

6 Estudo de Casos

6.1. Descrição

Para avaliar o desempenho do Sistema Neuro-Fuzzy-Genético foram utilizados dados de aplicações reais e *benchmarks*.

Os dados de aplicações reais são séries de carga de grandes companhias de energia elétrica do Brasil: Furnas, Light, Copel, Eletropaulo, Cerj e Cemig. Esses dados foram utilizados para avaliar o sistema em aplicações de previsão de séries temporais.

Para avaliação do sistema em aplicações de classificação de padrões, foram utilizadas bases *benchmark*, de modo a facilitar a comparação do modelo criado com outros existentes. Foram utilizadas quatro bases: *Wine Data*, *Glass Data*, *Pima Indians Diabetes Database* e *Bupa Livers Disorders Database*.

Para a realização de cada um dos estudos, inicialmente são executados os algoritmos de seleção de variáveis. Sendo assim, as ordens em que as variáveis devem ser utilizadas no sistema NFHB no momento de sua execução são previamente definidas para cada um dos algoritmos e armazenadas em arquivo. Isso foi feito para que não fosse necessário executar os algoritmos a todo o momento em que o sistema NFHB fosse treinado, já que os resultados são sempre os mesmos.

Após definidas as ordens das variáveis, os AGs coevolutivos têm seus parâmetros devidamente configurados, conforme demonstrado no capítulo anterior.

O sistema é então executado até que todos os ciclos coevolutivos sejam completados. Os resultados são acumulados em um arquivo para posterior análise do comportamento da evolução. A configuração de parâmetros final também é armazenada, já que representa o resultado definitivo do sistema.

A seguir serão definidos e apresentados os experimentos individualmente.

6.2. Previsão de Séries Temporais

Problemas de previsão de séries temporais são aqueles em que se deseja inferir valores futuros de uma série de valores obtidos ao longo do tempo, a partir de valores passados.

6.2.1. Séries de Carga Elétrica

Neste trabalho foram estudados problemas de previsão de séries de carga elétrica de seis importantes companhias brasileiras, citadas na seção anterior. Os dados das séries foram obtidos mensalmente no período entre Janeiro de 1983 e Agosto de 1998, porém, para comparação com resultados obtidos em outros trabalhos, foram utilizados apenas valores entre Janeiro de 1983 e Dezembro de 1994.

As previsões realizadas foram do tipo *one-step-ahead (single-step)*, ou seja, deseja-se prever o valor da série em $t+1$, onde t é o último valor conhecido da série.

Os padrões de entrada são criados a partir do valor do parâmetro correspondente à janela de previsão. Por exemplo, se a janela é de cinco, o primeiro padrão de entrada é formado por cinco valores consecutivos da série histórica (Janeiro a Maio de 1983), sendo o sexto valor da série (Junho de 1983) utilizado como saída desejada. O padrão seguinte terá como primeiro valor o mês de Fevereiro de 1983, e assim por diante.

Como devem ser definidos dois conjuntos de dados, um de treinamento e outro de validação, foi definida uma porcentagem *a priori* no valor de 92% de padrões para treinamento e de 8% para validação. Essas porcentagens foram definidas para manter a mesma proporção existente em outros trabalhos [SOUZ99][CONT02] [BEZE02], facilitando a comparação.

As tabelas a seguir apresentam as seqüências de variáveis calculadas para as séries temporais utilizadas. Nessas tabelas são mostrados os índices das variáveis, começando de zero, separados por vírgula. A ordem em que as variáveis são utilizadas está definida da esquerda para a direita. Na mesma tabela são apresentadas as seqüências encontradas para os três métodos estudados: Adaptado Anfis, LSE e SIE.

Tabela 6: Seqüências de entradas escolhidas pelos métodos Anfis, LSE e SIE para a série de Furnas

janela	Seqüência de Entradas		
	ANFIS	SIE	LSE
4	0,3,1,2	3	3,2,1,0
5	1,4,0,2,3	4	4,3,2,1,0
6	2,5,1,3,0,4	5	5,4,3,1,2,0
7	0,6,3,2,4,1,5	6,0,1	6,0,1,5,4,2,3
8	0,7,1,4,3,5,2,6	7,0,2,6	7,0,2,6,1,5,3,4
9	0,8,1,2,5,4,6,3,7	8,1,3,0,7,2	8,1,0,3,6,2,7,5,4
10	1,9,2,0,3,6,5,7,4,8	9,2,4,1,8,3,7,0	9,2,4,1,3,8,7,5,6,0
11	2,10,3,1,0,4,7,6,8,5,9	10,3,5,2,9,4,1,8	10,3,5,8,2,7,9,4,1,0,6
12	3,11,4,2,0,1,5,8,7,9,6,10	11,4,6,3,10,5,2,9	11,4,5,10,6,3,9,1,2,8,7,0

Tabela 7: Seqüências de entradas escolhidas pelos métodos Anfis, LSE e SIE para a série da Light

janela	Seqüência de Entradas		
	ANFIS	SIE	LSE
4	0,3,1,2	3,0,2	3,0,2,1
5	1,4,0,2,3	4,1,0,3	4,1,0,3,2
6	2,5,1,3,0,4	5,2,0,4	5,2,4,0,3,1
7	3,6,2,4,0,1,5	6,3,0,5	6,3,0,5,4,2,1
8	4,7,0,3,5,1,2,6	7,4,0,6,1,5,2	7,4,1,6,2,0,5,3
9	0,8,5,1,4,6,2,3,7	8,0,5,7,6,3	8,5,0,6,7,3,2,4,1
10	0,9,1,6,2,5,7,3,4,8	9,6,0,8,1,7	9,0,6,8,1,7,2,3,4,5
11	0,10,1,9,2,7,3,6,8,4,5	10,0,7,9,8,1,4	10,7,0,9,8,1,2,6,4,5,3
12	1,11,2,0,10,3,8,7,9,6,5,4	11,8,0,1,10,9,5,2	11,8,0,10,1,5,9,6,3,2,7,4

