

## Referências Bibliográficas

- [1] ANDERSEN, T.G., T. BOLLERSLEV, F.X. DIEBOLD and H. EBENS. **The distribution of realized stock return volatility.** Journal of Financial Economics, 61, 43 – 76, 2001.
- [2] BLACK, F. **Noise.** Journal of Finance, 41, 529 – 543, 1976.
- [3] BOLLERSLEV, T.. **Generalized autoregressive conditional heteroscedasticity.** Journal of Econometrics, 31, 307–327, 1986.
- [4] BREIMAN, L.; FRIEDMAN, J.; OLSHEN, R.; STONE, C. J.. **Classification and Regression Trees.** Belmont Wadsworth Int. Group, New York, 1984.
- [5] CHAN, K.; TONG, H.. **On estimating thresholds in autoregressive models.** Journal of Time Series Analysis, 7, 179–190, 1986.
- [6] CORRÊA DA ROSA J., VEIGA, A., AND MEDEIROS, M. **Tree structured smooth transition regression models.** Computational Statistics and Data Analysis, 52, 2469-2488, 2008.
- [7] CORRÊA DA ROSA, J., RAMOS, G., AND VEIGA, A. **Application of STAR-Tree Model to Brazilian Stock Market Time Series.** Working Paper do DEE, Puc-Rio, Apr 2005.
- [8] CORRÊA DA ROSA, J.. **Modelos de Regressão com Transição Suave Estruturados por Árvores.** 157p. PhD. Thesis, Puc-Rio, Departamento de Engenharia Elétrica, Rio de Janeiro, 2005.

- [9] COSTA, P.H. SOTO.. **Séries de Retornos de Ações Brasileiras: Volatilidade e Valor em Risco.** 175p. PhD. Thesis, Puc-Rio, Departamento de Engenharia Industrial, Rio de Janeiro, 2001.
- [10] DAVIES, R.. **Hypothesis testing when the nuisance parameter is present only under the alternative.** *Biometrika*, 64, 247–254, 1977.
- [11] DAVIES, R.. **Hypothesis testing when the nuisance parameter is present only under the alternative.** *Biometrika*, 74, 33–34, 1987.
- [12] DIEBOLD, F.X and MARIANO, R.S.. **Comparing predictive accuracy.** *Journal of Business and Economic Statistics*, 13, 253-263, 1995.
- [13] EITRHEIM, Ø.; TERÄSVIRTA, T. **Testing the adequacy of smooth transition autoregressive models.** *Journal of Econometrics*, 74, 59–75, 1996.
- [14] ENGLE, R.. **Autoregressive conditional heteroscedasticity.** *Econometrica*, 50, 987–1008, 1982.
- [15] GODFREY, L. G. **Misspecification Tests in Econometrics: the Lagrange Multiplier Principle and Other Approaches.** Cambridge University Press, 1988.
- [16] GRANGER, C.; TERÄSVIRTA, T.. **Modelling Nonlinear Economic Relationships.** Oxford University Press, Oxford, 1993.
- [17] HAMILTON, J.. **Time Series Analysis.** Princeton University Press, Princeton, 1994.
- [18] HARVEY, D., LEYBOURNE, S. and NEWBOLD, P.. **Testing de equality of prediction mean squared errors.** *International Journal of Forecasting*, 13, 281-291, 1997.

- [19] HILLEBRAND, E.; MEDEIROS, M. **Forecasting realized volatility models: the benefits of bagging and nonlinear specifications.** Texto para Discussão do Dept. de Economia, Puc-rio, 2007.
- [20] HORNIK, K.; STINCHOMBE, M.; WHITE, H.. **Multi-layer (feedforward) networks are universal approximators.** Neural Networks, 2, 359–366, 1989.
- [21] LEWIS, P.; STEVENS, J.. **Nonlinear modeling of time series using multivariate adaptative regression splines.** Journal of the American Statistical Association, 86, 864–877, 1991.
- [22] LUUKKONEN, R.; SAIKKONEN, R.; TERAÄSVIRTA, T.. **Testing linearity against smooth transition autoregressive models.** Biometrika, 75, 491–499, 1988.
- [23] MCALEER, M.; MEDEIROS, M. **Realized volatility: a review.** Econometric Reviews, 27, 10-45, 2008.
- [24] MEDEIROS, M. C., VEIGA, A. **A flexible coefficient smooth transition time series model.** IEEE Transactions on Neural Networks, 16, 97-113, 2005.
- [25] MEDEIROS, M. C., VEIGA, A. **Modeling multiple regimes in financial volatility with a flexible coefficient GARCH model.** Econometric Theory, to appear, 2008.
- [26] MEDEIROS, M.; VEIGA, A.. **A hybrid linear-neural model for time series forecasting.** IEEE Transactions on Neural Networks, 11, 1402–1412, 2000.
- [27] MEDEIROS, M.; VEIGA, A.. **Diagnostic checking in a flexible non-linear time series model.** Journal of Time Series Analysis, 24, 461–482, 2003.

- [28] MEDEIROS, M.; VEIGA, A.; PEDREIRA, E. **Modeling Exchange rates: smooth transition, neural networks, and linear models.** IEEE Transactions on Neural Networks, 12, 755-764, 2001.
- [29] MERTON, R.C. **On estimating the expected return on the market: an exploratory investigation.** Journal of Financial Economics, 8, 323 – 361, 1980.
- [30] PINTO, THIAGO REZENDE.. **Aplicação de Modelos Não Lineares em Negociação Automática no Mercado Acionário Brasileiro.** 76p. Dissertação de Mestrado, Puc-rio, Departamento de Engenharia Elétrica, Rio de Janeiro, 2006.
- [31] ROSENBLAT, F.. **A comparison of several perceptron models.** In: Books, S., editor, SELF-ORGANIZING SYSTEMS, volumen 1. Spartan Books, Washington D.C., 1962.
- [32] SCHARTH, M.; MEDEIROS, M. **Asymmetric effects and long memory in the volatility of Dow Jones stocks.** Texto para Discussão do Dept. de Economia, Puc-rio, 2006.
- [33] TAYLOR, S. **Modelling Financial Time Series.** John Wiley, Chichester, UK, 1986.
- [34] TERÄSVIRTA, T.. **Specification, estimation, and evaluation of smooth transition autoregressive models.** Journal of the American Statistical Association, 89, 208-218, 1994.
- [35] TONG, H. **Non-linear Time Series: A Dynamical System Approach.** Oxford University Press, 1990.

- [36] TONG, H.. **On a threshold model**. In: Chen, C, H., editor, In *Pattern Recognition and Signal Processing*, volumen 5. Sijhoff Noordhoff, Amsterdam, 1978.
- [37] VAN DIJK, D.; FRANSES, P.. **Modelling multiple regimes in the business cycle**. *Macroeconomic Dynamics*, 3:311–340, 1999.
- [38] VAN DIJK, D.; T.TERÄSVIRTA ; FRANSES, P.. **Smooth transition autoregressive models - A survey of recent developments**. *Econometric Reviews*, 21, 1-47, 2002.
- [39] ZADEH, L.. **Fuzzy sets**. *Information and Control*, 8, 338–353, 1965.
- [40] Análise Técnica e Indicadores Financeiros. Disponíveis em:  
<http://www.investmax.com.br/im/content.asp?contentid=657> e  
<http://www.investmax.com.br/im/content.asp?contentid=659>. Acessado em julho/2008.

## A Detalhamento do Teste de Harvey, Leybourne e Newbold (1997)

Considere duas previsões  $\{\hat{y}_{it}\}_{t=1}^T, i = 1, 2, h$  passos à frente que geraram erros  $e_{1t}$  e  $e_{2t}, t = 1, \dots, T$ . A qualidade da previsão será julgada a partir de uma função específica  $g(e)$  do erro de previsão  $e$  (“*loss function*”). A hipótese nula de igualdade de performance preditiva é

$$E[g(e_{1t}) - g(e_{2t})] = 0 \quad (\text{A.1})$$

Define-se

$$d_t = g(e_{1t}) - g(e_{2t}); t = 1, \dots, T \quad (\text{A.2})$$

É natural basear o teste na média amostral de  $d_t$ , definida como

$$\bar{d} = \frac{1}{T} \sum_{t=1}^T d_t \quad (\text{A.3})$$

É esperado que a série  $d_t$  seja autocorrelatada. Neste caso, assume-se que todas as autocorrelações de ordem maior ou igual a  $h$  são zero. Assim, mostra-se que a variância de  $\bar{d}$  é assintoticamente

$$V(\bar{d}) \approx \frac{1}{T} \left[ \gamma_0 + 2 \sum_{k=1}^{h-1} \gamma_k \right] \quad (\text{A.4})$$

onde  $\gamma_k$  é a  $k$ -ésima autocovariância de  $d_t$ . Essa autocovariância pode ser estimada por

$$\hat{\gamma}_k = \frac{1}{T} \sum_{t=k+1}^T (d_t - \bar{d})(d_{t-k} - \bar{d}) \quad (\text{A.5})$$

A estatística do teste de Diebold e Mariano (1995) é dada por

$$S_1 = [\hat{V}(\bar{d})]^{-1/2} \bar{d} \quad (\text{A.6})$$

onde  $\hat{V}(\bar{d})$  é obtida substituindo as estimativas (A.5) em (A.4). Sob a hipótese nula, essa estatística segue uma distribuição normal.

