

UM ESTUDO COMPARATIVO SOBRE A PREDIÇÃO DE TRÁFEGO EM ENLACES DE UM DOMÍNIO MPLS UTILIZANDO REDES NEURAIIS ARTIFICIAIS E NEURO-FUZZY

N. A. Maia¹, S. B. de O. e S. Maia¹, Rafael A. G. Lima¹ e L. De Errico²

Universidade Estadual de Montes Claros – UNIMONTES¹, Universidade Federal de Minas Gerais – UFMG²
nilton.maia@unimontes.br,sonia.beatriz@unimontes.br, rafaelglima@gmail.com, lerrico@cpdee.ufmg.br

Resumo – O conhecimento prévio do volume de tráfego de um enlace permite aos administradores de rede um melhor planejamento da expansão da capacidade de um domínio MPLS. Este artigo apresenta um estudo comparativo sobre a predição de tráfego em enlaces de um domínio MPLS utilizando Redes Neurais Artificiais e Neuro-Fuzzy. As redes foram construídas utilizando toolboxes do MATLAB. Para a avaliação do desempenho das redes foram utilizados o percentual do Erro Médio Absoluto (EMA) e o Tempo de Processamento. O ANFIS (*Adaptive Neuro-Fuzzy Inference System*) obteve a menor média de Erro Médio Absoluto (EMA). Entretanto, a Rede Neural de Base Radial (RBF) eficiente alcançou o menor Tempo de Processamento.

Palavras Chaves – Redes Neurais Artificiais, Redes Neuro-Fuzzy, Predição, Redes MPLS, Tráfego

Abstract – The foreknowledge of a link's traffic volume allows network administrators to better plan MPLS domain capacity growth. This paper presents a comparative study about the prediction of traffic in links of a MPLS domain using Artificial Neural Networks and Neuro-Fuzzy. The networks were built using toolboxes of MATLAB. For the evaluation of network's performance were used the percentile of the Absolute Medium Error and the Time of Processing. The ANFIS (*Adaptive Neuro-Fuzzy Inference System*) obtained the smallest average of Absolute Medium Error. However, the efficient Radial Basis Function Network reached the smallest Time of Processing.

Keywords – Artificial Neural Networks. Neuro-Fuzzy networks, Prediction, MPLS networks, Traffic.

1 Introdução

As telecomunicações têm apresentado um grande crescimento nos últimos anos e indubitavelmente continuará no mesmo ritmo. Há uma expectativa de integração das redes de voz e dados em uma única rede de alta velocidade na qual as aplicações utilizarão intensivamente de recursos multimídia. Dentre estas aplicações podem-se citar o comércio eletrônico, videoconferência, voz sobre IP, educação a distância, entre outras. Essas aplicações demandam monitoração e controle de Qualidade de Serviços (QoS, *Quality of Services*) e uma crescente capacidade de tráfego, implicando em consumo excessivo da largura de banda, recurso considerado escasso [1].

Para prover serviços com garantia de QoS, há necessidade de mecanismos e protocolos, que atendam aos requisitos dessas aplicações. Atualmente, existem algumas propostas para prover um conjunto de extensões ao tradicional modelo de melhor-esforço, visando fornecer uma melhor QoS. Uma destas propostas é o MPLS (*Multi Protocol Label Switching*). O MPLS consiste em encaminhamento de pacotes IP baseado em rótulos (labels) ao invés de endereços. Neste sentido, o MPLS acrescenta a noção de encaminhamento de pacotes orientado a conexão nas redes IP. Com isso, permite-se às redes IP o estabelecimento e o uso de caminhos de tráfego entre o nós origem e destino das aplicações. Os caminhos no domínio MPLS que os pacotes percorrem de um roteador de entrada ao de saída são chamados de LSPs (Label Switching Paths). Portanto, as redes MPLS possuem a flexibilidade das redes sem conexão e as vantagens inerentes às redes orientadas a conexão [2].

Por outro lado, a proliferação de tecnologias de internet, serviços e dispositivos, tem tornado as ferramentas atuais de projeto e gerenciamento incapazes de projetar de forma confiável e segura os sistemas e serviços de rede. Isto tem levado os pesquisadores a considerar técnicas alternativas de planejamento e projeto [1]. Uma destas técnicas é a previsão futura do tráfego nos enlaces da rede utilizando técnicas de Inteligência Computacional (CI, *Computational Intelligence*). O conhecimento da projeção do volume de tráfego passante em um enlace permite que se possa planejar com antecedência a expansão ou redução da sua capacidade.

