

6 Resultados

Os resultados obtidos com classificadores baseado em redes neurais MLP aqui desenvolvidos serão apresentados. O diagrama de Venn apresentado na figura 6.1 ilustra possíveis situações existentes no espaço de resultados dos modelos avaliados.

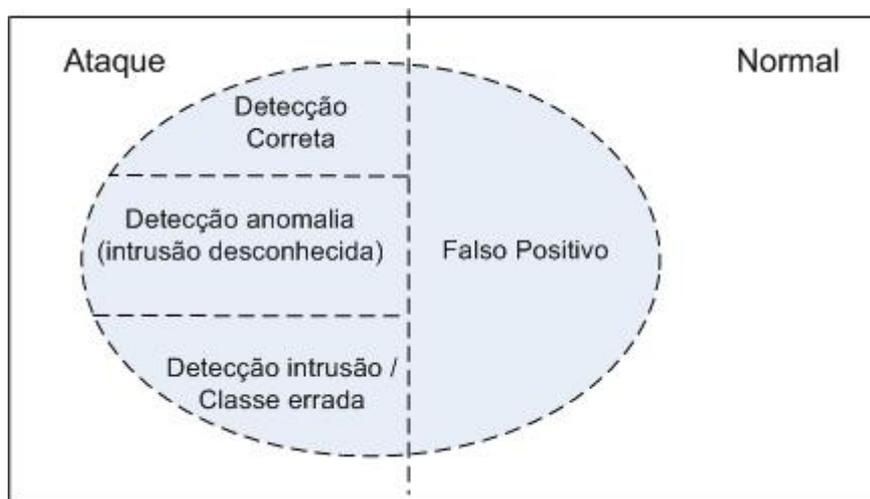


Figura 6-1 – Diagrama Venn

Os resultados obtidos serão apresentados através da matriz de confusão [35] gerada para cada classificador testado e da correspondente curva ROC – “Receiver Operating Characteristics”.

6.1. Matriz de Confusão e Curvas ROC

A construção de uma matriz de confusão é uma técnica empregada para se analisar o desempenho de sistemas classificadores. A tabela 6.1 apresenta um exemplo de matriz de confusão para um classificador baseado em duas classes distintas.

		Previsto	
		Negativo	Positivo
Real	Negativo	a	b
	Positivo	c	d

Tabela 6-1 : Exemplo de Matriz de Confusão

Para esta matriz de confusão temos definidos os seguintes parâmetros :

- **a** corresponde ao número de previsões corretas que uma instância é negativa
- **b** corresponde ao número de previsões incorretas que uma instância é positiva
- **c** corresponde ao número de previsões incorretas que uma instância é negativa.
- **d** corresponde ao número de previsões corretas que uma instância é positiva.

Utilizando os parâmetros **a,b,c** e **d** podemos classificar os seguintes indicadores associados ao classificador em análise :

-
- Precisão global (“*accuracy*” ou AC) corresponde a proporção de previsões corretas do classificador. É determinado pela equação :

$$AC = \frac{a + d}{a + b + c + d}$$

- Taxa de acerto (*recall* ou *True positive rate - TP*) é a proporção de casos positivos que foram corretamente identificados pelo classificador. É determinada pela equação :

$$TP = \frac{d}{c + d}$$

- A taxa de falso positivo (FP) consiste na proporção de casos negativos que foram incorretamente classificados como positivos. Determinada por :

$$FP = \frac{b}{a+b}$$

- A taxa de verdadeiro negativo (TN) consiste na proporção de casos negativos que foram corretamente classificados como tal. Determinada por :

$$TN = \frac{a}{a+b}$$

- A taxa de falso negativo (FN) é a proporção de casos positivos que foram incorretamente classificados como negativos. Dada por :

$$FN = \frac{c}{c+d}$$

- Finalmente a precisão (“*precision*” P) é a proporção de casos positivos que foram previstos corretamente dados por :

$$P = \frac{d}{b+d}$$

Adicionalmente, para cada sistema avaliado será apresentada a curva ROC (*Receiver Operating Characteristics*) tradicional associada a sua matriz de confusão. Curvas ROC são curvas que apresentam a taxa de verdadeiro positivo (TP) do sistema versus a taxa de falso positivo (FP) do sistema quando se varia um limiar de decisão/ajuste do classificador. Será empregado também uma variação da curva ROC utilizando a precisão (AC) versus taxa de falso positivo

Para redes neurais empregaremos curvas ROC para os cenários de classificação binária (saída identificando se conexão é normal ou intrusiva apenas). O limiar de decisão é variado de [-1;1] e todos os parâmetros são

recalculados. O resultado é uma matriz com os diversos parâmetros – AC,FP,FN,TP,TN e P – calculados para vários valores do limiar de decisão.

6.2. Classificador Binário

Para um classificador binário, capaz de distinguir se o padrão apresentado é um padrão de ataque ou um padrão normal, a saída da rede neural foi ajustada, no intervalo [-1 1] para gerar (-1) para padrão considerado intrusão e (1) para padrão considerado normal. As matrizes de confusão apresentadas consideram limiar de decisão $th = 0$. Para as redes com esta características efetuamos o treinamento com todas as possibilidades de entrada – todas as variáveis, apenas as características intrínsecas, apenas as características temporais, apenas as características especialistas – com o objetivo de avaliar qual grupo de características exerce maior influência no desempenho da rede. Foram avaliados os seguintes cenários.

6.2.1. Características intrínsecas como entrada

Apenas as nove variáveis associadas às características intrínsecas do TCP/IP foram utilizadas para treinar e avaliar as redes neurais. Redes MLP com duas camadas escondidas (10 neurônios escondidos por camada) foram treinadas com os cinco subconjuntos de treinamento e avaliadas com todos os registros da base de testes e avaliação.

Conjunto de treinamento DS1

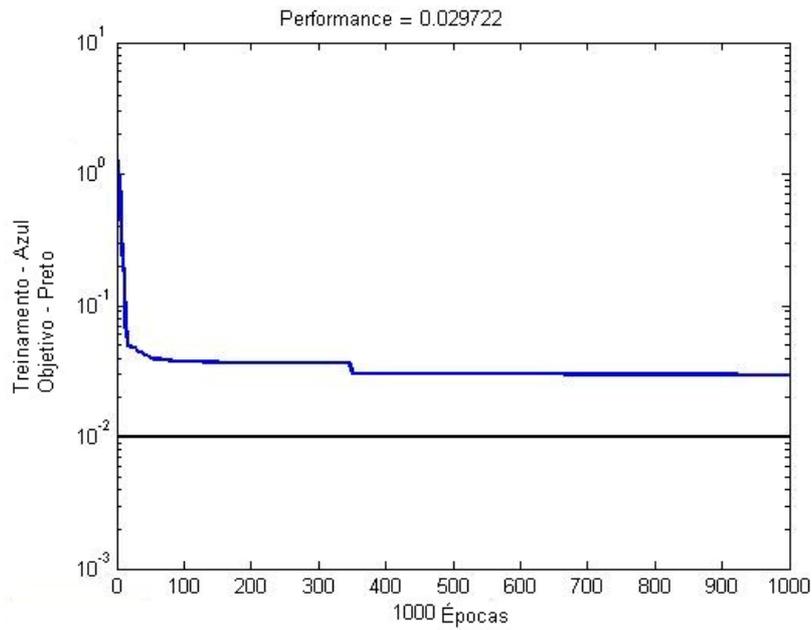


Figura 6-2 : Treinamento 1. DS1

		Previsto	
		Normal	Intrusão
Real	Normal	60227	366
	Intrusão	24518	225918

Tabela 6-2 : CM 1. DS1

Parâmetros Associados	Valor
AC	0.9200
TP	0.9021
FP	0.0060
TN	0.9940
FN	0.0979
P	0.9984

Tabela 6-3 : Parâmetros 1. DS1

Conjunto de treinamento DS2

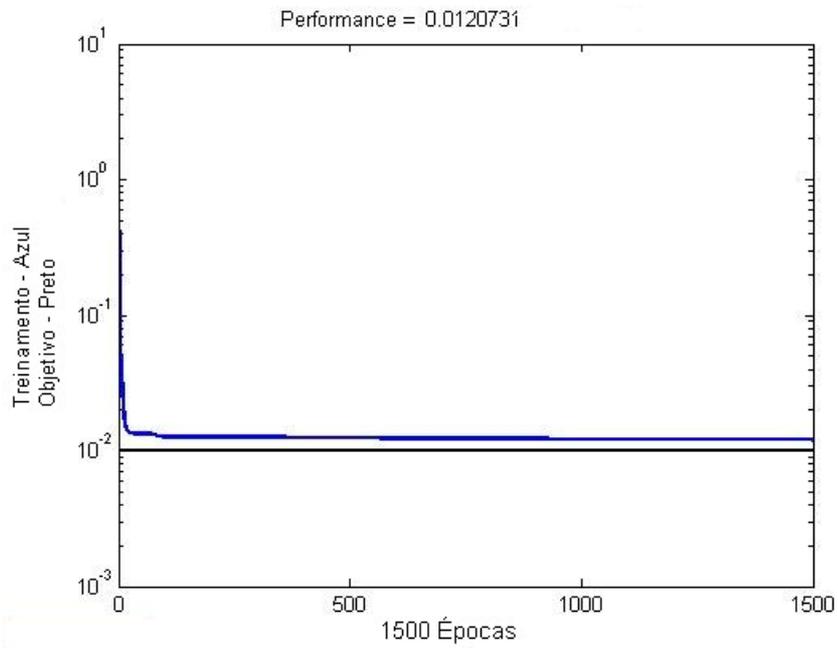


Figura 6-3 : Treinamento 1. DS2

		Previsto	
		Normal	Intrusão
Real	Normal	60049	544
	Intrusão	24127	226309

Tabela 6-4 : CM 1. DS2

Parâmetros Associados	Valor
AC	0.9207
TP	0.9037
FP	0.0090
TN	0.9910
FN	0.0963
P	0.9976

Tabela 6-5 : Parâmetros 1. DS2

Conjunto de treinamento DS3

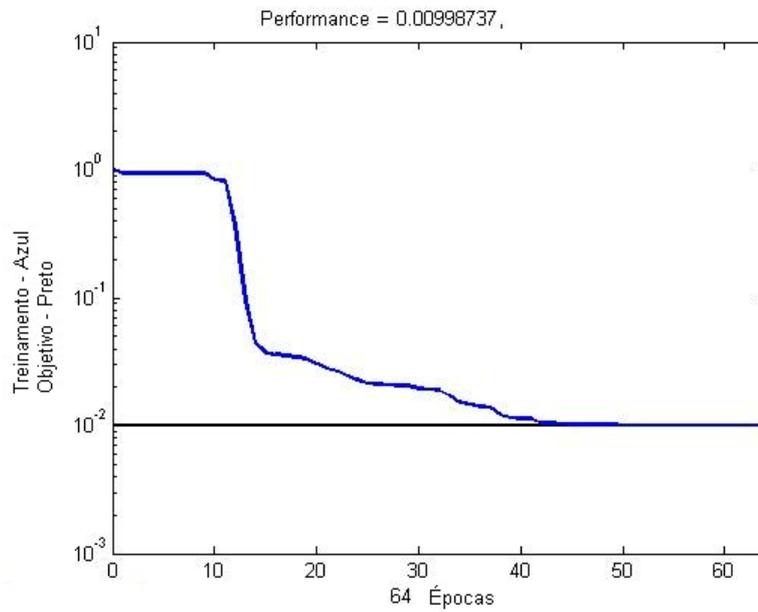


Figura 6-4 : Treinamento 1. DS3

		Previsto	
		Normal	Intrusão
Real	Normal	60425	168
	Intrusão	66852	183584

Tabela 6-6 : CM 1. DS3

Parâmetros Associados	Valor
AC	0.7845
TP	0.7331
FP	0.0028
TN	0.9972
FN	0.2669
P	0.9991

