

4 Testes e Comparações

Nos testes realizados a seguir, foram usadas duas técnicas : redes RBF e modelos Neuro-fuzzy. Devido ao fato de modelar diversas partições, é preciso fazer uso de um algoritmo que permita ajustar os parâmetros das redes RBF automaticamente, por este motivo foram usadas aqui rotinas que permitem ajustar tais parâmetros, otimizando-os (maior detalhe sobre as rotinas pode-ser achado em www.anc.ed.ac.uk/~mjo/rbf.html).

Deve-se notar, por tanto, que os resultados aqui apresentados das técnicas RBF e Neuro-fuzzy não representam necessariamente as modelagens ótimas globais, pois dentro do universo de possíveis valores para os parâmetros das técnicas sempre é possível existir uma modelagem melhor. Na modalidade tentativa-erro podem-se achar melhores modelos RBF e Neuro-fuzzy, mas isto implica em maior tempo computacional e experiência no ajuste dos parâmetros, o que se deseja evitar.

Como foram apresentadas duas contribuições, a forma de partição dos espaços e o Algoritmo de Cooperação, os casos teste eventualmente serão focados apenas na importância da partição e em outras situações também no algoritmo de cooperação

Observações e Resultados

1) O primeiro teste será realizado com um operador descrito por

$$y = x^3 + 10x . \quad (37)$$

O objetivo deste teste é estimar 300 amostras ao final de um treinamento com 700 amostras. O sinal de entrada será formado pela superposição de três sinais senoidais e um triangular de diferentes frequências, como é mostrado na Figura 54.




Figura 54 Entrada e Saída sistema $y = x^3 + 10x$

Na Figura 55 podem-se observar as partições e sub-partições feitas ao fim do processo iterativo.




Figura 55 Partições e sub-partições Sistema $y = x^3 + 10x$

Como se percebe na Figura 56, a nova técnica foi treinada com 800 amostras, e estimou as próximas 200 últimas amostras. O erro da modelagem é bastante aceitável. Entretanto este erro poderia diminuir se no processo da análise houvesse sido estimado um erro de modelagem bem menor que o originalmente utilizado. Entretanto, isto implicaria maiores necessidades em termos computacionais, como é comum aos métodos de otimização




Figura 56 Dados estimados pela técnica para o Sistema $y = x^3 + 10x$

Na sequência se mostram as estimações feitas individualmente pelas técnicas usadas (deixando que cada uma das técnicas faça suas próprias partições).




Figura 57 Saída estimada Rede RBF




Figura 58 Saída estimada Neuro-fuzzy




Figura 59 Comparação de erros devido às várias técnicas empregadas

Tabela de erros quadráticos médios

Erro Treinamento	Teste		
	RBF	Neuro-fuzzy	Técnica proposta
1e3	1.1905e+005	1.2215e+005	3.4683e+004

Tabela 7 Erros quadráticos médios (exemplo 1)

Como se pode observar na Figura 59, o resultado obtido pela técnica proposta apresenta menor erro.

No apêndice pode-ser conferida a cooperação das técnicas em cada uma das modelagens das partições.

2) O segundo teste será efetuado com um sistema descrito por:

$$y = (10^{-6}x^2 + 5^{-7}x^3 + 5^{-6} \cos(62.83x)) * (1 + 0.3 \int e^{\frac{x}{0.05}} - 1 dx) . \quad (38)$$

As correspondentes formas de onda do sinal de entrada e saída são mostradas na Figura 60.




Figura 60 Sinais de entrada e saída teste 2




Figura 61 Partições

Neste sistema o sinal de entrada é formado pela superposição de uma senóide, um sinal triangular e pequenos pulsos aleatórios, o conjunto descreve o sinal de entrada da Figura 60.

Novamente o treinamento será feito com 800 amostras e serão estimadas as 200 amostras finais. Os resultados obtidos pela técnica proposta apresentam um erro de modelagem aceitável, como é mostrado na Figura 62.




Figura 62 Amostras estimadas pela técnica

Em seguida serão apresentados, nas Figuras 63 e 64, os resultados obtidos pelas técnicas RBF e Neuro-fuzzy, usadas individualmente (cada técnica realiza suas próprias partições)




Figura 63 Amostras estimadas rede RBF




Figura 64 Amostras estimadas Neuro-fuzzy




Figura 65 Comparação erros

Tabela de erros quadráticos médios

	Teste		
Erro Treinamento	RBF	Neuro-fuzzy	Técnica proposta
1e3	2.5198e+004	1.6563e+004	2.9892e+003

Tabela 8 Erros quadráticos médios (exemplo 2)

Até o momento a técnica proposta vem apresentando erros de modelagem menores que as técnicas individualmente usadas.

