

5

ESTUDO DE CASO

5.1

Dados Simulados

O primeiro experimento para teste da metodologia proposta utiliza dados simulados. Esse experimento é extremamente importante, pois o modelo gerador é conhecido a priori; assim, o poder de classificação fica mais claro.

Primeiramente, alguns dados são simulados com modelos da família GARCH; em seguida, alguns métodos para seleção das variáveis são testados, de forma a definir quais variáveis utilizar na metodologia de identificação proposta. Estas variáveis servem como entrada para os modelos computacionais propostos para identificação.

Segundo o estudo de Hwang e Valls (2006), para séries com pouca informação, é necessário que a soma dos coeficientes seja alta para representar as características dos modelos. Por isso, para a simulação dos dados foram considerados parâmetros aleatórios, fixando sua soma em 0,9 com um desvio de 0,1 para cima ou para baixo.

Conforme mostrado na Tabela 3, foram geradas, para cada um dos modelos ARCH(1), ARCH(2), GARCH(1,1), GARCH(2,1) e GARCH(1,2), 1.600 séries mediante variação dos seus tamanhos, representando séries diárias de um mês (22), um trimestre(66), um semestre(132) e um ano(264), respectivamente).

Tabela 3: Séries Simuladas

Modelo	Número de Observações da Série	Quantidade de Séries
ARCH(1)	22	400
ARCH(1)	66	400
ARCH(1)	132	400
ARCH(1)	264	400
ARCH(2)	22	400
ARCH(2)	66	400
ARCH(2)	132	400
ARCH(2)	264	400
GARCH(1,1)	22	400
GARCH(1,1)	66	400
GARCH(1,1)	132	400
GARCH(1,1)	264	400
GARCH(2,1)	22	400
GARCH(2,1)	66	400
GARCH(2,1)	132	400
GARCH(2,1)	264	400
GARCH(1,2)	22	400
GARCH(1,2)	66	400
GARCH(1,2)	132	400
GARCH(1,2)	264	400
Total		8.000

Estimados os parâmetros dos modelos pelo método de máxima verossimilhança, os escolhidos pelos critérios de informação AIC e BIC foram os que apresentaram os menores valores dessas estatísticas. A Tabela 4 apresenta uma análise de sensibilidade para os acertos da identificação dos modelos quando se aumenta o tamanho das séries.

Tabela 4: Resultados das identificações dos modelos pelos critérios AIC e BIC

Tamanho das séries	Identificação pelo AIC		Identificação pelo BIC	
	Acertos	% de acertos	Acertos	% de acertos
22	488	24,4%	465	23,3%
66	809	40,5%	734	36,7%
132	1070.	53,5%	947	47,4%
264	1.371	68,6%	1.200	60,0%
Total	3.738	46,7%	3.346	41,8%

A identificação por esses critérios apresentou um acerto abaixo de 50% em média. Para as séries anuais, esse acerto foi melhor, alcançando 68,6%. Porém, considerando as séries com menor número de observações (por exemplo, séries de empresas que fizeram IPO recentemente), o percentual de identificação correta fica muito mais baixo.

Observando o erro de identificação por modelo, apresentado nas Tabelas 5 e 6, verifica-se que, quanto maior a ordem do modelo, maior o erro de identificação. Intuitivamente, esse resultado já era esperado, uma vez que estas estatísticas buscam a parcimônia, ou seja, elas penalizam os modelos com ordens mais altas, tendendo a viciar a identificação para modelos com ordens mais baixas.

Tabela 5: Percentual de acerto na identificação por modelo pelo AIC

	ARCH(1)	ARCH(2)	GARCH(1,1)	GARCH(2,1)	GARCH(1,2)	Total
22	94,5%	22,5%	3,5%	1,5%	0,0%	24,4%
66	92,8%	64,8%	29,5%	8,0%	7,3%	40,5%
132	92,3%	82,5%	54,0%	23,3%	15,5%	53,5%
264	93,0%	89,8%	74,5%	53,0%	32,5%	68,6%
Total	93,1%	64,9%	40,4%	21,4%	13,8%	46,7%

Tabela 6: Percentual de acerto na identificação por modelo pelo BIC

N	ARCH(1)	ARCH(2)	GARCH(1,1)	GARCH(2,1)	GARCH(1,2)	Total
22	96,8%	16,0%	3,0%	0,5%	0,0%	23,3%
66	98,8%	56,5%	25,0%	2,0%	1,3%	36,7%
132	99,3%	79,0%	53,8%	3,5%	1,3%	47,4%
264	99,5%	91,5%	83,0%	19,8%	6,3%	60,0%
Total	98,6%	60,8%	41,2%	6,4%	2,2%	41,8%

Com o intuito de melhorar a classificação, a metodologia proposta utiliza as informações contidas nas autocorrelações e autocorrelações parciais do quadrado da série. Portanto, o modelo de classificação tem como variáveis de entrada a classificação dada pelo critério AIC, as autocorrelações e autocorrelações parciais e as diferenças entre essas estatísticas para os três primeiros *lags*, ou seja, diferença entre a autocorrelação do *lag1* e a do *lag2*, a diferença entre a autocorrelação do *lag2* e a do *lag3*, a diferença entre a autocorrelação parcial do *lag1* e a do *lag2* e a diferença entre a autocorrelação parcial do *lag2* e a do *lag 3*.

O primeiro passo é selecionar quais variáveis são determinantes para a classificação. Para tal, alguns métodos de seleção de variáveis são utilizados:

- SIE (SIE)
- Fisher (F)
- SVM de ordem zero (peso) (SVM1)
- SVM de ordem zero (raio da esfera) (SVM2)
- SVM de primeira ordem (peso) (SVM11)
- SVM de primeira ordem (raio da esfera) (SVM12)

Por questões de formatação, utiliza-se a nomenclatura da Tabela 7 nas próximas tabelas.

Tabela 7: Nomenclatura utilizada

Modelo	Nomenclatura
ARCH(1)	(1)
ARCH(2)	(2)
GARCH(1,1)	(1,1)
GARCH(1,2)	(1,2)
GARCH(2,1)	(2,1)

As Tabelas 8, 9, 10, 11, 12 e 13 apresentam os resultados das variáveis ordenadas por suas importâncias na classificação entre os pares de modelos. A seleção de variáveis se concentrou nas variáveis que mais diferenciam os modelos se comparados um a um.

Tabela 8: Método SIE - Ranking de Importância das Variáveis

Variável	Comparação entre pares de modelos									
	(1)X(2)	(1)X(1,1)	(1)X(1,2)	(1)X(2,1)	(2)X(1,1)	(2)X(1,2)	(2)X(2,1)	(1,1)X(1,2)	(1,1)X(2,1)	(1,2)X(2,1)
ACF1	-	6	-	1	2	1	-	-	-	-
ACF2	1	-	4	-	-	3	-	2	1	1
ACF3	3	7	7	2	-	-	2	-	6	2
ACF4	-	-	-	-	-	-	3	-	8	-
ACF5	-	-	-	-	-	-	9	4	-	9
ACF6	-	-	-	-	-	-	-	-	5	7
ACF7	-	-	-	-	-	-	8	-	7	10
ACF8	-	-	-	-	-	-	5	-	2	5
ACF9	-	-	-	-	-	-	-	-	9	-
ACF10	-	-	-	-	-	-	6	-	3	8
PACF1	-	3	1	5	-	5	-	5	-	4
PACF2	-	4	3	6	-	4	4	7	-	-
PACF3	-	-	-	-	3	-	7	-	-	-
PACF4	-	-	-	-	-	-	-	-	4	-
PACF5	-	-	-	-	-	-	-	-	-	-
PACF6	-	-	-	-	-	-	-	-	-	-
PACF7	-	-	-	-	-	-	-	-	-	-
PACF8	-	-	-	-	-	-	-	-	-	-
PACF9	-	-	-	-	-	-	-	-	-	-
PACF10	-	-	-	-	-	-	-	-	-	-
Dif ACF1 X ACF2	-	2	6	3	1	2	-	1	10	-
Dif ACF2 X ACF3	2	1	5	4	-	-	1	3	-	6
Dif PACF1 X PACF2	-	5	2	7	-	6	-	6	-	3
Dif PACF2 X PACF3	-	-	-	-	-	7	-	-	-	-