Tabela 6-7 : Parâmetros 1. DS3

Conjunto de treinamento DS4

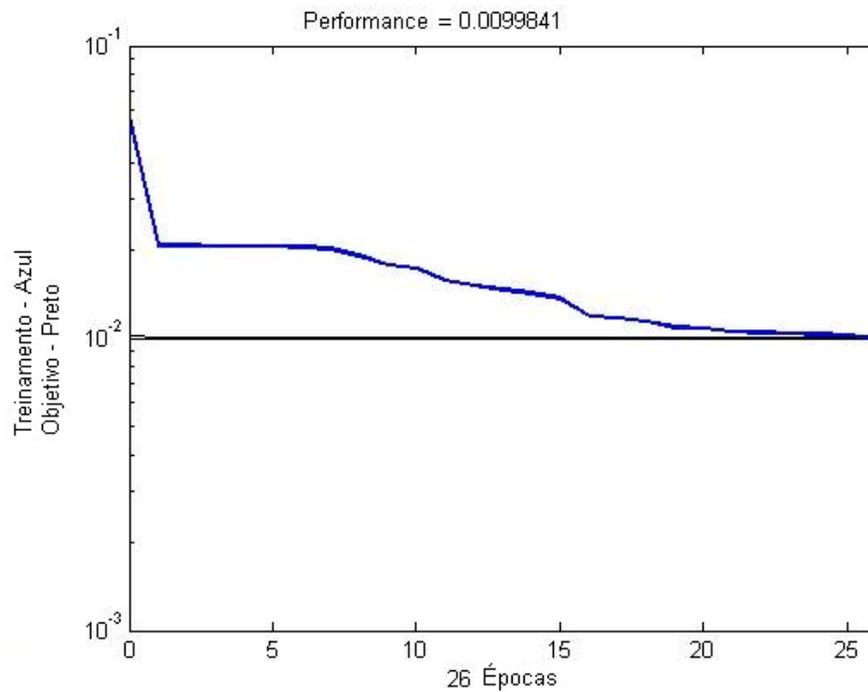


Figura 6-5 : Treinamento 1. DS4

		Previsto	
		Normal	Intrusão
Real	Normal	60345	248
	Intrusão	246729	3707

Tabela 6-8 : CM 1. DS4

Parâmetros Associados	Valor
AC	0.2059
TP	0.0148
FP	0.0041
TN	0.9959
FN	0.9852
P	0.9373

Tabela 6-9 : Parâmetros 1. DS4

Conjunto de treinamento DS5

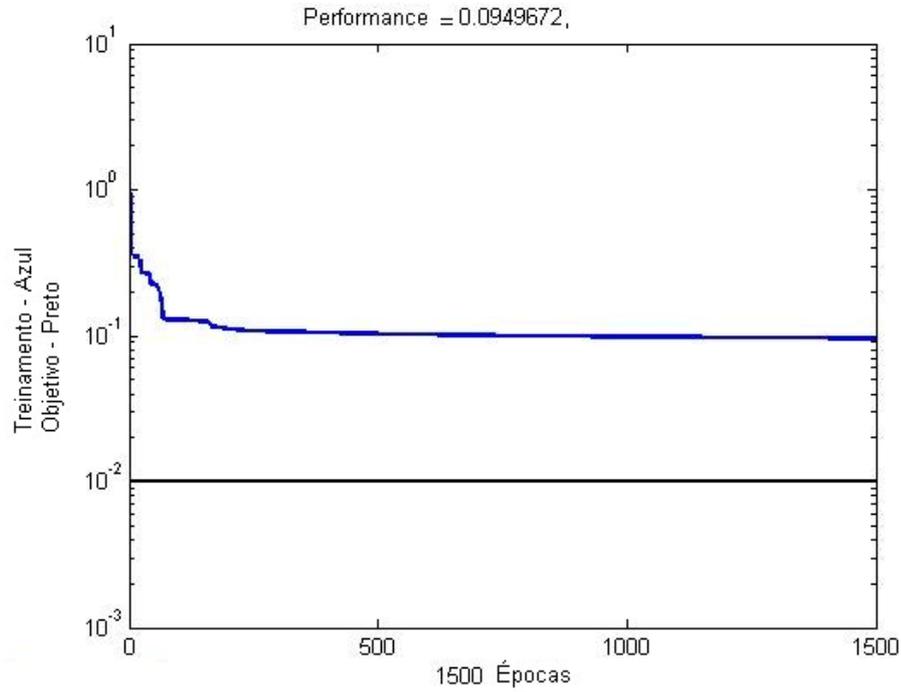


Figura 6-6 : Treinamento 1. DS5

		Previsto	
		Normal	Intrusão
Real	Normal	59403	1190
	Intrusão	247068	3368

Tabela 6-10 : CM 1. DS5

Parâmetros Associados	Valor
AC	0.201817
TP	0.013449
FP	0.019639
TN	0.980361
FN	0.986551
P	0.738921

Tabela 6-11 : Parâmetros : 1. DS5

Curvas ROC

Variando o limiar de decisão th temos condição de alterar a resposta do sistema classificador. As curvas ROC e sua variação apresentadas a seguir ilustram o comportamento dos parâmetros TP e AC em relação ao parâmetro FP quando se varia o limiar de decisão th de -1 a 1 em passos de 0,1 e nova matriz de confusão é determinada para cada novo limiar.

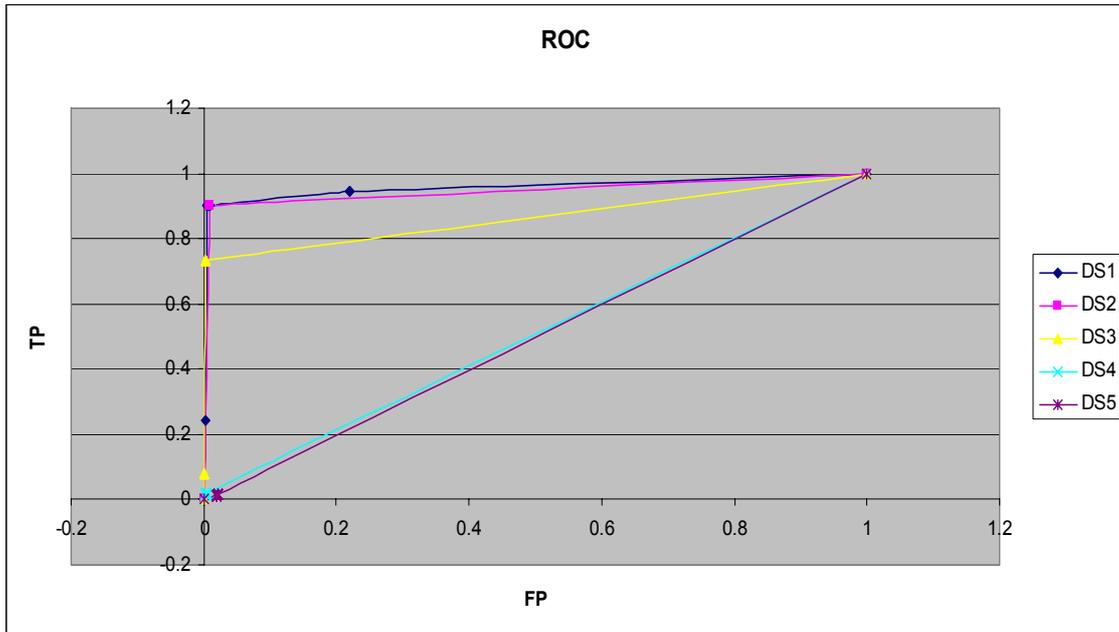


Figura 6-7 : 1. ROC : TP x FP

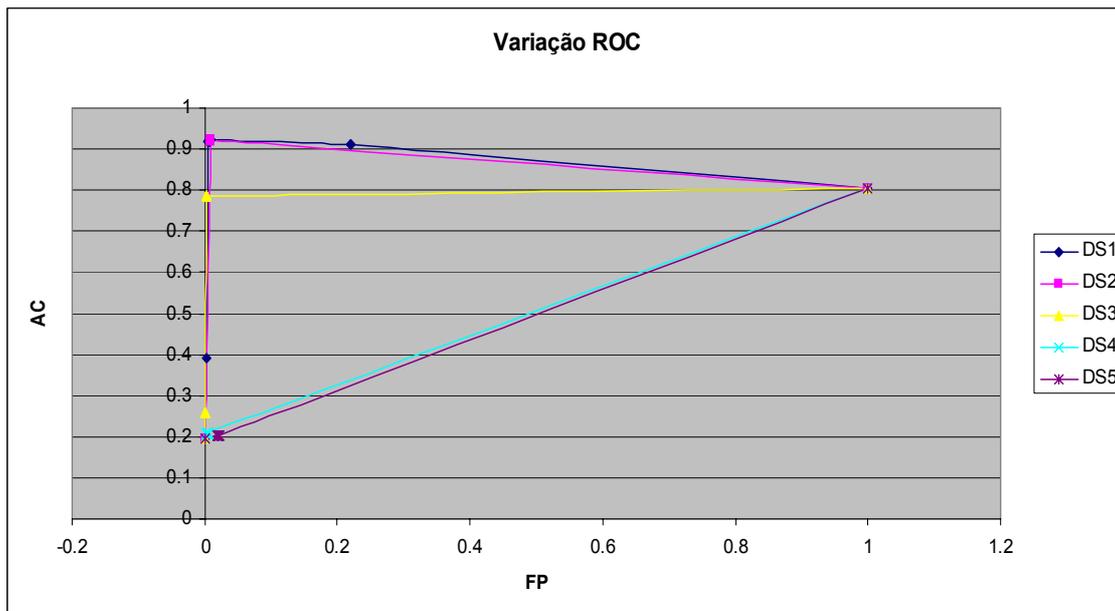


Figura 6-8 : 1. Variação ROC – AC x FP

A comparação entre o desempenho da mesma rede neural, quando treinada com subconjuntos diferentes mostra claramente a importância dos dados de treinamento. Como esperado, o melhor desempenho ocorreu quando a rede foi treinada com subconjunto 1, que contém a totalidade dos padrões de ataque e intrusão. A rede apresentou pior desempenho para os subconjuntos 4 e 5, que contém ataques apenas das classes U2R e R2L respectivamente. Como estas classes possuem um menor número de ocorrências para cada padrão de ataque, esta queda também era esperada. Importante ressaltar que para o subconjunto 5 o treinamento da rede neural não convergiu para o objetivo desejado.

6.2.2. Todas as características como entrada

Para este cenário, as 41 variáveis que identificam um registro foram utilizadas para treinar e validar uma rede neural MLP 41-15-15-1 (41 entradas, 2 camadas com 15 neurônios em cada e 1 saída). Como o vetor de entrada teve um aumento significativo o número de elementos processadores nas camadas ocultas foi aumentado.

Conjunto de treinamento DS1

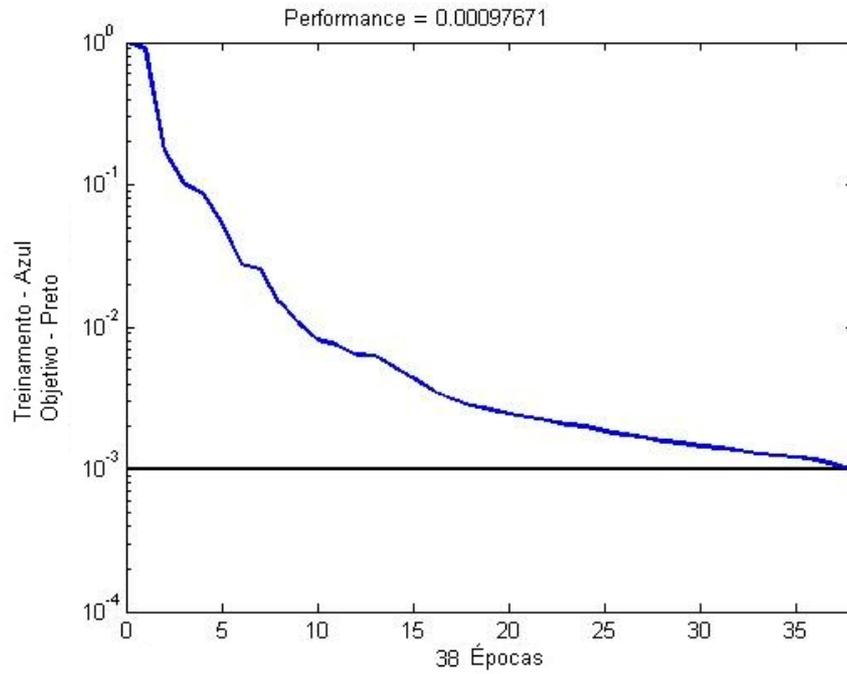


Figura 6-9 : Treinamento 2. DS1

		Previsto	
		Normal	Intrusão
Real	Normal	59783	810
	Intrusão	22530	227906

Tabela 6-12 : Parâmetros 2. DS1

Parâmetros Associados	Valor
AC	0.9250
TP	0.9100
FP	0.0134
TN	0.9866
FN	0.0900
P	0.9965