O teste modificado de Harvey, Leybourne e Newbold (1997) é baseado no uso de um estimador da variância de  $\bar{d}$  aproximadamente não viesado. Os autores mostram que empregando este estimador, chega-se à seguinte estatística

$$S_1^* = \left[ \frac{T + 1 - 2h + T^{-1}h(h-1)}{T} \right]^{1/2} S_1 \quad (\text{A.7})$$

onde  $S_1$  é a estatística original (A.6).

Sob a hipótese nula, a estatística  $S_1^*$  da equação (A.7) segue uma distribuição t de Student com  $T-1$  graus de liberdade. A hipótese alternativa é que os erros do modelo são menores que os da referência.

Na Seção (5.3.3), o teste de Harvey, Leybourne e Newbold (1997) foi aplicado para duas funções  $g(e)$ :

$$g(e_{it}) = |e_{it}| \quad (\text{A.8})$$

e

$$g(e_{it}) = e_{it}^2 \quad (\text{A.9})$$

para os casos de erro absoluto, e erro quadrático, respectivamente, onde

$$e_{it} = y_{it} - \hat{y}_{it} \quad (\text{A.10})$$

Como estamos tratando de séries financeiras, o maior interesse são os resultados financeiros que o modelo gera no caso da aplicação no mercado. Como não há restrições na construção da função  $g(e)$  utilizada na construção do teste, o teste de Harvey, Leybourne e Newbold (1997) também foi aplicado para uma função de perda financeira ao invés de uma função do erro de previsão.

Desta forma, define-se

$$g(\hat{y}_{it}) = \begin{cases} 0; & \text{se } \hat{y}_{it} \leq 0 \\ y_{it}; & \text{se } \hat{y}_{it} > 0 \end{cases} \quad (\text{A.11})$$

O teste é construído de forma análoga à descrita anteriormente, substituindo  $g(e_{it})$  de (A.8) e (A.9) por  $g(\hat{y}_{it})$  de (A.11) nas equações (A.1) e (A.2).

Como  $\hat{y}_{it}$  é a previsão dos retornos das ações gerada pelo modelo  $i$ ,  $g(\hat{y}_{it})$  é um vetor com os retornos observados após as transações de compra e venda, determinadas pelo sinal da previsão  $i$ . Neste caso, o teste é construído de forma inversa, já que a hipótese alternativa é que os retornos do modelo são maiores que os da referência.

# A1

## Anexo 1

Ação	Período	Média	Variância	Assimetria	Curtose	JB	p-valor
AA	<i>in-sample</i>	-54.36	4695.57	-2.54	13.58	12472.59	0.00
	<i>out-of-sample</i>	-5.34	280.70	-1.02	4.90	174.20	0.00
AIG	<i>in-sample</i>	-69.54	2097.37	-0.91	4.74	572.19	0.00
	<i>out-of-sample</i>	-62.12	3146.78	-2.11	14.65	3451.24	0.00
AXP	<i>in-sample</i>	-27.48	4314.55	-1.50	5.13	1229.94	0.00
	<i>out-of-sample</i>	12.42	1010.10	-1.47	3.68	206.30	0.00
BA	<i>in-sample</i>	-61.89	3728.55	-0.95	4.99	686.21	0.00
	<i>out-of-sample</i>	-17.34	1188.73	-0.10	2.43	8.50	0.01
CAT	<i>in-sample</i>	-59.98	4767.21	-1.58	6.56	2051.23	0.00
	<i>out-of-sample</i>	-140.26	11548.41	-0.81	3.61	66.89	0.00
DD	<i>in-sample</i>	-57.89	4737.47	-2.59	13.71	12799.19	0.00
	<i>out-of-sample</i>	-51.11	3183.77	-1.68	7.55	716.39	0.00
DIS	<i>in-sample</i>	-46.69	2006.75	-0.53	3.16	102.95	0.00
	<i>out-of-sample</i>	-12.50	782.34	-0.74	2.67	52.55	0.00
GE	<i>in-sample</i>	-45.48	5993.73	-2.13	8.36	4245.42	0.00
	<i>out-of-sample</i>	-5.74	554.24	-0.84	4.19	95.17	0.00
GM	<i>in-sample</i>	-75.02	4107.58	-1.87	7.74	3296.19	0.00
	<i>out-of-sample</i>	-77.36	6325.95	-5.86	53.66	60806.71	0.00
HD	<i>in-sample</i>	-58.41	3054.75	-0.09	2.22	59.03	0.00
	<i>out-of-sample</i>	-18.79	1900.32	-0.98	2.88	87.63	0.00
HOM	<i>in-sample</i>	-44.53	4265.68	-1.02	3.37	385.41	0.00
	<i>out-of-sample</i>	2.12	1081.96	-1.32	3.35	159.77	0.00
IBM	<i>in-sample</i>	-45.12	4647.27	-1.42	4.29	875.97	0.00
	<i>out-of-sample</i>	-7.63	1425.61	-1.55	3.87	234.36	0.00
JNJ	<i>in-sample</i>	-77.10	1825.18	-1.09	5.14	843.87	0.00
	<i>out-of-sample</i>	-98.07	3154.80	-0.82	2.99	60.24	0.00
JPM	<i>in-sample</i>	-34.89	5409.89	-3.10	21.62	34885.91	0.00
	<i>out-of-sample</i>	0.35	1320.03	-0.97	3.02	84.51	0.00
KO	<i>in-sample</i>	-43.68	5491.51	-3.29	22.79	39377.88	0.00
	<i>out-of-sample</i>	0.80	519.82	-1.58	5.87	408.91	0.00
MCD	<i>in-sample</i>	-54.56	5379.90	-3.20	21.96	36265.92	0.00
	<i>out-of-sample</i>	-19.21	1313.78	-2.72	16.46	4740.48	0.00
MMM	<i>in-sample</i>	-63.12	3929.52	-4.14	36.05	105095.22	0.00
	<i>out-of-sample</i>	-93.08	4758.77	-2.03	11.28	1908.94	0.00
MO	<i>in-sample</i>	-32.91	1686.64	-1.57	6.33	1897.05	0.00
	<i>out-of-sample</i>	-8.56	386.32	0.19	2.33	13.64	0.00
MRK	<i>in-sample</i>	-19.59	6027.27	-1.99	6.92	2825.79	0.00
	<i>out-of-sample</i>	20.14	1362.71	-5.29	49.88	51957.44	0.00
PFE	<i>in-sample</i>	-67.51	3961.69	-0.91	3.55	326.31	0.00
	<i>out-of-sample</i>	-23.13	1403.31	-1.19	3.16	128.70	0.00
PG	<i>in-sample</i>	-60.50	1375.56	-0.96	4.80	625.19	0.00
	<i>out-of-sample</i>	-35.30	654.28	1.29	3.06	149.80	0.00
UTX	<i>in-sample</i>	-37.38	3545.22	-0.77	3.04	214.78	0.00
	<i>out-of-sample</i>	4.49	1331.89	-1.05	3.00	100.25	0.00
WMT	<i>in-sample</i>	-58.18	4486.24	-2.61	14.83	15128.18	0.00
	<i>out-of-sample</i>	-44.56	1047.85	-2.19	18.72	5983.69	0.00