A CI compreende paradigmas computacionais que procuram desenvolver sistemas que apresentem alguma forma de inteligência similar à exibida por determinados sistemas biológicos. BEZDEK [3] sugere que um sistema é *computacionalmente inteligente* quando trabalha apenas com dados numéricos, tem um componente de reconhecimento de padrões e não usa conhecimento no sentido da inteligência artificial clássica (conhecimento simbólico, não-numérico); e, adicionalmente, quando ele exhibe (ou começa a exhibir): adaptabilidade computacional; tolerância computacional a falhas; velocidade de processamento comparável à de processos cognitivos humanos; taxas de erro que se aproximam do desempenho humano. A área de CI engloba diversos paradigmas computacionais diferentes. Os principais paradigmas da CI são Redes Neurais Artificiais (RNA), Sistemas Nebulosos (Fuzzy) e Computação Evolutiva [4]. Os paradigmas utilizados neste trabalho são Redes Neurais Artificiais e Rede Neuro-Fuzzy.

Entre os principais tipos de RNAs, destacam-se as redes *Multilayer Perceptrons* (MLP) treinadas pelo algoritmo *back-propagation* e as redes do tipo *Radial Basis Functions* (RBF). As redes RBF possuem características que as capacitam a aprender rapidamente padrões complexos e tendências presentes nos dados e a se adaptar rapidamente a mudanças. Essas características as tornam especialmente adequadas à predição de séries temporais [5], e similarmente à predição de tráfego.

Os sistemas *Fuzzy* são sistemas baseados em regras que utilizam variáveis linguísticas *Fuzzy* para executar um processo de tomada de decisão [6]. Os sistemas *Fuzzy* são baseados no conceito de conjunto *Fuzzy*. Os conjuntos *Fuzzy*, introduzidos por Zadeh [7], surgiram como uma nova forma de representação de conceitos como imprecisão e incerteza. Os conjuntos *Fuzzy* são especialmente adequados na descrição de sistemas de processamento de informação complexos, não-lineares ou não claramente definidos. Além de trabalhar com dados numéricos, os sistemas *Fuzzy* também são capazes de realizar processamento simbólico, através de uma base de regras.

A rede *Neuro-Fuzzy* é uma tecnologia da inteligência artificial que gera regras diretamente de dados numéricos, e associa probabilidades a estas regras [8]. A rede *Neuro-Fuzzy* combina a lógica *Fuzzy* com o aprendizado e capacidades adaptativas das Redes Neurais Artificiais. A rede *Neuro-Fuzzy* utilizada neste trabalho é conhecida como ANFIS (*Adaptive Neuro-Fuzzy Inference System*) [8], um sistema de inferência difusa neural adaptativa. A estrutura de rede ANFIS utiliza um algoritmo de aprendizado híbrido para identificar parâmetros de sistemas de inferência nebulosa do tipo Sugeno [9-10], [11].

O objetivo deste trabalho é realizar um estudo comparativo entre redes neurais artificiais e neuro-fuzzy para resolver o problema da previsão de vazão de tráfego em enlaces de um domínio MPLS alimentado com aplicações de dados, voz e vídeo. As redes foram implementadas utilizando as *toolboxes* de redes neurais e lógica *Fuzzy* do aplicativo MATLAB [12]. O domínio MPLS é simulado com a utilização o software *Network Simulator* (ns2)[14]. A alimentação do domínio é feita utilizando traces de tráfego real.

Este artigo está organizado da seguinte forma. Na Seção 2 é feita a descrição da implementação das Redes Neurais Artificiais e Neuro-Fuzzy. A Seção 3 mostra os resultados obtidos. A Seção 4 apresenta as conclusões e sugestões para a continuidade dos trabalhos.

2 Implementação das Redes Neurais Artificiais e Neuro-Fuzzy

2.1 Medições da vazão de tráfego nos enlaces do domínio MPLS

Inicialmente foram obtidos os dados de entrada das Redes Neurais Artificiais e Neuro-Fuzzy. As entradas de cada Rede são alimentadas com as medições das vazões de tráfego em cada enlace do domínio MPLS apresentado na Figura 1. É construída uma Rede para cada enlace.

