontes, com boa precisão. O desenvolvimento da ferramenta tem como principais focos:

- Oferecer uma interface gráfica amigável e intuitiva, de forma a viabilizar seu uso mesmo por usuários que não sejam especialistas nas teorias aplicadas, necessitando apenas de um conhecimento básico sobre as mesmas;
- Garantir a interpretabilidade do sistema e o entendimento do comportamento das previsões geradas, a partir da aplicação de Sistemas de Inferência Fuzzy;

- Permitir um ajuste automático do sistema de inferência fuzzy, através de algoritmos genéticos, de forma a determinar automaticamente a melhor configuração dos conjuntos fuzzy utilizados no modelo de previsão; e
- Garantir a precisão matemática nas formulações empregadas.

O artigo está organizado em mais cinco seções. A Seção 2 apresenta uma breve descrição do método de extração de regras fuzzy apresentado em (Wang & Mendel, 1992). A Seção 3 descreve em detalhes os módulos da ferramenta computacional proposta, denominada FuzzyFuture. A Seção 4 apresenta os resultados obtidos com diferentes séries temporais e a Seção discute as conclusões do trabalho.

2 Técnicas de Previsão de Séries Temporais

Há inúmeras técnicas estatísticas para previsão de séries temporais. A maioria se baseia na identificação de uma ou mais componentes da série temporal (Hanke & Reitsch, 1995): nível, tendência, sazonalidade, ciclo e aleatoriedade. Entre as técnicas estatísticas mais conhecidas de previsão de séries estão os amortecimentos exponenciais (simples, duplo e triplo) (Hanke & Reitsch, 1995), as médias móveis (simples e dupla) (Mentzer & Bienstock, 1998), o ARIMA e o SARIMA (Box & Jenkins, 1976). Essas técnicas são bastante utilizadas, porém exigem uma análise prévia da série, de forma a identificar as componentes presentes, e assim possibilitar a seleção da técnica mais adequada. Além disso, todas se baseiam na premissa de relação linear entre os valores passados e os futuros. Assim, no caso de séries com comportamentos mais complexos, técnicas de inteligência computacional vêm sendo aplicadas com o objetivo de se obter previsões mais precisas, principalmente Redes Neurais Artificiais (RNA) (Kong & Martin, 1995; Yip et al., 1997; Thiesing & Vomberger, 1997) e Sistemas de Inferência Fuzzy (FIS) (Chen & Chen, 2011; Elias & Hatzigargyriou, 2009). Observa-se também o crescente desenvolvimento de modelos híbridos, nos quais duas ou mais técnicas de inteligência computacional são combinadas (Gorzalczany, 1998; Kung et al., 1998; Kim & Kim, 1997; Bermudez et al., 2007).

2.1 Sistemas de Inferência Fuzzy aplicadas em Previsão

No caso de previsão de séries temporais, a geração de regras fuzzy unicamente a partir do conhecimento de especialistas pode se mostrar inviável. Assim, a utilização de um método automático de extração de regras, como o proposto em (Wang & Mendel, 1992), se torna extremamente importante neste tipo de aplicação. A seguir apresenta-se, de forma resumida, os cinco passos que compõem este método.

- **Passo 1: Dividir o domínio de entrada e de saída em regiões fuzzy** \Rightarrow Seja um conjunto de pares entrada / saída composto de n variáveis de entrada (x_1, x_2, \dots, x_n) e uma variável de saída (y). O universo de discurso de cada variável de entrada e saída deve ser dividido em $2N+1$ regiões, sendo atribuído um conjunto fuzzy para cada uma (**Figura 1**);




Figura 1 - Divisão do universo de discurso da série em conjuntos fuzzy

- **Passo 2: Gerar regras fuzzy a partir dos dados fornecidos** \Rightarrow Primeiramente determina-se o grau de pertinência de cada um dos dados fornecidos ($x_1^{(i)}, x_2^{(i)}, \dots, x_n^{(i)}, y^{(i)}$) a cada região. Em seguida, atribui-se a um valor dado a região de maior grau de pertinência. Por último, define-se uma regra a partir de cada par de dado entrada/saída. As regras geradas dessa forma utilizam sempre o conectivo “e” no antecedente, ou seja, regras nas quais todos os antecedentes devem ter grau de pertinência diferente de zero para que o conseqüente ocorra;
- **Passo 3: Atribuir um grau a cada regra gerada** \Rightarrow Como geralmente em aplicações práticas se trabalha com muitos pares de dados, é altamente provável a geração de regras conflitantes. Regras conflitantes são regras que apresentam os mesmos antecedentes, mas com conseqüentes diferentes. O tratamento dado para resolver essa questão consiste em atribuir um grau para cada regra, e dentro de um conjunto de regras conflitantes, aceita-se apenas aquela de maior grau, eliminando as demais. O grau de uma regra é calculado multiplicando-se o grau de pertinência de cada elemento da regra (antecedentes e conseqüente);
- **Passo 4: Criar uma base de regras combinada** \Rightarrow Após a geração de todas as regras possíveis a partir dos dados numéricos – e exclusão das regras conflitantes – pode-se criar a base de regras combinada, consolidando essas regras com as regras lingüísticas criadas pelos especialistas. Para isso, assume-se que cada regra criada pelos especialistas também tem um grau associado, definido pelo próprio especialista, que traduz a importância daquela regra;