Tabela 8: Seqüências de entradas escolhidas pelos métodos Anfis, LSE e SIE para a série de Copel

janela	Seqüência de Entradas		
	ANFIS	SIE	LSE
4	0,1,2,3	3,2,0	3,2,0,1
5	0,1,2,3,4	4,3,0,2	4,3,0,2,1
6	0,1,2,3,4,5	5,4,1,3,2	5,4,1,3,2,0
7	0,1,2,3,4,5,6	6,5,2,1,0,4,3	6,5,2,1,0,4,3
8	0,1,2,3,4,5,6,7	7,6,3,2,4,5	7,6,3,2,5,1,4,0
9	1,2,3,0,4,5,6,7,8	8,7,4,3,5,6,2,0	8,7,4,3,5,6,2,0,1
10	2,3,1,4,5,0,6,7,8,9	9,8,5,4,0,6,7,3	9,8,5,4,6,3,7,0,1,2
11	3,4,2,5,6,1,7,8,0,9,10	10,6,9,5,0,7,4,8	10,6,9,5,0,7,8,4,1,2,3
12	4,5,3,6,7,2,8,9,1,0,10,11	11,7,10,6,1,8,5,9	11,7,10,6,8,1,9,5,2,0,3,4

Tabela 9: Seqüências de entradas escolhidas pelos métodos Anfis, LSE e SIE para a série de Eletropaulo

janela	Seqüência de Entradas		
	ANFIS	SIE	LSE
4	0,3,1,2	3	3,0,2,1
5	0,4,1,2,3	4,0	4,0,3,1,2
6	0,5,1,2,3,4	5,0	5,0,4,1,2,3
7	1,6,2,3,0,4,5	6,0	6,0,3,2,5,1,4
8	2,7,0,3,4,5,1,6	7,0	7,0,1,2,3,4,6,5
9	3,8,0,1,4,5,6,2,7	8,1,0	8,1,0,4,2,6,7,5,3
10	4,9,0,1,2,5,6,7,3,8	9,0,2	9,1,2,0,8,4,7,3,5,6
11	0,10,5,1,3,6,7,8,2,4,9	10,0,3,1	10,0,3,1,9,8,2,4,7,6,5
12	0,11,1,6,2,4,7,8,9,3,5,10	11,0,1,4,2	11,4,1,0,5,7,6,2,3,10,9,8

Tabela 10: Seqüências de entradas escolhidas pelos métodos Anfis, LSE e SIE para a série da Cerj

janela	Seqüência de Entradas		
	ANFIS	SIE	LSE
4	0,3,1,2	3	3,2,1,0
5	1,4,2,0,3	4,0,1	4,1,0,3,2
6	2,5,3,0,1,4	5,2,0	5,2,1,0,4,3
7	3,6,0,4,1,2,5	6,0,3,2	6,0,3,1,4,2,5
8	4,7,0,1,5,2,3,6	7,0,4	7,2,4,1,0,3,5,6
9	0,8,5,1,2,6,3,4,7	8,0,5,4	8,0,5,1,3,4,2,6,7
10	4,5,3,6,2,1,7,0,8,9	9,0,6,5,1	9,0,6,8,1,4,5,7,2,3
11	5,6,4,7,3,8,2,1,9,0,10	10,0,7,6,2	10,0,7,2,6,9,1,4,5,3,8
12	6,7,5,8,4,9,3,2,10,1,0,11	11,0,8,7,3,1	11,0,8,7,2,6,1,3,10,5,9,4

Tabela 11: Seqüências de entradas escolhidas pelos métodos Anfis, LSE e SIE para a série da Cemig

janela	Seqüência de Entradas		
	ANFIS	SIE	LSE
4	0,3,1,2	3,1	3,1,2,0
5	1,4,2,0,3	4,1,0,2	4,0,1,2,3
6	2,5,3,0,1,4	5,2,0,4,3	5,2,0,4,3,1
7	3,6,4,0,1,2,5	6,3,0,5	6,3,0,5,4,1,2
8	0,7,4,5,1,2,3,6	7,4,0,6	7,4,0,6,5,2,3,1
9	0,8,1,5,6,2,3,4,7	8,5,0,7	8,5,0,7,4,1,6,2,3
10	0,9,1,2,6,7,3,4,5,8	9,6,1,8,0	9,6,1,8,0,7,5,2,3,4
11	0,10,1,2,3,7,8,4,5,6,9	10,7,2,9,1	10,1,9,8,7,6,3,2,0,4,5
12	1,11,2,3,0,4,8,9,5,6,7,10	11,8,3,10,2	11,8,2,7,10,3,0,9,6,4,1,5

Percebe-se nas tabelas que o método SIE despreza uma série de entradas que julga possuírem pouca importância para o problema em questão. Os métodos LSE e SIE apresentam seqüências muito semelhantes na maioria dos casos quando se leva em consideração as variáveis que o método SIE seleciona.

Com as seqüências de variáveis definidas, o sistema Coevolutivo pode ser executado para otimizar os parâmetros do sistema NFHB. Com isso, definem-se todos os parâmetros desse sistema de forma automática. Os parâmetros encontrados para todas as séries de carga utilizadas são apresentados na Tabela 12.

No parâmetro *MétodoSeleçãoVariáveis* foi adotada a seguinte codificação:

- 1 corresponde ao método Adaptado Anfis;
- 2 corresponde ao método LSE;
- 3 corresponde ao método SIE.

Tabela 12: Tabela de parâmetros otimizados pelo Sistema Coevolutivo para todas as séries de carga.

Parâmetro	Copel	Cemig	Light	Furnas	Cerj	Eletropaulo
δ	0.136361	0.09	0.131058	0.185919	0.174046	0.128906
MétodoSeleçãoVariáveis	3	1	2	1	3	2
UsarTolerânciaSeparação	false	true	false	true	false	false
a^*	3.6871	3.395477	3.34481	3.813246	1.475996	3.171016
λ^+	1.270729	1.414793	1.361245	1.34983	1.439479	1.31184
λ^-	0.1	0.368836	0.308326	0.361931	0.120505	0.244505
numCiclosRProp	27	30	26	19	21	29
step	86	84	96	90	83	82
NívelCombinaçãoLinear	4	3	7	1	6	7
numCiclosMQO	44	57	51	28	24	38
UsarCombinaçãoLinear	true	true	true	true	true	true
Janela	12	10	10	10	10	12

Comparando-se os valores otimizados dos parâmetros, percebe-se que apenas o parâmetro *UsarCombinaçãoLinear* teve o mesmo valor para todas as séries, demonstrando que em aplicações de previsão o uso de consequentes do tipo combinação linear é uma boa prática.