3) O terceiro teste realizado foi feito com um sistema retificador com memória (circuito RC), as formas de onda do sinal de entrada e saída estão apresentadas na Figura 66. A Figura 67 indica as partições feitas nos sinais (partições iniciais e finais).




Figura 66 Sinais de entrada e saída (sistema retificador com memória)




Figura 67 Partições Sistema Retificador com memória

Neste exemplo vamos realizar o treinamento com 375 primeiras amostras.

Na etapa de síntese serão usadas as 160 seguintes amostras da entrada esperando que o algoritmo identifique as partições mais adequadas feitas com os dados do treinamento. O resultado é apresentado na Figura 68.





Figura 68 Saída estimada Sistema retificador com memória

Como se pode observar na Figura 68, o algoritmo consegue identificar as partições feitas no treinamento, de comportamento mais parecido às amostras de entrada (das quais estimamos as suas saídas). Na sequência do trabalho vamos fazer uma

comparação com os modelos estimados pela técnica da rede neural RBF e pelo neuro-fuzzy, o propósito desta comparação é notar quais seriam as diferenças entre as técnicas.

Usando os mesmos dados de entrada e saída com os quais foi treinado o exemplo anterior vamos treinar a rede RBF.




Figura 69 Saída estimada pela rede RBF

Da Figura 69 pode-se observar que os parâmetros da rede não foram ajustados de forma ótima, o que implica, que não necessariamente as rotinas usadas aqui para modelar as redes RBF, conseguem ajustar os parâmetros para todo tipo de sistema de modo a satisfazer o erro de modelagem.

Na modalidade tentativa-erro podem-se achar parâmetros melhores que os obtidos no caso anterior.

A Figura 70 mostra uma outra rede RBF especialmente modificada para o caso.




Figura 70 Saída estimada pela rede RBF (ajustando os parâmetros)

Na técnica proposta, seja qual for o modelo obtido por cada uma das técnicas vai-se tirar deles o melhor possível, e isto é feito pela combinação linear (atribuição de pesos) dos autovetores e autovalores.

Na Figura seguinte temos os resultados da mesma modelagem pela técnica Neuro-fuzzy.




Figura 71 Saída estimada pelo modelo Neuro-fuzzy

Pode-se observar que o modelo Neuro-fuzzy não consegue o erro de modelagem desejado. Tal como no caso da rede neural RBF, novamente aqui os resultados podem ser melhorados mexendo nos parâmetros, mas isto implicaria em maior tempo de testes, fugindo ao escopo do trabalho.




Figura 72 Comparação erros

Tabela de erros quadráticos médios

Teste		
RBF	Neuro-fuzzy	Técnica proposta
0.7091	0.7170	0.0174

Tabela 9 Erros quadráticos médios (exemplo 3)

É importante observar que, sendo os modelos RBF e Neuro-fuzzy não apropriados para esta situação, eles apresentam melhores resultados quando são aplicados ao sistema de partições dentro da técnica proposta (Figura 68). Isto reforça a contribuição do sistema de partições, por si, para o resultado do processo.

Comparando todos estes resultados (Figuras 68, 69 e 70) podemos dizer que a técnica proposta consegue um erro de modelagem bastante aceitável, em comparação às técnicas RBF e Neuro-fuzzy isoladamente usadas no teste.

Na Figura 73, podem-se observar as respectivas entrada e saída, considerando um ruído superposto ao sinal de entrada, criando uma espécie de teste (não conclusivo) sobre o quanto cada técnica proposta consegue ou não seguir o comportamento do retificador.




Figura 73 Entrada e saída com ruído




Figura 74 Saída estimada (entrada com ruído)

Na Figura 74, pode-se observar que a técnica proposta apresentou erros muito maiores que os anteriores em determinadas amostras, devido a identificações equivocadas das partições nos dados de treinamento.

O aumento de ruído naturalmente prejudica a técnica proposta como também às outras técnicas. Isso se agrava no caso da técnica proposta, já que a estimação de novas amostras depende da escolha da partição correta nos dados de treinamento.