Tabela 9: Método de Fisher - Ranking de Importância das Variáveis

Variável	Comparação entre pares de modelos									
	(1)X(2)	(1)X(1,1)	(1)X(1,2)	(1)X(2,1)	(2)X(1,1)	(2)X(1,2)	(2)X(2,1)	(1,1)X(1,2)	(1,1)X(2,1)	(1,2)X(2,1)
ACF1	9	11	9	4	18	5	10	7	2	13
ACF2	4	10	6	20	2	18	1	4	1	1
ACF3	6	5	4	13	17	10	19	9	13	7
ACF4	5	4	5	9	15	13	17	11	22	17
ACF5	7	2	7	3	9	8	13	19	16	18
ACF6	8	7	8	5	11	6	12	12	12	16
ACF7	11	8	11	8	7	2	8	16	10	12
ACF8	14	9	12	7	8	3	5	14	5	8
ACF9	15	13	13	12	12	12	7	18	7	10
ACF10	18	14	14	14	10	9	6	17	6	9
PACF1	13	12	10	6	14	4	9	8	3	14
PACF2	2	6	3	10	4	20	4	3	11	2
PACF3	16	16	16	15	13	1	14	10	15	20
PACF4	17	18	17	16	16	17	15	24	8	11
PACF5	19	22	19	22	23	21	20	15	18	15
PACF6	22	21	20	18	21	19	21	20	21	23
PACF7	24	24	24	23	22	24	24	22	23	24
PACF8	21	23	21	19	20	16	18	13	17	21
PACF9	20	20	23	24	24	23	22	21	19	19
PACF10	23	19	22	17	19	22	23	23	24	22
Dif ACF1 X ACF2	1	1	1	2	5	11	11	1	20	3
Dif ACF2 X ACF3	10	15	18	11	1	7	2	5	4	4
Dif PACF1 X PACF2	3	3	2	1	6	14	16	2	14	6
Dif PACF2 X PACF3	12	17	15	21	3	15	3	6	9	5

Tabela 10: Método SVM ordem zero (pesos) - Ranking de Importância das Variáveis

Variável	Comparação entre pares de modelos									
	(1)X(2)	(1)X(1,1)	(1)X(1,2)	(1)X(2,1)	(2)X(1,1)	(2)X(1,2)	(2)X(2,1)	(1,1)X(1,2)	(1,1)X(2,1)	(1,2)X(2,1)
ACF1	21	17	19	18	18	17	22	17	16	21
ACF2	23	24	24	14	24	19	24	24	19	18
ACF3	14	22	23	20	21	21	11	20	24	12
ACF4	20	20	13	15	15	12	15	21	15	17
ACF5	6	21	22	22	17	20	18	15	9	16
ACF6	12	23	21	10	2	23	17	10	14	24
ACF7	19	10	18	23	20	4	21	19	11	23
ACF8	22	13	10	21	19	24	16	22	12	19
ACF9	15	8	9	24	10	18	23	8	17	14
ACF10	24	18	16	17	14	14	12	23	21	20
PACF1	18	12	17	16	13	9	13	16	23	13
PACF2	16	19	20	13	16	16	20	13	22	22
PACF3	10	14	11	11	12	11	9	12	18	9
PACF4	8	7	7	6	9	8	5	1	8	4
PACF5	9	9	1	8	5	10	6	7	6	7
PACF6	5	3	5	1	1	7	4	6	4	6
PACF7	3	11	6	2	6	3	7	3	3	5
PACF8	4	4	4	3	3	2	3	2	5	1
PACF9	1	2	3	4	8	6	2	5	1	3
PACF10	2	1	2	5	4	1	1	4	2	2
Dif ACF1 X ACF2	17	16	14	12	23	22	19	18	20	10
Dif ACF2 X ACF3	13	15	15	19	22	15	14	14	13	15
Dif PACF1 X PACF2	11	5	8	7	7	13	10	11	10	8
Dif PACF2 X PACF3	7	6	12	9	11	5	8	9	7	11

Tabela 11: Método SVM ordem zero (radius/margin) - Ranking de Importância das Variáveis

Variável	Comparação entre pares de modelos									
	(1)X(2)	(1)X(1,1)	(1)X(1,2)	(1)X(2,1)	(2)X(1,1)	(2)X(1,2)	(2)X(2,1)	(1,1)X(1,2)	(1,1)X(2,1)	(1,2)X(2,1)
ACF1	16	20	12	17	17	16	23	19	24	19
ACF2	21	24	21	18	24	17	22	22	23	20
ACF3	19	12	18	22	15	24	16	24	21	21
ACF4	18	23	14	23	16	12	19	2	15	9
ACF5	10	15	20	24	11	20	24	21	10	24
ACF6	24	17	23	6	18	10	1	1	16	15
ACF7	23	13	10	19	20	23	14	12	19	23
ACF8	22	14	22	14	21	18	11	18	22	1
ACF9	20	16	24	15	14	21	17	14	20	22
ACF10	15	11	15	20	19	15	10	23	11	17
PACF1	17	19	8	10	12	13	21	17	14	16
PACF2	12	18	19	21	22	14	20	20	12	18
PACF3	11	10	17	16	2	22	9	13	17	11
PACF4	6	2	7	9	3	7	12	3	1	8
PACF5	8	7	1	11	4	9	8	6	8	2
PACF6	5	3	2	1	7	2	3	7	2	7
PACF7	4	9	3	2	5	3	7	10	3	3
PACF8	1	4	4	5	6	4	4	8	4	4
PACF9	2	5	5	3	8	6	5	11	5	6
PACF10	3	6	6	4	9	5	6	9	6	5
Dif ACF1 X ACF2	14	22	13	12	23	11	18	15	18	13
Dif ACF2 X ACF3	13	21	16	13	1	19	13	16	13	14
Dif PACF1 X PACF2	9	8	9	8	13	1	15	4	7	12
Dif PACF2 X PACF3	7	1	11	7	10	8	2	5	9	10

Tabela 12: Método SVM de primeira ordem (pesos) - Ranking de Importância das Variáveis

Variável	Comparação entre pares de modelos									
	(1)X(2)	(1)X(1,1)	(1)X(1,2)	(1)X(2,1)	(2)X(1,1)	(2)X(1,2)	(2)X(2,1)	(1,1)X(1,2)	(1,1)X(2,1)	(1,2)X(2,1)
ACF1	21	2	1	2	20	7	10	8	20	15
ACF2	7	9	5	15	17	16	17	6	6	1
ACF3	5	18	8	9	4	4	19	2	14	12
ACF4	11	12	10	22	3	24	6	19	13	18
ACF5	4	10	20	17	5	20	24	15	23	9
ACF6	18	24	4	21	19	10	1	7	10	14
ACF7	17	13	21	10	22	15	3	18	18	10
ACF8	16	21	19	6	21	13	12	20	21	13
ACF9	19	19	9	19	8	19	23	5	8	8
ACF10	23	6	12	24	11	12	21	23	7	17
PACF1	1	1	22	11	14	6	15	24	22	6
PACF2	22	5	13	13	10	3	8	13	15	23
PACF3	12	23	17	8	15	9	5	9	3	3
PACF4	10	7	7	4	12	11	22	3	5	11
PACF5	24	4	14	5	18	23	14	17	2	7
PACF6	13	17	23	12	2	1	4	21	4	21
PACF7	8	8	18	20	24	21	13	1	12	19
PACF8	20	15	6	7	13	5	11	12	1	5
PACF9	2	22	2	3	7	18	9	22	24	2
PACF10	6	16	11	18	1	22	2	16	16	24
Dif ACF1 X ACF2	14	11	3	14	16	14	7	4	9	16
Dif ACF2 X ACF3	15	14	15	23	23	8	18	14	19	4
Dif PACF1 X PACF2	9	20	16	1	6	2	20	11	17	20
Dif PACF2 X PACF3	3	3	24	16	9	17	16	10	11	22

Tabela 13: Método SVM de primeira ordem (radius/margin) - Ranking de Importância das Variáveis

Variável	Comparação entre pares de modelos									
	(1)X(2)	(1)X(1,1)	(1)X(1,2)	(1)X(2,1)	(2)X(1,1)	(2)X(1,2)	(2)X(2,1)	(1,1)X(1,2)	(1,1)X(2,1)	(1,2)X(2,1)
ACF1	21	1	17	6	6	7	16	18	7	22
ACF2	20	3	20	15	8	3	9	13	15	19
ACF3	24	9	7	20	5	4	10	6	11	21
ACF4	7	18	11	9	15	17	6	22	2	15
ACF5	18	21	15	18	16	18	14	14	8	20
ACF6	11	11	16	12	13	11	15	16	24	6
ACF7	14	17	18	23	21	8	19	23	9	11
ACF8	19	22	22	24	22	6	11	4	17	8
ACF9	12	23	21	16	19	9	24	10	5	7
ACF10	15	10	23	17	14	20	22	20	4	13
PACF1	13	15	8	5	12	5	12	11	10	18
PACF2	6	5	2	22	20	13	8	7	14	3
PACF3	23	14	14	21	24	16	18	8	13	17
PACF4	8	19	12	2	9	19	5	19	12	24
PACF5	22	12	5	10	7	10	7	9	20	10
PACF6	5	13	3	3	18	2	13	5	21	9
PACF7	10	6	9	11	1	15	20	17	22	23
PACF8	17	24	13	13	17	22	3	24	3	2
PACF9	9	8	1	7	10	24	4	12	16	12
PACF10	1	7	6	14	3	12	17	2	18	16
Dif ACF1 X ACF2	3	20	24	19	23	23	2	21	19	5
Dif ACF2 X ACF3	2	2	10	4	4	21	1	1	6	4
Dif PACF1 X PACF2	4	4	19	1	2	1	23	3	23	1
Dif PACF2 X PACF3	16	16	4	8	11	14	21	15	1	14

A Tabela 14 apresenta um resumo das três variáveis selecionadas como mais importantes por cada um dos métodos das tabelas acima. Nesta tabela, faz-se o cruzamento das variáveis mais importantes pela intuição teórica (marcadas) com as três variáveis mais importantes definidas por cada um dos métodos de seleção de variáveis. Os resultados mostram que o método que demonstrou mais aderência com à abordagem teórica foi o de Fisher, pois deu mais importância às variáveis que teoricamente seriam relevantes para diferenciar as séries geradas pelos pares de modelos. O segundo método mais aderente foi o SIE, que apresentou boa relação com a teoria também. Dentre os métodos que utilizam o SVM para selecionar as variáveis, os de primeira ordem apresentam resultados bem superiores aos de ordem zero.