Os demais parâmetros, de uma forma geral, apresentaram baixa variância frente ao seu universo possível. Isso demonstra que em aplicações de séries de carga, os parâmetros permanecem, salvo algumas exceções, dentro de uma restrita faixa de valores. Dessa forma, o modelo coevolutivo tem a sua

importância aumentada, já que pode realizar um ajuste fino nos parâmetros, tarefa difícil de ser realizada empiricamente por especialistas.

Cabe salientar que todos os métodos de seleção de variáveis foram utilizados em diferentes séries, comprovando que para cada problema existe um método mais adequado, onde todos são candidatos.

O parâmetro *UsarTolerânciaSeparação* variou bastante entre verdadeiro e falso, demonstrando que, dependendo da série, pode ser mais interessante o crescimento da estrutura NFHB limitado apenas pela taxa de decomposição.

Após a especificação desses parâmetros, pode-se treinar o Sistema NFHB e calcular os valores de RMSE, MAPE e Utheil, cujas fórmulas estão definidas na subseção 4.2.1.1. Os resultados para todas as séries são apresentados na Tabela 13.

Tabela 13: Tabela de métricas de avaliação para todas as séries de carga analisadas

Companhia	Treinamento			Validação		
	RMSE	MAPE	Utheil	RMSE	MAPE	Utheil
COPEL	29.59	2.03	0.07	23.20	1.25	0.35
CEMIG	4.19	2.16	0.06	5.95	1.74	0.19
LIGHT	57.00	1.87	0.14	78.55	2.13	0.35
FURNAS	37.42	5.50	0.11	50.94	5.06	0.47
CERJ	15.83	2.14	0.09	27.59	2.72	0.46
ELETROPAULO	146.77	1.96	0.10	96.43	1.06	0.34

Analisando os valores encontrados percebe-se que algumas séries são mais complexas, visto que apresentam erros médios quadráticos maiores, apesar de serem séries características da mesma aplicação. Em relação ao RMSE, os melhores resultados foram obtidos para a Cemig, que representa uma série mais comportada. Por outro lado, a Eletropaulo, que é a série mais complexa, apresentou piores resultados de RMSE. Isso se deve ao fato do RMSE ser uma métrica que penaliza erros grandes, mesmo que ocorram em poucos pontos, já que o erro é elevado ao quadrado.

Ao analisar o MAPE vemos que o melhor resultado foi obtido justamente com a Eletropaulo que, conforme foi comentado, havia apresentado o pior RMSE. Isso se deve ao fato dessa métrica ser percentual, avaliando o erro proporcionalmente aos valores da série.

Os erros de treinamento de uma forma geral são mais baixos que os de validação, como era de se esperar, apesar de em dois casos ocorrer o oposto.

Para algumas séries ocorre de o erro de validação ser mais baixo que o de treinamento, mesmo com o fato desse último ser sempre decrescente ao longo do treinamento.

A seguir, serão apresentados gráficos nas figuras 26 a 31 que demonstram as séries real e prevista para todas as companhias de energia elétrica. O eixo das abscissas representa o tempo, que nesse caso é mensal. O eixo das ordenadas representa o valor das cargas, de ambas as séries.

Os valores da série prevista foram obtidos configurando-se o sistema NFHB com os parâmetros obtidos pela coevolução, apresentados na Tabela 12, e executando o algoritmo para todos os padrões existentes, englobando dados de treinamento e validação. Sendo assim, os padrões são gerados a partir do tamanho da janela otimizado. A primeira previsão plotada é representada no instante janela+1, já que os primeiros valores da série real são utilizados para formar o primeiro padrão.