4) Neste teste será usado um sistema com um sinal de saída variado, correspondendo a um sinal de entrada repetitivo. O objetivo aqui é verificar se a técnica proposta consegue identificar partições de saída diferentes, correspondendo a uma mesma aplicação como sinal de entrada.

A Figura 75 mostra os sinais de entrada e saída do sistema em questão.




Figura 75 Entrada e Saída

Na Figura 76 observam-se as partições (iniciais e finais) feitas nos sinais.

Observe-se que as 100 primeiras amostras no sinal de entrada representam basicamente o comportamento do sinal, que se repete por 4 períodos. Entretanto, para cada período no sinal de entrada temos comportamentos diferentes no sinal de saída.




Figura 76 Partições

Serão usadas as primeiras 300 amostras para treinamento e estimadas as 200 amostras restantes. Na Figura 77 são apresentados os resultados desta estimação.




Figura 77 Amostras estimadas pela nova técnica

A Figura 77 indica que a técnica proposta consegue identificar comportamento do sinal de saída, mesmo correspondendo a um mesmo comportamento no sinal de entrada.

Agora vejamos os resultados obtidos pelas técnicas RBF e Neuro-fuzzy usadas individualmente, cada uma das técnicas faz suas próprias partições (Figuras 72 e 73, respectivamente).




Figura 78 Amostras estimadas Rede RBF




Figura 79 Amostras estimadas Neuro-fuzzy

Como se pode ver nas Figuras 78 e 79, as técnicas RBF e Neuro-fuzzy não conseguiram estimar as respectivas amostras da saída, isto é, não identificaram as

partições que correspondiam às novas amostras do sinal de entrada, comprovando neste caso o melhor desempenho da técnica proposta.




Figura 80 Comparação erros

Tabela de erros quadráticos médios

Teste		
RBF	Neuro-fuzzy	Técnica proposta
0.5000	0.5000	0.0183

Tabela 10 Erros quadráticos médios (exemplo 4)

5) O exemplo seguinte, é realizado utilizando apenas uma técnica, representada por uma rede neural de uma camada linear (aqui é usado o comando “newlind” do Matlab), o propósito deste teste é observar se uma técnica linear seria capaz de estimar tão bem quanto as redes empregadas.




Figura 81 Partições e sub-partições




Figura 82 Saída estimada (rede com função linear)

Tabela de erros quadráticos médios

Erro Treinamento	Teste	
	Técnica proposta (funções não lineares)	Técnica proposta (funções lineares)
0.005	0.0174	0.0077

Tabela 11 Erros quadráticos médios (exemplo 5)

Pode-se observar que o resultado utilizando a técnica da rede linear é significativamente melhor que o das redes RBF e Fuzzy. Isto se deve, provavelmente, à técnica de partições empregada, funcionando quase que como uma linearização por partes.

6) Vejamos agora, a modelagem do sistema do exemplo 1, pela técnica linear.




Figura 83 Partições e sub-partições

Observe-se da Figura 83, que o número de partições/sub-partições é maior que no caso do exemplo 1.




Figura 84 Saída estimada (rede com função linear)

Tabela de erros quadráticos médios

Erro Treinamento	Teste	
	Técnica proposta (funções não lineares)	Técnica proposta (funções lineares)
1e3	3.4683e+004	3.4562e+7

Tabela 12 Erros quadráticos médios (exemplo 6)

Pode-se observar que neste exemplo o erro de modelagem aumentou com respeito ao obtido com as técnicas RBF e neuro-fuzzy. Neste caso, claramente, as redes não lineares superaram a técnica linear. Portanto, a técnica de partição nem sempre possibilita ou facilita a identificação por redes lineares.

7) A seguir será vista a modelagem do exemplo 2, usando uma rede de uma camada linear.




Figura 85 Partições e sub-partições

Novamente aqui, temos maior número de partições e sub-partições.




Figura 86 Saída estimada (rede com função linear)

Tabela de erros quadráticos médios

	Teste	
Erro Treinamento	Técnica proposta (funções não lineares)	Técnica proposta (funções lineares)
1e3	2.9892e+003	8.0544e+003

Tabela 13 Erros quadráticos médios (exemplo 7)

O erro de modelagem apresentado com esta rede de uma camada linear aumenta à medida que se façam mais sub-partições, e isto é devido aos comportamentos não lineares que apresentam os resíduos, mais adiante será detalhado o efeito dos resíduos na modelagem.