Tabela 14: Cruzamento das três variáveis mais importantes selecionadas pelos modelos com a intuição pela teoria

Variável	Comparação entre pares de modelos									
	(1)X(2)	(1)X(1,1)	(1)X(1,2)	(1)X(2,1)	(2)X(1,1)	(2)X(1,2)	(2)X(2,1)	(1,1)X(1,2)	(1,1)X(2,1)	(1,2)X(2,1)
ACF1		SVM11 / SVM12	SVM11	SIE / SVM11	SIE	SIE			F	
ACF2	SIE	SVM12	SIE		F	SIE / SVM12	F	SIE	SIE / F	SIE / F / SVM11
ACF3	SIE			SIE			SIE	SVM11		SIE
ACF4					SVM11		SIE	SVM2	SVM12	
ACF5		F		F				SIE		
ACF6					SVM1		SMV2 / SVM11	SVM2	SIE	
ACF7						F	SVM11			
ACF8						F	SIE		SIE	SIE / SVM2
ACF9										
ACF10									SIE	
PACF1	SVM11	SIE / SVM11	SIE	SIE		SIE		SIE	F	SIE
PACF2	F		SIE / F / SVM12			SIE / SVM11	SIE	F		F / SVM12
PACF3					SIE / SVM2	F			SVM11	SVM11
PACF4		SVMM2		SVM12	SVM2			SVM1 / SVM2 / SVM11	SIE / SVM2	
PACF5			SVM1 / SVM2						SVM11	SVM2
PACF6		SVM1 / SVM2	SVM2 / SVM12	SVM1 / SVM2 / SVM11 / SVM12	SVM1 / SVM11	SVM2 / SVM11 / SVM12	SVM2		SVM2	
PACF7	SVM1		SVM2	SVM1 / SVM2	SVM12	SVM1 / SVM2		SVM1 / SVM11	SVM1 / SVM2	SVM2
PACF8	SVM2			SVM1	SVM1	SVM1	SVM1 / SVM12	SVM1	SVM11 / SVM12	SVM1 / SVM12
PACF9	SVM1 / SVM2 / SVM11	SVM1	SVM1 / SVM11 / SVM12	SVM2			SVM1		SVM1	SVM1 / SVM11
PACF10	SVM1 / SVM2 / SVM12	SVM1	SVM1	SVM11	SVM11 / SVM12	SVM1	SVM1 / SVM11	SVM12	SVM1	SVM1
Dif ACF1 X ACF2	F / SVM12	SIE / F	F / SVM11	SIE / F	SIE	SIE	SVM12	F		F
Dif ACF2 X ACF3	SIE / SVM12	SIE / SVM12	SIE	SIE	F / SVM2		SIE / F / SVM12	SVM12		
Dif PACF1 X PACF2	F	F	SIE / F	F / SVM12	SVM12	SVM2 / SVM11 / SVM12		F / SVM12		SVM12
Dif PACF2 X PACF3	SVM11	SVM2 / SVM11			F		F / SVM2		SVM12	

Tendo em vista os resultados do processo de seleção de variáveis, optou-se por utilizar o método do discriminante de Fisher. O próximo passo é escolher quantas variáveis serão utilizadas. Para isso, recorre-se novamente a intuição teórica. Os resultados que serão comentados a seguir referem-se à análise da Tabela 9.

Utilizando a comparação dos modelos ARCH(1) com ARCH(2) como exemplo, a principal diferença entre as características das autocorrelações e autocorrelações parciais teóricas desses modelos está no $lag2$. O modelo

ARCH(2) deve apresentar, teoricamente, no segundo *lag*, uma PACF mais significativa, o método de Fisher elegeu essa variável como a segunda mais importante, sendo a diferença entre a PACF (*lag1*) e a PACF (*lag2*) a terceira mais importante, representando a característica que diferencia estes dois modelos. Como a autocorrelação não deve diferenciar muito os modelos, optou-se por incluir apenas a diferença entre a ACF(*lag1*) e a ACF(*lag2*) como variável do modelo. Isto pode ser repetido para as demais comparações, demonstrando que a escolha de variáveis pelo método de Fisher foi aderente à identificação pelas funções de autocorrelação e autocorrelação parcial.

A Tabela 15 apresenta um resumo das variáveis que serão utilizadas na classificação dos modelos.

Tabela 15: Resumo das variáveis selecionadas

Variável	Comparação entre pares de modelos									
	(1)X(2)	(1)X(1,1)	(1)X(1,2)	(1)X(2,1)	(2)X(1,1)	(2)X(1,2)	(2)X(2,1)	(1,1)X(1,2)	(1,1)X(2,1)	(1,2)X(2,1)
ACF1									X	
ACF2					X		X		X	X
ACF3										
ACF4										
ACF5										
ACF6										
ACF7						X				
ACF8										
ACF9										
ACF10										
PACF1									X	
PACF2	X		X		X		X	X		X
PACF3						X				
PACF4										
PACF5										
PACF6										
PACF7										
PACF8										
PACF9										
PACF10										
Dif ACF1 X ACF2	X	X	X	X	X			X		X
Dif ACF2 X ACF3					X		X		X	X
Dif PACF1 X PACF2	X	X	X	X				X		X
Dif PACF2 X PACF3					X		X			X

Selecionadas as variáveis, para a primeira metodologia proposta, ajustou-se uma rede neural *feedforward* treinada pelo algoritmo de retropropagação. A figura 5.1 representa a topologia da rede testada.

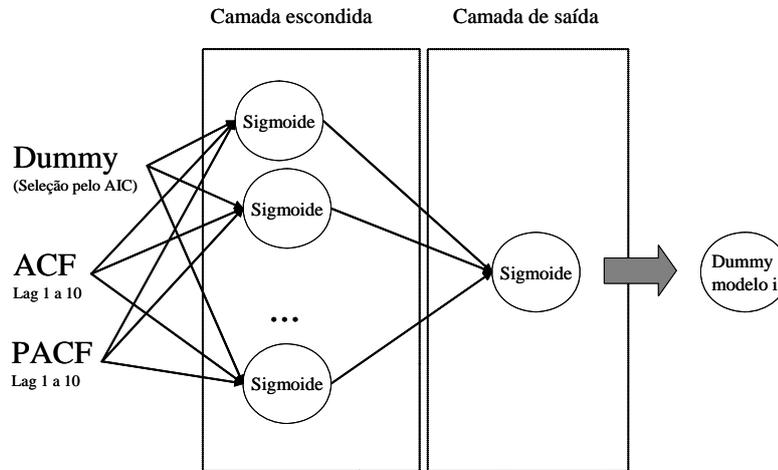


Figura 5.1: Estrutura da rede neural para identificação dos modelos GARCH

As variáveis de entrada das redes foram as selecionadas pelo método de Fisher. Foram treinadas 25 topologias para definir qual teria a melhor composição de camadas e neurônios. Para cada topologia foram treinadas 10 redes e os resultados médios são apresentados na Figura 5.2.

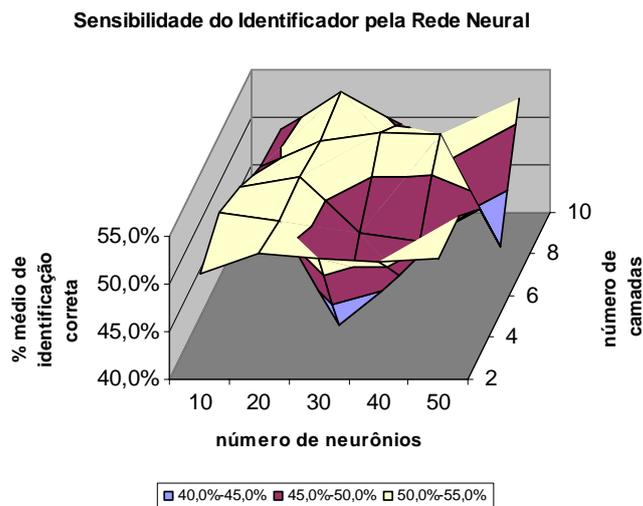


Figura 5.2: Sensibilidade do Identificador pela Rede Neural

O melhor resultado geral de acerto na classificação foi alcançado pela rede que utilizou duas camadas com vinte neurônios em cada camada. Para a escolha do melhor resultado, recorreu-se à validação cruzada. Pode-se observar na Figura 5.2 que os resultados pioram quando se utilizam muitos neurônios em poucas camadas. Isto se deve ao *overfitting*, que tende a viciar a rede (pois ela acaba incorporando ruídos no seu aprendizado).