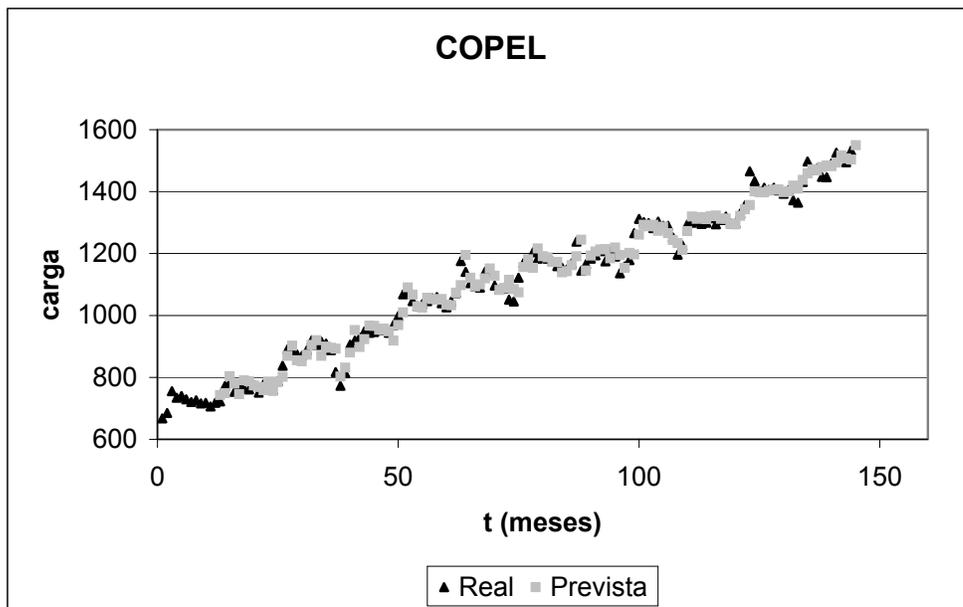


Figura 26: Séries real e prevista da Copel

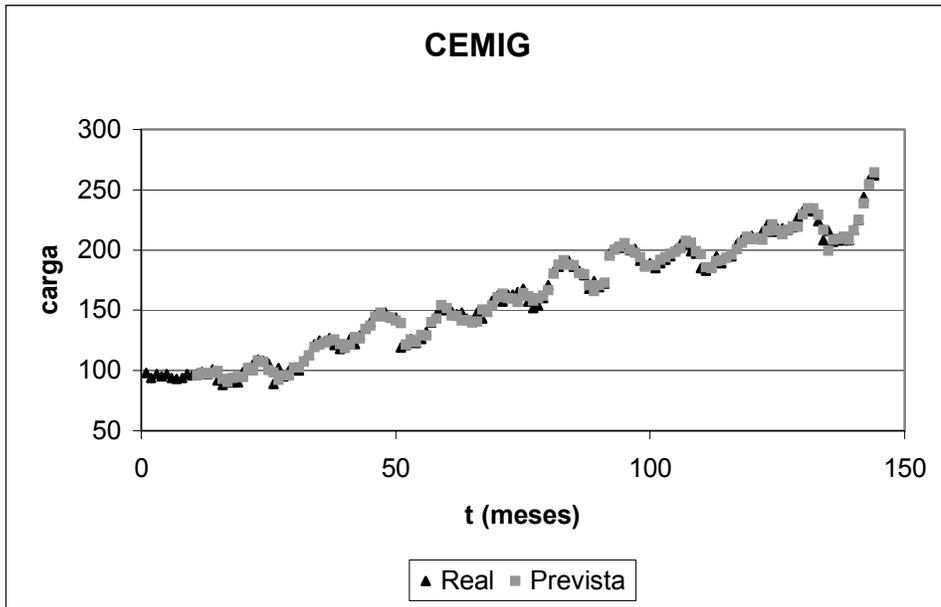


Figura 27: Séries real e prevista da Cemig

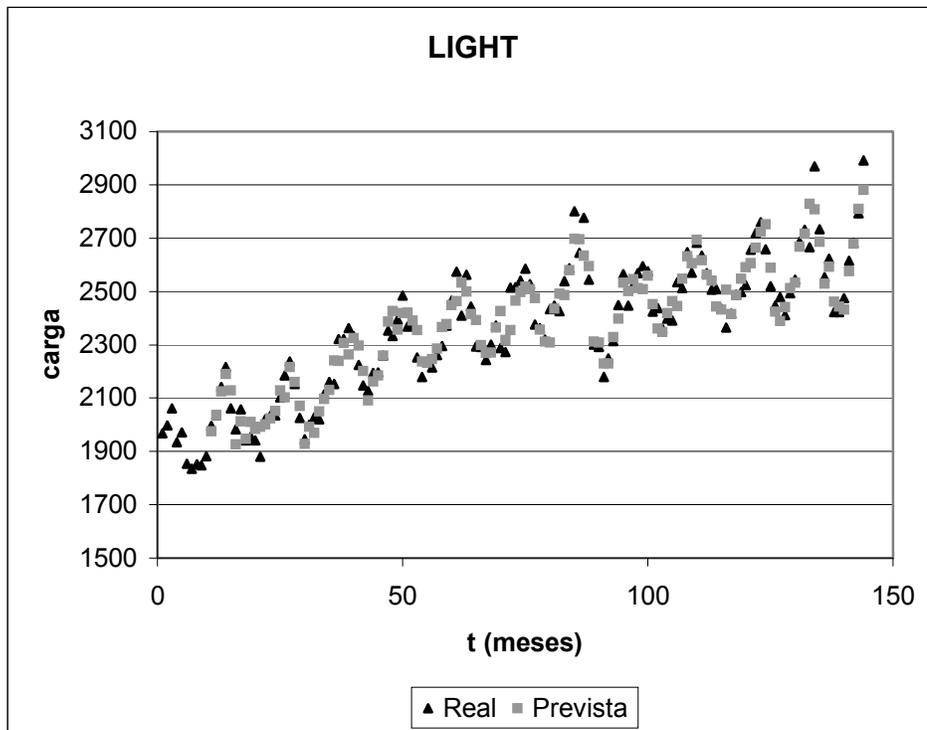


Figura 28: Séries real e prevista da Light

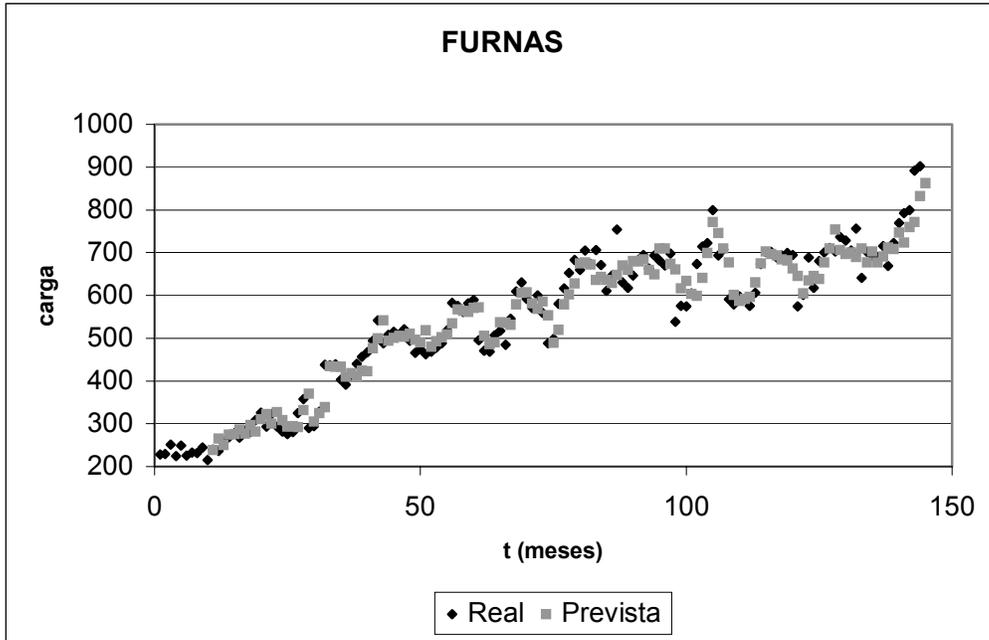


Figura 29: Séries real e prevista de Furnas

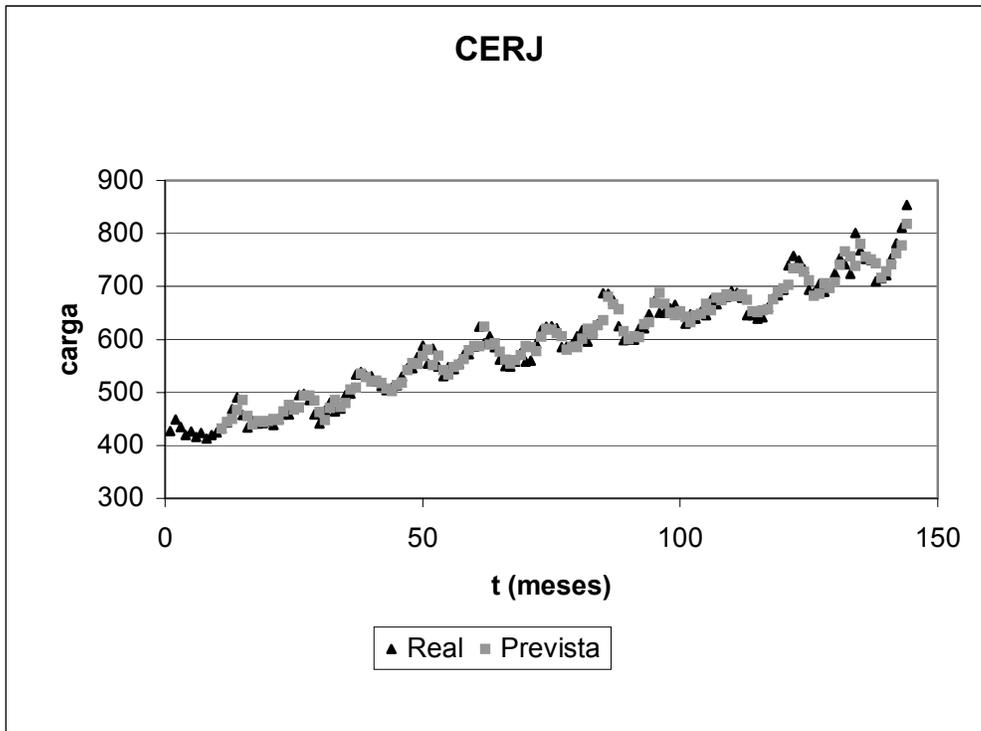


Figura 30: Séries real e prevista da Cerj

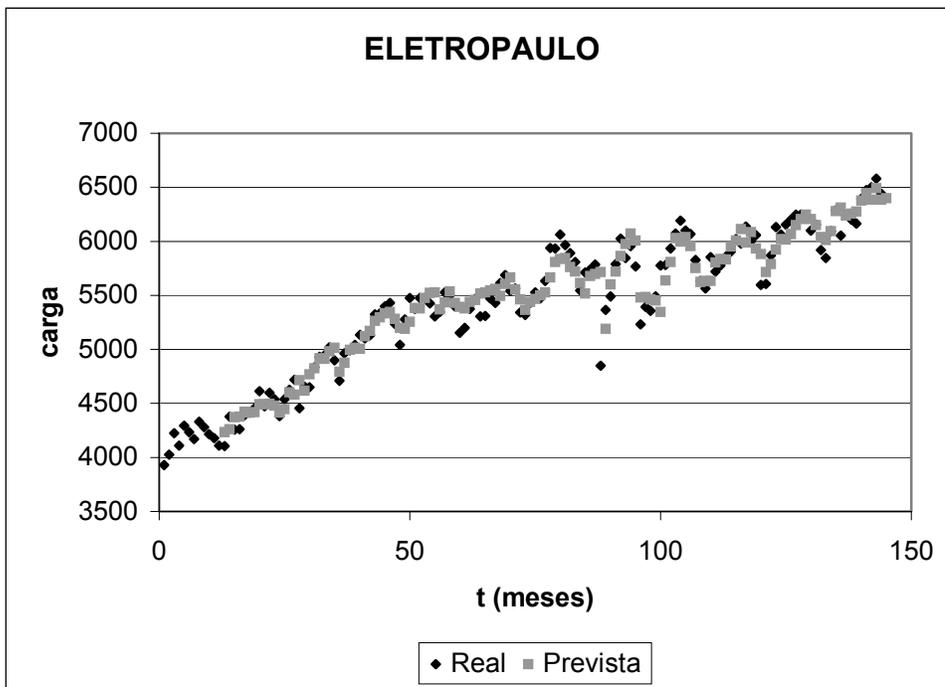


Figura 31: Séries real e prevista da Eletropaulo

Os gráficos apresentados comprovam as métricas calculadas. Percebe-se, no melhor resultado obtido com os dados da Cemig, que o sistema infere com baixíssimo erro os valores da série. Em compensação, nos casos da Eletropaulo e de Furnas, onde as séries apresentam oscilações mais bruscas, o erro é bem maior.

6.3. Classificação de Padrões

Problemas de classificação de padrões são aqueles em que o sistema deve, após treinamento, determinar a que classe um novo padrão pertence.

Para esse tipo de aplicação, foram realizados testes em quatro bases de dados do tipo *benchmark*: *Wine Data*, *Glass Data*, *Pima Indians Diabetes Database* e *Bupa Livers Disorders Database*.