- **Passo 5: Definir estratégia de defuzzificação** ⇨ Para calcular o valor de saída para um dado conjunto de valores de entrada primeiramente deve-se percorrer todas as regras geradas, calculando o grau de ativação de cada uma, através do uso da implicação MAMDANI, definido da seguinte forma:

$$\mu_{O_i}^i = \mu_{I_1^i}(x_1) \cdot \mu_{I_2^i}(x_2) \cdot \dots \cdot \mu_{I_n^i}(x_n) \quad (1)$$

onde O_i denota a região (conjunto fuzzy) do conseqüente da regra i , e I_j^i denota a região do antecedente j na regra i . Finalmente, utiliza-se, por exemplo, o método de defuzzificação por centróide para calcular a saída precisa y .

3 FuzzyFuture: Ferramenta de Previsão de Séries Temporais

3.1 Introdução

O FuzzyFuture é uma ferramenta computacional que tem como objetivo realizar previsões de séries temporais utilizando Sistemas de Inferência Fuzzy com otimização de parâmetros por Algoritmos Genéticos. O FuzzyFuture foi desenvolvido em linguagem de programação C# para ambiente Windows. Seu código é aberto, porém restrito para uso acadêmico apenas. A tela principal da ferramenta é exibida na Figura 2.

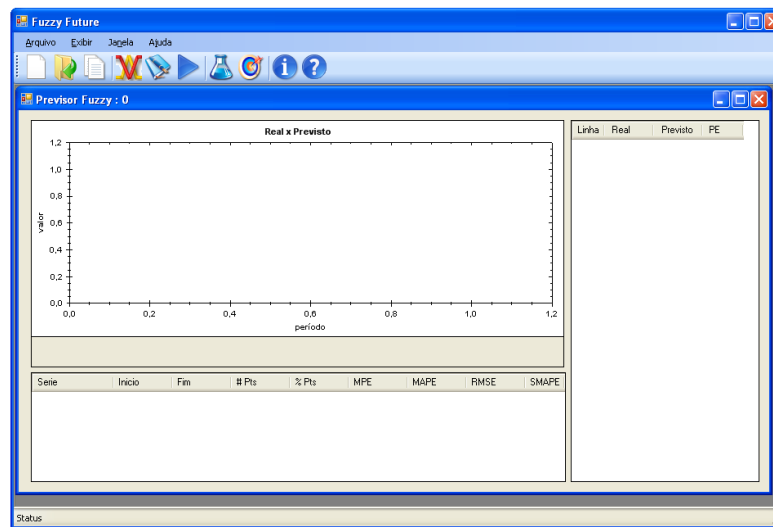


Figura 2- Tela Principal do FuzzyFuture

3.2 Estrutura e Metodologia

O FuzzyFuture está estruturado em seis módulos (ver Figura 3): Laboratório, Fuzzificação, Regras, Inferência, Defuzzificação e Otimização de Parâmetros, descritos a seguir.

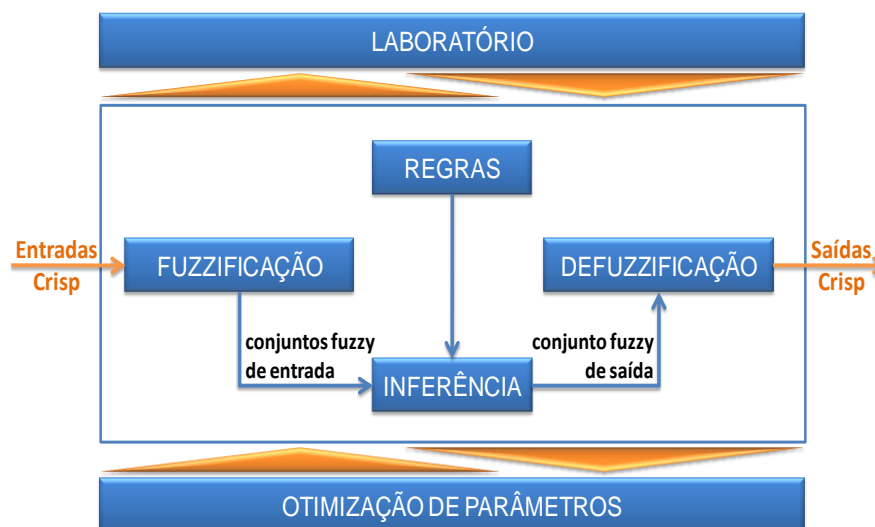


Figura 3 - Os seis módulos do FuzzyFuture

- **Módulo de Fuzzificação** ⇒ configura-se a variável fuzzy de entrada, definindo o formato das funções de pertinência (triangular, trapezoidal ou sino) e seus parâmetros. Os conjuntos são apresentados graficamente e podem ser editados arrastando-se seus pontos no gráfico (ver **Figura 4**);