Tabela 6-13 : Parâmetros 2. DS1

Conjunto de treinamento DS2

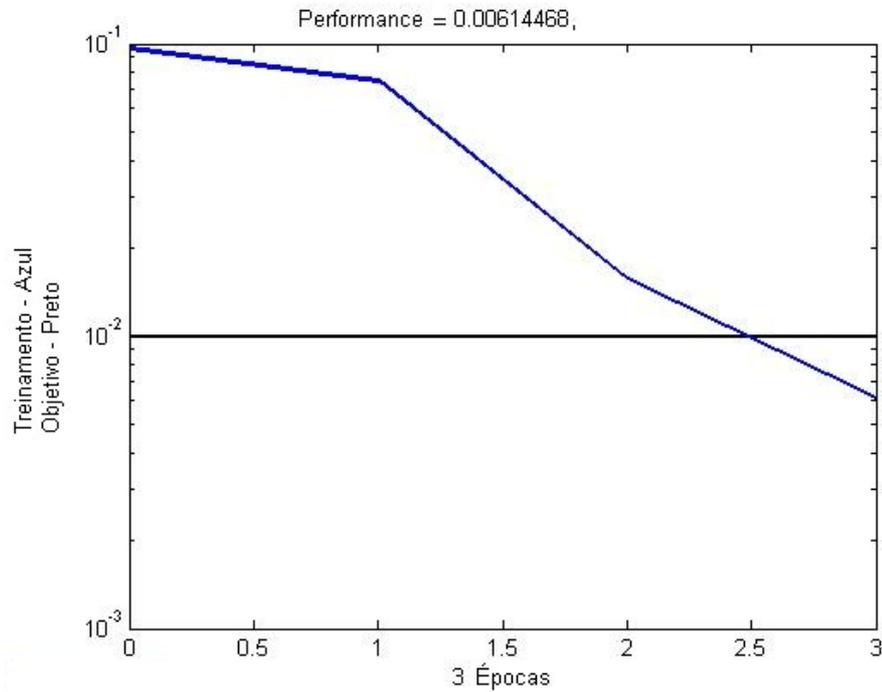


Figura 6-10 : Treinamento 2. DS2

		Previsto	
		Normal	Intrusão
Real	Normal	60361	232
	Intrusão	189597	60839

Tabela 6-14 : CM 2. DS2

Parâmetros Associados	Valor
AC	0.3897
TP	0.2429
FP	0.0038
TN	0.9962
FN	0.7571
P	0.9962

Tabela 6-15 : Parâmetros 2. DS2

Conjunto de treinamento DS3

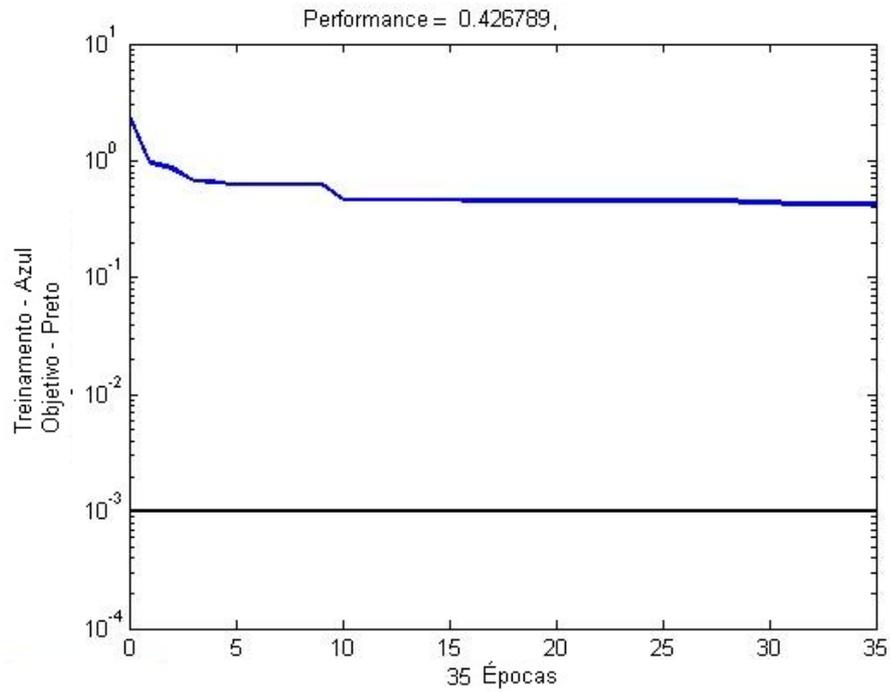


Figura 6-11 : Treinamento 2. DS3

		Previsto	
		Normal	Intrusão
Real	Normal	45009	15584
	Intrusão	57504	192932

Tabela 6-16 : CM 2. DS3

Parâmetros Associados	Valor
AC	0.7650
TP	0.7704
FP	0.2572
TN	0.7428
FN	0.2296
P	0.9253

Tabela 6-17 : Parâmetros 2. DS3

Conjunto de treinamento DS4

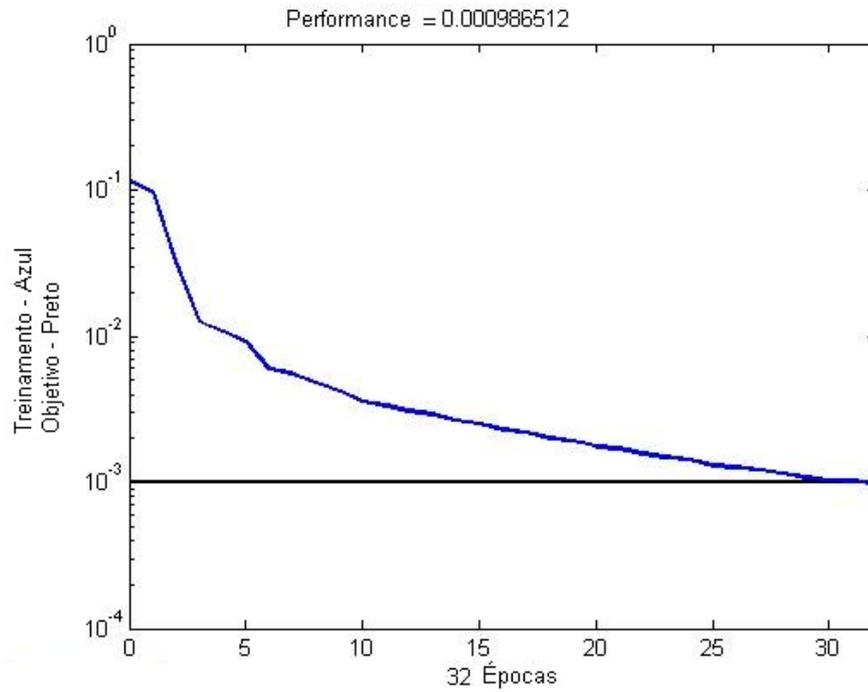


Figura 6-12 : Treinamento 2. DS4

		Previsto	
		Normal	Intrusão
Real	Normal	60558	35
	Intrusão	250157	279

Tabela 6-18 : CM 2. DS4

Parâmetros Associados	Valor
AC	0.1956
TP	0.0011
FP	0.0006
TN	0.9994
FN	0.9989
P	0.8885

Tabela 6-19 : Parâmetros 2. DS4

Conjunto de treinamento DS5

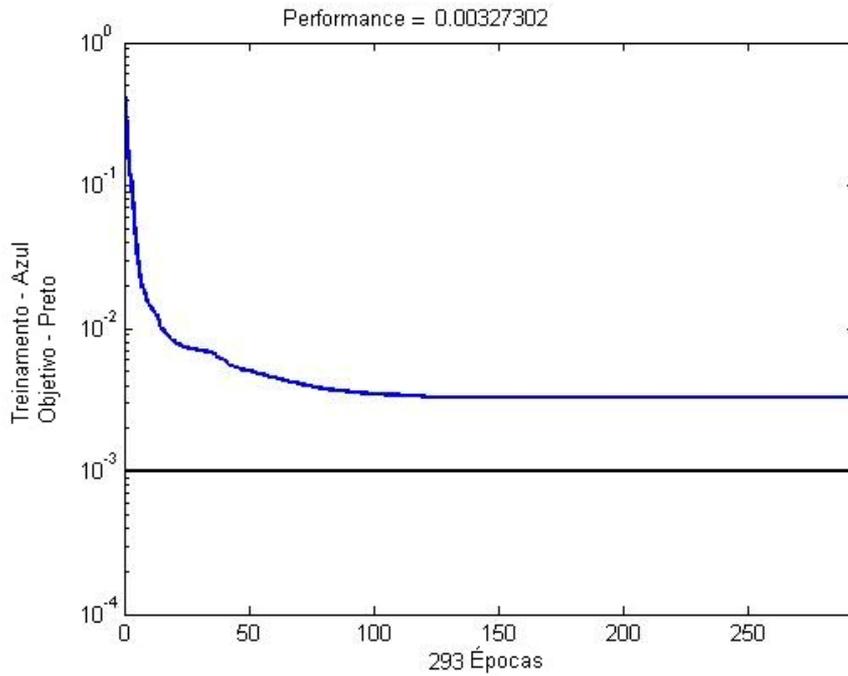


Figura 6-13 : Treinamento 2. DS5

		Previsto	
		Normal	Intrusão
Real	Normal	60509	84
	Intrusão	248946	1490

Tabela 6-20 : CM 2. DS5

Parâmetros Associados	Valor
AC	0.1993
TP	0.0059
FP	0.0014
TN	0.9986
FN	0.9941
P	0.9466

Tabela 6-21 : Parâmetros 2. DS5

Curvas ROC

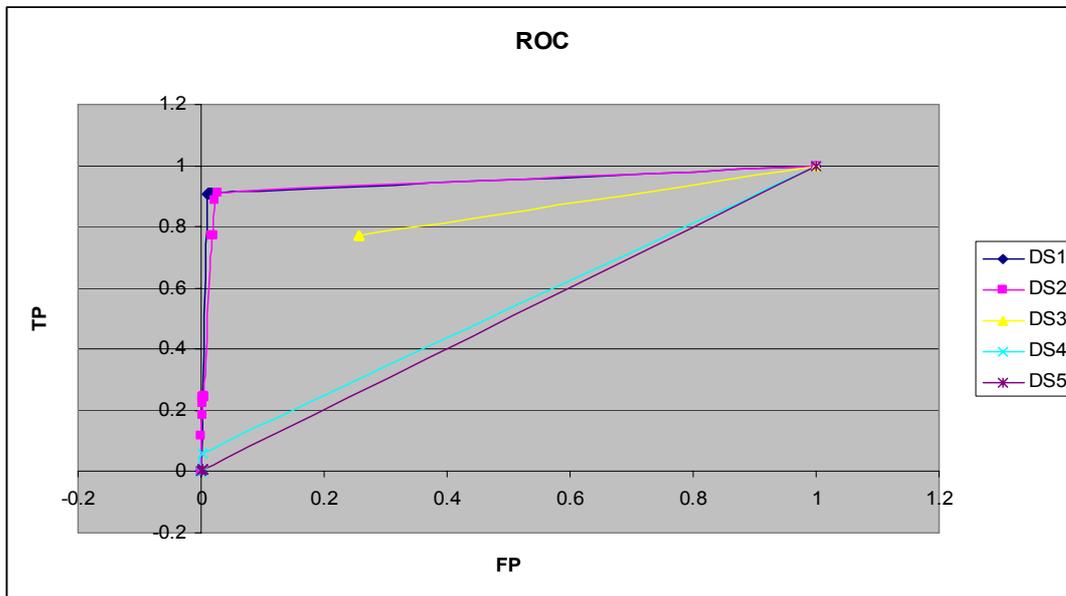


Figura 6-14 : 2. ROC – TP x FP

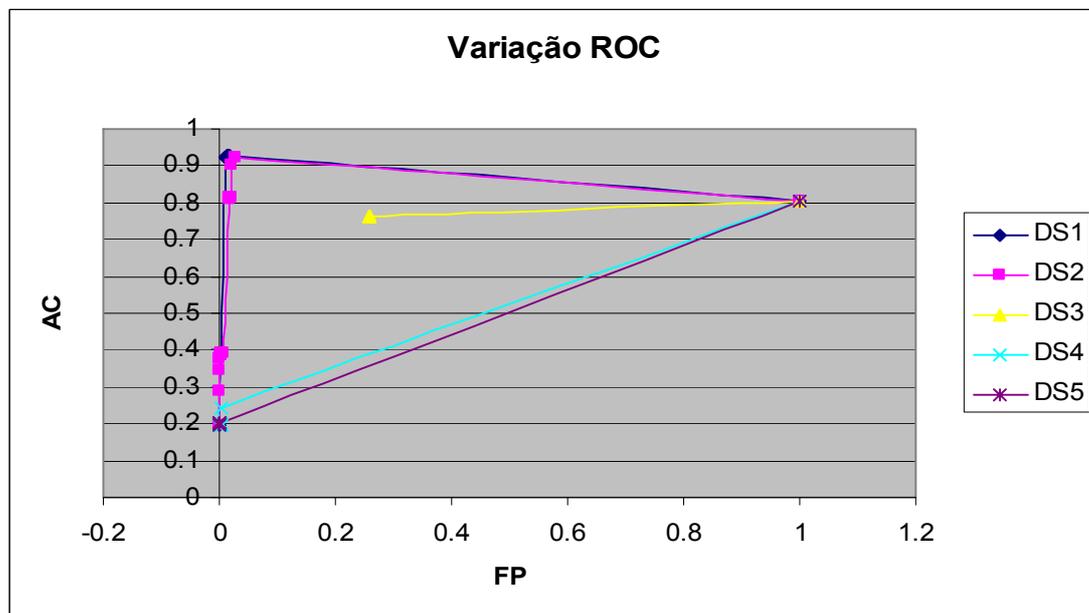


Figura 6-15 : 2. Variação ROC – AC x FP

Neste grupo de simulações, novamente ficou evidente a importância dos dados de treinamento para o desempenho da rede. O maior número de elementos de entrada (41 variáveis neste caso) indicaria, em análise preliminar, que este grupo de redes teria desempenho melhor que o 1º grupo – que teve

apenas as características intrínsecas como entrada. Entretanto, este melhor desempenho não foi comprovado na prática. O desempenho para subconjunto 1 foi ligeiramente inferior para a rede com 41 entradas em relação a rede com apenas 9 entradas.