Tabela A1.1: Estatísticas dos Resíduos das Redes Neurais

## A2 Anexo 2

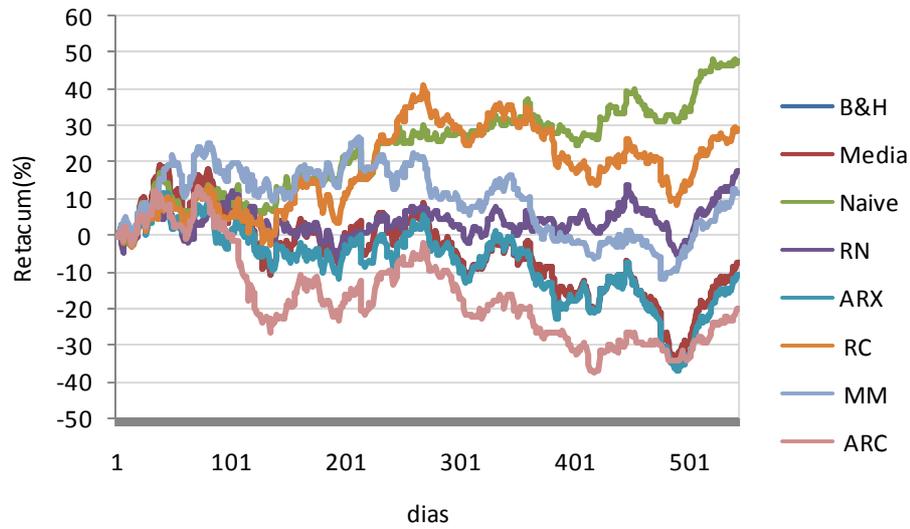


Figura A2.1: Gráfico do Retorno Acumulado AA

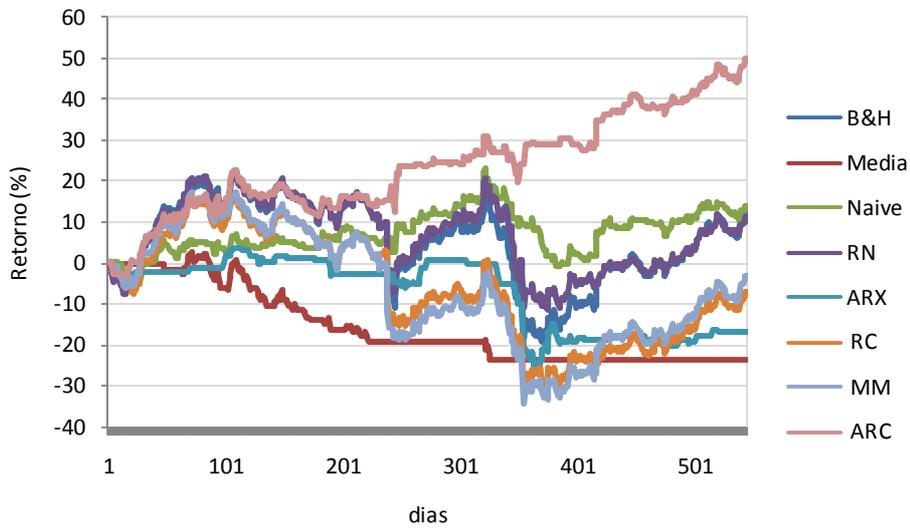


Figura A2.2: Gráfico do Retorno Acumulado AIG

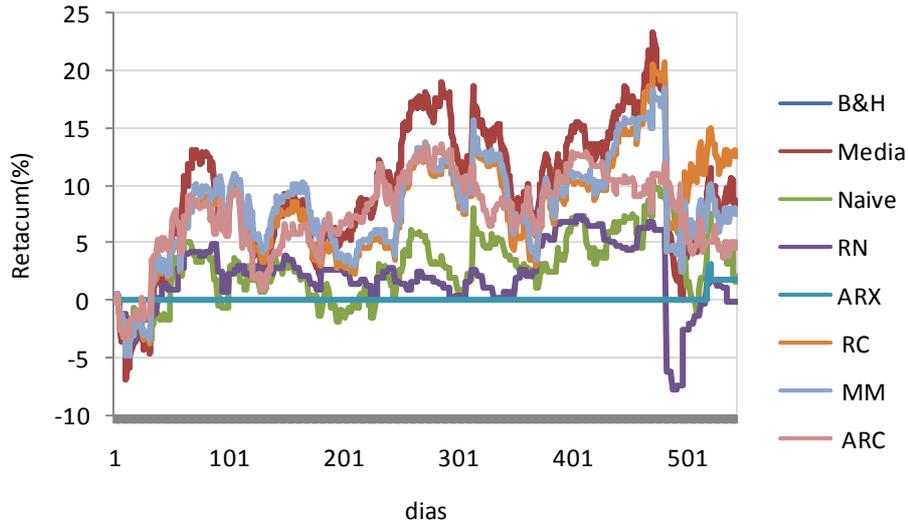


Figura A2.3: Gráfico do Retorno Acumulado AXP

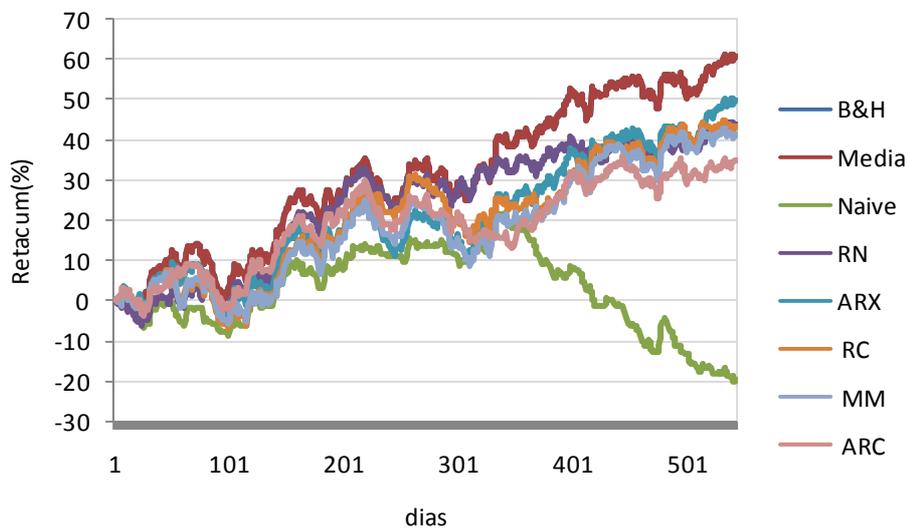


Figura A2.4: Gráfico do Retorno Acumulado BA

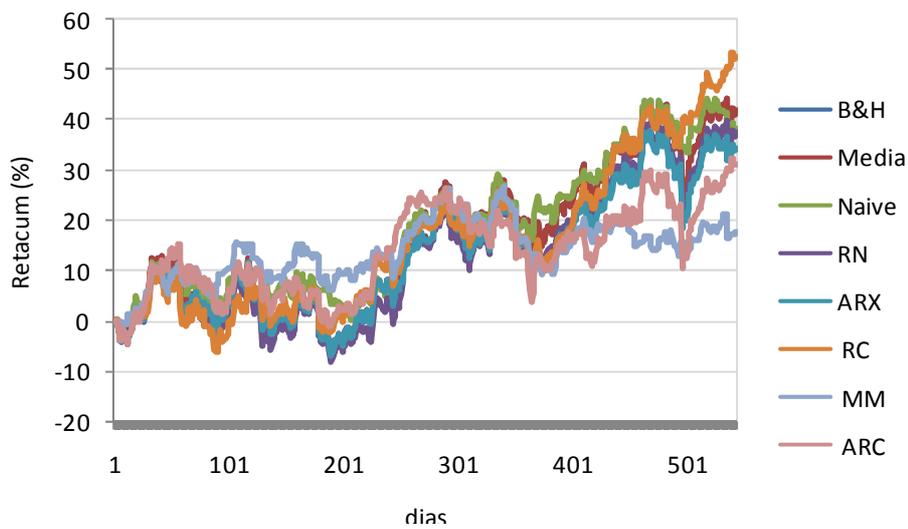


Figura A2.5: Gráfico do Retorno Acumulado CAT