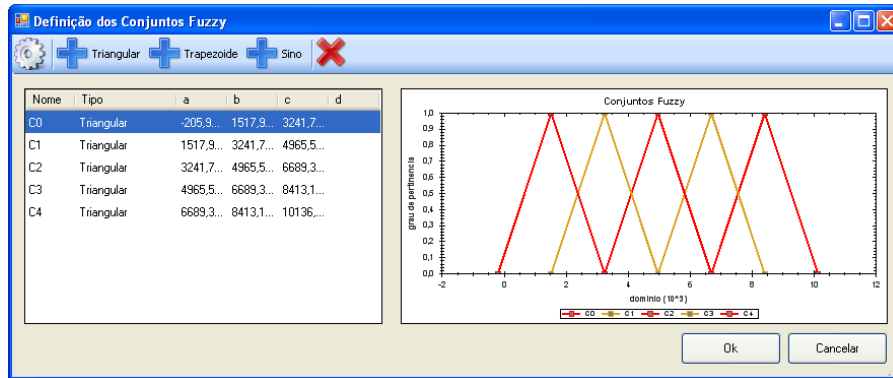


Figura 4 - Definição dos conjuntos fuzzy

- **Módulo de Regras** ⇒ as regras são geradas automaticamente a partir da definição do tamanho da janela, do horizonte de previsão e do tipo de previsão (*singlestep* ou *multistep*), conforme ilustrado na **Figura 5**. Caso seja selecionado o tipo de previsão *multistep*, as regras são geradas considerando o horizonte de um passo à frente, isto é, a variável de saída (consequente da regra) será o valor da série no instante seguinte ao último valor observado. Enquanto que no *multistep* os valores do horizonte são previstos sempre 1 passo a frente da janela, no *singlestep* são realizadas *h* previsões do *h*-ésimo valor a frente, onde *h* é o horizonte de previsão. As regras são geradas considerando o horizonte *h* informado pelo usuário. Como resultado, a base de regras criada após o término do treinamento é utilizada para calcular a previsão para o horizonte definido previamente. Como se pode notar, diferentemente do *multistep*, no *singlestep* os valores previstos nunca são utilizados na janela de entrada. Essa diferença é fundamental e tem grande impacto no desempenho do predictor. Espera-se que, para determinadas séries, a previsão por *singlestep* gere melhores resultados, enquanto que em outras, previsões mais acuradas sejam obtidas utilizando o *multistep*.



Figura 5 – Geração de Regras

- **Módulo de Inferência** ⇒ calcula o grau de ativação de cada regra gerada, resultando na previsão representada por uma variável fuzzy (ver **Figura 6**);

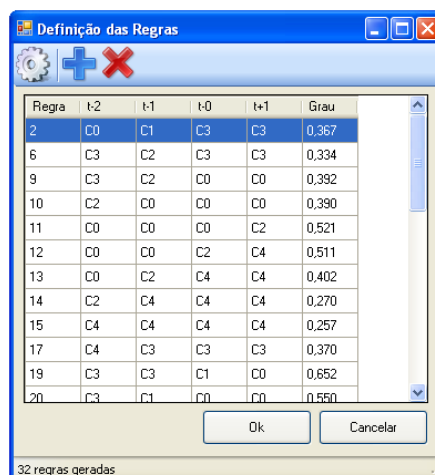


Figura 6 – Regras geradas e graus de pertinência calculados

- **Módulo de Defuzzificação** ⇒ traduz o conjunto fuzzy de saída, resultante do processo de inferência, em uma saída numérica precisa. As previsões então são apresentadas de forma gráfica para cada período da série;
- **Módulo Laboratório** ⇒ permite a geração de diversos previsores, com diferentes parametrizações de conjuntos fuzzy, diferentes tamanhos de janela e horizontes. Os experimentos gerados podem ser testados em série de forma automática e ordenados por qualquer indicador de erro do grupo de validação (ver **Figura 7**). Qualquer experimento pode ser aberto, exibindo a tela padrão com o gráfico comparativo, tabela de dados e indicadores de erros por grupo (treinamento, validação e teste). Após a realização de cada experimento, as diferentes métricas de erro no conjunto de validação são exibidas (MPE, MAPE, RMSE e SMAPE), após serem calculadas de acordo com as equações abaixo:

$$MPE = \frac{1}{n} \cdot \sum_{t=1}^n \frac{R_t - P_t}{R_t} \times 100 \quad (2)$$

$$MAPE = \frac{1}{n} \cdot \sum_{t=1}^n \frac{|R_t - P_t|}{R_t} \times 100 \quad (3)$$

$$RMSE = \sqrt{\frac{1}{n} \cdot \sum_{t=1}^n (R_t - P_t)^2} \quad (4)$$

$$SMAPE = \frac{1}{n} \cdot \sum_{t=1}^n \frac{|R_t - P_t|}{(R_t + P_t)/2} \quad (5)$$

onde:

R_t : observação no t -ésimo período do conjunto de validação

P_t : valor previsto para o t -ésimo período do conjunto de validação

n : número de períodos no conjunto de validação

A ferramenta também apresenta o valor do indicador “capacidade de previsão” (cp) de cada experimento. O indicador “cp” mede o percentual de pontos de dados no conjunto validação para os quais o SIF foi capaz de realizar a previsão, isto é, pelo menos uma regra foi ativada. Esse indicador pode ser utilizado para descartar aqueles previsores que, apesar de apresentarem um erro médio baixo, provavelmente não serão eficientes para prever o comportamento da série futura;