Como a saída do sistema NFHB tradicional é um valor do tipo real, foi necessária uma codificação desse valor para se adequar ao problema de classificação.

A saída deve ser um valor inteiro, indicativo de uma classe. Sendo assim, foram definidas faixas de valores que são utilizadas para realizar a codificação. Por exemplo, em um problema de classificação com três classes, a codificação ocorre da seguinte forma:

$$\begin{aligned} [-\infty, 1.49] &\Rightarrow \textit{classe 1} \\ [1.5, 2.49] &\Rightarrow \textit{classe 2} \\ [2.5, +\infty] &\Rightarrow \textit{classe 3} \end{aligned}$$

Figura 32: Exemplo de Codificação da Saída do NFHB para Classificação

Neste caso, as métricas são um pouco diferentes. A métrica Utheil não faz mais sentido, pois está intimamente relacionada a problemas de previsão. Entretanto, a métrica porcentagem de acerto é utilizada e representa a avaliação mais importante do sistema em problemas de classificação.

Nas seções a seguir os casos estudados são descritos em detalhe.

6.3.1. Base de Dados *Glass Data*

A base de dados *Glass Data* foi criada a partir de um estudo sobre investigação criminológica, onde na cena de um crime são coletados pedaços de

vidro. Tenta-se descobrir, a partir de análises físico-químicas, o tipo do vidro encontrado.