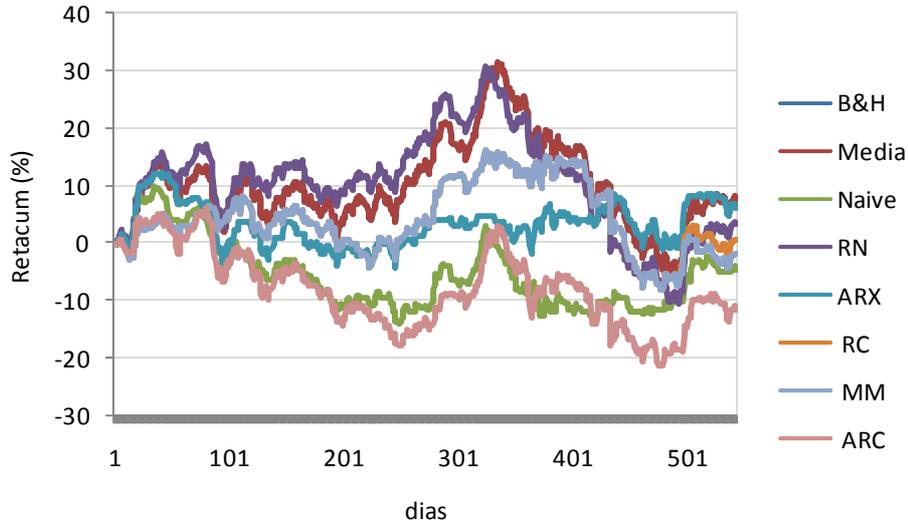


Figura A2.6: Gráfico do Retorno Acumulado DD

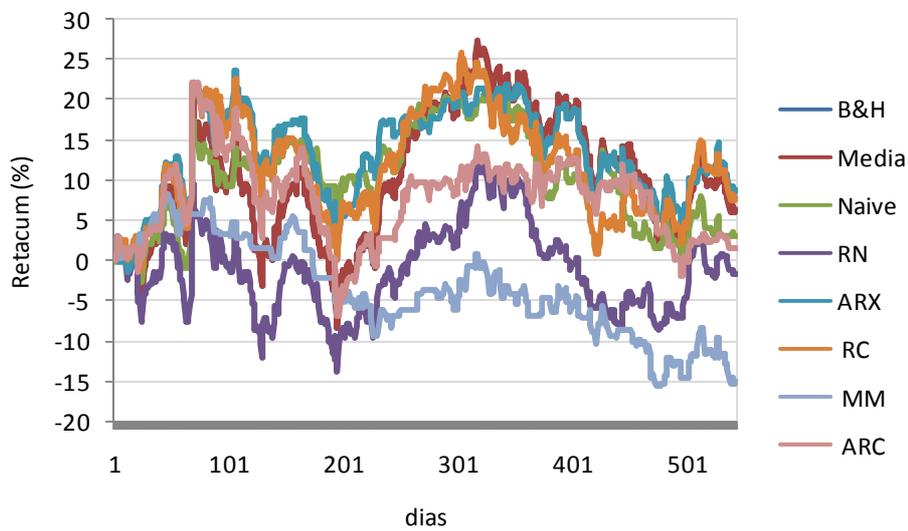


Figura A2.7: Gráfico do Retorno Acumulado DIS

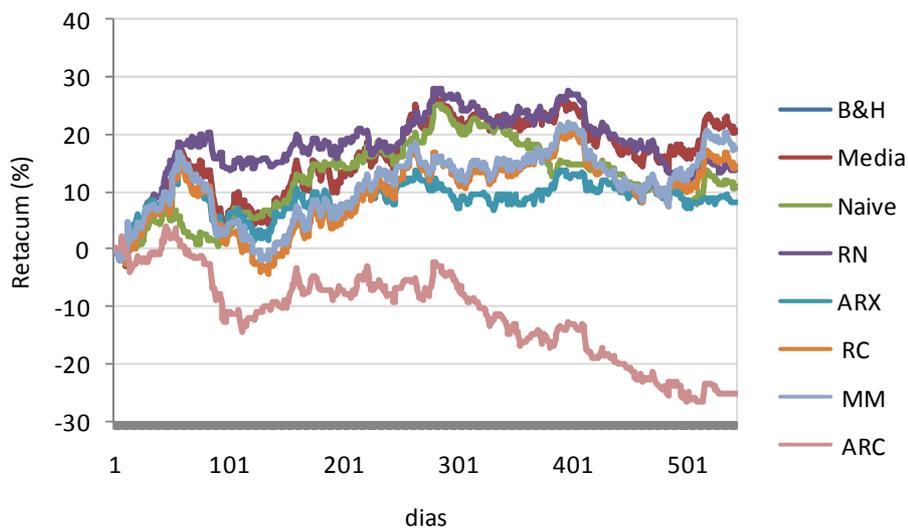


Figura A2.8: Gráfico do Retorno Acumulado GE

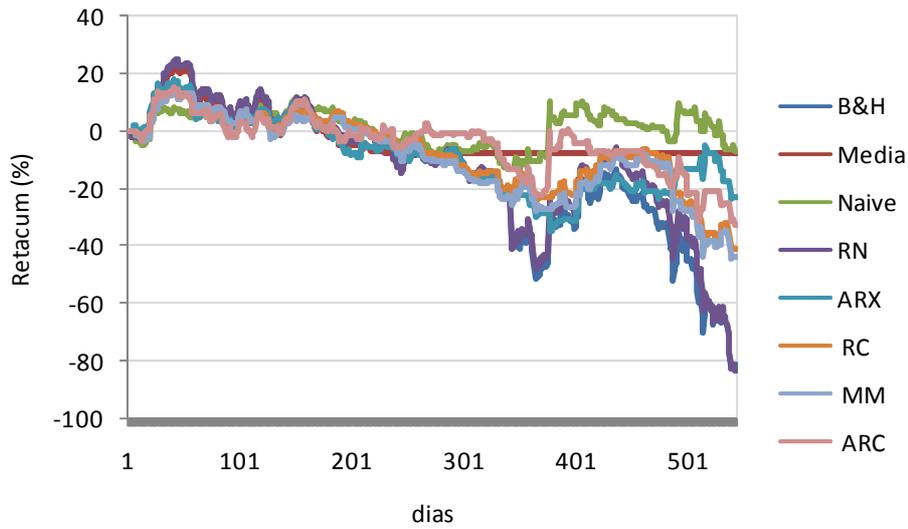


Figura A2.9: Gráfico do Retorno Acumulado GM

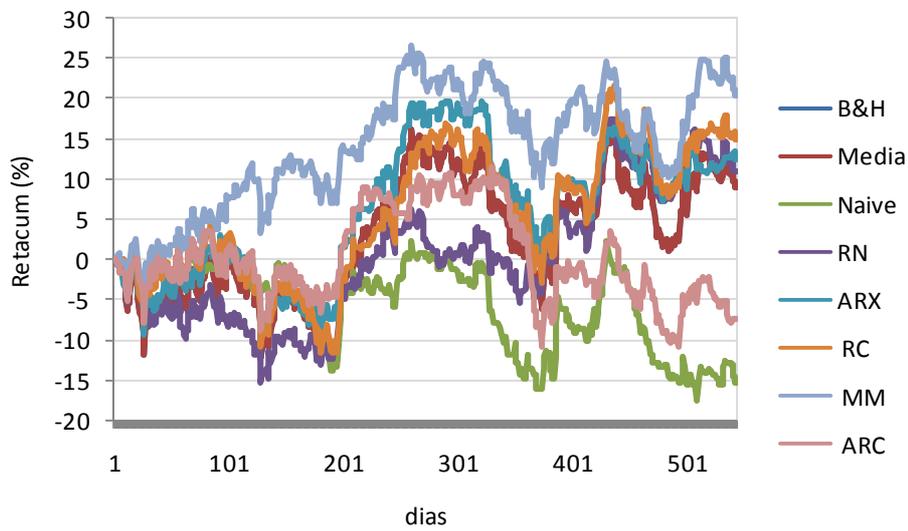


Figura A2.10: Gráfico do Retorno Acumulado HD

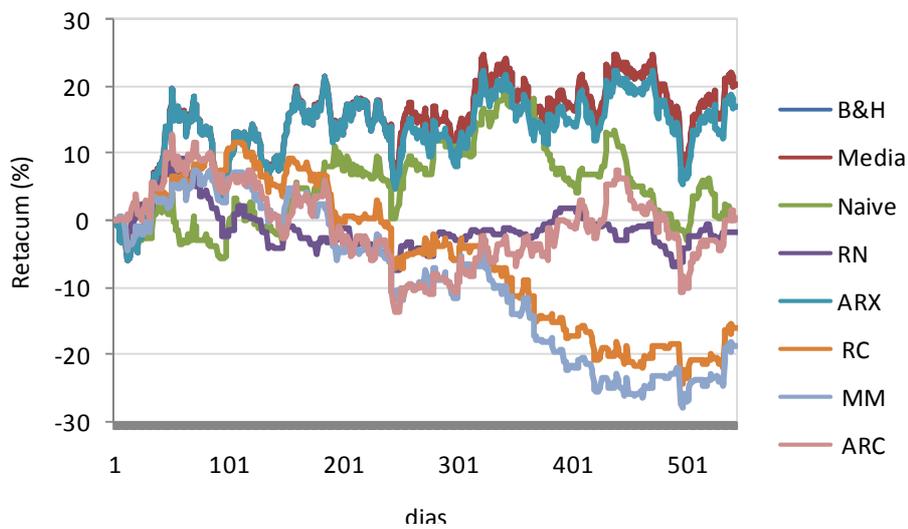


Figura A2.11: Gráfico do Retorno Acumulado HOM