Id	Função	Num Conj	Tam Janela	Multi Step	Horizonte	Interseção	Margem	MPE	MAPE	RMSE	SMAPE	cp
1	Triangular	3	3	Não	1	0,4	0,1	-0,0911	0,1771	0,4208	0,1479	1
2	Triangular	3	3	Sim	1	0,4	0,1	-0,4966	0,5173	0,7192	0,3169	1
3	Triangular	3	4	Não	1	0,4	0,1	-0,0247	0,1766	0,4202	0,166	1
4	Triangular	3	4	Sim	1	0,4	0,1	0,0526	0,1265	0,3557	0,1395	1
5	Triangular	3	5	Não	1	0,4	0,1	0,002	0,1974	0,4443	0,1984	1
6	Triangular	3	5	Sim	1	0,4	0,1	-0,4576	0,5403	0,7351	0,3504	1
7	Triangular	3	6	Não	1	0,4	0,1	-0,0051	0,1878	0,4333	0,1821	1
8	Triangular	3	6	Sim	1	0,4	0,1	0,0826	0,2427	0,4926	0,2666	1
9	Triangular	3	7	Não	1	0,4	0,1	-0,011	0,1814	0,4259	0,1809	1
10	Triangular	3	7	Sim	1	0,4	0,1	0,0552	0,1963	0,4431	0,223	1
11	Triangular	3	8	Não	1	0,4	0,1	-0,0175	0,1677	0,4095	0,1721	1
12	Triangular	3	8	Sim	1	0,4	0,1	0,1263	0,3677	0,6063	0,4617	0,7647
13	Triangular	3	9	Não	1	0,4	0,1	-0,0101	0,1417	0,3765	0,1474	1
14	Triangular	3	9	Sim	1	0,4	0,1	0,0373	0,1881	0,4337	0,202	1
15	Triangular	3	10	Não	1	0,4	0,1	-0,0306	0,1527	0,3907	0,1564	1

Figura 7 – Geração e teste de experimentos

- **Módulo Otimização de Parâmetros** ⇒ aplica a técnica de algoritmos genéticos para otimizar os parâmetros dos conjuntos fuzzy que compõem a variável fuzzy de um determinado previsor, de forma a melhorar seu desempenho.

3.2.1 Modelagem do Algoritmo Genético do Módulo de Otimização de Parâmetros

A seguir são descritos os principais componentes da modelagem do algoritmo genético que compõe o módulo de otimização.

Representação: Foi considerada a representação real, onde o tamanho do cromossomo é definido pelo número de parâmetros a serem otimizados, sendo que cada gene representa um desses parâmetros. Como cada conjunto triangular possui 3 parâmetros, tem-se: tamanho do cromossomo = 3 * num_conjuntos. Assim, uma variável fuzzy com 3 conjuntos terá 9 parâmetros a serem otimizados (Figura 8).




Figura 8 - Exemplo de representação com variável fuzzy de 3 conjuntos

Decodificação: a solução é reconstruída a partir do cromossoma, considerando que cada conjunto de 3 genes seqüenciais representam os valores dos parâmetros de cada conjunto da variável fuzzy otimizada.

Avaliação: a função de avaliação utilizada é a média dos erros percentuais absolutos (MAPE) no conjunto de validação.

Seleção e Reprodução: A seleção dos genitores foi implementada com o método da roleta (Davis, 1990). Já a técnica empregada para reprodução dos indivíduos foi a troca parcial da população a cada geração (*steady state*). A parcela da população trocada a cada geração (GAP) pode ser parametrizada pelo usuário usando a interface da ferramenta.

Operadores: Foram implementados dois operadores: o cruzamento aritmético e a mutação *creep* (Davis, 1990).

Parâmetros da Evolução: Todos os principais parâmetros da evolução podem facilmente ser modificados pelo usuário, usando a interface da ferramenta: número de experimentos, número de gerações, tamanho da população, taxas iniciais e finais de *crossover*, taxas iniciais e finais de mutação e taxas iniciais e finais de *steady state*.

A geração da população inicial é feita por um algoritmo auxiliar, elaborado para criar variações de um indivíduo inicial, respeitando algumas restrições para evitar a geração de parâmetros inconsistentes em um indivíduo. O algoritmo auxiliar de geração da população inicial tem extrema importância, pois garante que a evolução iniciará somente com indivíduos válidos. A seleção do *crossover* do tipo aritmético como operador tem papel semelhante, pois uma combinação linear de dois cromossomos genitores válidos gera cromossomos filhos também válidos. Assim, a única possibilidade de geração de soluções com parâmetros inconsistentes durante a evolução seria em função da mutação *creep*. Para minimizar essa possibilidade, a mutação *creep* foi implementada de forma a garantir variações pequenas ao redor do valor original. Assim, garante-se que a geração de soluções com parâmetros inconsistentes é bem pequena, podendo-se então assumir que todos os cromossomos gerados são válidos, preservando o desempenho do GA. É importante ressaltar que aqueles cromossomas que representam soluções com parâmetros inconsistentes, além de serem gerados com baixa frequência, tendem a ser eliminados da população por apresentarem baixa aptidão.