As Tabelas 16 e 17 apresentam os resultados da classificação utilizando a metodologia descrita anteriormente com duas camadas ocultas e vinte neurônios em cada camada.

Tabela 16: Percentual de Acertos do Sistema de Identificação Utilizando Redes Neurais

N	ARCH(1)	ARCH(2)	GARCH(1,1)	GARCH(2,1)	GARCH(1,2)	Total
22	63,8%	23,8%	8,8%	16,5%	48,5%	32,3%
66	89,8%	58,3%	22,8%	20,0%	46,3%	47,4%
132	90,5%	83,0%	45,0%	25,3%	55,5%	59,9%
264	92,5%	91,0%	56,8%	54,3%	77,3%	74,4%
Total	84,1%	64,0%	33,3%	29,0%	56,9%	53,5%

Tabela 17: Matriz de Classificação Cruzada da Identificação pela Rede Neural

Real / Classificado	ARCH(1)	ARCH(2)	GARCH(1,1)	GARCH(2,1)	GARCH(1,2)
ARCH(1)	84,1%	2,9%	3,1%	0,8%	9,1%
ARCH(2)	15,8%	64,0%	5,9%	6,8%	7,6%
GARCH(1,1)	21,1%	15,4%	33,3%	6,6%	23,6%
GARCH(2,1)	12,8%	26,7%	17,3%	29,0%	14,2%
GARCH(1,2)	17,5%	4,7%	16,0%	4,9%	56,9%

Como pode ser observado, o resultado global é superior ao da classificação pelos critérios AIC e BIC.

Um ponto a ser observado na Tabela 17 é que as séries geradas pelos modelos GARCH(1,1) e GARCH (2,1) são geralmente classificadas como modelos de ordens mais baixas. Esse fato será explorado mais a frente.

Outra característica que pode ser observada é a melhora da classificação quando o número de observações aumenta. Para tentar aprimorar a identificação para as séries com menos observações, optou-se por estimar uma rede para cada tamanho de série.

As Tabelas 18 e 19 apresentam os resultados da classificação utilizando a metodologia descrita com uma topologia para cada tamanho de série. As topologias utilizadas podem ser observadas na Tabela 20.

Tabela 18: Percentual de Acertos Utilizando Uma Redes Neural para cada Tamanho de Série

N	ARCH(1)	ARCH(2)	GARCH(1,1)	GARCH(2,1)	GARCH(1,2)	Total
22	57,5%	49,0%	16,0%	79,5%	52,8%	51,0%
66	36,0%	17,8%	75,0%	70,3%	60,0%	51,8%
132	90,5%	83,0%	45,0%	25,3%	55,5%	59,9%
264	92,5%	91,0%	56,8%	54,3%	77,3%	74,4%
Total	69,1%	60,2%	48,2%	57,3%	61,4%	59,2%

Tabela 19: Matriz de Classificação Cruzada Utilizando Uma Redes Neural para cada Tamanho de Série

Real / Classificado	ARCH(1)	ARCH(2)	GARCH(1,1)	GARCH(2,1)	GARCH(1,2)
ARCH(1)	69,1%	9,4%	6,6%	2,3%	12,5%
ARCH(2)	9,3%	60,2%	16,6%	9,1%	4,8%
GARCH(1,1)	5,7%	18,2%	48,2%	15,5%	12,4%
GARCH(2,1)	2,4%	17,9%	13,6%	57,3%	8,8%
GARCH(1,2)	13,3%	7,2%	13,8%	4,4%	61,4%

Tabela 20: Topologia da Rede Utilizada Para Cada Tamanho de Série

Tamanho da Série	Número de Camadas	Número de Neurônios
22	4	20
66	3	15
132	2	20
264	2	20

A utilização de uma topologia para cada tamanho de série melhorou a classificação geral em 5,7 p.p. ou 10,6% em relação à identificação pela rede neural treinada com todas as séries em conjunto. A melhora pode ser observada mais nitidamente nas séries com 22 observações, que apresentaram um aumento de 18,7 p.p. ou 57,9% de identificação correta.

Obtidos os resultados com as redes neurais, elaborou-se outro processo de identificação utilizando SVM. Para isso, decidiu-se comparar a especificação dos modelos em pares – dez diferentes combinações entre modelos. Para cada uma dessas combinações foi ajustado um classificador SVM.

Para combinar os dez classificadores com o classificador pelo critério AIC e se ter um único classificador, foi criada uma máquina de comitê, agregando todos os classificadores por uma rede neural *feedforward*. Essa máquina de comitê é descrita na Figura 5.3.

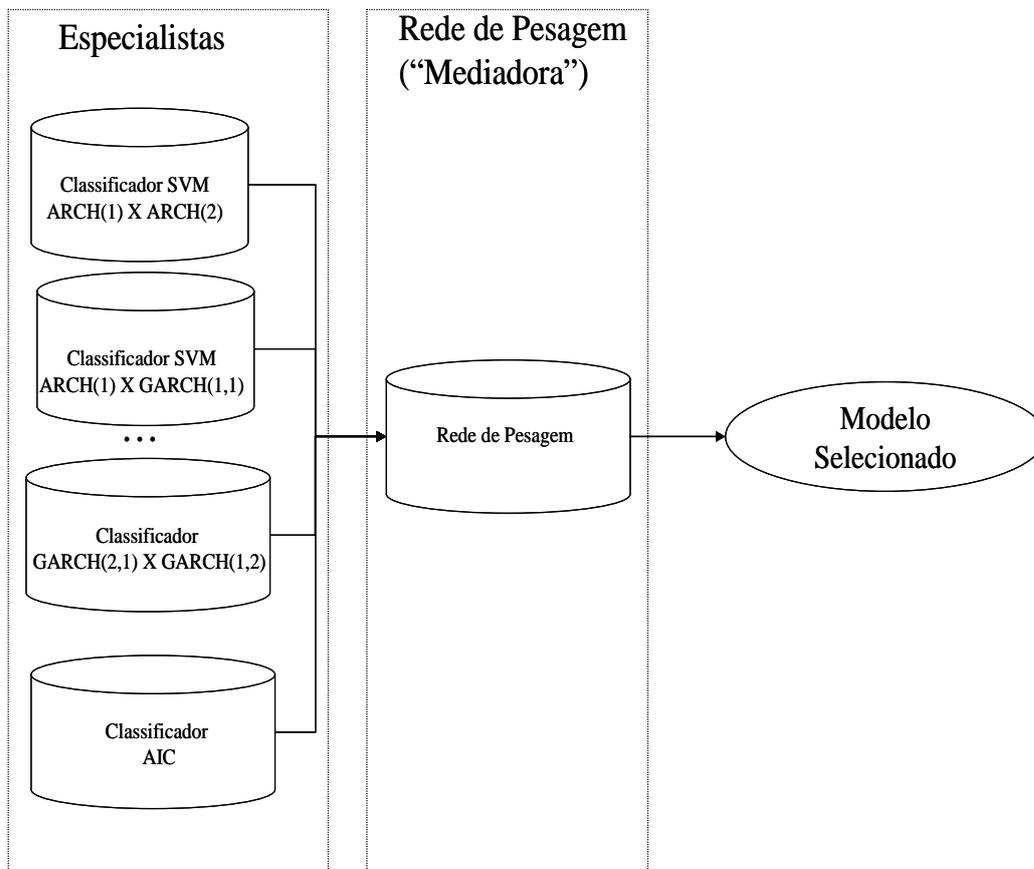


Figura 5.3: Representação da Máquina de Comitê que combina os classificadores SVM e AIC

Nos classificadores SVM utiliza-se o núcleo (*kernel*) do produto interno gaussiano, testando a sensibilidade do desvio-padrão e do parâmetro de regularização do SVM. O algoritmo de treinamento utilizado foi o de programação quadrática.

Para a rede de pesagem, utilizou-se a mesma estrutura definida anteriormente, ou seja, uma rede *feedforward* com duas camadas ocultas e vinte neurônios em cada camada. As funções de ativação utilizadas foram sigmóides e a camada de saída sigmóide. O algoritmo do treinamento foi o de retropropagação do erro.

O resultado da sensibilidade dos parâmetros do SVM pode ser observado na Figura 5.4.