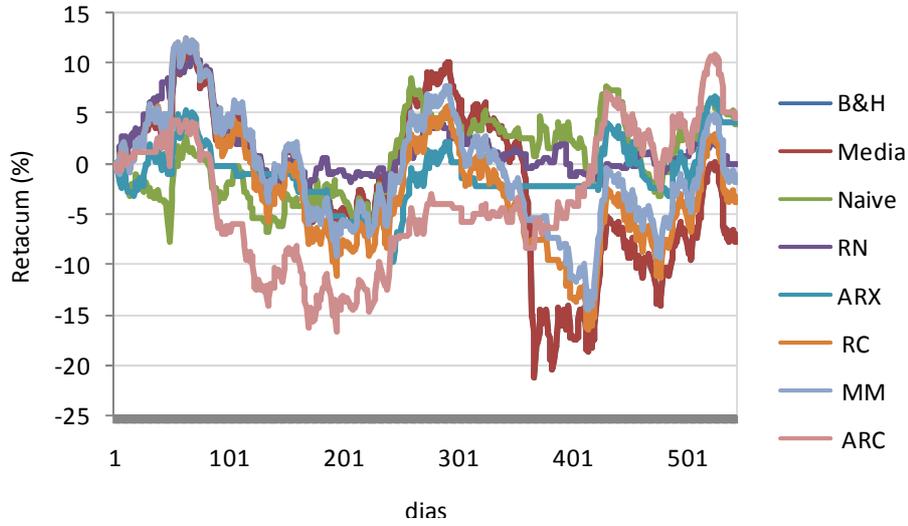


Figura A2.12: Gráfico do Retorno Acumulado IBM

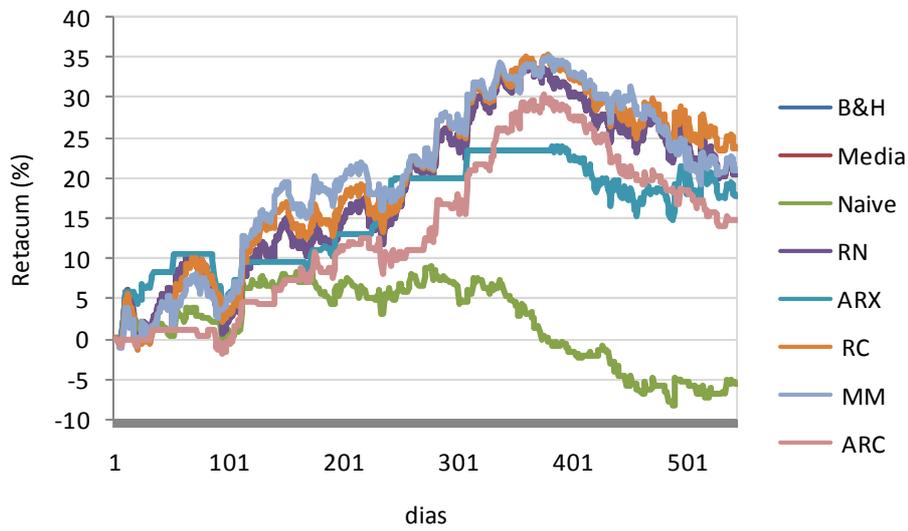


Figura A2.13: Gráfico do Retorno Acumulado JNJ

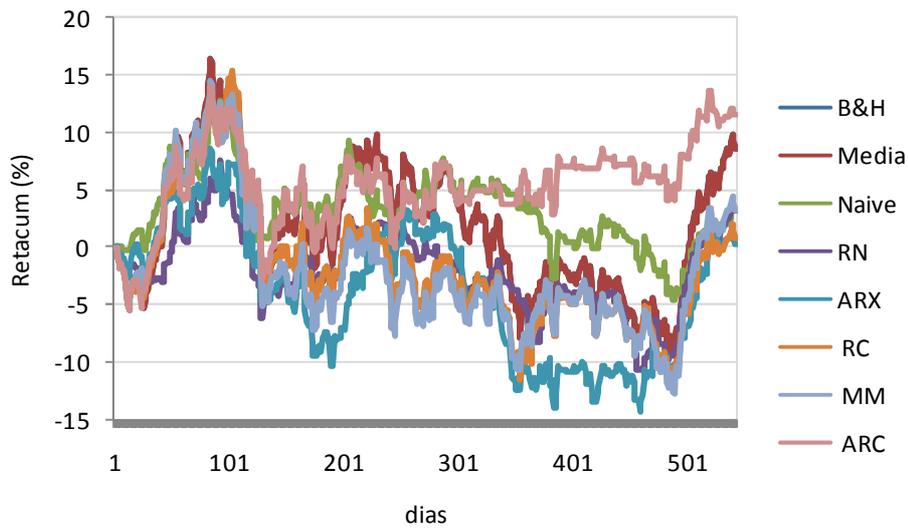


Figura A2.14: Gráfico do Retorno Acumulado JPM

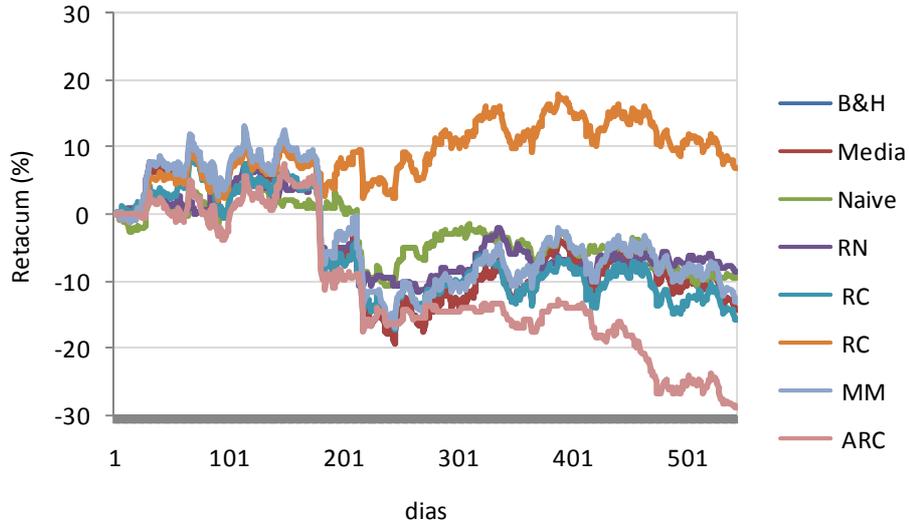


Figura A2.15: Gráfico do Retorno Acumulado KO

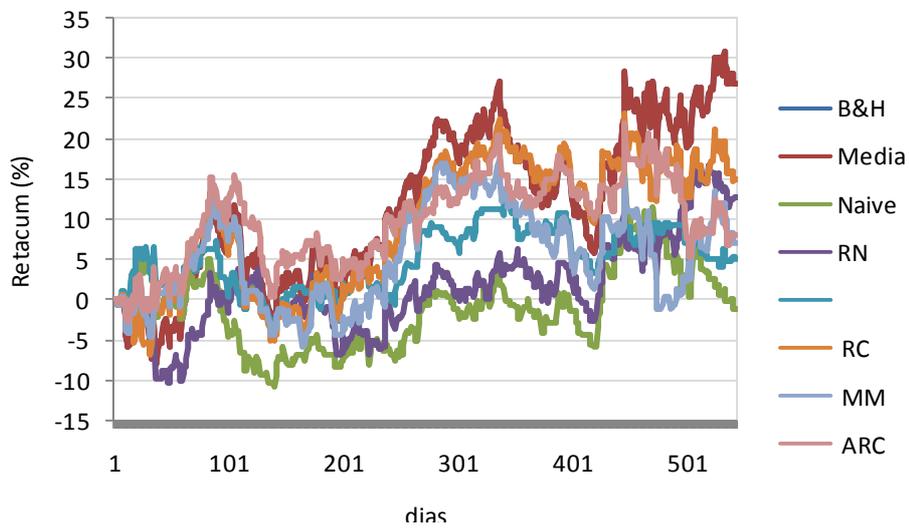


Figura A2.16: Gráfico do Retorno Acumulado MCD

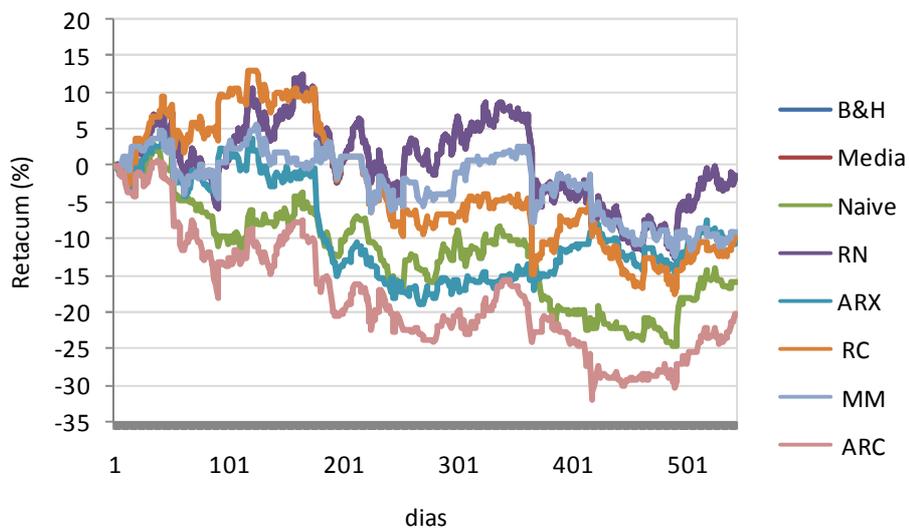


Figura A2.17: Gráfico do Retorno Acumulado MMM