Para simulação do domínio MPLS foi utilizado o software *Network Simulator* (ns2). O ns2 é um simulador de redes de comunicação de dados baseado em eventos discretos e orientado a objetos. O domínio MPLS é composto de cinco nós (LSR's) e está interligado a outros dezesseis nós. Os dezesseis nós correspondem a oito nós de origem e oito nós de destino de aplicações. As medições das vazões de tráfego foram realizadas nos enlaces que compõem o núcleo do domínio MPLS, ou seja: 8-9, 9-10, 10-12, 8-12, 8-11 e 11-12.

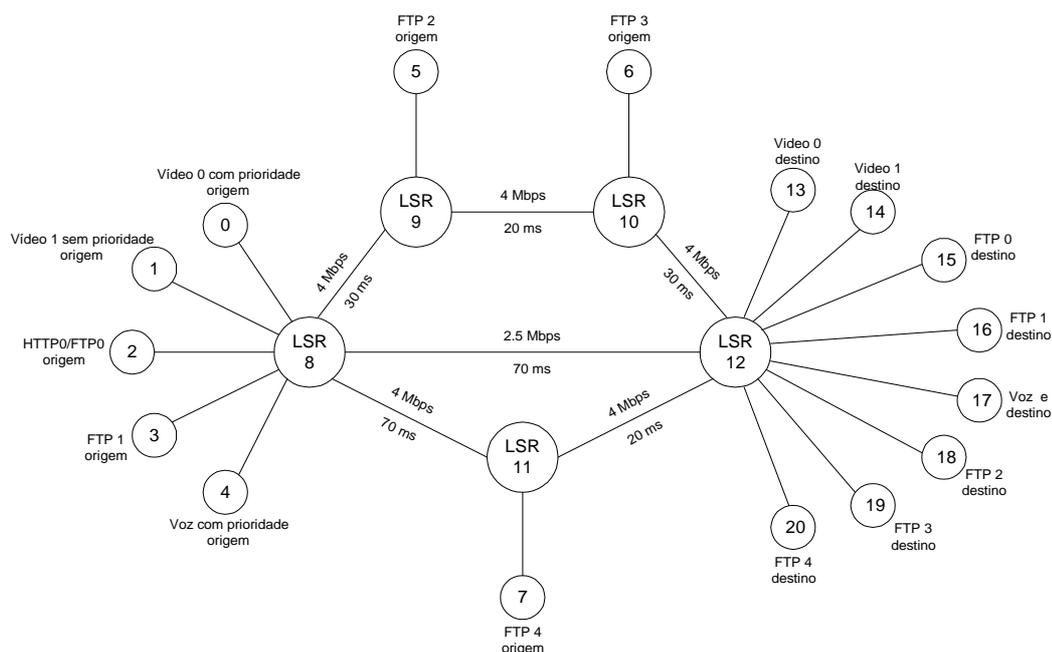


Figura 1 - Topologia do domínio MPLS
Fonte: MAIA (2006), p. 105

As medições da vazão de tráfego efetuadas em cada enlace do domínio MPLS foram armazenadas em arquivos específicos. Cada arquivo, associado a um enlace, possui 360 valores de medições em intervalos de décimos de segundos.

2.2 Estrutura das Redes RBF, MLP e Neuro-Fuzzy

Os dados resultantes das medições das vazões de tráfego em cada enlace foram divididos em dois grupos. O primeiro grupo é utilizado para treinamento da rede e contém 60% dos dados. O segundo grupo, contendo os 40% dos dados restantes, é utilizado para o teste da rede.

Para a definição das entradas e saídas das redes adotou-se a forma utilizada por MAIA [1] e por RENTERÍA [16] em que os valores de saída são realimentados na entrada, ou seja, é utilizado o tipo de previsão conhecido como *multi-step*. Portanto, foram adotados como entradas da rede os valores atuais, simbolizados por Vazão (t) e anteriores da vazão de tráfego em cada enlace, simbolizados por Vazão (t-1) até Vazão (t-2) e a saída de cada rede é a vazão futura, simbolizada por Vazão (t+1) conforme mostra a Figura 2.