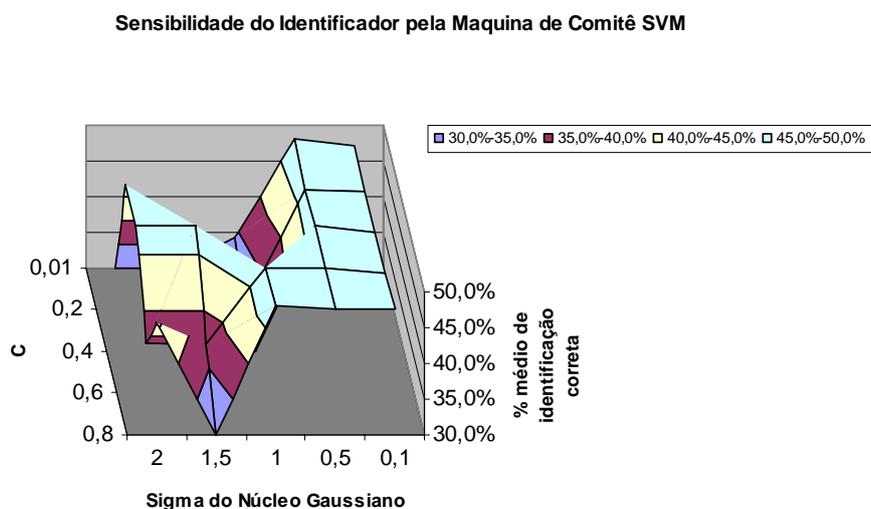


Figura 5.4: Sensibilidade da classificação pela Máquina de Comitê SVM

O modelo que utilizou o desvio padrão 1 para a função Gaussiana do núcleo do produto interno e parâmetro de regularização 0,8 foi o que apresentou o melhor resultado, acertando 48,1% dos casos.

Percebe-se pela Figura 5.4 que existe uma saturação no desempenho quando este se aproxima de 46%, e que o desempenho não é bom quando se utiliza um desvio padrão maior do que 1.

As Tabelas 21 e 22 apresentam os resultados da classificação com a metodologia que utiliza SVM, considerando os parâmetros descritos acima.

Tabela 21: Percentual de Acertos do Sistema de Identificação Utilizando SVM

N	ARCH(1)	ARCH(2)	GARCH(1,1)	GARCH(2,1)	GARCH(1,2)	Total
22	95,5%	22,3%	3,3%	1,0%	2,3%	24,9%
66	97,3%	64,3%	24,8%	11,5%	16,8%	42,9%
132	91,8%	84,8%	46,0%	21,0%	33,5%	55,4%
264	92,8%	91,8%	61,3%	53,5%	47,8%	69,4%
Total	94,3%	65,8%	33,8%	21,8%	25,1%	48,1%

Tabela 22: Comparação dos Modelos Reais e Identificados pelo Sistema de Identificação Utilizando SVM

Real / Classificado	ARCH(1)	ARCH(2)	GARCH(1,1)	GARCH(2,1)	GARCH(1,2)
ARCH(1)	94,3%	3,4%	1,7%	0,0%	0,5%
ARCH(2)	24,7%	65,8%	7,1%	2,3%	0,1%
GARCH(1,1)	38,4%	19,3%	33,8%	2,8%	5,6%
GARCH(2,1)	24,6%	31,3%	21,4%	21,8%	0,9%
GARCH(1,2)	34,1%	5,2%	34,4%	1,3%	25,1%

Como pode ser observado, o resultado global é superior ao resultado da classificação pelo critério AIC, porém inferior ao da identificação com apenas uma rede *feedforward*.

A Tabela 22 apresenta novamente as séries geradas pelos modelos GARCH(1,1) e GARCH (2,1) classificadas como modelos de ordens mais baixas.

Devido à subestimação do número de parâmetros dos modelos, a técnica de sobrefixação proposta por Box e Jenkins (1976) será aplicada. Essa técnica consiste em aumentar a ordem do modelo adicionando um parâmetro e testar sua significância pelo teste estatístico T. Para tal, decidiu-se testar a sobrefixação incluindo um coeficiente ARCH e então utilizar o mesmo procedimento para um coeficiente GARCH. Essa sobrefixação se restringiu as cinco possibilidades de modelos sob estudo. A Tabela 23 mostra como essa sobrefixação será testada.

Tabela 23: Modelos a serem testados na sobrefixação

Modelo Identificado	Modelo Sobrefixado1	Modelo Sobrefixado2
ARCH(1)	ARCH(2)	GARCH(1,1)
ARCH(2)	GARCH(2,1)	Nenhum
GARCH(1,1)	GARCH(2,1)	GARCH(1,2)
GARCH(2,1)	Nenhum	Nenhum
GARCH(1,2)	Nenhum	Nenhum

Como a rede neural foi a alternativa que apresentou maiores índices de acerto, optou-se por testar a sobrefixação nesse modelo. Optou-se por escolher o modelo sobrefixado com o coeficiente mais significativo pelo teste-T. O nível de significância foi determinado pelo que maximizou o percentual de acerto.

Ao se observar as Tabelas 24 e 25, percebe-se que a sobrefixação aprimorou os resultados da rede neural em 2,6 p.p. ou 4,9%.

Tabela 24: Percentual de Acertos da Rede Neural com sobre fixação

N	ARCH(1)	ARCH(2)	GARCH(1,1)	GARCH(2,1)	GARCH(1,2)	Total
22	57,5%	49,0%	16,0%	79,5%	52,8%	51,0%
66	34,0%	18,5%	76,0%	70,3%	60,8%	51,9%
132	86,3%	79,8%	44,8%	50,5%	56,8%	63,6%
264	92,5%	91,0%	56,8%	54,3%	77,3%	74,4%
Total	67,6%	59,6%	48,4%	63,6%	61,9%	60,2%

Tabela 25: Comparação dos Modelos Reais e Identificados da Rede Neural com sobre fixação

Real / Classificado	ARCH(1)	ARCH(2)	GARCH(1,1)	GARCH(2,1)	GARCH(1,2)
ARCH(1)	67,6%	9,5%	7,7%	2,5%	12,8%
ARCH(2)	8,4%	59,6%	16,5%	10,8%	4,8%
GARCH(1,1)	4,9%	18,0%	48,4%	15,9%	12,8%
GARCH(2,1)	0,6%	12,3%	13,4%	63,6%	10,1%
GARCH(1,2)	8,1%	6,8%	14,8%	8,5%	61,9%

A Tabela 26 e a Tabela 27 apresentam a comparação dos resultados das metodologias propostas com o critério AIC.

Observa-se na Tabela 26 que todas as metodologias melhoram o desempenho à medida que o número de observações aumenta. Percebe-se também que o desempenho da Rede *Feedforward* é consistentemente superior para todos os tamanhos de séries, principalmente após a sobre fixação. Já a Máquina de Comitê SVM apresenta resultados de acertos superiores ao critério AIC, porém inferiores aos da Rede *Feedforward*, para todos os tamanhos das séries.

Tabela 26: Comparação dos acertos de identificação das metodologias por número de observações das séries

Observações	Critério AIC	Rede <i>Feedforward</i>	Rede <i>Feedforward</i> para cada tamanho de série com sobre fixação	Máquina de Comitê SVM
22	24,4%	32,3%	51,0%	24,9%
66	40,5%	47,4%	51,9%	42,9%
132	53,5%	59,9%	63,6%	55,4%
264	68,6%	74,4%	74,4%	69,4%
Total	46,7%	53,5%	60,2%	48,1%

Ao observar a Tabela 27 percebe-se que o critério AIC apresenta 93% de acertos no modelo ARCH(1), apenas 14% no modelo GARCH(1,2) e 21,4% no GARCH(2,1).

Os resultados dos modelos GARCH(1,2) e GARCH(2,1) são bastante melhorados pela Rede *Feedforward*, apresentando acertos de 57% e 29% respectivamente. O ganho na classificação desses dois modelos pela Rede *Feedforward* é parcialmente compensado por uma redução de acertos no ARCH(1) e GARCH(1,1), que passam para 84% e 33% respectivamente.

Considerando a Rede *Feedforward* para cada tamanho de série após a sobrefixação, os resultados dos modelos GARCH(1,2) e GARCH(2,1) são melhorados ainda mais, apresentando acertos de 61,9% e 63,6% respectivamente. O ganho na classificação desses dois modelos é parcialmente compensado por uma redução de acertos no ARCH(1) e GARCH(1,1), que passam para 67,6% e 59,6% respectivamente.

A Máquina de Comitê SVM apresentou resultados de acertos superiores ao AIC em quatro dos cinco modelos, tendo resultado inferior apenas para o modelo GARCH(1,1). A melhoria do resultado, principalmente do GARCH(1,2), foi responsável pelo total de acertos dessa metodologia ser superior ao critério AIC, porém não superior à Rede *Feedforward*.

Tabela 27: Comparação dos acertos de identificação das metodologias por tipo de modelo

Observações	Critério AIC	Rede <i>Feedforward</i>	Rede <i>Feedforward</i> para cada tamanho de série com sobre fixação	Máquina de Comitê SVM
ARCH(1)	93,1%	84,1%	67,6%	94,3%
ARCH(2)	64,9%	64,0%	59,6%	65,8%
GARCH(1,1)	40,4%	33,3%	48,4%	33,8%
GARCH(2,1)	21,4%	29,0%	63,6%	21,8%
GARCH(1,2)	13,8%	56,9%	61,9%	25,1%
Total	46,7%	53,5%	60,2%	48,1%

Apenas para efeito comparativo, aplicou-se o método linear K-means. Como mostra a Tabela 28, os resultados foram inferiores aos das metodologias propostas.