A base é composta ao todo por 214 padrões, com 9 atributos e 6 classes. A distribuição dos padrões entre as classes é a seguinte: 70, 17, 76, 13, 9 e 26 por classe.

Para a realização do treinamento, os dados foram divididos em 2 grupos, um de treinamento e outro de validação, de 71 padrões aleatoriamente. Esses valores foram escolhidos para manter compatibilidade com os números utilizados em outros trabalhos, possibilitando a realização de uma análise comparativa.

A Tabela 14 demonstra as seqüências de entradas encontradas pelos métodos Adaptado Anfis, LSE e SIE.

Tabela 14: Seqüências de entradas escolhidas pelos métodos Anfis, LSE e SIE para a base *Glass Data*

Método de Seleção de Variáveis	Seqüência de Entradas
SIE	6,2,5,0,4,1
LSE	6,2,5,0,4,1,7,3,8
ANFIS	3,4,5,6,1,8,7,2,0

Após realizada a evolução utilizando o modelo criado, foram obtidos os valores para os parâmetros, conforme ilustrado na Tabela 15.

Tabela 15: Parâmetros Otimizados para a base *Glass Data*

Parâmetro	Glass
δ	0.224695
MétodoSeleçãoVariáveis	3
UsarTolerânciaSeparação	false
\hat{a}	5.427052
$\hat{\lambda}$	1.291883
$\hat{\lambda}$	0.275007
numCiclosRProp	18
step	60
NívelCombinaçãoLinear	4
numCiclosMQO	46
UsarCombinaçãoLinear	false

Com esses valores, o sistema NFHB pode ser configurado, resultando nas métricas calculadas apresentadas na

Tabela 16.

Tabela 16: Métricas do Sistema NFHB Otimizado para a base *Glass Data*

Treinamento			Validação		
RMSE	MAPE	% Acerto	RMSE	MAPE	% Acerto
0.636417	26.9977	60.6	1.00617	31.8549	62

6.3.2.

Base de Dados *Wine Data*

A bases de dados *Wine Data* é proveniente de análises químicas de vinhos cultivados em uma mesma região da Itália, porém provenientes de diferentes cultivadores de videiras. A análise determina a quantidade de 13 constituintes encontrados em cada um dos três tipos de vinhos estudados.

A base é constituída ao todo por 178 padrões com 13 atributos e 3 classes, sendo a sua distribuição feita da seguinte forma: 59, 71 e 48. Para a realização dos testes, os dados foram divididos em 2 grupos de 59 padrões aleatoriamente. Da mesma forma que no caso anterior, os dados foram divididos de forma a manter compatibilidade com outros trabalhos, possibilitando a comparação.

A Tabela 17 representa as seqüências de variáveis encontradas pelos métodos Adaptado Anfis, LSE e SIE.

Tabela 17: Seqüências de entradas escolhidas pelos métodos Anfis, LSE e SIE para a base *Wine Data*

Método de Seleção de Variáveis	Seqüência de Entradas
SIE	2,6,0,10,5,11,7,9,1
LSE	2,6,0,10,5,11,7,9,1,8,3,4,12
ANFIS	6,10,9,12,5,11,0,1,7,8,2,3,4

Após realizada a evolução utilizando o modelo criado, foram obtidos os valores para os parâmetros, conforme demonstrado na Tabela 18.

Tabela 18: Parâmetros Otimizados para a base *Wine Data*

Parâmetro	Wine
δ	0.160119
MétodoSeleçãoVariáveis	3
UsarTolerânciaSeparação	false
a^*	4.875866
λ^+	1.241525
λ^-	0.296874
numCiclosRProp	35
step	87
NívelCombinaçãoLinear	4
numCiclosMQO	44
UsarCombinaçãoLinear	false

Com esses valores, o sistema NFHB pode ser configurado, resultando nas métricas apresentadas na Tabela 19.

Tabela 19: Métricas do Sistema NFHB Otimizado para a base *Wine Data*

Treinamento			Validação		
RMSE	MAPE	% Acerto	RMSE	MAPE	% Acerto
0.0003256	0.011456	100	0.231083	3.50478	94.9

6.3.3.

Base de Dados *Pima Indians Diabetes*

Este conjunto de dados refere-se ao diagnóstico do diabetes em uma população indígena que vive próxima à cidade de Phoenix no Arizona. O conjunto possui ao todo 768 padrões com 8 atributos e 2 classes: doente e não doente de diabetes. A distribuição das classes é de 65,1% para classe 1 e 34,9% para a classe 2.

Para a realização dos testes, o conjunto inicial de 768 padrões foi dividido, de forma aleatória, em dois conjuntos de 384 padrões cada, um para treinamento e outro para validação.

A Tabela 20 demonstra as seqüências de variáveis encontradas para cada um dos métodos utilizados.

Tabela 20: Seqüências de entradas escolhidas pelos métodos Anfis, LSE e SIE para a base Pima Indians Diabetes

Método de Seleção de Variáveis	Seqüência de Entradas
SIE	6,0
LSE	6,0,5,1,2,7,3,4
ANFIS	0,1,5,2,3,6,4,7

Após realizada a evolução utilizando o modelo criado, foram obtidos os valores para os parâmetros ilustrados na Tabela 21.

Tabela 21: Parâmetros Otimizados para a base Pima Indians Diabetes

Parâmetro	Pima Indians Diabetes
δ	0.173519
MétodoSeleçãoVariáveis	2
UsarTolerânciaSeparação	false
a^*	4.442553
λ^+	1.319504
λ	0.36527
numCiclosRProp	24
step	92
NívelCombinaçãoLinear	9
numCiclosMQO	55
UsarCombinaçãoLinear	true

Com os valores otimizados dos parâmetros, o sistema NFHB foi configurado e treinado, gerando as seguintes métricas.

Tabela 22: Métricas do Sistema NFHB Otimizado para a base Pima Indians Diabetes

Treinamento			Validação		
RMSE	MAPE	% Acerto	RMSE	MAPE	% Acerto
0.38603	15.095	78.13	0.380334	13.9485	80.2

6.3.4. Base de Dados *Bupa Liver Disorders*

Este conjunto de dados refere-se ao diagnóstico de problemas no fígado, criado pela BUPA Medical Research Ltd. O conjunto possui ao todo 345 padrões

com 6 atributos e 2 classes distribuídas da seguinte forma: 145 padrões na classe 1 e 200 na classe 2.