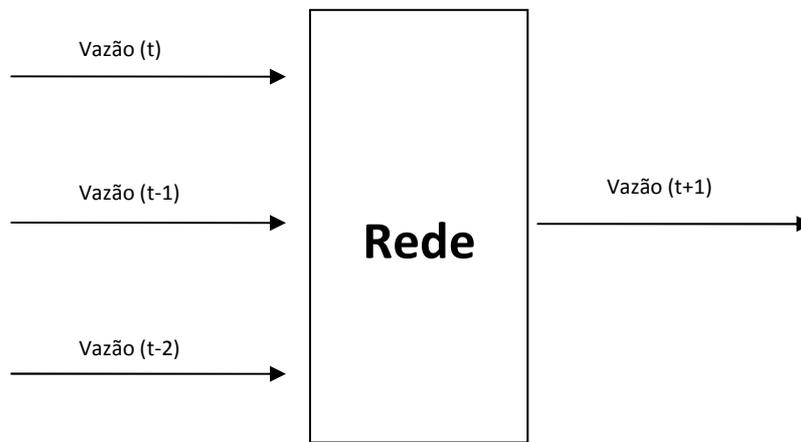


Figura 2 - Estrutura das redes RBF, MLP e neuro-fuzzy

Antes do treinamento das redes, foi utilizada a função Z-score com o intuito de atribuir a mesma importância a cada dado de entrada [15]. Para avaliar o desempenho das redes foi utilizado o percentual do Erro Médio Absoluto (EMA) conforme ALTRAN [16] e RENTERÍA [17]. O EMA é calculado através das Fórmulas (1) e (2) respectivamente.

$$EABS = 100 \left(\frac{|\text{Valor Real} - \text{Valor Previsto}|}{|\text{Valor Real}|} \right) \quad (1)$$

$$EMA = \left(\frac{1}{npp} \right) \sum_{j=1}^{npp} EABS_j \quad (2)$$

Onde npp = Número de padrões previstos

Os resultados obtidos também foram comparados com um preditor Naive. Este preditor é considerado um patamar mínimo de predição, sendo usado apenas para a comparação. O preditor Naive realiza a operação conforme a Fórmula (3).

$$\text{Naive: } Y(t+1) = Y(t) \quad (3)$$

2.3 Parâmetros das Redes Neurais MLP

Foram utilizadas redes MLP's com duas camadas, uma escondida e outra de saída. Durante os testes, verificou-se que os melhores resultados foram obtidos com a utilização de 12 (doze) neurônios na camada escondida.

O algoritmo de treinamento utilizado foi Backpropagation com taxa de aprendizado adaptativa. A taxa de aprendizado inicial utilizada para todos os enlaces foi 0.01. A taxa de erro desejada durante o treinamento das redes neurais também foi 0.01.

2.4 Parâmetros das Redes Neurais RBF

No trabalho são utilizados dois tipos de Redes Neurais Artificiais do tipo RBF: exata e eficiente. Para a criação das redes foram utilizados dois comandos: *newrb* e *newrbe* do MATLAB. O comando *newrbe* cria uma rede RBF exata, em que define um neurônio para cada par de entrada/saída. Já o comando *newrb* cria uma rede RBF eficiente de forma incremental, em que os neurônios são inseridos até que o erro especificado seja satisfeito ou atinja o número máximo de neurônios. Os comandos *newrb* e *newrbe* utilizam o treinamento de forma híbrida, sendo que a função gaussiana é utilizada para a camada escondida e a função linear para a camada de saída, uma vez que os dados na camada de saída são linearmente separáveis.

O algoritmo desenvolvido para previsão realiza vários treinamentos e simulações das redes, alterando de forma automática a quantidades de neurônios da camada escondida, e os valores da largura da função radial (constante Spread). Esses parâmetros são incrementados a cada iteração e após a seleção dos melhores valores são mostrados os resultados e gráficos.

Os parâmetros utilizados para criação da rede RBF eficiente através do comando *newrb(P,T,Goal,Spread,MN)* foram os seguintes:

- Matriz de vetores de entrada (*P*)
- Matriz de vetores de saída desejada (*T*)
- Erro médio quadrático pretendido (*Goal*)
- Largura para a função de base radial (*Spread*)
- Número máximo de neurônios na camada escondida (*MN*)

O número de neurônios na camada de saída foi igual a 1, representando a vazão futura no período $t+1$.