Tabela 28: Percentual de Acertos do Discriminante de Fisher

N	ARCH(1)	ARCH(2)	GARCH(1,1)	GARCH(2,1)	GARCH(1,2)	Total
22	41,3%	27,5%	42,0%	33,3%	0,0%	28,8%
66	50,0%	64,8%	29,5%	10,0%	34,5%	37,8%
132	92,3%	82,5%	54,0%	23,5%	16,0%	53,7%
264	93,0%	89,5%	74,3%	53,0%	32,5%	68,5%
Total	69,1%	66,1%	49,9%	29,9%	20,8%	47,2%

5.2

Dados Reais

Com o intuito de testar a metodologia de identificação dos modelos GARCH proposta nesse trabalho, selecionaram-se dez ações de empresas brasileiras que abriram capital recentemente. Primeiramente um detalhamento breve sobre cada empresa será feito; em seguida, testes univariados serão aplicados com o intuito de selecionar as séries que possuam características dos modelos GARCH. Uma vez selecionadas essas séries, serão comparados os modelos identificados para elas pelo AIC e pela rede neural.

Os dados referentes a esse estudo de caso foram extraídos de www.infomoney.com.br, sempre se referindo à data de início das negociações dos novos ativos negociados na Bolsa de Valores de São Paulo (BOVESPA), até a data indicada. Os testes são aplicados nas séries de retornos diários dos ativos negociados e têm como base os mesmos períodos de dados do estudo de caso passado, ou seja, 22 observações (refletindo o período de um mês), 66 observações (refletindo o período de um trimestre), 132 observações (refletindo o período de um semestre) e 264 observações (refletindo o período de um ano).

A seguir, as empresas selecionadas para esse estudo são apresentadas de forma resumida:

Amil Participações S.A. (Código da ação negociada na BOVESPA: AMIL3, página na Internet: www.amil.com.br): iniciou suas atividades em 1978, sendo atualmente a maior empresa de medicina de grupo do país. Conta com rede própria de hospitais, clínicas, laboratórios e médicos. Suas ações começaram a ser negociadas na BOVESPA em 29 de outubro de 2007.

BR Malls (Código da ação negociada na BOVESPA: BRML3, página na Internet: www.brmalls.com.br): tem sua origem na empresa ECISA constituída em 1949 para desenvolver atividades de construção civil, com foco rodovias. A partir da década de 70, a ECISA ingressou no segmento de desenvolvimento e investimentos em Shoppings Centers. A BR Malls é hoje a maior empresa integrada de Shoppings Centers do Brasil, com participação em 34 Shoppings. Suas ações começaram a ser negociadas na BOVESPA em 05 de abril de 2007.

Banco Cruzeiro do Sul (Código da ação negociada na BOVESPA: CZRS4, página na Internet: www.bcsul.com.br): em 1993, a família Índio da Costa adquiriu o controle do banco múltiplo, que passou a concentrar suas forças no crédito consignado (crédito ao consumidor com desconto em folha de pagamento). Atualmente sua carteira de crédito é de R\$ 4 bilhões. Suas ações começaram a ser negociadas na BOVESPA em 26 de junho de 2007.

Brasil Ecodiesel (Código da ação negociada na BOVESPA: ECOD3, página na Internet: www.brasilecodiesel.com.br): a empresa iniciou a elaboração de seu projeto para a produção do biodiesel em março de 2003, sendo hoje o maior produtor do país, com 6 unidades de produção em operação e um total de 640 mil m³ por ano de capacidade instalada de produção. Suas ações começaram a ser negociadas na BOVESPA em 13 de novembro de 2006.

Hypermarcas (Código da ação negociada na BOVESPA: HYPE3, página na Internet: www.hypermarcas.com.br): iniciou suas operações em dezembro de 2001, quando a Monte Cristalina adquiriu a Prátika Industrial Ltda. (cuja

denominação foi posteriormente alterada para Assolan Industrial Ltda.). É hoje uma das maiores e mais diversificadas empresas de bens de consumo com capital de origem brasileira, atuando em quatro linhas de negócios: Higiene e Limpeza, Alimentos, Beleza e Higiene Pessoal, e Medicamentos Isentos de Prescrição Médica. Suas ações começaram a ser negociadas na BOVESPA em 18 de abril de 2008.

Banco Pine (Código da ação negociada na BOVESPA: PINE4, página na Internet: www.bancopine.com.br): fundado em maio de 1997 pela família Pinheiro, que está no setor bancário desde 1939. O Banco Pine é um Banco Múltiplo especializado em crédito a empresas, e oferece serviços de assessoria financeira e estratégica, produtos de Tesouraria, investimento, linhas de crédito especializado e repasses. Suas ações começaram a ser negociadas na BOVESPA em 02 de abril de 2007.

Redecard (Código da ação negociada na BOVESPA: RDCD3, página na Internet: www.redecard.com.br): foi fundada em 1996 a partir da cisão das atividades de credenciamento da Credicard, que por sua vez foi fundada em 1970. Atualmente é uma das companhias líderes da indústria de cartões de pagamento no mercado brasileiro e principal Credenciadora das Bandeiras MasterCard e Diners Club International no Brasil. Suas ações começaram a ser negociadas na BOVESPA em 13 de julho de 2007.

SLC Agrícola (Código da ação negociada na BOVESPA: SLCE3, página na Internet: www.slcagricola.com.br): iniciou as suas atividades em 1977, com a compra da Fazenda Paineira,RS. É hoje uma produtora de *commodities* agrícolas, tendo como principal atividade a produção de algodão, soja e milho, contando com 11 unidades de produção, que totalizam mais de 200 mil hectares plantados. Suas ações começaram a ser negociadas na BOVESPA em 15 de junho de 2007.

SulAmérica Seguros (Código da *unit* negociada na BOVESPA: SULA11, página na Internet: www.sulamerica.com.br): fundada em 1895, começou a atuar como uma empresa de seguros de vida no Estado do Rio de Janeiro. É hoje o maior grupo segurador independente de canal bancário do Brasil e atua em

diversos ramos de seguros, com concentração principalmente em seguro saúde e seguro de automóvel. Suas ações começaram a ser negociadas na BOVESPA em 5 de outubro de 2007.

Tempo Participações (Código da ação negociada na BOVESPA: TEMP3, página na Internet: www.tempopar.com.br): iniciou seus negócios em 2000, com a Connectmed-CRC, como uma empresa de tecnologia da informação para suporte à gestão de planos de saúde. Atua em três segmentos: Administração de Planos de Saúde, Operação de Planos Odontológicos e Assistência Especializada. Suas ações começaram a ser negociadas na BOVESPA em 19 de dezembro de 2007.

Todos os testes de hipótese desse estudo foram aplicados nas séries dos retornos diários dos ativos financeiros, referente às empresas descritas acima, nos períodos refletindo um mês (22 informações), um trimestre (66 informações), um semestre (132 informações) e um ano (264 informações), sempre iniciando na data de início de negociação do ativo financeiro na BOVESPA.

Os primeiros testes aplicados estão relacionados a estacionariedade das séries. Os testes de hipótese aplicados para estacionariedade foram o Augmented Dickey-Fuller (teste ADF) e o Phillips-Perron (teste PP).

As Tabelas 29 e 30 mostram que, em um nível de aceitação de 5%, pode-se rejeitar, para todas as séries testadas, a hipótese nula de não estacionariedade; logo as séries podem ser consideradas como estacionárias (primeiro fato estilizado).