Para a realização dos testes, o conjunto inicial de 345 padrões foi dividido, de forma aleatória, em dois conjuntos com 173 e 172 padrões cada, o primeiro para treinamento e o segundo para validação.

A seguir, na Tabela 23, são apresentadas as seqüências de variáveis encontradas pelos os métodos utilizados.

Tabela 23: Seqüências de entradas escolhidas pelos métodos Anfis, LSE e SIE para a base Bupa Liver Disorders

Método de Seleção de Variáveis	Seqüência de Entradas
SIE	2,3,0,4
LSE	2,3,0,4,1,5
ANFIS	2,3,0,4,5,1

Após realizada a coevolução para a base em questão, foram encontrados os parâmetros apresentados na tabela a seguir.

Tabela 24: Parâmetros Otimizados para a base Bupa Liver Disorders

Parâmetro	Bupa Liver Disorders
δ	0.141263
MétodoSeleçãoVariáveis	1
UsarTolerânciaSeparação	false
\hat{a}	2.588209
λ^+	1.307561
λ^-	0.28899
numCiclosRProp	23
step	70
NívelCombinaçãoLinear	0
numCiclosMQO	47
UsarCombinaçãoLinear	true

Com esses parâmetros é possível configurar o sistema NFHB e após executá-lo, foram encontradas as seguintes métricas.

Tabela 25: Métricas do Sistema NFHB Otimizado para a base Bupa Liver Disorders

Treinamento			Validação		
RMSE	MAPE	% Acerto	RMSE	MAPE	% Acerto
0.423169	18.4031	75.72	0.439017	18.6389	75.58

6.3.5. Comentários sobre os Resultados dos Parâmetros

A tabela a seguir apresenta os parâmetros encontrados para todos os casos estudados.

Tabela 26: Tabela de parâmetros otimizados pelo Sistema Coevolutivo para todas as bases de classificação estudadas

Parâmetro	<i>Glass</i>	<i>Wine</i>	<i>Pima Indians Diabetes</i>	<i>Bupa Liver Disorders</i>
δ	0.224695	0.160119	0.173519	0.141263
MétodoSeleçãoVariáveis	3	3	2	1
UsarTolerânciaSeparação	false	false	false	false
\hat{a}	5.427052	4.875866	4.442553	2.588209
λ^+	1.291883	1.241525	1.319504	1.307561
λ	0.275007	0.296874	0.36527	0.28899
numCiclosRProp	18	35	24	23
step	60	87	92	70
NívelCombinaçãoLinear	4	4	9	0
numCiclosMQO	46	44	55	47
UsarCombinaçãoLinear	false	false	true	true

Para os casos de classificação, da mesma forma que em previsão, os valores dos parâmetros, de uma forma geral, ficaram muito próximos, residindo em uma restrita faixa de valores. O método de seleção de variáveis mais uma vez variou entre os três utilizados, comprovando a importância de se escolher o melhor método para cada problema.

O parâmetro *UsarTolerânciaSeparação* apresentou em todos os casos o valor falso, demonstrando que para as bases de classificação estudadas o Sistema NFHB obtém melhores resultados com o crescimento da estrutura limitado apenas pela taxa de decomposição.

Percebe-se que o parâmetro *UsarCombinaçãoLinear* apresentou o valor verdadeiro para duas bases, sendo que em uma delas o valor do parâmetro *NívelCombinaçãoLinear* foi zero, sendo equivalente a não utilizar combinação

linear. Dessa forma, o comportamento para esse parâmetro foi bem diferente dos casos de previsão estudados, que sempre apresentaram esse parâmetro tendo verdadeiro como valor. Sendo assim, para os casos estudados, previsão e classificação apresentam melhores resultados para configurações opostas, onde para classificação o uso de combinações lineares nos conseqüentes não é tão eficaz.

6.4. Comparação com Resultados sem Otimização

Depois de realizados os treinamentos e de obtidos os resultados com o modelo coevolutivo, faz-se necessário comparar o sistema criado neste trabalho com outros modelos configurados por especialistas.

A Tabela 27 apresenta, de forma resumida, os resultados obtidos pelo sistema NFHB Takagi-Sugeno [SOUZ99] e pelo sistema híbrido neuro-fuzzy-genético criado neste trabalho, para os problemas de previsão estudados.

Tabela 27: Tabela Comparativa entre o modelo NFHB configurado por especialista e o NFHB Otimizado por Coevolução em aplicações de previsão

Companhia	NFHB		NFHB (Coevolutivo)	
	MAPE	RMSE	MAPE	RMSE
Copel	1.17	28.89	1.29	23.43
Cemig	1.12	58.49	1.85	5.85
Light	2.22	81.74	2.11	78.6
Furnas	3.76	50.78	4.32	38.89
Cerj	1.35	15.66	2.72	27.59
Eletropaulo	1.17	108.11	1.06	96.43

Os resultados apresentados em [SOUZ99] foram obtidos utilizando dois conjuntos, um de treinamento e outro de validação, assim como neste trabalho. Sendo assim, o sistema foi treinado e, posteriormente validado utilizando o conjunto de validação. A parametrização que obtivesse os melhores resultados de validação era definida como a melhor.

Percebe-se na tabela que o sistema neuro-fuzzy-genético gerou resultados bem próximos ou até melhores que o sistema configurado por especialistas. Nota-se que o sistema tendeu a baixar o erro médio quadrático RMSE, pois apresentou melhores resultados em 5 dos 6 problemas estudados nessa

métrica. Porém, no erro percentual MAPE, foi melhor em apenas 2 dos 6 casos, apesar de estar próximo nos outros casos.

A seguir são apresentados resultados obtidos com outros métodos para a previsão das mesmas séries estudadas neste trabalho.