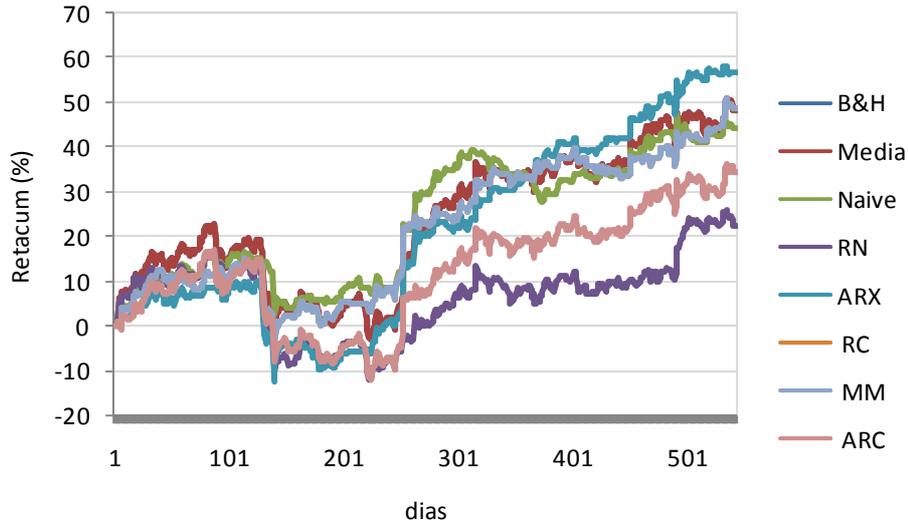


Figura A2.18: Gráfico do Retorno Acumulado MO

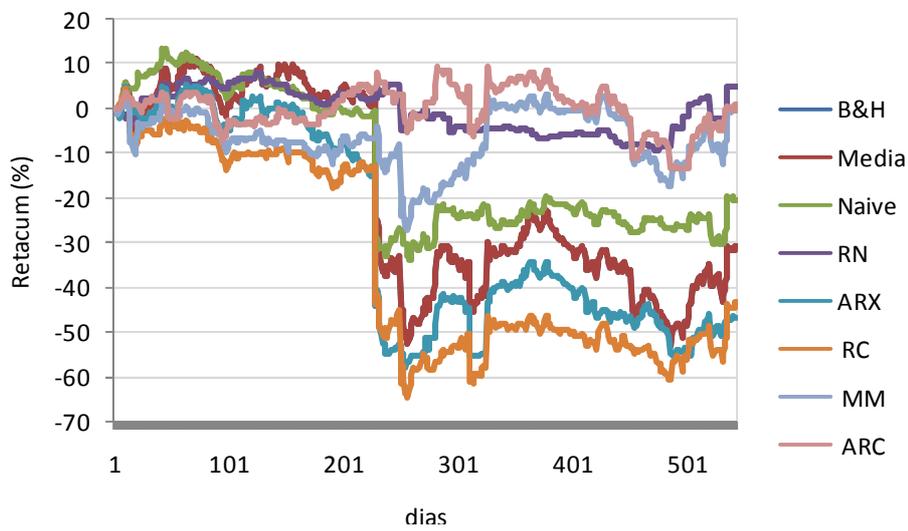


Figura A2.19: Gráfico do Retorno Acumulado MRK

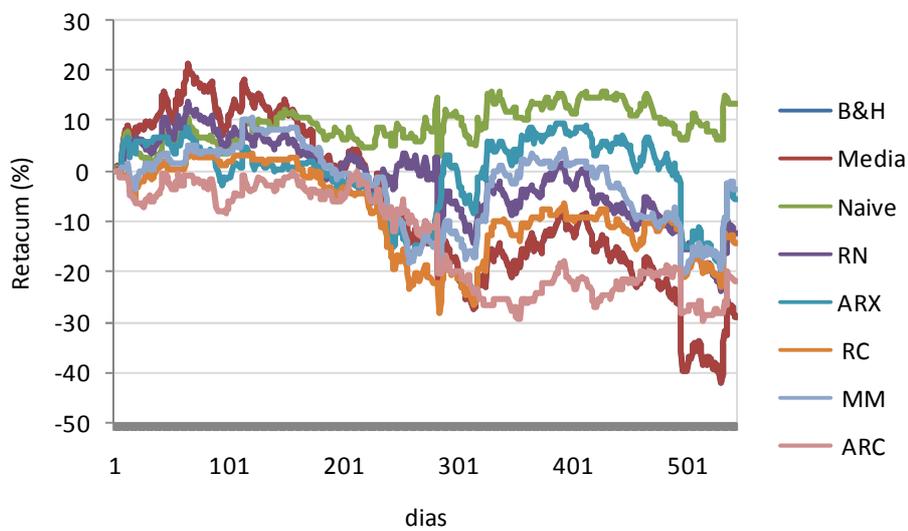


Figura A2.20: Gráfico do Retorno Acumulado PFE

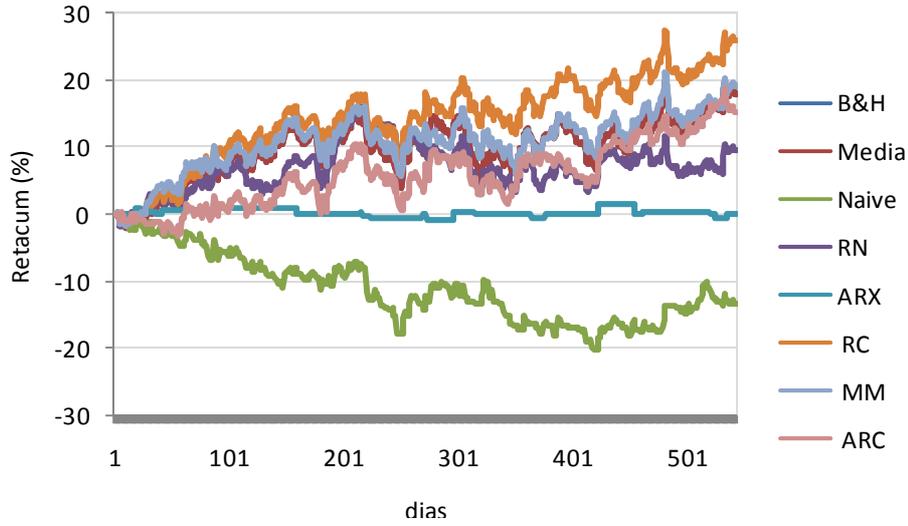


Figura A2.21: Gráfico do Retorno Acumulado PG

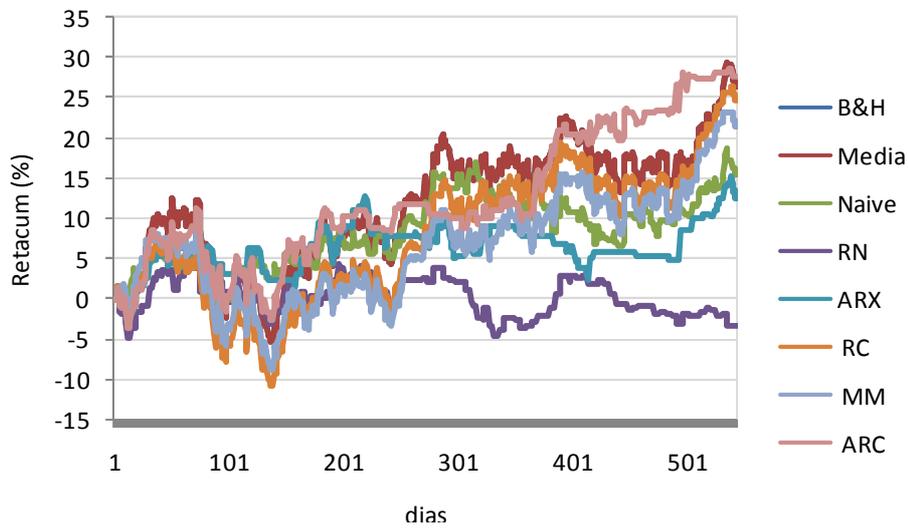


Figura A2.22: Gráfico do Retorno Acumulado UTX

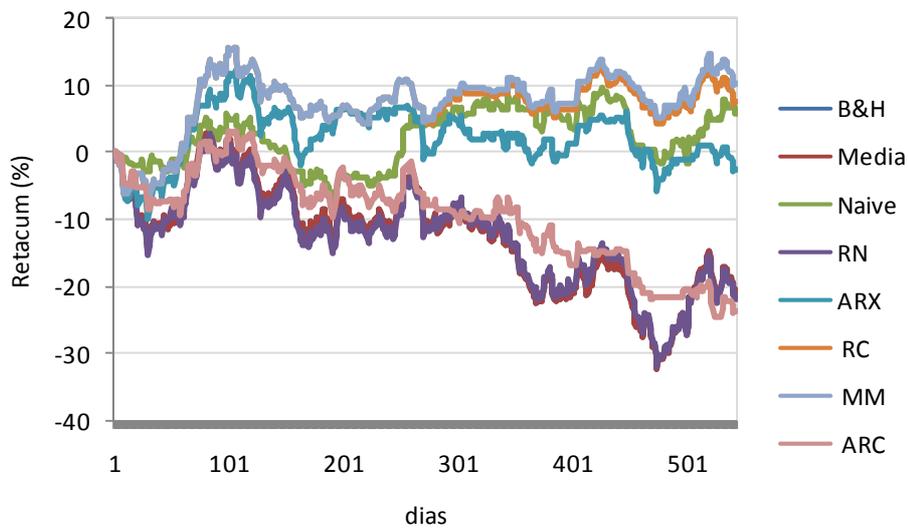


Figura A2.23: Gráfico do Retorno Acumulado WMT