Tabela 29: Resultados do Teste ADF

Teste ADF – [$t_i(\hat{\alpha}_1, p)$] (P-Valor)				
Ativo	Número de Observações			
	22	66	132	264
AMIL3	-6,16 (0,001)	-10,69 (0,001)	-15,67 (0,001)	NA
BRML3	-7,69 (0,001)	-10,39 (0,001)	-15,14 (0,001)	-25,43 (0,001)
CZRS4	-7,43 (0,001)	-11,96 (0,001)	-18,81 (0,001)	-27,29 (0,001)
ECOD3	-6,33 (0,001)	-11,86 (0,001)	-16,02 (0,001)	-24,24 (0,001)
HYPE3	-8,61 (0,001)	-13,6 (0,001)	NA	NA
PINE4	-8,6 (0,001)	-14,88 (0,001)	-18,22 (0,001)	-28,12 (0,001)
RDCD3	-7,23 (0,001)	-13,61 (0,001)	-20,17 (0,001)	-29,61 (0,001)
SLCE3	-6,32 (0,001)	-12,65 (0,001)	-17,22 (0,001)	-26,7 (0,001)
SULA11	-4,11 (0,0208)	-10,85 (0,001)	-16,36 (0,001)	NA
TEMP3	-7,79 (0,001)	-13,91 (0,001)	-16,12 (0,001)	NA

Tabela 30: Resultados do Teste PP

Teste PP – [$t_i(\hat{\alpha}_1, p)$] (P-Valor)				
Ativo	Número de Observações			
	22	66	132	264
AMIL3	-6,33 (0,001)	-10,78 (0,001)	-15,73 (0,001)	NA
BRML3	-7,8 (0,001)	-10,46 (0,001)	-15,2 (0,001)	-25,47 (0,001)
CZRS4	-7,62 (0,001)	-12,05 (0,001)	-18,87 (0,001)	-27,34 (0,001)
ECOD3	-6,49 (0,001)	-11,95 (0,001)	-16,08 (0,001)	-24,29 (0,001)
HYPE3	-8,85 (0,001)	-13,7 (0,001)	NA	NA
PINE4	-8,69 (0,001)	-14,88 (0,001)	-18,27 (0,001)	-28,16 (0,001)
RDCD3	-7,39 (0,001)	-13,72 (0,001)	-20,25 (0,001)	-29,66 (0,001)
SLCE3	-6,49 (0,001)	-12,75 (0,001)	-17,28 (0,001)	-26,75 (0,001)
SULA11	-4,21 (0,0045)	-10,94 (0,001)	-16,41 (0,001)	NA
TEMP3	-7,68 (0,001)	-13,96 (0,001)	-16,16 (0,001)	NA

Antes de abordar propriamente a dependência quadrática das séries de retorno, cabe analisar alguma dependência linear. Para isso, faz-se uso do teste de Ljung-Box, que mede a dependência linear em um conjunto de *lags*.

A Tabela 31 mostra que, com exceção das séries dos ativos BRML3, SLCE3 e TEMP3 (apenas para as séries com 132 e 264 observações), as demais séries apresentam características de não existência de dependência linear. Mesmo as séries SLCE3 e TEMP3 apresentam baixa dependência linear. Para retirar essa dependência linear, um modelo AR(1) foi ajustado para cada uma das séries. Após esta filtragem linear, o teste Ljung-Box aplicado aos resíduos aceita a hipótese nula para as três séries.

Tabela 31: Resultados do Teste Ljung-Box

Teste LB				
Ativo	Número de Observações			
	22	66	132	264
AMIL3	7,09 (0,6275)	8,9 (0,4469)	11,6 (0,2371)	NA
BRML3	3,9 (0,9178)	14,59 (0,103)	14,86 (0,0949)	9,11 (0,4276)
CZRS4	11,78 (0,226)	9,78 (0,3682)	14,65 (0,1011)	9,15 (0,4235)
ECOD3	4,99 (0,8349)	5,08 (0,8271)	8,33 (0,5013)	11,17 (0,264)
HYPE3	7,04 (0,6333)	14,65 (0,1011)	NA	NA
PINE4	2,77 (0,9727)	1,73 (0,9951)	7,25 (0,6107)	9,22 (0,4171)
RDCD3	7,2 (0,6168)	7,63 (0,5717)	10,78 (0,2914)	13,57 (0,1385)
SLCE3	7,14 (0,622)	11,61 (0,2365)	23,57 (0,005)	20,79 (0,0136)
SULA11	11,54 (0,2404)	8,46 (0,489)	11,46 (0,2457)	NA
TEMP3	8,79 (0,4572)	6,99 (0,6382)	36,04 (0)	NA

Para completar o segundo fato estilizado, recorre-se ao teste de McLeod-Li, que consiste basicamente no teste Ljung-Box aplicado nos quadrados dos resíduos. A Tabela 32 apresenta os resultados, que comprovam o segundo fato estilizado, pois a maior parte das séries apresenta correlação no quadrado das séries.

Tabela 32: Resultados do Teste McLeod-Li

Teste ML				
Ativo	Número de Observações			
	22	66	132	264
AMIL3	0,28 (0,8699)	0,22 (0,8971)	0,29 (0,8635)	NA
BRML3	0,05 (0,9738)	5,25 (0,0723)	10,69 (0,0048)	643,96 (0)
CZRS4	0,65 (0,7232)	0,88 (0,6426)	9,75 (0,0076)	707,36 (0)
ECOD3	6,37 (0,0414)	9,72 (0,0078)	17,47 (0,0002)	40,09 (0)
HYPE3	1,07 (0,5863)	75,68 (0)	NA	NA
PINE4	0,92 (0,6322)	6,05 (0,0487)	7,2 (0,0274)	630,71 (0)
RDCD3	0,01 (0,9947)	0,79 (0,6722)	5,89 (0,0527)	710,24 (0)
SLCE3	1,24 (0,5367)	1,32 (0,5158)	1,73 (0,4208)	705,21 (0)
SULA11	3,55 (0,1697)	6,29 (0,043)	6,12 (0,047)	NA
TEMP3	1,09 (0,5792)	0,18 (0,9156)	11,13 (0,0038)	NA

Outra característica de séries financeiras é que em geral elas não são Gaussianas. Para testar essa característica, recorre-se ao teste de Jarque-Bera.

A Tabela 33 mostra que a maior parte das séries rejeita a hipótese nula de normalidade, dando um indício do terceiro fato estilizado: os ativos financeiros normalmente fogem da curva gaussiana.

Tabela 33: Resultados do Teste Jarque-Bera

Teste JB				
Ativo	Número de Observações			
	22	66	132	264
AMIL3	47,97 (0,001)	37,81 (0,001)	262,18 (0,001)	NA
BRML3	23,33 (0,0015)	187,89 (0,001)	625,05 (0,001)	294,58 (0,001)
CZRS4	1,3 (0,2993)	12,73 (0,0097)	54,57 (0,001)	35,8 (0,001)
ECOD3	0,41 (0,5)	7,68 (0,0257)	56,75 (0,001)	135,42 (0,001)
HYPE3	7,27 (0,0187)	7,5 (0,0267)	NA	NA
PINE4	0,06 (0,5)	2,11 (0,2271)	62,9 (0,001)	46,86 (0,001)
RDCD3	0,84 (0,5)	0,96 (0,5)	36,77 (0,001)	48,05 (0,001)
SLCE3	0,22 (0,5)	0,25 (0,5)	1,01 (0,5)	25,45 (0,001)
SULA11	5,25 (0,0323)	9,17 (0,0185)	45,39 (0,001)	NA
TEMP3	10,86 (0,0088)	18,96 (0,0041)	3,52 (0,1175)	NA

Em seguida, o teste BDS é aplicado com o objetivo de avaliar a independência das séries. As séries aqui testadas já são descorrelacionadas (as séries dos ativos que demonstraram dependência linear foram substituídas pelos erros dos modelos AR(1) ajustados para essas séries).

Os resultados apresentados na Tabela 34 mostram que, para algumas séries, aceita-se a hipótese nula de independência; para outras, não. As séries consideradas dependentes (nível de significância de 10%) são submetidas ao teste de Hsieh, para testar se a dependência não linear é aditiva ou multiplicativa.

Tabela 34: Resultados do Teste BDS

Teste BDS				
Ativo	Número de Observações			
	22	66	132	264
AMIL3	0,09 (0,7129)	0,69 (0,5098)	2,07 (0,0631)	NA
BRML3	-3,01 (0,3775)	2,5 (0,0406)	3,9 (0,0009)	5,29 (0)
CZRS4	-2,74 (0,0945)	-2,19 (0,3201)	2,44 (0,035)	1,98 (0,0902)
ECOD3	-8,05 (0,4314)	1,31 (0,2732)	1,86 (0,0876)	4,83 (0,0003)
HYPE3	1,03 (0,3991)	0,41 (0,2866)	NA	NA
PINE4	-0,69 (0,4088)	-0,28 (0,7388)	1,71 (0,1024)	1,37 (0,2004)
RDCD3	-2,67 (0,1831)	-1,1 (0,3186)	0,12 (0,7846)	3,16 (0,0022)
SLCE3	-0,24 (0,7443)	1,23 (0,3102)	1,54 (0,1753)	5,62 (0,0002)
SULA11	3,11 (0,0383)	1,32 (0,2135)	3,2 (0,0201)	NA
TEMP3	0,69 (0,5369)	0,98 (0,3711)	2,65 (0,0793)	NA

Analisando os resultados da Tabela 35, observa-se que praticamente todas as estatísticas de Hsieh são menores do que 1,65 (significância de 10%) em módulo. Pode-se concluir que essas séries possuem dependência não linear na variância (multiplicativa). Assim, essas séries possuem as características modeláveis pelos modelos da família GARCH.