O desempenho da rede para o subconjunto 2 foi péssimo pela análise da matriz de confusão com limiar de decisão em zero. Entretanto, analisado a curva ROC para este mesmo cenário, verifica-se que o desempenho geral foi similar ao mesmo caso para o 1º grupo. Este fato ilustra a importância do limiar de decisão. Mantendo-o em zero, temos uma rede com péssimo desempenho quando treinada com o subconjunto 2. Deslocando este limiar, atingimos índices de acerto bem mais aceitáveis.

6.2.3. Características Especialistas como Entrada

Apenas as 13 características geradas através de especialista – ver tabela 5.2 - foram utilizadas para treinar as redes neurais neste cenário. Uma rede MLP 13-15-15-1 (13 entradas, 2 camadas ocultas com 15 elementos processadores cada e uma saída) foi empregada.

Conjunto de treinamento DS1

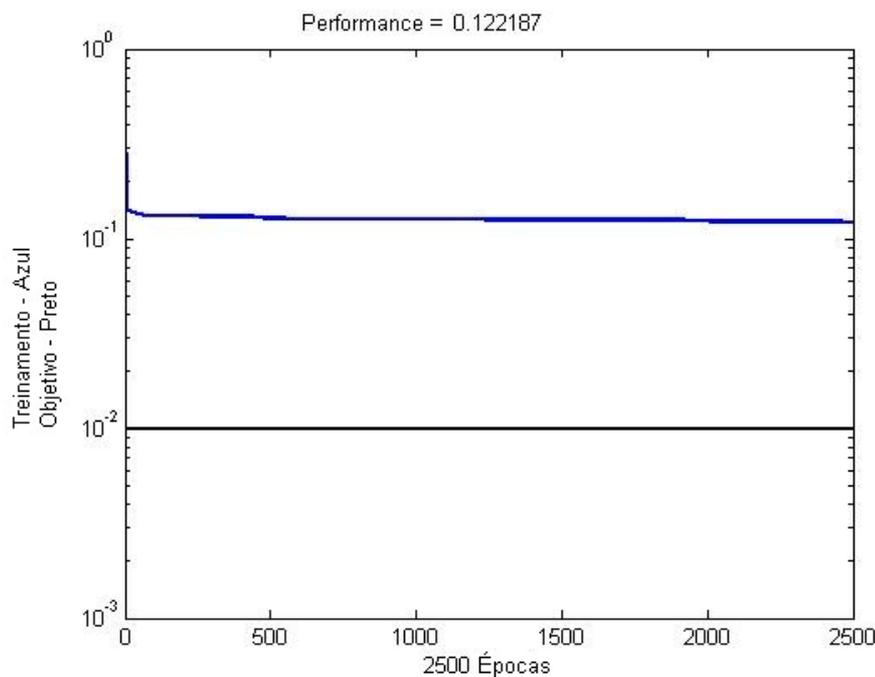


Figura 6-16 : Treinamento 3. DS1

		Previsto	
		Normal	Intrusão
Real	Normal	58643	1950
	Intrusão	25206	225230

Tabela 6-22 : CM 3. DS1

Parâmetros Associados	Valor
AC	0.9127
TP	0.8994
FP	0.0322
TN	0.9678
FN	0.1006
P	0.9914

Tabela 6-23 : Parâmetros 3. DS1

Conjunto de treinamento DS2

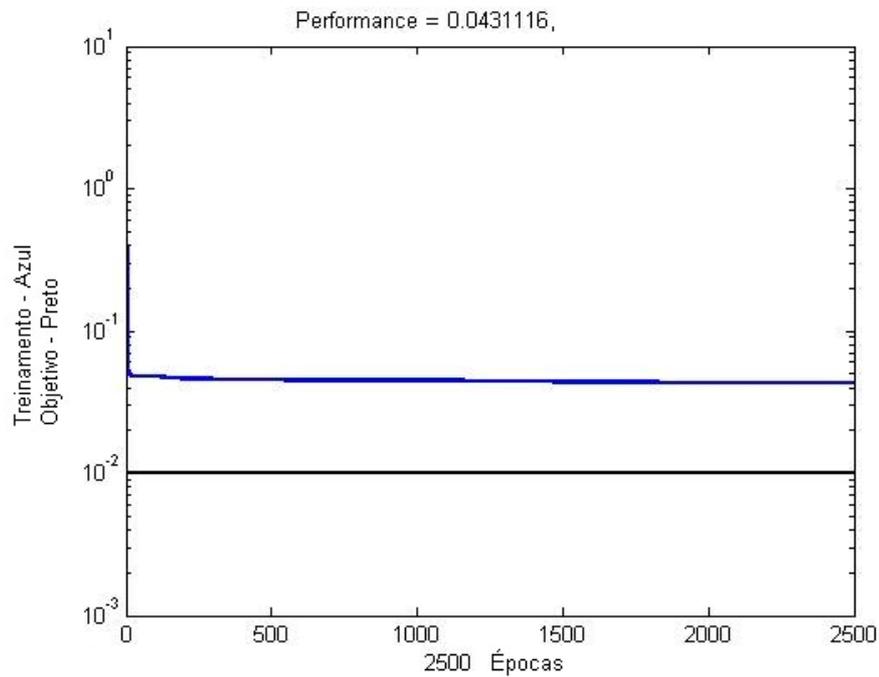


Figura 6-17 : Treinamento 3. DS2

		Previsto	
		Normal	Intrusão
Real	Normal	59895	698
	Intrusão	112722	137714

Tabela 6-24 : CM 3. DS2

Parâmetros Associados	Valor
AC	0.6353
TP	0.5499
FP	0.0115
TN	0.9885
FN	0.4501
P	0.9950

Tabela 6-25 : Parâmetros 3. DS2

Conjunto de treinamento DS3

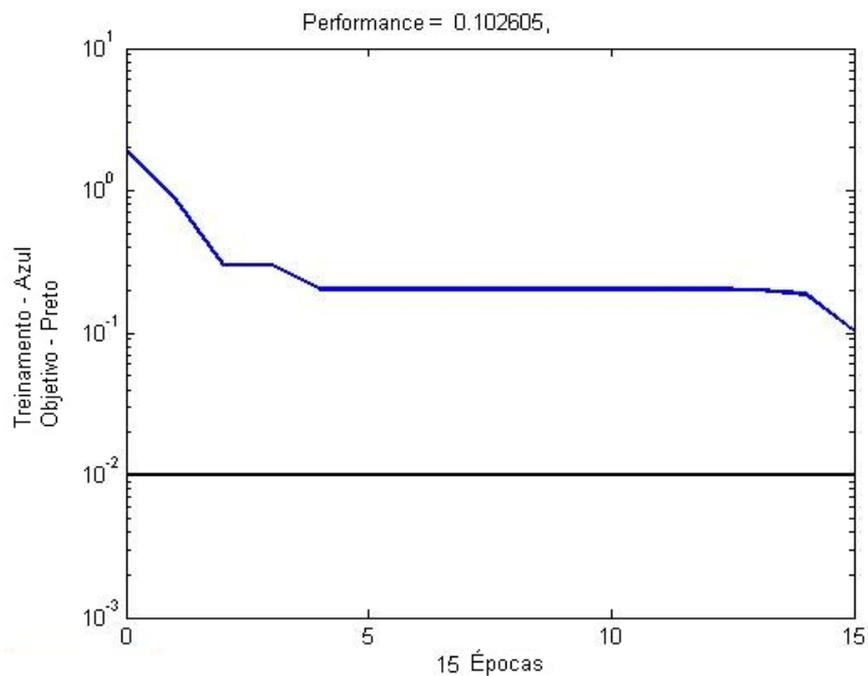


Figura 6-18 : Treinamento 3. DS3

		Previsto	
		Normal	Intrusão
Real	Normal	59122	1471
	Intrusão	27233	223203

Tabela 6-26 : CM 3. DS3

Parâmetros Associados	Valor
AC	0.9077
TP	0.8913
FP	0.0243
TN	0.9757
FN	0.1087
P	0.9935

Tabela 6-27 : Parâmetros 3. DS3

Conjunto de treinamento DS4

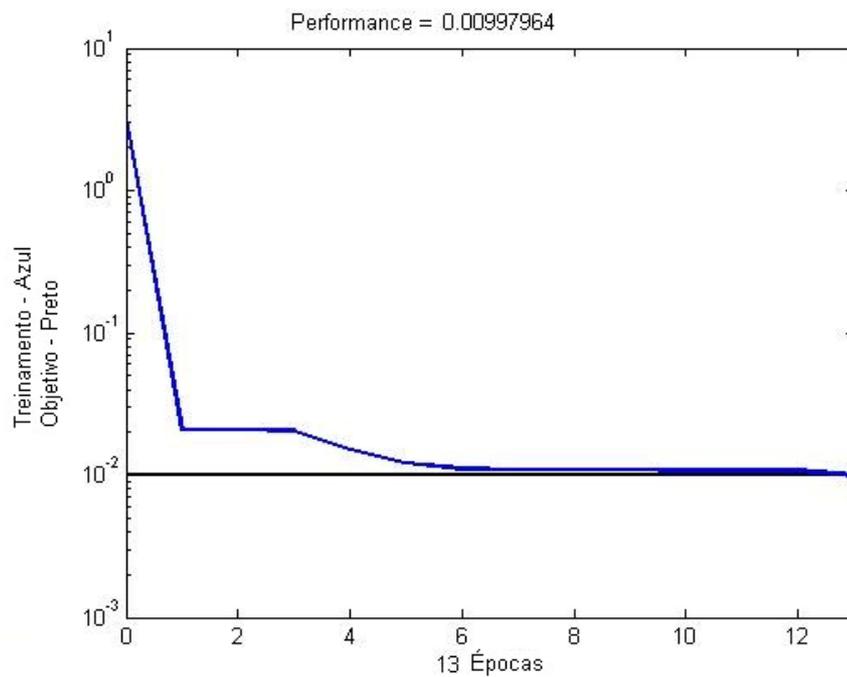


Figura 6-19 : Treinamento 3. DS4

		Previsto	
		Normal	Intrusão
Real	Normal	60574	19
	Intrusão	250412	24

Tabela 6-28 : CM 3. DS4

Parâmetros Associados	Valor
AC	0.1948
TP	0.0001
FP	0.0003
TN	0.9997
FN	0.9999
P	0.5581

Tabela 6-29 : Parâmetros 3. DS4

Conjunto de treinamento DS5

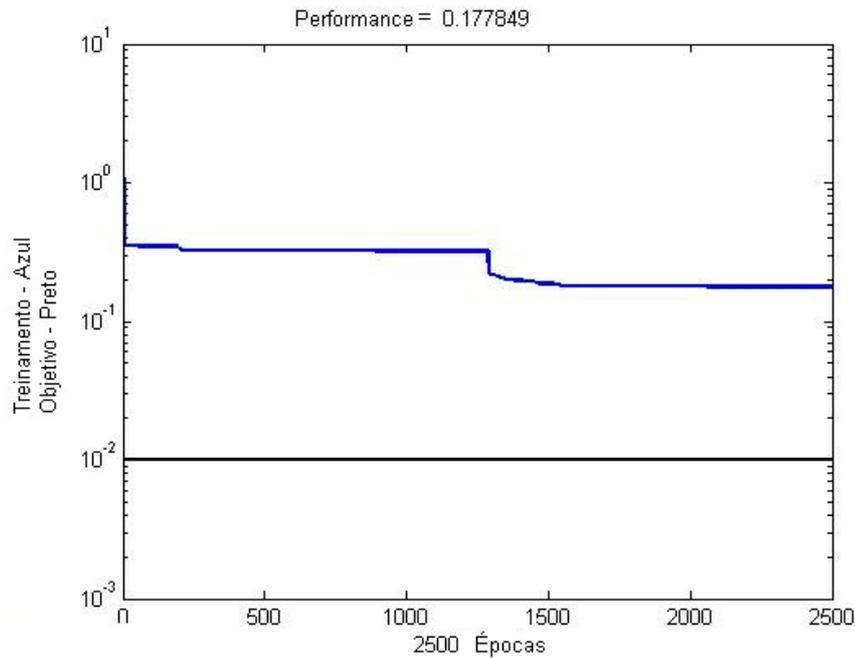


Figura 6-20 : Treinamento 3. DS5

		Previsto	
		Normal	Intrusão
Real	Normal	60445	148
	Intrusão	246546	3890

Tabela 6-30 : CM 3. DS5

Parâmetros Associados	Valor
AC	0.2068
TP	0.0155
FP	0.0024
TN	0.9976
FN	0.9845
P	0.9633