3.3 Funcionalidades Básicas

O FuzzyFuture foi criado com foco na interface e na customização de todos os elementos do Sistema de Inferência Fuzzy para a previsão da série temporal de interesse. As funcionalidades básicas que contribuem para uma interface amigável são:

- **Importação da Série:** O FuzzyFuture permite a importação de arquivos em formato txt, com valores separados em linhas e separador de decimal igual ao do sistema (ver Figura 9);

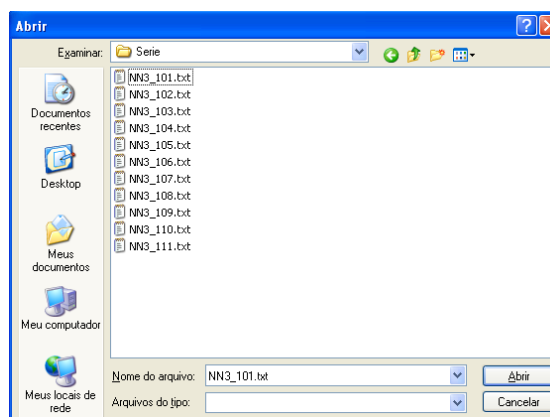


Figura 9 – Importação de arquivos txt

- **Visualização dos dados:** a série real e a série prevista podem ser visualizadas de forma gráfica e seus valores são exibidos em tabelas (ver **Figura 10**);
- **Definição dos grupos de treinamento, validação e teste:** a série temporal pode ser facilmente dividida nos três grupos necessários para uma boa modelagem da série (ver **Figura 10**);
- **Avaliação do previsor:** a série prevista é calculada e plotada no mesmo gráfico da série real para facilitar comparação (ver **Figura 10**). Os indicadores de erro MAPE, MPE, RMSE e SMAPE são calculados para os três grupos previamente definidos (treinamento, validação e teste);

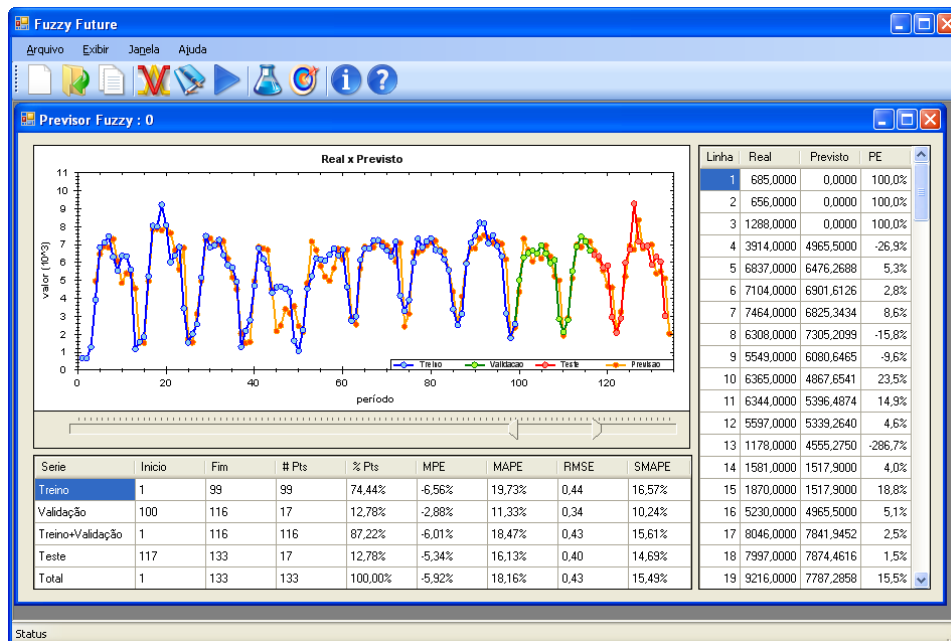


Figura 10 – Visualização dos dados importados, da série prevista, e dos indicadores de erro

- **Comparação de previsores:** diversos previsores podem ser configurados simultaneamente, em diferentes janelas, permitindo a comparação dos resultados. Um previsor pode ser duplicado para uma nova janela (ver **Figura 11**), possibilitando que sua configuração possa ser alterada, sem que se perca o previsor original, facilitando assim uma comparação direta.