Tabela 35: Resultado do Teste Hsieh

Ativo	Observações	v(1,1)	V(2,1)	v(2,2)	v(3,1)	v(3,2)	v(3,3)	v(4,1)	v(4,2)	v(4,3)	v(4,4)
CZRS4	22	-0,40	-0,48	0,52	-1,56	-0,51	0,48	0,18	0,02	1,36	0,22
SULA11	22	-0,26	1,59	0,36	-4,15	0,38	0,43	-2,71	-2,74	-0,44	2,23
BRML3	66	0,22	0,38	1,11	-1,17	0,66	0,53	-1,21	-1,94	1,00	-0,61
AMIL3	132	-0,45	-0,70	-0,08	-1,26	-0,11	-0,05	-0,74	0,68	0,61	0,56
BRML3	132	0,11	-0,37	-0,16	0,55	-0,19	-0,24	-1,33	0,80	-0,42	-0,45
CZRS4	132	-0,25	-0,53	-0,37	-0,22	-0,12	-0,41	1,17	-0,61	-0,47	0,16
ECOD3	132	-0,09	-0,47	-0,41	0,08	-0,31	-0,72	0,04	1,12	-0,56	-1,06
SULA11	132	-0,10	1,96	0,47	0,13	0,40	0,23	0,76	-0,05	0,80	1,73
TEMP3	132	0,70	0,83	0,01	0,18	0,34	0,38	-1,14	0,01	0,20	0,20
BRML3	264	0,14	-0,67	-0,14	0,81	-0,61	-0,01	-0,83	0,25	-0,06	-0,53
CZRS4	264	-0,35	-0,59	-0,46	-0,21	-0,37	-0,72	0,75	-0,81	-0,43	-0,04
ECOD3	264	-0,11	-0,37	-0,49	0,02	-0,35	-0,80	-0,26	1,13	-0,83	-1,22
RDCD3	264	0,37	-0,12	-0,56	0,35	0,03	-0,05	-0,63	1,00	-0,38	0,28
SLCE3	264	-0,24	0,82	0,27	1,29	0,55	0,34	-0,34	0,31	0,51	0,26

Realizados os testes univariados, foram selecionadas 14 séries com características da família GARCH para teste dos critérios de classificação.

A Tabela 36 relaciona as 14 séries que foram selecionadas por possuírem características dos modelos GARCH, e mostra a identificação dos modelos pelos critérios AIC e BIC.

Tabela 36: Identificação dos Modelos para as Séries Reais Utilizando os Critérios AIC e BIC

Ativo	N	Modelo Selecionado (AIC)	Modelo Selecionado (BIC)
CZRS4	22	ARCH(1)	ARCH(1)
SULA11	22	ARCH(2)	ARCH(2)
BRML3	66	ARCH(1)	ARCH(1)
AMIL3	132	ARCH(1)	ARCH(1)
BRML3	132	ARCH(1)	ARCH(1)
CZRS4	132	GARCH(1,1)	GARCH(1,1)
ECOD3	132	ARCH(1)	ARCH(1)
SULA11	132	ARCH(2)	ARCH(1)
TEMP3	132	ARCH(1)	ARCH(1)
BRML3	264	ARCH(2)	ARCH(2)
CZRS4	264	GARCH(1,2)	ARCH(1)
ECOD3	264	GARCH(1,2)	GARCH(1,2)
RDOD3	264	ARCH(1)	ARCH(1)
SLCE3	264	GARCH(1,2)	ARCH(1)

A Tabela 37 mostra a identificação dos modelos pela rede neural. O sistema identificou o modelo GARCH(1,2) como o melhor para todas as séries utilizadas, não se requerendo o teste de sobrefixação.

Tabela 37: Identificação dos Modelos para as Séries Reais Utilizando Rede Feedforward

Ativo	N	Modelo Selecionado
CZRS4	22	GARCH(1,2)
SULA11	22	GARCH(1,2)
BRML3	66	GARCH(1,2)
AMIL3	132	GARCH(1,2)
BRML3	132	GARCH(1,2)
CZRS4	132	GARCH(1,2)
ECOD3	132	GARCH(1,2)
SULA11	132	GARCH(1,2)
TEMP3	132	GARCH(1,2)
BRML3	264	GARCH(1,2)
CZRS4	264	GARCH(1,2)
ECOD3	264	GARCH(1,2)
RDOD3	264	GARCH(1,2)
SLCE3	264	GARCH(1,2)

Para comparar os modelos sob a ótica de previsão, foi considerado o número de observações para estimar os parâmetros dos modelos. As previsões foram feitas sempre um passo a frente. Esse procedimento foi repetido diversas vezes até a série não possuir mais informações para serem comparadas. Ou seja, tomando a série CZRS4 com N=22 como exemplo:

- ✓ O total de informações da base é de 297 informações de retornos diários.
- ✓ Considerando que 22 observações serão sempre utilizadas para estimar os parâmetros e 1 será sempre utilizada para previsão, tem-se um total de $297-22=275$ previsões um passo a frente.

Ativo	Quantidade de informações disponíveis	Quantidade de previsões um passo a frente realizadas quando o tamanho da série é:			
		22	66	132	264
AMIL3	213	191	147	81	0
BRML3	352	330	286	220	88
CZRS4	297	275	231	165	33
ECOD3	443	421	377	311	179
HYPE3	96	74	30	0	0
PINE4	355	333	289	223	91
RD3D3	287	265	221	155	23
SLCE3	303	281	237	171	39
SULA11	227	205	161	95	0
TEMP3	192	170	126	60	0

A comparação das previsões realizadas um passo a frente foi obtida através da estatística Raiz do Erro Quadrático Médio de Previsão (REQMP), definida como:

$$REQMP(h) = \sqrt{\frac{1}{n} \sum_{i=1}^n (h_i - u_i^2)^2}$$

onde:

n é o número de previsões realizadas

h_i é a estimativa da variância condicional no instante i

u_i^2 é o quadrado dos retornos no instante i , corrigido pela média

A Tabela 38 mostra a comparação das previsões utilizando os modelos identificados com as metodologias pelo critério REQMP. A REQMP dos modelos

selecionados pelo sistema que utilizou a Rede Neural *Feedforward* foi menor em 10 das 14 séries testadas, igual em 3 séries e maior em apenas uma.

Tabela 38: Comparação das Previsões dos Modelos Identificados pela estatística REQM

Ativo	obs	REQMP AIC	REQMP BIC	REQMP RN
CZRS4	22	0,362%	0,362%	0,297%
SULA11	22	0,425%	0,425%	0,403%
BRML3	66	0,496%	0,496%	0,466%
AMIL3	132	0,819%	0,819%	0,800%
BRML3	132	0,598%	0,598%	0,592%
CZRS4	132	0,618%	0,618%	0,628%
ECOD3	132	0,561%	0,561%	0,558%
SULA11	132	0,824%	0,827%	0,812%
TEMP3	132	1,045%	1,045%	1,025%
BRML3	264	0,998%	0,998%	0,983%
CZRS4	264	1,447%	1,471%	1,447%
ECOD3	264	0,775%	0,775%	0,775%
RDCD3	264	1,878%	1,878%	1,863%
SLCE3	264	1,446%	1,458%	1,446%

Esse resultado pode ser facilmente interpretado em conjunto com os resultados do caso com séries simuladas. O método AIC apresentou um maior erro quando o modelo gerador das séries era o GARCH(1,2). Nesse experimento, todos os modelos escolhidos pelo sistema proposto foram GARCH(1,2), o que pode ser um indício de que o AIC tenha errado.

Como outra comparação entre os métodos de identificação, aplicou-se o teste de McLeod-Li nos resíduos para se testar se a dependência não linear foi completamente retirada. Conforme a Tabela 38, das 14 séries testadas, em apenas três delas os modelos identificados pelo AIC foram capazes de retirar a

dependência quadrática. Já os modelos identificados pelo BIC foram capazes de retirar a dependência quadrática de apenas uma série. Em contrapartida, os modelos identificados pela rede neural foram capazes de retirar a dependência quadrática em 11 das 14 séries testadas.

Tabela 38: Teste McLeod-Li para os Resíduos dos Modelos Identificados

Ativo	obs	H ₀ AIC	H ₀ BIC	H ₀ RN
CZRS4	22	Rejeita	Rejeita	Rejeita
SULA11	22	Rejeita	Rejeita	Aceita
BRML3	66	Rejeita	Rejeita	Aceita
AMIL3	132	Rejeita	Rejeita	Aceita
BRML3	132	Rejeita	Rejeita	Aceita
CZRS4	132	Rejeita	Rejeita	Aceita
ECOD3	132	Rejeita	Rejeita	Aceita
SULA11	132	Rejeita	Rejeita	Rejeita
TEMP3	132	Rejeita	Rejeita	Rejeita
BRML3	264	Rejeita	Rejeita	Aceita
CZRS4	264	Aceita	Rejeita	Aceita
ECOD3	264	Aceita	Aceita	Aceita
RDCD3	264	Rejeita	Rejeita	Aceita
SLCE3	264	Aceita	Rejeita	Aceita

Portanto, com esses dois estudos de caso, conclui-se que o sistema proposto efetivamente melhora o desempenho da identificação correta do modelo a ser usado, e, por consequência, melhora a previsão das séries a serem modeladas e retira a dependência quadrática dessas séries.