Tabela 6-31 : Parâmetros 3. DS5

Curvas ROC

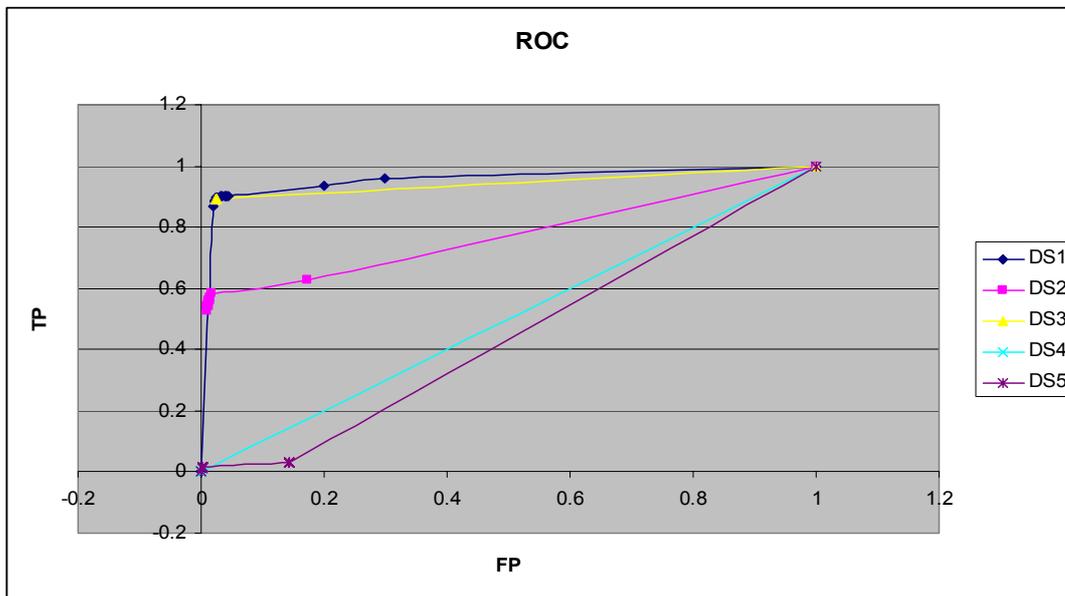


Figura 6-21 : 3. ROC – TP x FP

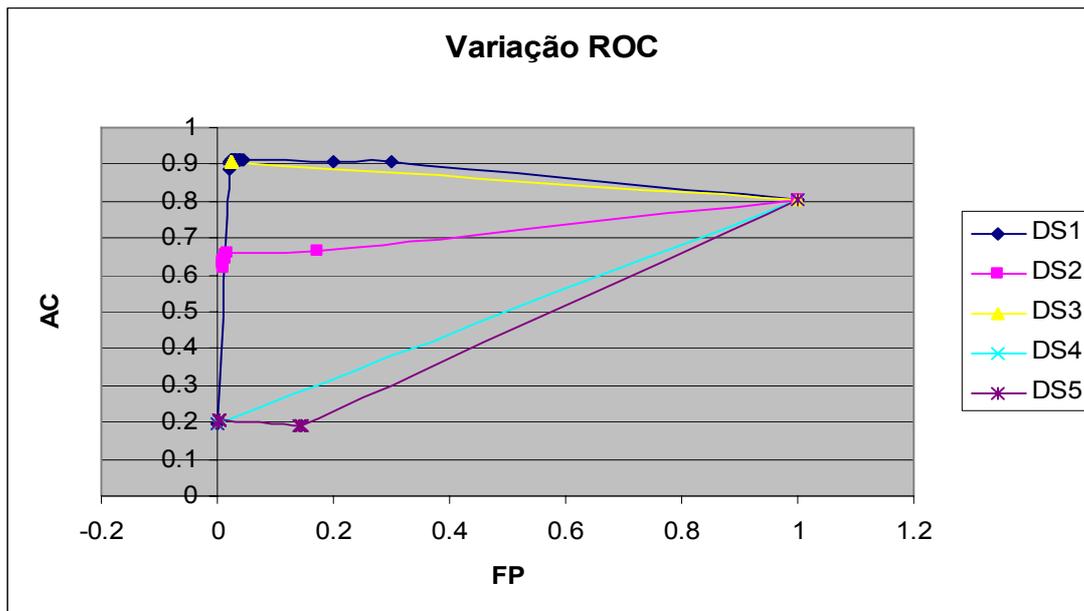


Figura 6-22 : 3. Variação ROC – AC x FP

Neste grupo, observamos uma queda no desempenho da rede para a maioria dos subconjuntos. Esta queda está associada também a uma dificuldade de convergência do processo de treinamento das redes.

Observa-se, entretanto, que as 13 características especialistas quando combinadas com um treinamento com o subconjunto 3 – padrões normais e apenas padrões da classe negação de serviço – resultam numa melhora significativa nos índices desta rede, quando comparada aos 2 grupos anteriores. Paralelamente, observa-se uma queda nos índices da rede quando treinada com o subconjunto 2 – normal e reconhecimento apenas. É possível inferir que as características especialistas são mais importantes para a detecção de padrões de negação de serviços.

6.2.4. Características Temporais como Entrada

Para este cenário, as 19 características temporais obtidas através de janela de 2 segundos – tabela 5.3 - foram utilizadas para treinar as redes neurais neste cenário. Uma rede MLP 19-15-15-1 (19 entradas, 2 camadas ocultas com 15 elementos processadores cada e uma saída) foi empregada.

Conjunto de treinamento DS1

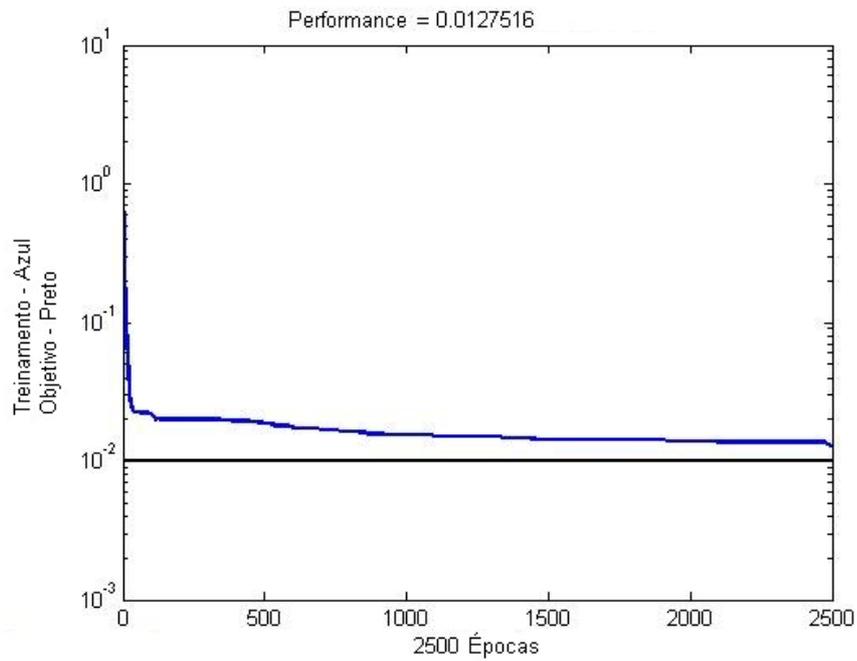


Figura 6-23 : Treinamento 4. DS1

		Previsto	
		Normal	Intrusão
Real	Normal	59339	1254
	Intrusão	55348	195088

Tabela 6-32 : CM 4. DS1

Parâmetros Associados	Valor
AC	0.8180
TP	0.7790
FP	0.0207
TN	0.9793
FN	0.2210
P	0.9936

Tabela 6-33 : Parâmetros 4. DS1

Conjunto de treinamento DS2

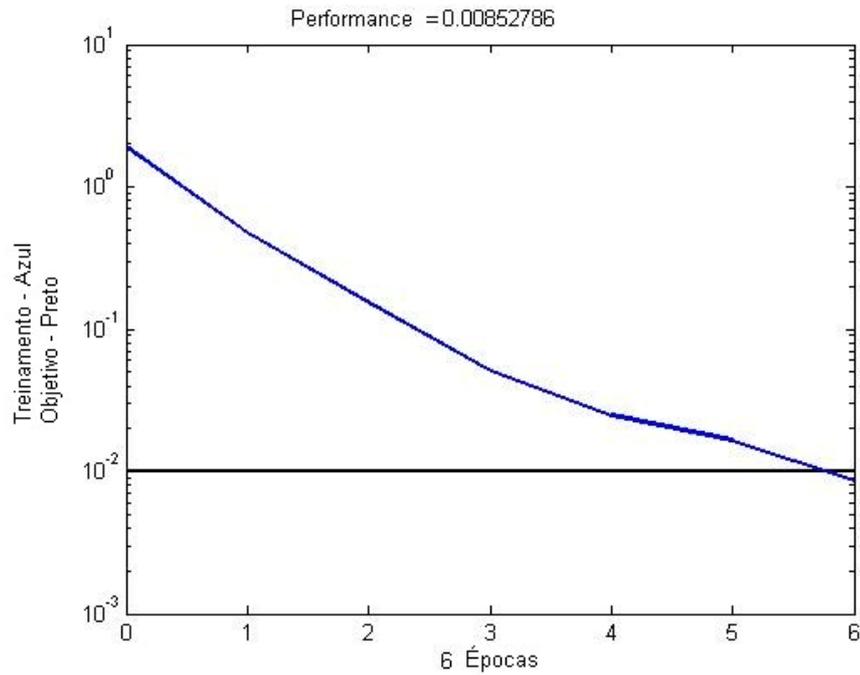


Figura 6-24 : Treinamento 4. DS2

		Previsto	
		Normal	Intrusão
Real	Normal	60372	221
	Intrusão	188624	61812

Tabela 6-34 : CM 4. DS2

Parâmetros Associados	Valor
AC	0.3928
TP	0.2468
FP	0.0036
TN	0.9964
FN	0.7532
P	0.9964

Tabela 6-35 : Parâmetros 4. DS2

Conjunto de treinamento DS3

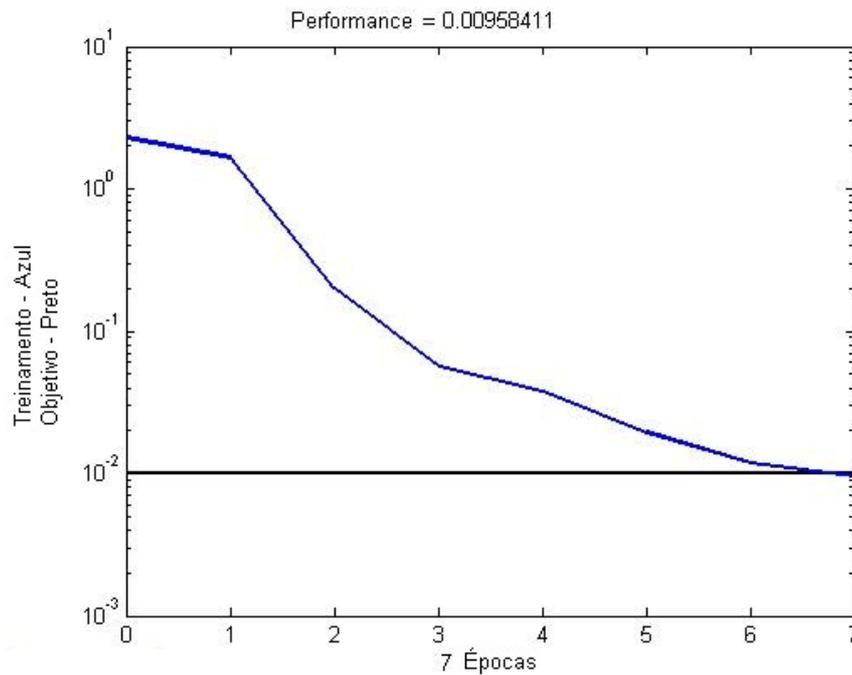


Figura 6-25 : Treinamento 4. DS3

		Previsto	
		Normal	Intrusão
Real	Normal	59793	800
	Intrusão	25654	224782

Tabela 6-36 : CM 4. DS3

Parâmetros Associados	Valor
AC	0.9149
TP	0.8976
FP	0.0132
TN	0.9868
FN	0.1024
P	0.9965