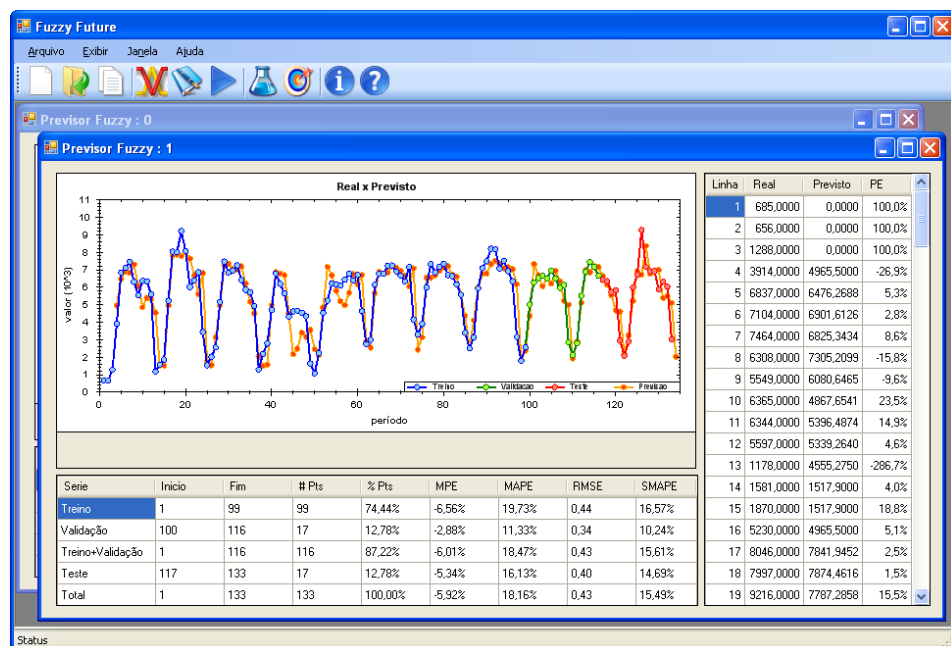


Figura 11 – Duplicação de Previsores

4. Estudo de Caso e Resultados

Finalizado o desenvolvimento da ferramenta, é indispensável testar suas funcionalidades e a eficácia da aplicação conjunta dos seus módulos de geração de experimentos e de otimização dos parâmetros dos conjuntos fuzzy por algoritmos genéticos. Assim, foi selecionado um conjunto de séries temporais e, utilizando apenas a ferramenta desenvolvida nesse estudo, foram realizadas previsões para essas séries.

4.1 Dados utilizados e tratamento

Foram selecionadas as 11 séries temporais com dados mensais que compõem o conjunto reduzido do *Forecasting Competition* de 2006/07 organizado pela *Artificial Neural Network & Computational Intelligence Forecasting Competition* (<http://www.neural-forecasting-competition.com/NN3/>).

O objetivo principal desta competição consiste em avaliar o progresso no desenvolvimento de modelos de previsão de séries temporais baseados em redes neurais e outras técnicas de inteligência computacional. O evento em questão foi patrocinado pela empresa SAS e pelo *International Institute of Forecasters* (IIF).

Das 11 séries selecionadas, oito apresentam 144 pontos de dados, duas apresentam 133 pontos de dados e uma apresenta 141 pontos de dados. Assim como na competição, foram calculadas previsões para 18 passos a frente em cada uma das séries. Logo, os últimos 18 pontos de dados de cada série foram reservados para o grupo de teste. Os 18 pontos de dados anteriores a esses foram reservados para o conjunto de validação. As observações restantes compuseram o grupo de treino.

4.2 Procedimentos e Parametrizações

Para cada uma das onze séries temporais avaliadas foi realizado o procedimento composto por três etapas:

- **Seleção da melhor configuração de FIS avaliada:** Para cada uma das 11 séries temporais foram avaliadas 96 configurações diferentes, resultantes da combinação das seguintes opções de parâmetros: número de conjuntos fuzzy: 3, 5, 7, 9, 11, 13, 15, 17, 19, 21, 23 e 25; tamanho da janela: 3, 6, 9 e 12 meses; tipo de previsão: multistep e singlestep; função de pertinência: triangular.

É importante ressaltar que, independente do tipo de previsão escolhido, sempre são calculados os valores previstos para os 18 passos seguintes ao conjunto de validação, sem que as observações do grupo de teste sejam utilizadas. No entanto, enquanto que no *multistep* são geradas 18 previsões sempre do valor logo a frente da janela, no *singlestep* são calculadas 18 previsões sempre do 18º valor a frente da janela. Em função desta diferença, poder-se-ia dizer que a previsão por *multistep* sempre resultará em um desempenho melhor. No entanto, enquanto que no *multistep*, a partir do 2º passo, previsões anteriores são utilizadas para o cálculo das previsões seguintes, no *singlestep* somente os dados reais são utilizados na janela. Assim, é esperado que em algumas séries a previsão por *multistep* gere melhores resultados, e em outras o melhor desempenho seja alcançado com o *singlestep*.

O desempenho de cada configuração foi analisado pelo MAPE no conjunto de validação. Para o cálculo do desempenho de cada uma das 96 configurações, foi utilizado o módulo “laboratório” implementado na ferramenta.

Como dentre as configurações avaliadas existem variáveis com muitos conjuntos fuzzy combinados com longas janelas, o indicador “capacidade de previsão” calculado pela ferramenta foi utilizado para realizar um filtro inicial. Configurações que apresentaram incapacidade de prever mais de 2 pontos entre os 18 do conjunto de validação foram excluídas, independente do MAPE resultante. Assim, somente as configurações com “capacidade de previsão” igual a 88,9% ou superior foram classificadas pelo MAPE.

Para cada série temporal, foi selecionada a configuração que apresentou o menor MAPE no conjunto de validação, após o filtro pela “capacidade de previsão”.