O erro médio quadrático pretendido foi considerado 0 para todos os testes realizados. Isso permitiu que na comparação com o comando *newrbe* fosse considerado apenas a quantidade de neurônios da camada escondida (o comando *newrb* poderá adicionar neurônios até o valor máximo fixado), e a largura da função.

Os parâmetros utilizados para criação da rede RBF exata através do comando *newrbe (P,T,Spread)* foram os seguintes:

- Matriz de vetores de entrada (*P*)
- Matriz de vetores de saída desejada (*T*)
- Largura para a função de base radial (*Spread*)

A largura para a função de base radial foi testada atribuindo diversos valores em ambos os comandos *newrb* e *newrbe*. O valor que apresentou menor Erro Médio Absoluto (EMA) dentro do intervalo especificado foi considerado para a previsão do respectivo enlace.

2.5 Parâmetros das Redes Neuro-Fuzzy

Para a construção da rede Neuro-Fuzzy foi utilizado o ANFIS do Matlab. A estrutura do ANFIS gerado é a seguinte: possui três (3) neurônios na camada de entrada; cinco (5) funções de pertinência do tipo sino (gbell) na camada 1; a camada 2 possui cento e vinte e cinco (125) regras; a camada 3 tem-se a agregação das regras; e finalmente um (1) neurônio na camada de saída. O método de treinamento utilizado é híbrido.

3 Previsão da vazão de tráfego

3.1 Resultados obtidos com a Rede Neural Artificial do tipo MLP

A Tabela 1 apresenta os resultados do Erro Médio Absoluto (EMA) e Tempos de Processamento obtidos durante as fases de treinamento, testes e global para a MLP e para o preditor Naive.

Tabela 1 - Erros Médios Absolutos e Tempos de Processamento obtidos pela MLP e preditor naive nos enlaces

Enlaces	Preditor	EMA (%)			Tempo de Processamento (s)
		Treinamento	Testes	Global	
8_9	MLP	10,2626	10,3902	10,2750	392
	Naive	18,3722	18,8984	18,4236	
9_10	MLP	7,7343	7,8993	7,7504	381
	Naive	12,1366	12,5218	12,1742	
10_12	MLP	13,6739	14,0100	13,7068	412
	Naive	16,7853	17,2448	16,8302	
8_12	MLP	12,6179	12,7652	12,6323	373
	Naive	72,3955	74,3828	72,5897	
8_11	MLP	15,0754	15,4678	15,1137	366
	Naive	22,3549	22,9803	22,4160	
11_12	MLP	17,4214	17,9029	17,4685	365
	Naive	22,3549	22,9803	22,4160	
Média	MLP	12,7976	13,0726	12,8245	381,4870
	Naive	27,3999	28,1681	27,4750	

Observando-se a Tabela 1, nota-se que os resultados obtidos com o uso da MLP são superiores ao do “Preditor” Naive conforme era esperado.

3.2 Resultados obtidos com a Rede Neural Artificial do tipo RBF exata

A Tabela 2 apresenta os resultados do Erro Médio Absoluto (EMA) e Tempos de Processamento obtidos durante as fases de treinamento, testes e global para a RBF exata.

Tabela 2 - Erros Médios Absolutos e Tempos de Processamento obtidos pela RBF exata

Enlaces	EMA (%)			Tempo de processamento (s)
	Treinamento	Testes	Global	
8_9	0,5624	0,5741	0,5635	57,74
9_10	0,0059	0,0039	0,0057	58,45
10_12	7,3922E-10	6,7847E-10	7,3328E-06	58,63
8_12	1,5050E-11	1,4275E-11	1,4974E-11	59,38
8_11	4,1882E-12	4,1568E-12	4,1851E-12	61,39
11_12	4,1882E-12	4,1568E-12	4,1851E-12	58,86
Media	0,094717	0,096333	0,094868	59,07

Observando-se a Tabela 1 e a Tabela 2, nota-se que os resultados obtidos com o uso da RBF exata são melhores que o do “Preditor” Naive conforme era esperado. Além disso, pode-se observar que os resultados obtidos com o uso da RBF exata também são muito superiores ao da MLP. Na media dos enlaces, o Erro Médio Absoluto Global obtido pela RBF exata é cento e trinta e cinco (135) vezes menor do que o obtido pela MLP. Da mesma forma, o Tempo de Processamento obtido pela RBF exata é aproximadamente seis (6) vezes menor.