**A3**  
**Anexo 3**

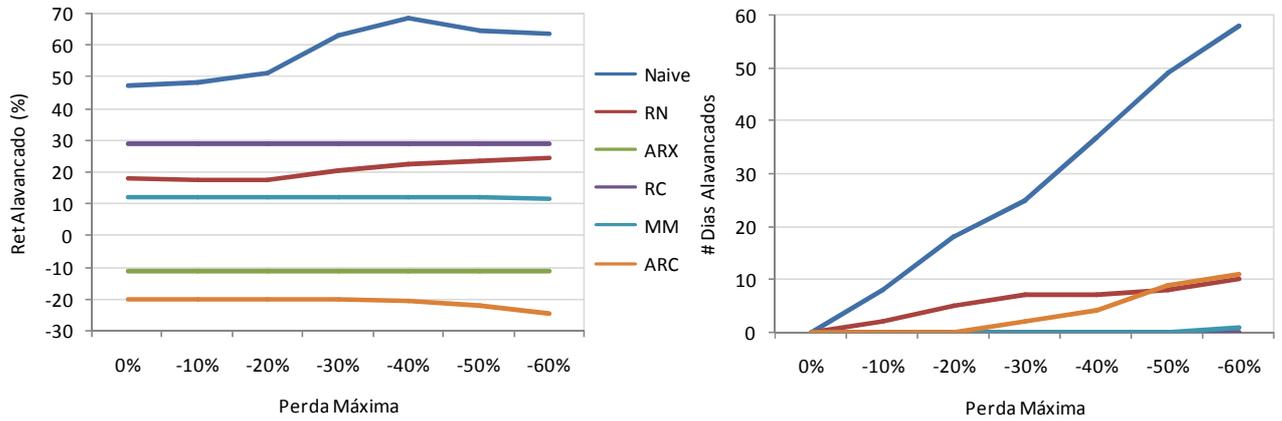


Figura A3.1: Retorno alavancado acumulado e Núm de Dias Alavancados AA

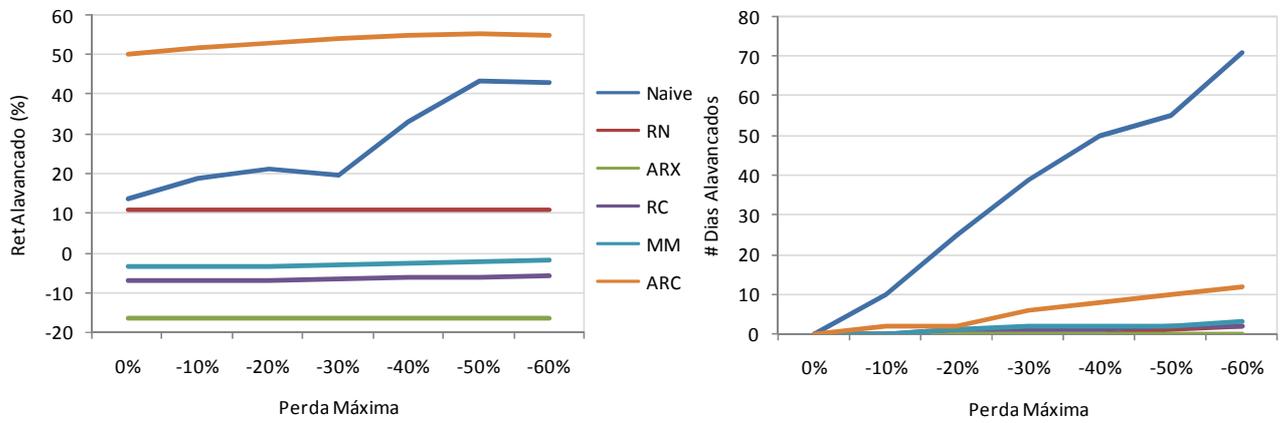


Figura A3.2: Retorno alavancado acumulado e Núm de Dias Alavancados AIG

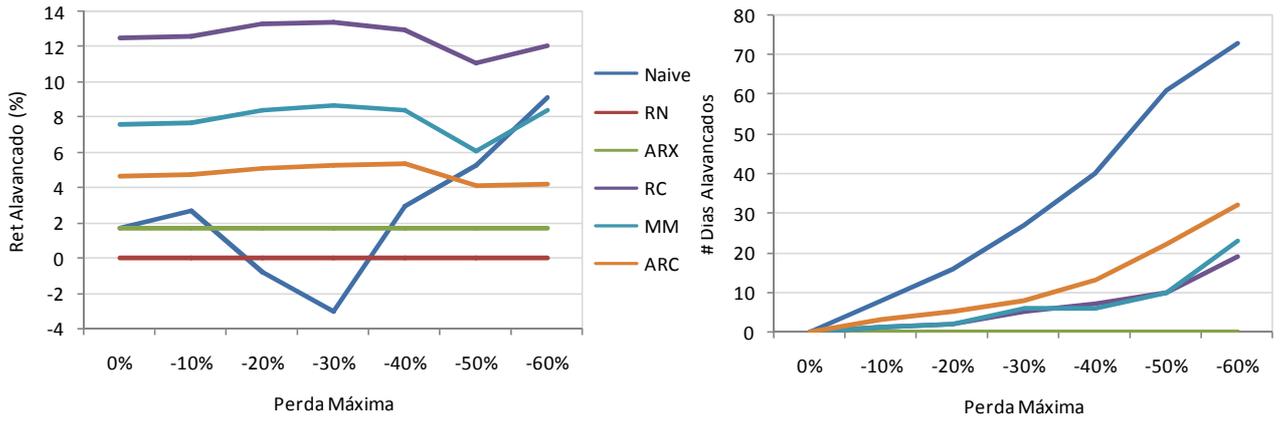


Figura A3.3: Retorno alavancado acumulado e Núm de Dias Alavancados AXP

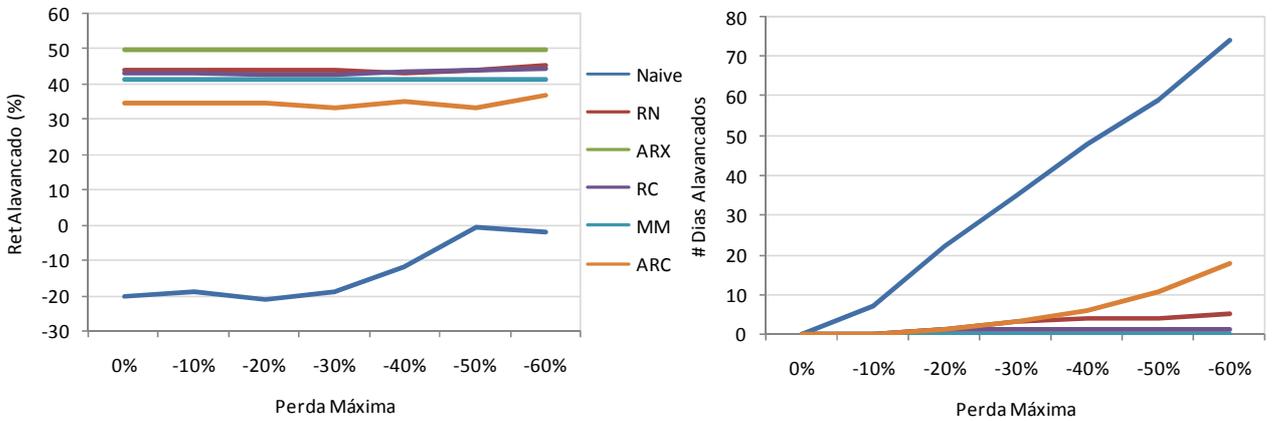


Figura A3.4: Retorno alavancado acumulado e Núm de Dias Alavancados BA

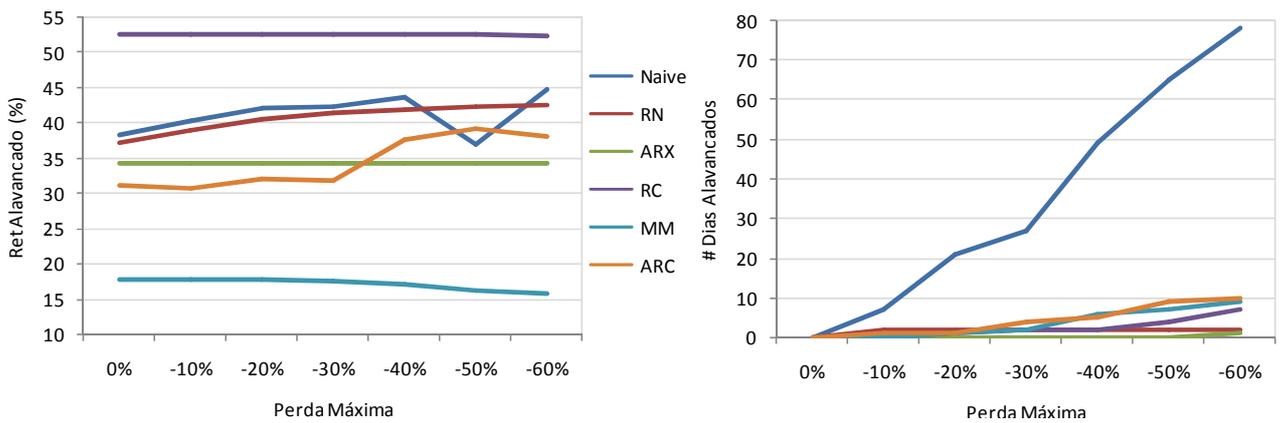