Tabela 6-37 : Parâmetros 4. DS3

Conjunto de treinamento DS4

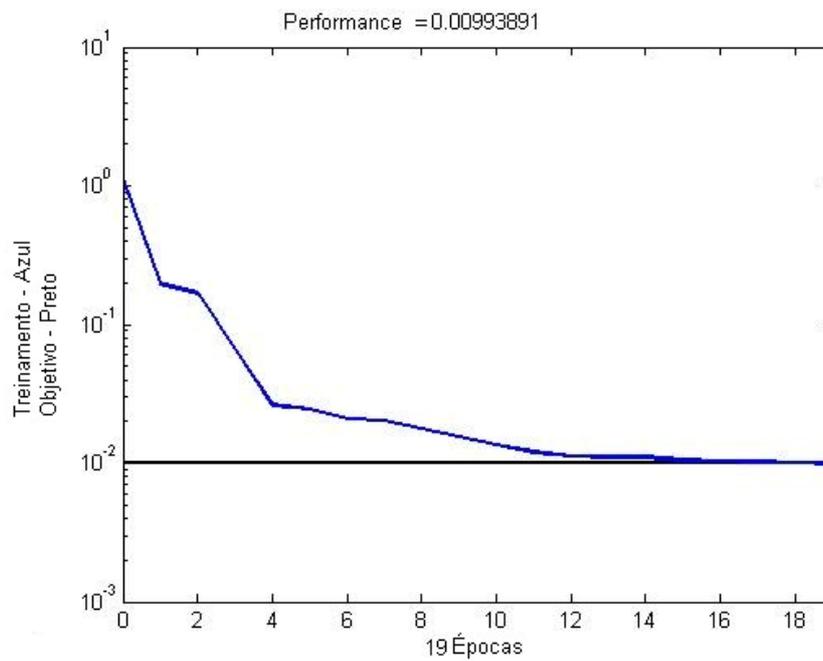


Figura 6-26 : Treinamento 4. DS4

		Previsto	
		Normal	Intrusão
Real	Normal	60513	80
	Intrusão	249480	956

Tabela 6-38 : CM 4. DS4

Parâmetros Associados	Valor
AC	0.1976
TP	0.0038
FP	0.0013
TN	0.9987
FN	0.9962
P	0.9228

Tabela 6-39 : Parâmetros 4. DS4

Conjunto de treinamento DS5

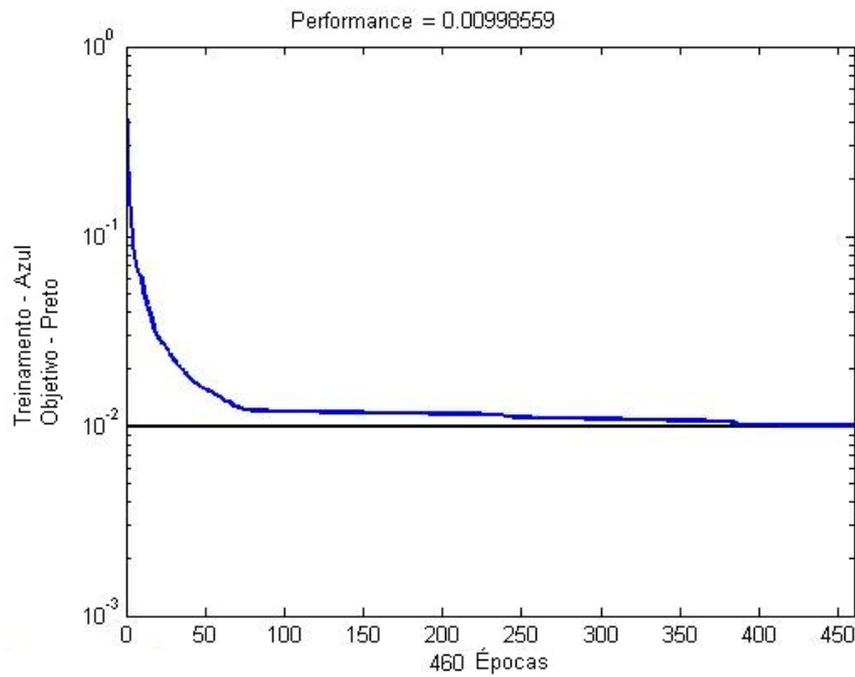


Figura 6-27 : Treinamento 4. DS5

		Previsto	
		Normal	Intrusão
Real	Normal	60294	299
	Intrusão	195529	54907

Tabela 6-40 : CM 4. DS5

Parâmetros Associados	Valor
AC	0.3704
TP	0.2192
FP	0.0049
TN	0.9951
FN	0.7808
P	0.9946

Tabela 6-41 : Parâmetros 4. DS5

Curvas ROC

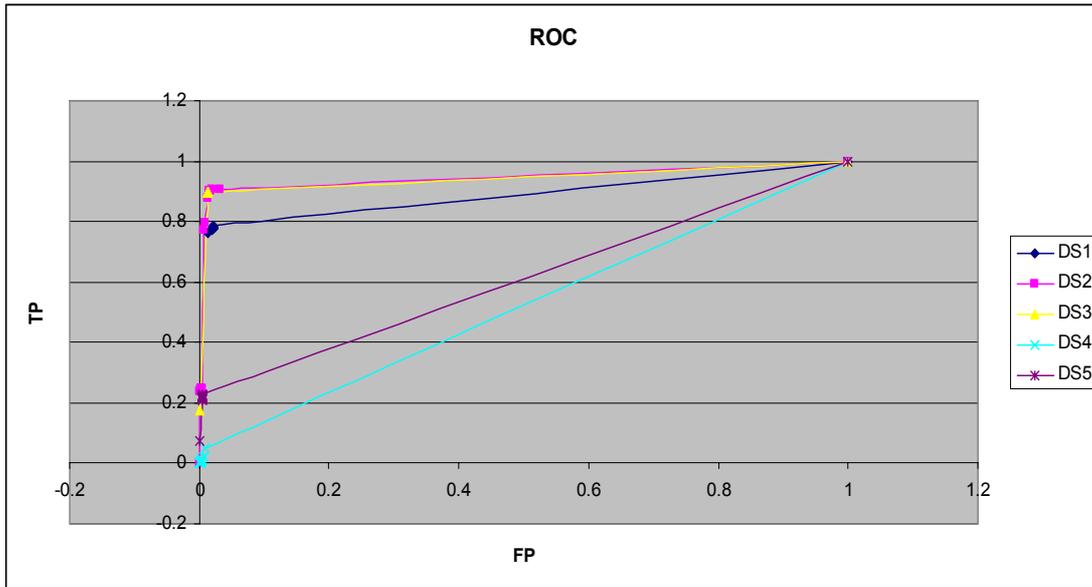


Figura 6-28 : 4. ROC – TP x FP

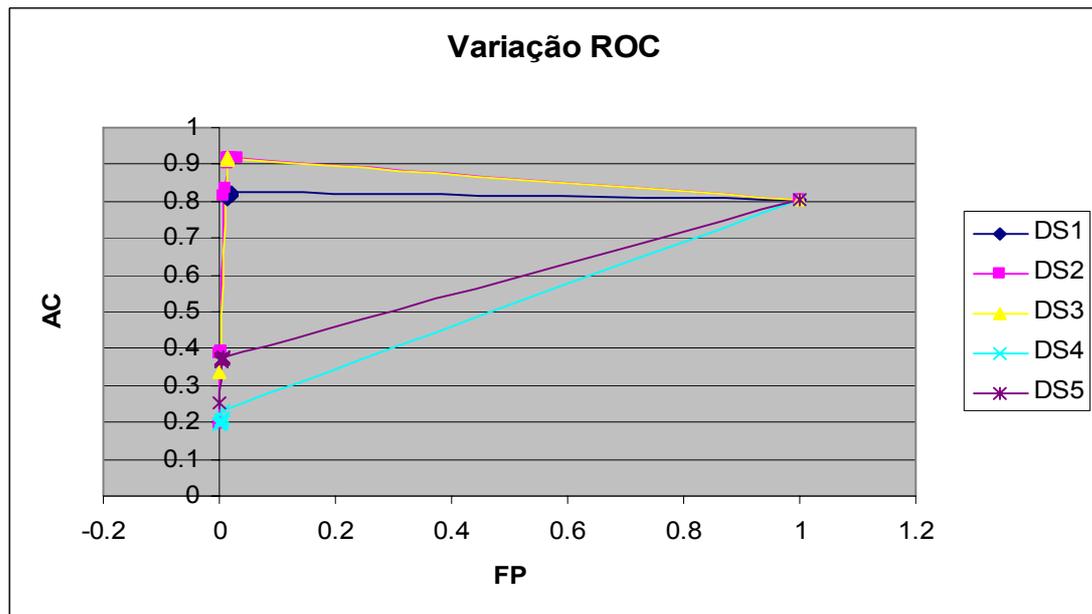


Figura 6-29 : 4. Variação ROC – AC x FP

Neste grupo, foi obtido um desempenho razoável com destaque para a rede treinada com o subconjunto 2. Pela característica dos padrões de ataque da classe de reconhecimento esperava-se uma relação forte com as características obtidas através de janela temporal. Alguns padrões da classe negação de serviço apresentam esta dependência, mas não são todos.

6.3. Classificador por Classes

Uma rede neural MLP foi treinada e avaliada para distinguir, para cada padrão de entrada apresentado, se o mesmo pertence a classe normal ou, caso seja um padrão de ataque / intrusão, determinar em qual das quatro classes de ataque – DoS, reconhecimento, usuário para super-usuário e remoto para local – o padrão pertence. Neste cenário, a rede foi treinada utilizando todas as 41 características para cada vetor de entrada e apenas o conjunto DS1 de treinamentos foi utilizado. A utilização de apenas parte das características do vetor de entradas para o treinamento desta rede não foi empregada uma vez que, para detectar com precisão a classe, é esperado que a rede precisará do máximo de informação disponível para seu aprendizado.

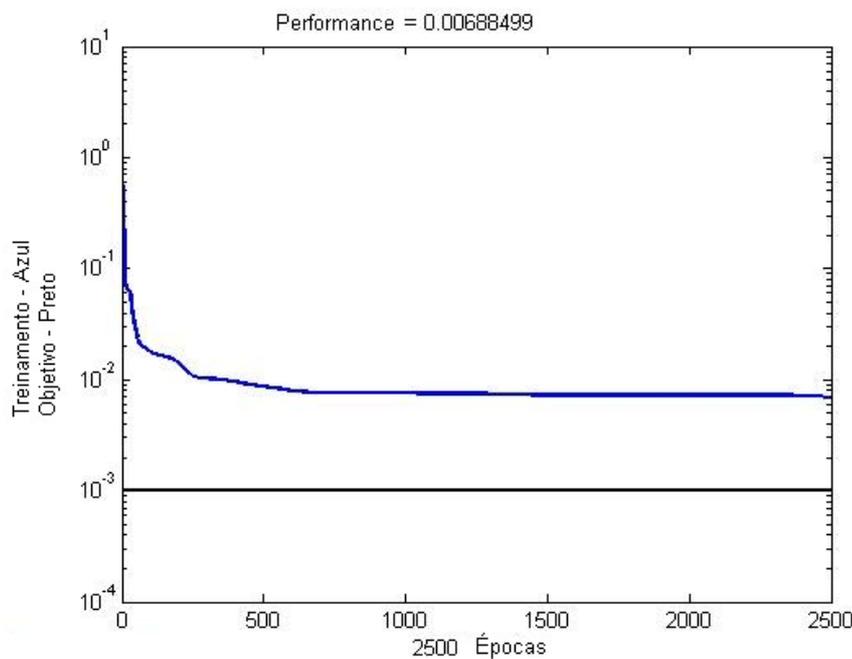


Figura 6-30 : Treinamento RN por classe – DS1

		Previsto					Taxa detecção
		Normal	R2L	DoS	U2R	Probe	
Real	Normal	59314	1	215	1	150	0.9939
	R2L	14960	149	40	2	75	0.0098
	DoS	6626	19	222781	0	121	0.9705
	U2R	39	7	1	7	1	0.1273
	Probe	580	0	243	0	2586	0.7586
	Precisão geral (AC - "Accuracy")						

Tabela 6-42 : CM por classe - DS1

Para este cenário é possível realizar a comparação dos resultados obtidos pela rede neural treinada com resultados do concurso KDDCup 1999. 24 participantes utilizaram a mesma base de dados para treinamento e testes e empregaram diversas técnicas de mineração de dados e descoberta de conhecimento para classificar um registro de conexão dentro da classe correta. A técnica vencedora [36], baseada em árvores de decisão e na ferramenta de mineração de dados C5, apresentou a seguinte matriz de confusão como resultado.