Tabela 28: Tabela comparativa do Modelo Coevolutivo com outros métodos de previsão

Companhia	Box&Jenkins		Holt-Winters		BackProp.		NFHB (Coevolutivo)	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
COPEL	1.63	30.6	1.96	31.91	1.57	26.57	1.25	23.20
CEMIG	1.67	79.93	1.75	85.54	1.47	69.23	1.74	5.95
LIGHT	4.02	122.2	2.73	88.13	3.57	123.1	2.13	78.55
FURNAS	5.43	55.29	4.55	47.51	5.28	50.32	5.06	50.94
CERJ	3.24	31.15	2.69	23.91	3.16	28.46	2.72	27.59
ELETROPAULO	2.23	165.8	1.85	148.61	1.58	127.5	1.06	96.43

Tabela 29: Tabela comparativa do Modelo Coevolutivo com outros métodos de previsão

Companhia	BNN (G. Aproxim.)		BNN (MCMC)		NFHB (Coevolutivo)	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
COPEL	1.45	17.4	1.16	16.4	1.25	23.20
CEMIG	1.29	16.7	1.28	17.1	1.74	5.95
LIGHT	1.44	17.3	2.23	27.5	2.13	78.55
FURNAS	1.33	17.3	3.85	56.2	5.06	50.94
CERJ	1.50	21.2	1.33	19.7	2.72	27.59
ELETROPAULO	0.79	14.3	0.78	10.6	1.06	96.43

Percebe-se que os resultados do novo modelo criado, quando comparado com *BackPropagation* e com alguns métodos estatísticos, como *Box&Jenkins* [BOX 70] e *Holt-Winters*, apresenta excelentes resultados. Porém quando comparados com as Redes Neurais Bayesianas, treinadas por aproximação gaussiana e pelo método MCMC, apresenta resultados ligeiramente inferiores, apesar de esses métodos levarem cerca de 8 horas para treinamento em um processador Pentium 4 com 1.4Ghz utilizando 256M de memória, enquanto o sistema NFHB treina em poucos segundos na mesma máquina. Assim, o fato de o sistema criado ser automático representa uma grande vantagem em relação a outros métodos, mesmo que esses apresentem resultados melhores.

Para os casos estudados em problemas de classificação de padrões, foi criada a Tabela 30 com a comparação de resultados entre o sistema criado e o sistema NFHB configurado por especialista. O sistema NFHB teve seus valores calculados no trabalho realizado em [CONT02].

Tabela 30: Tabela Comparativa entre o modelo NFHB configurado por especialista e o NFHB Otimizado por Coevolução em aplicações de classificação

Base	NFHB [SOUZ99]	NFHB (Coevolutivo)
	%Acerto	%Acerto
Glass Data	77.57%	62.00%
Wine Data	93.22%	94.90%
Pima Indians Diabetes	77.08%	80.20%
Bupa Liver Disorders	74.49%	75.58%

Percebe-se que apenas para a base Glass Data o sistema criado foi inferior ao configurado por um especialista. Dessa forma, através dos resultados fica comprovado que o sistema coevolutivo é capaz de realizar um ajuste fino nos parâmetros que gera uma pequena melhora na maioria dos casos.

A Tabela 31 compara os resultados obtidos pelo sistema neuro-fuzzy-genético com outros algoritmos bastante utilizados em problemas de classificação de padrões: NN (*nearest neighbor*) [AHA 94], kNN (*k nearest neighbor*) [AHA 94], FSS (*nearest neighbor with forward sequential selection of feature*) [AHA 94], BSS (*nearest neighbor with backward sequential selection of feature*) [AHA 94], MFS (*Multiple Feature Subsets*) [BAY 98], CART (árvore de decisão CART) [RIPL96], C4.5 (árvore de decisão C4.5) [QUIN93], FID3.1 (árvore de decisão FID3.1) [JANI99a], MLP (MultiLayer Perceptron) [LANA00], NFHQ (modelo neuro-fuzzy hierárquico quadtree) [SOUZ99], NFHB-Invertido[GONÇ01], NFHB-Class [GONÇ01] e NFHB Mamdani [BEZE02]

Para a base Glass Data, os resultados não foram tão bons quando comparados com o NFHQ e o NFHB-Class, apesar de o segundo ser um sistema criado especificamente para problemas de classificação.

Para a base Wine Data, o resultado do sistema coevolutivo foi pior que a maioria dos outros modelos comparados. Entretanto, todos os modelos apresentaram excelentes resultados para essa base, inclusive o modelo coevolutivo, porém esse possui a vantagem de ser completamente automático.

Observando as bases *Pima Indians Diabetes* e *Bupa Liver Disorders* os resultados do sistema neuro-fuzzy-genético foram muito bons comparados com os outros modelos. No primeiro caso, o resultado obtido foi o melhor, superando até modelos criados especificamente para resolver problemas de classificação. No segundo caso, o sistema criado foi pior apenas que o NFHB-Class, versão do

sistema NFHB voltado para classificação por apresentar tantas saídas quanto classes do problema.

Tabela 31: Tabela comparativa do Modelo Coevolutivo com outros métodos de Classificação

	<i>Glass Data</i>	<i>Wine Data</i>	<i>Pima Indians Diabetes Database</i>	<i>Bupa Liver Disorders</i>
NN		95.20%		60.40%
KNN		96.70%	65.10%	61.30%
FSS		92.80%	69.70%	56.80%
BSS		94.80%	73.60%	60.00%
MFS¹		97.60%	67.70%	65.40%
MFS²		97.90%	68.50%	64.40%
CART			74.50%	
C4.5			74.70%	
FID3.1			75.90%	
MLP			75.20%	
NFHQ	80.37%	98.88%	77.08%	75.07%
NFHB-Invertido		99.44%	78.26%	73.33%
NFHB-Class	70.42%	98.88%	79.04%	79.09%
NFHB-Mamdani		96.61%		
NFHB (Coev.)	62.00%	94.90%	80.02%	75.58%

Após a apresentação de todos os resultados, o sistema demonstrou ter grande potencial, merecendo atenção por ser completamente automático. Quando o sistema não foi melhor, esteve próximo aos resultados obtidos pelos especialistas que criaram os modelos comparados.

Comercialmente o modelo automático possui um futuro promissor por facilitar o seu uso por pessoas leigas com relação ao modelo utilizado. É notório que os especialistas responsáveis por configurar o sistema nos casos estudados possuíam grande conhecimento sobre o modelo. Dificilmente pessoas com pouco conhecimento no modelo serão capazes de configurar o sistema de forma a obter melhor performance que os especialistas criadores. Já o sistema automático pode ser utilizado por pessoas com menor conhecimento sobre o modelo e os resultados são bastante próximos, quando não são melhores.