3.3 Resultados obtidos com a Rede Neural Artificial do tipo RBF eficiente

A Tabela 3 apresenta os resultados do Erro Médio Absoluto (EMA) e Tempos de Processamento obtidos durante as fases de treinamento, testes e global para a RBF eficiente e para o preditor Naive.

Tabela 3 - Erros Médios Absolutos e Tempos de Processamento obtidos pela RBF eficiente

Enlaces	EMA (%)			Tempo de processamento (s)
	Treinamento	Testes	Global	
8_9	0,5624	0,5741	0,5635	3,13
9_10	0,0059	0,0039	0,0057	1,61
10_12	7,3598E-06	6,7488E-06	7,3000E-06	1,45
8_12	1,5139E-11	1,4364E-11	1,5063E-11	1,52
8_11	4,14E-12	4,11E-12	4,14E-12	1,52
11_12	4,14E-12	4,11E-12	4,14E-12	1,58
Média	0,0947	0,0963	0,0949	1,7993

Comparando-se os resultados apresentados nas Tabela 2 e 3, nota-se que a RBF eficiente e RBF exata obtém resultados semelhantes com relação ao Erro Médio Absoluto Global, na media dos enlaces. Entretanto, o tempo de processamento da RBF eficiente é aproximadamente trinta e duas (32) menor.

Nos gráficos obtidos, os valores de previsão para as redes RBF eficiente se sobrepõem quase que totalmente em relação aos valores reais, indicando assim que os valores foram previstos de forma satisfatória para os enlaces. Como exemplo, a Figura 3 mostra os gráficos da vazão de tráfego real e prevista no enlace 8-9.

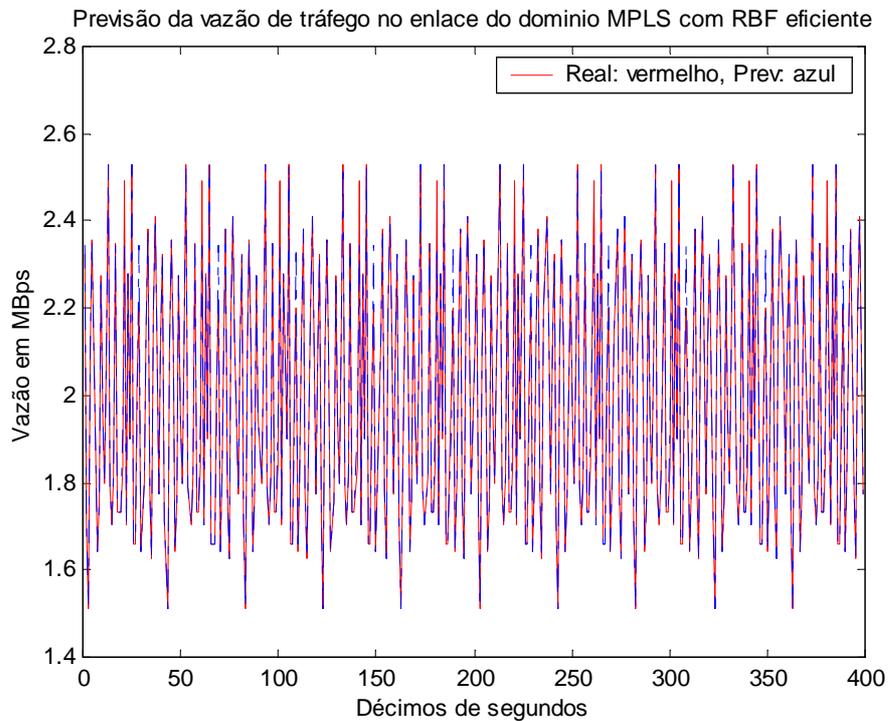


Figura 3 - Dados reais e de previsão da rede RBF eficiente no enlace 8-9

3.4 Resultados obtidos com o ANFIS

A Tabela 4 apresenta os resultados do Erro Médio Absoluto (EMA) e Tempos de Processamento obtidos durante as fases de treinamento, testes e global para o ANFIS e para o preditor Naive.