		Previsto					Taxa detecção
		Normal	R2L	DoS	U2R	Probe	
Real	Normal	60262	243	78	4	6	0,9950
	R2L	14527	294	0	8	1360	0,0840
	DoS	5299	1328	223226	0	0	0,9710
	U2R	168	20	0	30	10	0,1320
	Probe	511	3471	184	0	0	0,8339
	Precisão geral (AC - "Accuracy")						

Tabela 6-43 : CM para técnica ganhadora do KDDCup 1999

Os resultados obtidos pela rede neural foram bastante próximos do obtido pela técnica vencedora. Vantagem razoável foi notada para a técnica baseada em árvore de decisão apenas na detecção das classes R2L e reconhecimento (*Probe*).

6.4. Classificador Preciso para Classe DoS

Existem 6 padrões de intrusão da classe Negação de Serviço presentes na base de dados de treinamento. A base de dados para testes possui quatro novos padrões para esta mesma classe. Neste cenário uma rede neural MLP foi treinada para realizar a classificação precisa de padrões de ataque para a classe negação de serviço apenas. A saída da rede treinada será capaz de identificar o padrão de entrada como normal, como um dos 6 padrões presentes na base de treinamento ou como um outro padrão de ataque desconhecido (classe “Outros”). Duas redes – configuração 41-20-15-8 – foram empregadas neste cenário : a primeira foi treinada com o subconjunto de treinamento DS1 e a segunda com o subconjunto DS3 (que possui apenas padrões normais e da classe DoS).

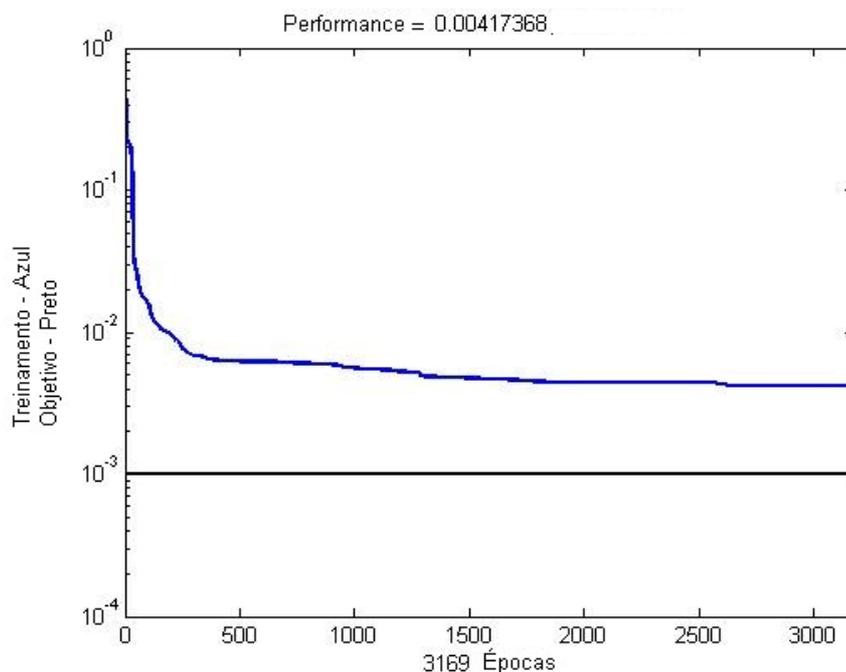


Figura 6-31 : Treinamento RN Classe DoS – DS1

		Previsto								Taxa Detecção
		Normal	Outros	Neptune	Smurf	Pod	Land	TearDrop	Back	
Real	Normal	60198	233	0	4	108	0	0	0	0.9935
	Outros	22448	4286	270	4	3	0	0	0	0.1579
	Neptune	1	67	57927	0	0	0	0	0	0.9987
	Smurf	1	0	0	163959	49	0	0	0	0.9992
	Pod	2	0	0	1	84	0	0	0	0.9655
	Land	0	0	0	0	0	0	0	0	0.0000
	Teardrop	0	4	0	0	0	0	0	0	0.0000
	Back	1098	0	0	0	0	0	0	0	0.0000
Precisão Geral (AC – “Accuracy”)										0.9210

Tabela 6-44 : CM Classe DoS – DS1

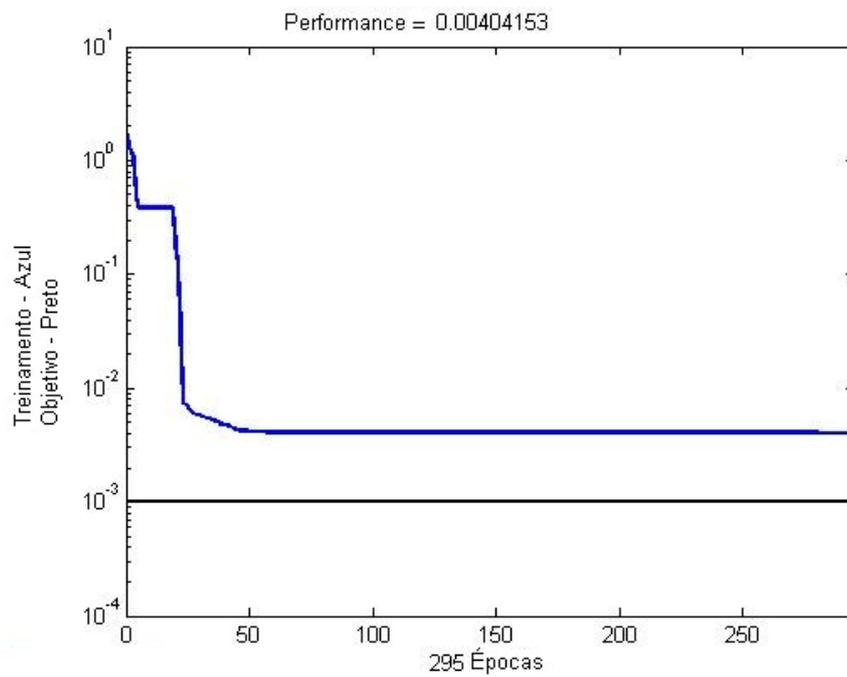


Figura 6-32 : Treinamento RN Classe DoS – DS3

		Previsto								Taxa Detecção
		Normal	Outros	Neptune	Smurf	Pod	Land	TearDrop	Back	
Real	Normal	59909	0	17	0	0	0	0	0	0.9887
	Outros	24409	0	2185	0	0	0	0	0	0.0000
	Neptune	15	0	57968	0	0	0	0	0	0.9994
	Smurf	12	0	0	0	0	0	0	0	0.0000
	Pod	78	0	0	0	0	0	0	0	0.0000
	Land	0	0	0	0	0	0	0	0	0.0000
	Teardrop	1	0	0	0	0	0	0	0	0.0000
	Back	1098	0	0	0	0	0	0	0	0.0000
Precisão Geral (AC – “Accuracy”)										0.3790

Tabela 6-45 : CM Classe DoS - DS3

Estas redes foram treinadas para tentar uma identificação precisa, dentro da classe negação de serviço, do padrão exato de ataque apresentado na sua entrada. Fico evidente que a eficiência da rede depende do treinamento com dados de entrada contendo todos os padrões (subconjunto 1). Ainda assim, a rede não conseguiu identificar corretamente nenhum caso dos padrões Land, Teardrop e Back. É importante observar que estes padrões de ataque podem ser facilmente identificados por um sistema de detecção de intrusão baseado em conhecimento (sistema especialista com regras codificadas).

6.5.

Classificador Preciso para Classe Reconhecimento

A classe de padrões de ataque de reconhecimento (“Probe”) possui 4 padrões de ataques presentes na base de treinamento e 6 na base de testes. Uma rede neural MLP – 41-20-15-6 - foi treinada – utilizando os subconjuntos DS1 e DS2 - para identificar padrões apresentados na sua entrada como pertencentes a normal, a um dos 4 padrões da classe reconhecimento ou a uma categoria de padrão intrusivo desconhecido (outros).

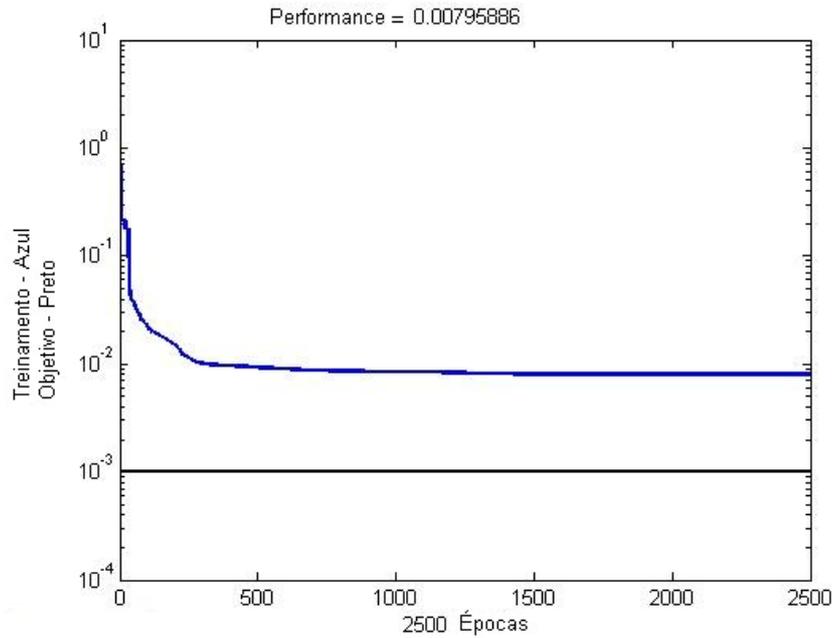


Figura 6-33 : Treinamento RN Classe “Probe” – DS1

		Previsto						Taxa Detecção
		Normal	Outros	mscan	ipsweep	nmap	satan	
Real	Normal	60093	220	71	29	0	0	0.9917
	Outros	23250	223688	64	156	0	0	0.7290
	mscan	0	9	319	2	0	0	0.3029
	ipsweep	0	6	0	235	0	0	0.7680
	nmap	0	0	0	0	84	0	1.0000
	satan	86	0	1	0	0	0	0.0000
	Precisão Geral (AC – “Accuracy”)							

Tabela 6-46 : CM Classe Reconhecimento – DS1

		Previsto						Taxa Detecção
		Normal	Outros	mscan	ipsweep	nmap	satan	
Real	Normal	60481	0	86	0	0	0	0.9982
	Outros	206319	0	940	0	0	0	0.0000
	mscan	4	0	326	0	0	0	0.3096
	ipsweep	306	0	0	0	0	0	0.0000
	nmap	84	0	0	0	0	0	0.0000
	satan	227	0	27	0	0	0	0.0000
	Precisão Geral (AC – “Accuracy”)							

Tabela 6-47 : CM Classe Reconhecimento – DS2

Como na rede com classificação precisa para a classe negação de serviço, a rede neste cenário apresentou uma precisão geral razoável quando treinada com o subconjunto 1 e muito ruim quando treinada com o subconjunto 2. Não existe boa correlação entre as características especialistas e padrões específicos da classe reconhecimento. Novamente, pelo menos um padrão de ataque (satan) não foi identificado corretamente.

6.6. Classificador Preciso para Classe U2R

Rede neural MLP – 41-20-15-6 – foi treinada para identificar os 4 padrões da classe U2R presentes na base de treinamento com precisão. A rede foi treinada com os subconjuntos DS1 e DS4 – DS4 possui apenas registros da classe U2R e normais.

Para esta classe de ataques a rede não foi capaz de detectar precisamente os padrões. Quando treinada com o subconjunto DS1 conseguiu operar apenas como classificador binário detectando conexões como normal ou intrusão. Para a versão treinada com o subconjunto DS4 a rede conseguiu identificar corretamente apenas padrões da classe normal.

		Previsto						Taxa Detecção
		Normal	Outros	mscan	ipsweep	nmap	satan	
Real	Normal	60155	406	0	0	0	0	0.9928
	Outros	23670	226635	0	0	0	0	0.9051
	rootkit	7	6	0	0	0	0	0.0000
	perl	2	0	0	0	0	0	0.0000
	loadmodule	1	1	0	0	0	0	0.0000
	buffer_overflow	17	5	0	0	0	0	0.0000
	Precisão Geral (AC – “Accuracy”)							0.9221

Tabela 6-48 : CM Classe U2R – DS1

		Previsto						Taxa Detecção
		Normal	Outros	mscan	ipsweep	nmap	satan	
Real	Normal	60593	0	0	0	0	0	1.0000
	Outros	250397	0	0	0	0	0	0.0000
	rootkit	13	0	0	0	0	0	0.0000
	perl	2	0	0	0	0	0	0.0000
	loadmodule	2	0	0	0	0	0	0.0000
	buffer_overflow	22	0	0	0	0	0	0.0000
	Precisão Geral (AC – “Accuracy”)							

Tabela 6-49 : CM Classe U2R – DS4

6.7.