- **Otimização do FIS selecionado:** Os parâmetros dos conjuntos fuzzy do FIS selecionado foram otimizados utilizando o módulo de algoritmos genéticos. Com o objetivo de estabelecer os parâmetros de evolução adequados, realizou-se um estudo preliminar. Primeiramente selecionou-se uma das onze séries para ser utilizada no estudo. Como os comportamentos das onze séries são significativamente distintos entre si, a série NN3_101 foi selecionada de forma arbitrária. Em seguida, um previsor singlestep com 9 conjuntos fuzzy e janela de 3 períodos foi utilizado para a previsão de 18 períodos a frente da série NN3_101. Esta série foi escolhida arbitrariamente, uma vez que nenhuma das onze séries apresenta uma característica diferenciada que motivasse sua seleção. Essa configuração foi otimizada pela ferramenta, considerando as 8 diferentes combinações de parametrização representadas na Tabela 1.

A evolução por 40 gerações de uma população com 100 indivíduos garantiu a convergência de todas as combinações testadas, sendo a combinação “GA 06” a que resultou em um melhor desempenho. O resultado deste estudo foi extrapolado para as demais séries, ou seja, para todas as 11 séries selecionadas para aplicação da ferramenta, o módulo de otimização por GA foi parametrizado conforme a combinação GA 06. Porém, sabe-se que apesar da combinação do GA06 ter se mostrado a melhor para a série selecionada, não há garantia que para as demais séries a convergência também seja atingida mais rapidamente com essa parametrização.

Tabela 1 - Combinações de parametrizações avaliadas

Parâmetro	GA 01	GA 02	GA 03	GA 04	GA 05	GA 06	GA 07	GA 08
Taxa inicial de crossover	0,80	0,80	0,95	0,95	0,90	0,90	0,90	0,90
Taxa final de crossover	0,80	0,80	0,05	0,05	0,70	0,70	0,60	0,60
Taxa inicial de mutação	0,05	0,05	0,05	0,05	0,01	0,01	0,01	0,01
Taxa final de mutação	0,05	0,05	0,95	0,95	0,10	0,10	0,20	0,20
Gap do Steady State	0,30	0,70	0,30	0,70	0,30	0,70	0,30	0,70

- **Comparação de resultados:** Os desempenhos do SIF selecionado e do SIF otimizado são comparados analisando o erro percentual médio absoluto (MAPE) no conjunto de teste. O sucesso da otimização do SIF selecionado é determinado pela redução desse indicador.

A diferença das médias dos erros percentuais absolutos das previsões em toda a série foi testada a partir do teste-t de duas amostras pareadas (Decoursey, 2003). Como o objetivo final é saber se a média dos erros gerados pela previsão do SIF otimizado é estatisticamente menor que a média dos erros gerados pela previsão do SIF selecionado, foi utilizado o teste-t uni caudal. Caso a hipótese H0 possa ser rejeitada com nível de significância de 10%, pode-se afirmar que a previsão gerada pelo SIF otimizado apresenta MAPE significativamente menor que a previsão gerada pelo FIS selecionado.

4.3 Resultados

A **Tabela 2** exibe os resultados obtidos com a aplicação da ferramenta nas séries selecionadas.

Tabela 2 – Resultados do estudo de caso

Série	MAPE Treino+Validação			MAPE Teste			Resultado Teste-t valor-p
	SIF Selecionado	SIF Otimizado	Var %	SIF Selecionado	SIF Otimizado	Var %	
NN3_101	2.2%	1.9%	-14.0%	3.4%	3.1%	-10.5%	4.4%
NN3_102	24.2%	19.2%	-20.3%	54.3%	17.9%	-66.9%	0.0%
NN3_103	105.8%	98.5%	-6.9%	49.0%	49.1%	0.1%	NA
NN3_104	16.2%	13.9%	-14.5%	9.3%	6.4%	-31.3%	0.5%
NN3_105	1.2%	1.2%	-6.5%	3.1%	3.1%	-1.6%	6.2%
NN3_106	6.6%	5.6%	-16.2%	3.4%	7.0%	105.3%	NA
NN3_107	2.8%	1.9%	-31.9%	4.8%	4.4%	-9.3%	0.0%
NN3_108	19.9%	19.3%	-3.2%	26.8%	26.1%	-2.7%	14.6%
NN3_109	2.2%	1.8%	-18.3%	11.4%	3.8%	-66.9%	0.0%
NN3_110	62.8%	44.3%	-29.4%	35.8%	35.7%	-0.4%	7.9%
NN3_111	8.8%	6.9%	-22.3%	46.3%	17.3%	-62.8%	0.0%
Média 1	23.0%	19.5%	-16.7%	22.5%	15.8%	-13.4%	2.4%
Média 2	15.1%	11.4%	-19.6%	21.1%	11.5%	-31.2%	2.4%

Pode-se perceber que, para a maioria das séries, a otimização dos parâmetros, visando à minimização do MAPE nos conjuntos de treino e validação, ocasionou uma redução do erro no conjunto de teste. As exceções foram nas séries NN3_103 e NN3_106 que apesar de terem o erro da previsão reduzido nos conjuntos de treino e validação, houve um aumento do MAPE no conjunto de teste. Já a série NN3_108, apesar de ter apresentado uma redução do MAPE, o resultado do teste-t indicou que o erro médio alcançado com a otimização não pode ser considerado menor - com um nível de significância de 10% - que o obtido inicialmente. Dessa forma, em oito das onze séries testadas o procedimento de otimização dos parâmetros teve como consequência o aumento do grau de precisão dos valores previstos no conjunto de teste.