Tabela 4 - Erros Médios Absolutos e Tempos de Processamento obtidos pelo ANFIS

Enlaces	EMA (%)			Tempo de processamento (s)
	Treinamento	Testes	Global	
8_9	6,16E-05	6,27E-05	6,21E-05	77,69
9_10	0,0135	0,0115	0,0127	77,53
10_12	6,09E-04	6,19E-04	6,13E-04	78,81
8_12	1,88E-05	1,88E-05	1,88E-05	79,42
8_11	1,48E-04	1,59E-04	1,53E-04	77,94
11_12	1,48E-04	1,59E-04	1,53E-04	79,28
Média	0,002414	0,002086	0,002283	78,45

Comparando-se os resultados apresentados nas Tabela 3 e 4, nota-se que o ANFIS obtém, na média dos enlaces, um Erro Médio Absoluto Global quarenta e uma (41) vezes menor que a RBF eficiente. Entretanto, o tempo de processamento do ANFIS é quarenta e três (43) vezes maior.

3.5 Comparação dos resultados obtidos pela MLP, RBF exata, RBF eficiente, ANFIS e preditor naive

A Tabela 5 apresenta a Média Geral dos Erros Médios Absolutos e Tempos de Processamento obtidos pela MLP, RBF exata, RBF eficiente, ANFIS e preditor naive.

Tabela 5- Média Geral dos Erros Médios Absolutos e Tempos de Processamento obtidos pela MLP, RBF exata, RBF eficiente, ANFIS e preditor naive

Preditor	EMA (%)			Tempo de processamento (s)
	Treinamento	Testes	Global	
MLP	12,7976	13,0726	12,8245	381,4870
RBF exata	0,094717	0,096333	0,094868	59,07
RBF eficiente	0,0947	0,0963	0,0949	1,7993
ANFIS	0,002414	0,002086	0,002283	78,45
Naive	27,3799	28,1681	27,4750	381,4870

O ANFIS apresenta a melhor Média Geral dos Erros Médios Absolutos de todos os preditores avaliados. A RBF exata e a RBF eficiente apresentam resultados semelhantes com relação à Média Geral dos Erros Médios Absolutos. A RBF eficiente obteve a menor média de tempo de processamento. Já a Média Geral dos Erros Médios Absolutos apresentada pela rede MLP somente foi superior ao preditor Naive. Além disso, a rede MLP obteve o maior tempo de processamento de todos os preditores avaliados.

4 Conclusão

Neste trabalho foram apresentados os resultados de um estudo sobre a previsão da vazão de tráfego em enlaces de um domínio MPLS alimentado com fontes de tráfego do tipo dados, voz e vídeo.

Os resultados da previsão nos enlaces foram avaliados utilizando redes MLP, RBF exata, RBF eficiente e ANFIS. Além disso, o trabalho procurou realizar comparações das previsões realizadas com o preditor Naive. Os resultados apresentados mostraram que os dois tipos de redes RBF apresentaram valores semelhantes com relação ao Erro Médio Absoluto. Entretanto, no quesito Erro Médio Absoluto, o melhor resultado foi obtido pelo ANFIS. O ANFIS obteve, na média dos enlaces, um Erro Médio Absoluto Global quarenta e uma (41) vezes menor que as redes RBF. A rede MLP, neste quesito, somente foi superior ao preditor Naive.

Além disso, foi avaliado o esforço computacional das redes RBF com medições dos tempos gastos para treinamento e testes. Nesse caso, verificou-se que a rede RBF eficiente apresentou uma convergência muito rápida, cerca de trinta e duas (32) vezes mais veloz que a rede RBF exata, e esta cerca de quarenta e três (43) vezes mais veloz que o ANFIS. As redes MLP apresentaram os menores tempos de convergência entre todas as redes avaliadas.