Classificador Preciso para Classe R2L

Para a classe remoto para local – R2L – existem 8 padrões distintos de ataque na base de dados de treinamento. Uma rede neural MLP 41-20-15-10 foi treinada para detectar estes 8 padrões, além de padrões representando conexões normais e uma última classe representando todos os outros ataques e intrusões.

		Previsto										Taxa Detecção
		Normal	Outros	Warezmaster	Guess_passwd	Multihop	Imap	Spy	ftp_write	Warezclient	Phf	
Real	Normal	59503	1048	2	2	2	0	0	3	0	1	0.9820
	Outros	18798	225536	0	23	1	0	0	2	0	1	0.8795
	warezmaster	0	0	0	0	0	0	0	0	0	0	0.0000
	guess_passwd	2	0	0	0	0	0	0	0	0	0	0.0000
	multihop	2	0	0	0	0	0	0	0	0	0	0.0000
	imap	1	0	1	0	0	0	0	0	0	0	0.0000
	spy	1	0	0	0	0	0	0	0	0	0	0.0000
	ftp_write	15	1	0	0	2	0	0	0	0	2	0.0000
	warezclient	4356	8	0	1	0	0	0	0	0	0	0.0000
	phf	492	10	0	1	8	0	0	511	0	68	0.5667
Precisão Geral (AC – “Accuracy”)											0.8933	

Tabela 6-50 : CM Classe R2L - DS1

		Previsto										Taxa Detecção
		Normal	Outros	Warezmaster	Guess_passwd	Multihop	Imap	Spy	ftp_write	Warezclient	Phf	
Real	Normal	60563	0	0	23	0	0	0	0	1	0	0.9995
	Outros	244178	0	0	74	0	0	11	0	3	0	0.0000
	warezmaster	0	0	0	0	0	0	0	0	0	0	0.0000
	guess_passwd	2	0	0	0	0	0	0	0	0	0	0.0000
	multihop	2	0	0	0	0	0	0	0	0	0	0.0000
	imap	2	0	0	0	0	0	0	0	0	0	0.0000
	spy	1	0	0	0	0	0	0	0	0	0	0.0000
	ftp_write	15	0	0	3	0	0	0	0	0	0	0.0000
	warezclient	4363	0	0	3	0	0	0	0	0	0	0.0000
	phf	906	0	0	26	0	0	2	0	0	0	0.0000
Precisão Geral (AC – “Accuracy”)											0.1910	

Tabela 6-51 : CM Classe R2L – DS5

A tentativa de identificação precisa para as classes R2L e U2R não apresentou desempenho satisfatório em nenhum caso. O número reduzido de ocorrências de padrões destas duas classe é uma explicação para a falha da rede aprender corretamente estes padrões. Em uma situação real, o percentual de pacotes representando ataques desta classe é usualmente muito inferior ao percentual de padrões normais, negação de serviço ou reconhecimento. Mesmo para um alto número de intrusões, pois a natureza dos ataques desta classe envolve, tipicamente, poucos pacotes por ataque.

Esta péssimo desempenho torna necessário a utilização de outras técnicas em conjunto com sistemas de redes neurais.

6.8. Comitê de Redes Especialistas

Comitê de redes neurais especialistas são sistemas que combinam as respostas de várias redes para gerar uma resposta final. O objetivo é que esta combinação gere uma resposta final melhor que a resposta individual de qualquer rede pertencente ao comitê. Utilizando as diversas redes treinadas como classificadores binários, como um comitê, efetuou-se a análise do resultado final quando as saídas individuais são combinadas pela média e pelo voto majoritário (o padrão é considerado uma intrusão quando a maioria das redes o considera uma intrusão).

6.8.1. Decisão por voto majoritário

		Previsto	
		Normal	Intrusão
Real	Normal	60591	2
	Intrusão	228727	21709

Tabela 6-52 : CM Comitê por voto majoritário

Parâmetros Associados	Valor
AC	0.2646
TP	0.0867
FP	0.0000
TN	1.0000
FN	0.9133
P	0.9999

Tabela 6-53 : Parâmetros Comitê por voto majoritário

Este comitê apresentou um excelente desempenho para identificar padrões normais (errou apenas em 2 casos). Entretanto, seu desempenho com limiar em zero foi muito ruim para identificar intrusões. Ajustando o limiar, como mostrado na curva ROC a seguir, as taxas de acerto se tornam razoáveis. Entretanto os resultados obtidos por esta combinação de redes especialistas não é melhor que várias redes individuais.

6.8.2. Decisão pela Média

		Previsto	
		Normal	Intrusão
Real	Normal	60592	1
	Intrusão	217232	33204

Tabela 6-54 : CM Comitê pela média

Parâmetros Associados	Valor
AC	0.3016
TP	0.1326
FP	0.0000
TN	1.0000
FN	0.8674
P	1.0000

Tabela 6-55 : Parâmetros Comitê pela média

Novamente, uma excelente capacidade de detectar padrões normais e uma péssima capacidade de detectar intrusões com limiar $th = 0$. A curva ROC mostra que esta rede tem bom desempenho geral quando limiar é ajustado.

6.8.3. Decisão por algoritmo adaptativo proposto

Foi desenvolvido um algoritmo adaptativo de combinação de redes neurais. O princípio deste algoritmo foi selecionar de forma adaptativa quais redes devem ter direito a voto no processo final baseado em análise empírica e processo de tentativa e erro. O algoritmo faz uso da rede neural que identifica a classe do padrão (normal, reconhecimento, negação de serviços, U2R e R2L) e do comitê baseado na média. A lógica do algoritmo proposta esta esquematizada a seguir :

Se (RN_Classe = Normal) & (Comitê_Média (P1,th) = “Normal”)

– Resposta = Normal

- Senão Se (RN_Classe = (DoS ou Probe)) &
 - (Comitê_Média (P2,th) = “Ataque”)
 - Resposta = Intrusão
 - Senão Se (RN_Classe = (R2L ou U2R)) & (Comitê_Media(P3,th) = “Ataque”)
 - Resposta = Intrusão
 - Senão
- Resposta = Resposta (Comitê_Média, th)

A matriz de confusão e parâmetros associados indicam que o algoritmo proposto conseguiu o melhor desempenho para o limiar de decisão $th=0$. Apenas um caso de padrão normal não foi identificado corretamente e quase 95% dos casos de intrusão também foram acertadamente identificados.

		Previsto	
		Normal	Intrusão
Real	Normal	60592	1
	Intrusão	14309	236075

Tabela 6-56 : CM para Algoritmo de decisão proposto

Parâmetros Associados	Valor
AC	0.9540
TP	0.9429
FP	0.0000
TN	1.0000
FN	0.0571
P	1.0000

Tabela 6-57 : Parâmetros para Algoritmo de decisão proposto

6.8.4. Curvas ROC

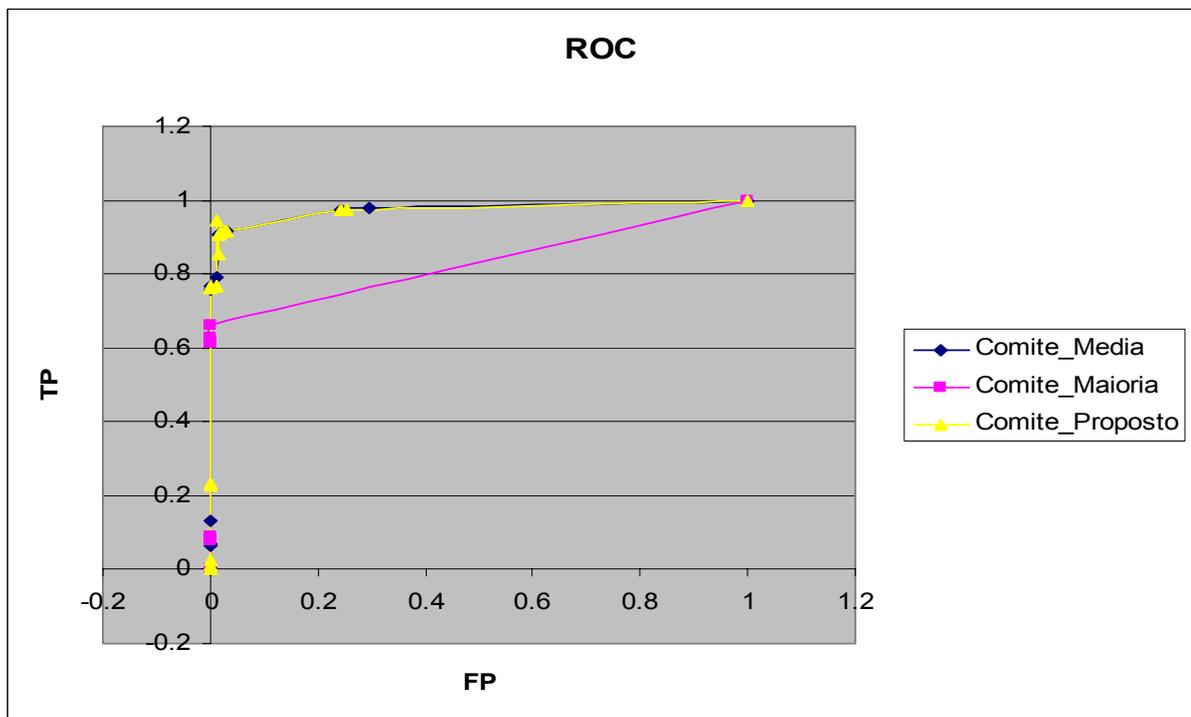


Figura 6-34 : ROC para Comitês – TP x FP

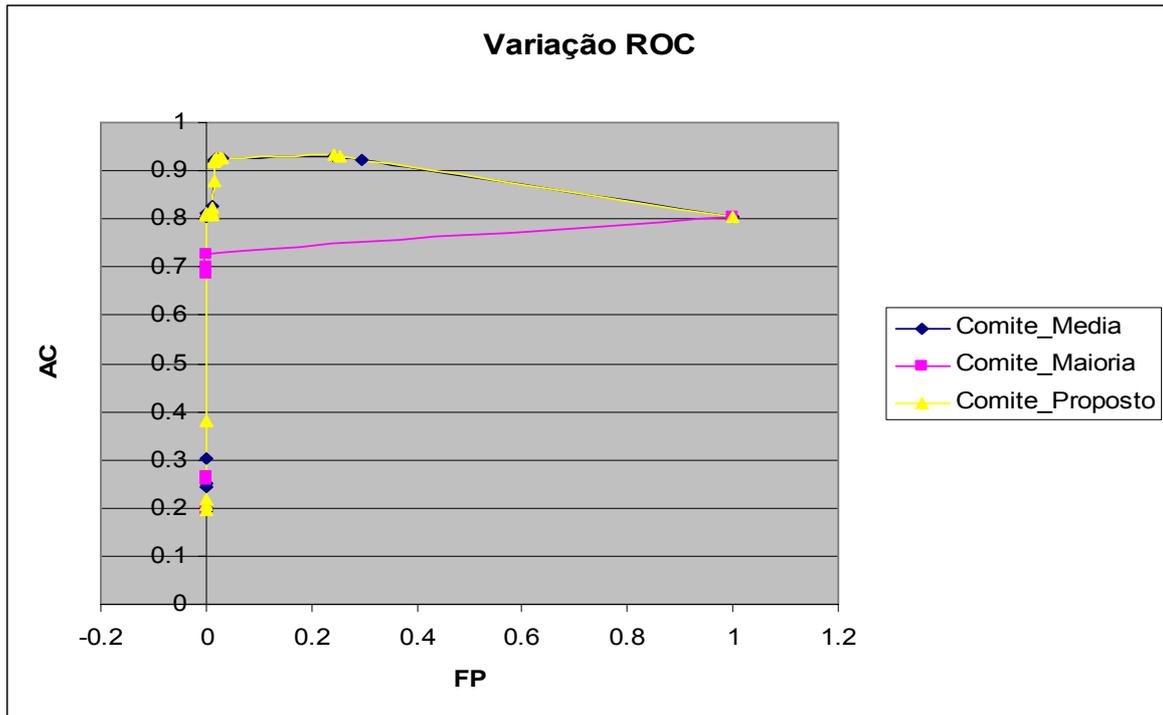


Figura 6-35 : Variação ROC para Comitês – AC x FP

As curvas ROC mostram que o comitê pela média consegue um desempenho muito similar ao algoritmo proposto. Este tem, entretanto, a vantagem de fornecer o melhor desempenho sem necessitar de ajustes no limiar de decisão.