Com isso, a média do MAPE entre todas as 11 séries (Média 1) reduziu de 22,5% para 15,8% no conjunto de teste. Considerando apenas as 8 séries que apresentaram redução do erro no conjunto de teste (Média 2) o MAPE foi reduzido de 21,1% para 11,5%. Esses resultados comprovam o potencial do módulo de otimização do FuzzyFuture.

5 Conclusões

Este artigo teve como principal proposta o desenvolvimento de uma ferramenta computacional capaz de realizar previsões de séries temporais, aplicando a teoria de sistemas de inferência fuzzy em conjunto com a otimização de parâmetros por algoritmos genéticos, oferecendo, simultaneamente, uma interface gráfica intuitiva de forma a viabilizar seu uso mesmo por usuários que não sejam especialistas nas teorias aplicadas.

Assim, foi concebido o FuzzyFuture, ferramenta desenvolvida em C#, compatível com o Microsoft Windows, completamente baseada em interface gráfica, na qual há a janela principal do programa, a partir da qual pode-se criar vários previsores, alterando facilmente a visualização entre eles, caracterizando um funcionamento semelhante a de softwares de uso altamente difundido com o editores de textos e planilhas eletrônicas.

A base conceitual matemática do FuzzyFuture consiste em um sistema híbrido fuzzy-genético, no qual o sistema de inferência fuzzy invoca um algoritmo genético para a otimização dos parâmetros dos conjuntos que compõem a variável fuzzy utilizada como variável de entrada e de saída.

A ferramenta foi avaliada com a previsão das 11 séries temporais com dados mensais que compõem o conjunto reduzido do *Forecasting Competition* de 2006/07. Foi evidenciada a facilidade de uso do FuzzyFuture, assim como o potencial do módulo de otimização de parâmetros por algoritmos genéticos, que resultou em uma redução média do MAPE no conjunto de teste em 13,4%. Adicionalmente, considerando o SMAPE médio das séries – a principal métrica utilizada pelos organizadores da competição no julgamento dos métodos submetidos – os resultados encontrados neste trabalho colocariam o FuzzyFuture na 9ª posição da competição (SMAPE médio do conjunto de teste = 15,83%).

6 Referências

- Bermudez, J., Segura, J., Vercher, E. (2007). A fuzzy decision support tool for demand forecasting, International Fuzzy Systems Conference (FUZZ-IEEE).
- Box, G., Jenkins, G. (1976). Time series analysis: forecasting and control, Holden-Day.
- Chen, S.-M., Chen, C.-D. (2011). TAIEX forecasting based on fuzzy time series and fuzzy variation groups, IEEE Transactions on Fuzzy Systems, vol. 19, no. 1, pp. 1-12.
- Davis, L. (1990), Handbook of Genetic Algorithms, VNR Computer Library.
- Decoursey, W. (2003). Statistics and probability for engineering applications, Newes.
- Elias, C., Hatziargyriou, N. (2009). An annual midterm energy forecasting model using fuzzy logic, IEEE Transactions on Power Systems, vol. 24, no. 1, pp. 469-478.
- Gorzalczany, M. (1998). Business data modelling and forecasting with the use of fuzzy neural networks, International Symposium on Industrial Electronics, pp. 396-401.
- Hanke, J., Reitsch, A. (1995). Business forecasting. 5th Ed. , Prentice Hall.
- Kim, D., Kim, C. (1997). Forecasting time series with genetic fuzzy predictor ensemble, IEEE Transactions on Fuzzy Systems, vol. 5, pp. 523-535.
- Kong, J., Martin, G. (1995). A backpropagation neural network for sales forecasting, IEEE International Conference on Neural Networks, pp. 1007-1011.
- Kung, C.-H., Devaney, M., Huang, C.-M, Kung, C.-M. (1998). An adaptive power system load forecasting scheme using a genetic algorithm embedded neural network, Instrumentation and Measurement Technology Conference, pp. 308-311.
- Mentzer, J., Bienstock, C. (1998). Sales forecasting management, Sage Publication.
- Thiesing, F., Vornberger, O. (1997). Sales Forecasting using neural networks, IEEE International Conference on Neural Networks, pp. 2125-2128.
- Wang, L.-X., Mendel, J. (1992). Generating fuzzy rules by learning from examples, IEEE Transactions on Systems, Man, and Cybernetics, vol. 22, no.6, pp. 1414-1427.
- Yip, D., Hines, E., Yu, W. (1997). Application of artificial neural networks in sales forecasting, IEEE International Conference on Neural Networks, pp. 2121-2124.
- Zhang, G., Kline, D. (2007). Quarterly time-series forecasting with neural networks, IEEE Transactions on Neural Networks, pp. 1800-1814.