Como continuação pode-se sugerir os seguintes trabalhos futuros: a) Utilizar o tipo de rede RBF conhecida como Rede de Regressão Generalizada como alternativa à utilização da rede RBF exata. b) Utilizar as redes *Multilayer Perceptrons* para predição com funções de ativação do tipo base radial. c) Utilizar as redes *Multilayer Perceptrons* para predição com outros algoritmos em vez do *backpropagation*. d) Realizar previsões de tráfego em uma topologia MPLS com maior número de enlaces. e) Incorporar os resultados obtidos neste trabalho ao modelo desenvolvido por MAIA (2006). f) Desenvolver um aplicativo para predição que meça dados reais de tráfego com os conceitos e métodos apresentados nesse trabalho.

5 Referências

- [1] Maia, N. A. Engenharia de Tráfego em Domínio MPLS Utilizando Técnicas de Inteligência Computacional. 192 f. Tese (Doutorado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Minas Gerais, Belo Horizonte, 2006. Disponível em: <<http://www.cpdee.ufmg.br/documentos/Defesas/654/TeseDoutorado-Nilton-TextoFinal.pdf>>. Acesso em: Maio de 2008 (2006).
- [2] Girish, M. K.; Zhou, B.; Hu, J. Q. Formulation of the traffic engineering problems in MPLS based IP networks. In: Proceedings of the Fifth IEEE Symposium on Computers and Communications (ISCC'00), (2000), p. 214-219.
- [3] Bezdek, J. C. What is Computational Intelligence,. In: Zurada, J. M.; Marks II, R. J.; Robinson, C. J. Computational Intelligence – Imitating Life, IEEE Press (1994).
- [4] Iyoda, E. M.; Inteligência computacional no projeto automático de redes neurais híbridas e redes neurofuzzy heterogêneas, Dissertação de Mestrado, FEEC/ UNICAMP (2000).
- [5] Haykin S. Neural Networks: A Comprehensive Foundation, Upper Saddle River, New Jersey, USA, Prentice-Hall (1999).
- [6] Adiléia, W. *Extração de Conhecimento a partir de Redes Neurais aplicada ao Problema da Cinemática Inversa na Robótica*. Dissertação de Mestrado. Universidade do Vale do Rio dos Sinos (2003).
- [7] Zadeh L. Fuzzy Sets, Information and Control, Vol. 8, (1965), 338-353.
- [8] Buragohain, M.; Mahanta, C. A Novel Approach for ANFIS Modelling based on Full Factorial Design, Applied Soft Computing, Vol. 8, (2008), 609–625.
- [9] Sugeno M.; Kang G.T. Structure Identification of Fuzzy Models, Fuzzy Sets Systems, Vol. 28, (1998), 15-33.
- [10] Terano T.; Asai K.; Sugeno M. Fuzzy Systems Theory and its Applications, U.S.A., Academic Press (1991).
- [11] Takagi T.; Sugeno M. Fuzzy Identification of Systems and its Applications to Modeling and Control, IEEE Transactions on Systems Man, and Cybernetics, Vol. 15, No. 1, (1985) ,116-132.
- [12] Manual de Utilização Do Matlab. The Mathworks Inc. 1996.
- [13] Buragohain M. Mahanta C. A Novel Approach for ANFIS Modelling based on Full Factorial Design, Applied Soft Computing, Vol. 8, (2008) , 609–625.
- [14] VINT Network Simulator – version 2. Disponível em: <http://www-mash.cs.berkeley.edu/ns> (2003).
- [15] Hines, J. W. *Fuzzy and Neural Approaches in Engineering MatLab supplement*, John Wiley & Sons, (1997).
- [16] Altran, A. B. Minussi, C. R. Villarreal, F. Previsão de Cargas Elétricas Usando Redes Neurais Artificiais com Função de Base **Radial**. 10 f. 7th Brazilian Conference on Dynamics, Control e Applications. Disponível em: <http://www4.fct.unesp.br/dmec/dincon2008/artigos/09/12-Altran_AB.pdf> (2008).
- [17] Renteria, A. R. Controle de Semáforos por Lógica Fuzzy e Redes Neurais. 67 f. Dissertação (Mestrado em Engenharia Elétrica) – Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2002. Disponível em: <http://www.maxwell.lambda.ele.puc-rio.br/cgi-bin/PRG_0599.EXE/2695.PDF?NrOcoSis=4905&CdLinPrg=pt>. Acesso em: Outubro de 2008 (2002).