Deste teste fica a conclusão que pode-se mesclar dentre as redes empregadas algumas com técnica linear já que eventualmente a partição empregada viabiliza suas utilizações no método proposto.

8) Neste teste vai-se aplicar a nova técnica a um sistema real. A síntese da vazão natural à usina de Itaipu é aqui tomada como caso ilustrativo, sendo a síntese de amostras feita a partir de relação causa-efeito discutida na referência [15]. Essencialmente, mostra-se que a vazão de Itaipu durante seus períodos de cheia (novembro a abril) têm forte relação com duas séries climatológicas explicativas: as temperaturas da superfície do oceano (SST, ou sea surface temperature).

A primeira destas séries têm forte influência durante períodos que correspondem a fortes ocorrências do fenômeno “el Niño/la Niña”, como em 1982 e 1998. A segunda série de SST acompanha a vazão de Itaipu fora destes períodos críticos. Nenhuma das duas séries de SST relaciona-se com o período de vazões fora da época de cheias (invernos).

As Figuras 87 e 88 representam as duas curvas de SST, superpostas à vazão de Itaipu, retirada a vazão média.




Figura 87 Vazão Normalizada de Itaipu, SST 1




Figura 88 Vazão Normalizada de Itaipu, SST 2

O objetivo do teste é “prever” vazões para o período de novembro de 2002 a abril de 2003; note-se que, como estes dados já são conhecidos, será fácil comparar o realizado com o previsto e avaliar a qualidade da “previsão”. O período de treinamento corresponde ao restante do histórico das variáveis explicativas: dezembro de 1981 a outubro de 2002.

O processo físico é extremamente sensível ao instante de ocorrência da excitação. Afora a natural sazonalidade, percebe-se a necessidade de não alterar o instante em que atua a excitação para preservar a relação causa-efeito. Uma mesma SST provoca uma vazão em novembro totalmente diversa da que provocaria em julho.

A solução encontrada para lidar com esta característica foi quebrar a série total em pequenas séries referentes a um mesmo mês (apenas novembros, por exemplo), resultando num treinamento com não mais que 21/22 amostras, dependendo do mês considerado. Como consequência, é necessário trabalhar com um volume extremamente escasso de dados. Esta situação é bastante comum, já que as fortes alterações climáticas da década de 70 limitam a disponibilidade das séries históricas disponíveis.

Neste teste, são usadas duas redes do tipo RBF, cada qual com parametrização diversa e um modelo Neuro-Fuzzy. Esta escolha é arbitrária e atendeu apenas a facilidades de implementação; um maior número de redes neurais não impediria a operação do sistema, apenas o tornaria mais lento.

Percebe-se que após alguma experiência no treinamento com um tipo de processo, algumas destas redes apresentam sistematicamente desempenho muito superior ao de outras. Assim, o próprio sistema indica, por seus resultados, as melhores composições e parametrizações para suas redes componentes.

O sistema proposto foi aplicado a esta situação, treinando com respeito às duas séries de SST, anteriormente descritas. Entretanto, como o período selecionado

para a síntese não é passível de ser influenciado pelo fenômeno El Niño (há indicadores de sua evolução), selecionaram-se como saídas as vazões sintetizadas a partir da série de SST2 correlacionada com o período extra El Niño.

O resultado, abrangendo o período novembro de 2002 a abril de 2003, pode ser visto na Figura 89, superposto à vazão real de Itaipu. A Figura 90 apresenta o detalhe das curvas em questão.




Figura 89 Vazões de Itaipu com o Trecho Sintetizado




Figura 90 Detalhe das Vazões de Itaipu e Sintetizadas

Uma inspeção visual mostra sua irregularidade e conseqüente dificuldade em efetuar previsões, mesmo de um ano para o próximo. No entanto, a síntese apresentada pela técnica proposta acompanha a seqüência de dados reais.

A eficiência do sistema é claramente observada na capacidade de prever dados baseados num histórico de poucas amostras, como foi o caso deste teste. Pode-se notar que foram usadas 21 ou 22 amostras para modelar cada serie mensal, tendo como resultado da síntese valores muito próximos dos esperados. O uso do SVD no processo de partição permite extrair valiosa informação sobre o comportamento dos sinais.