Figura A3.5: Retorno alavancado acumulado e Núm de Dias Alavancados CAT

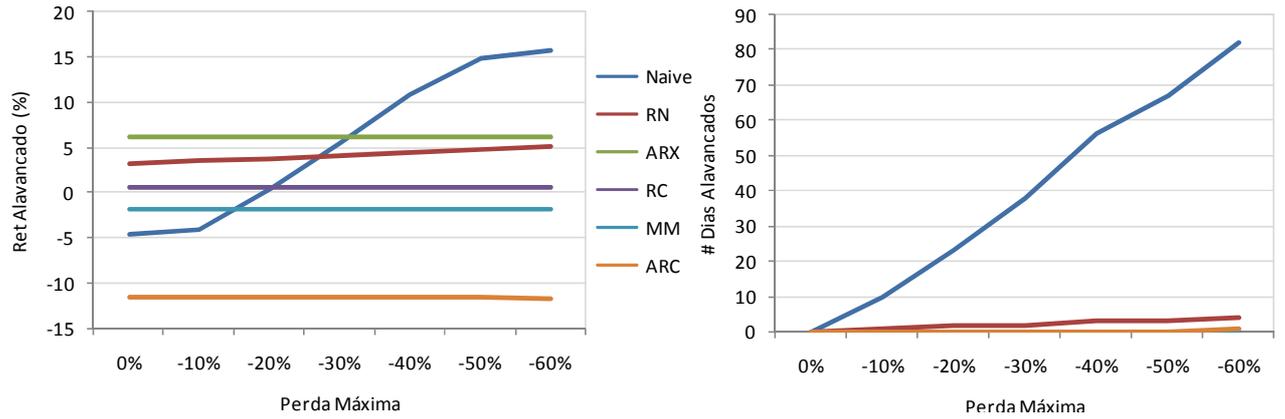


Figura A3.6: Retorno alavancado acumulado e Núm de Dias Alavancados DD

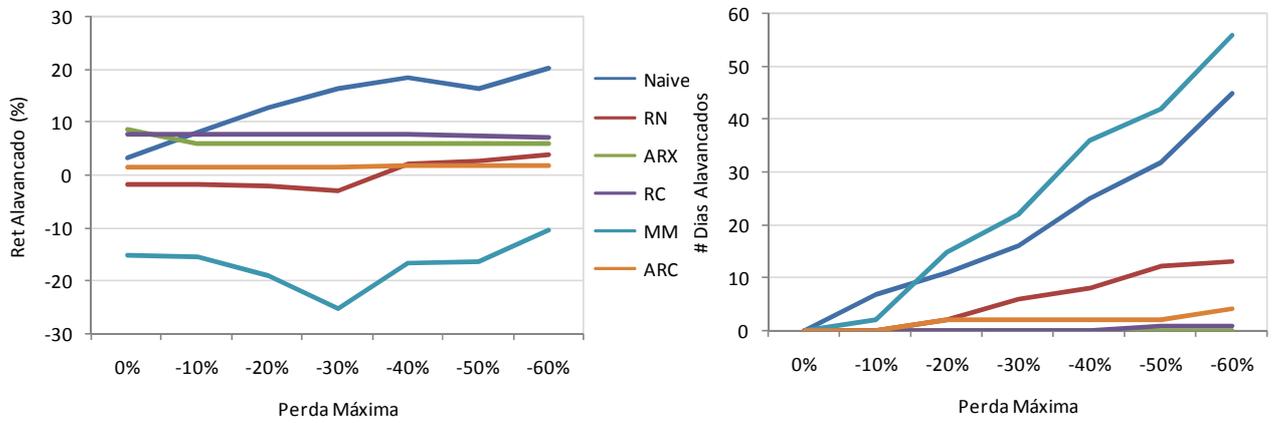


Figura A3.7: Retorno alavancado acumulado e Núm de Dias Alavancados DIS

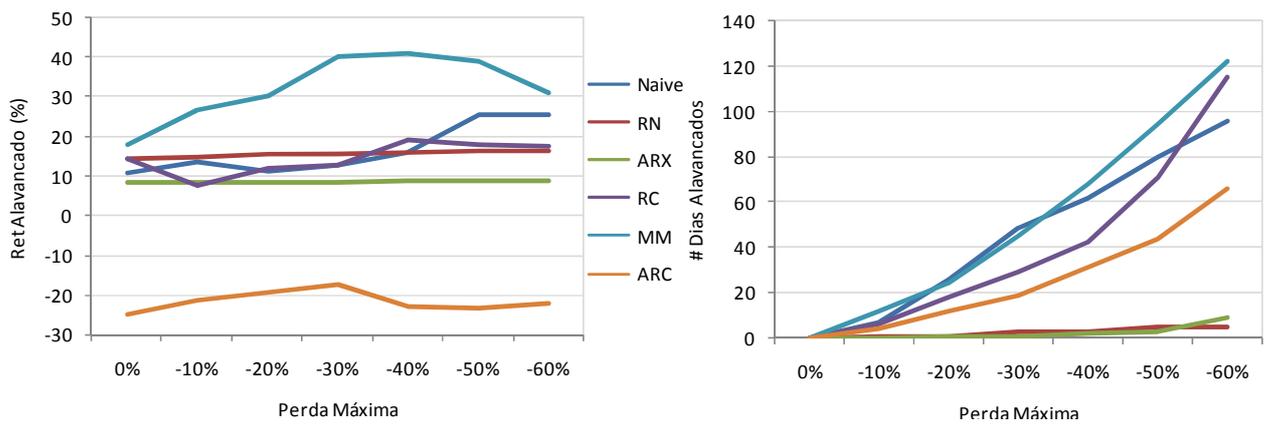


Figura A3.8: Retorno alavancado acumulado e Núm de Dias Alavancados GE

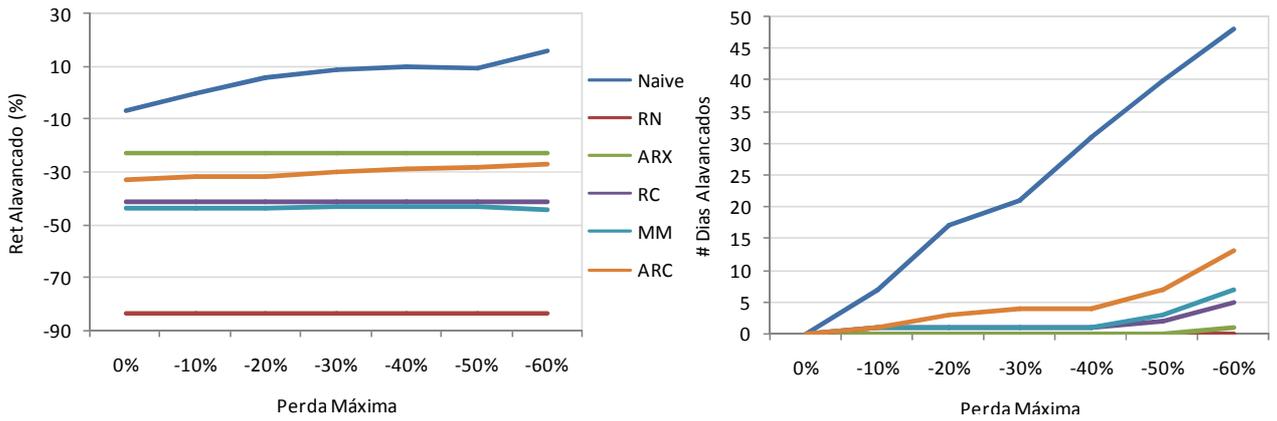


Figura A3.9: Retorno alavancado acumulado e Núm de Dias Alavancados GM

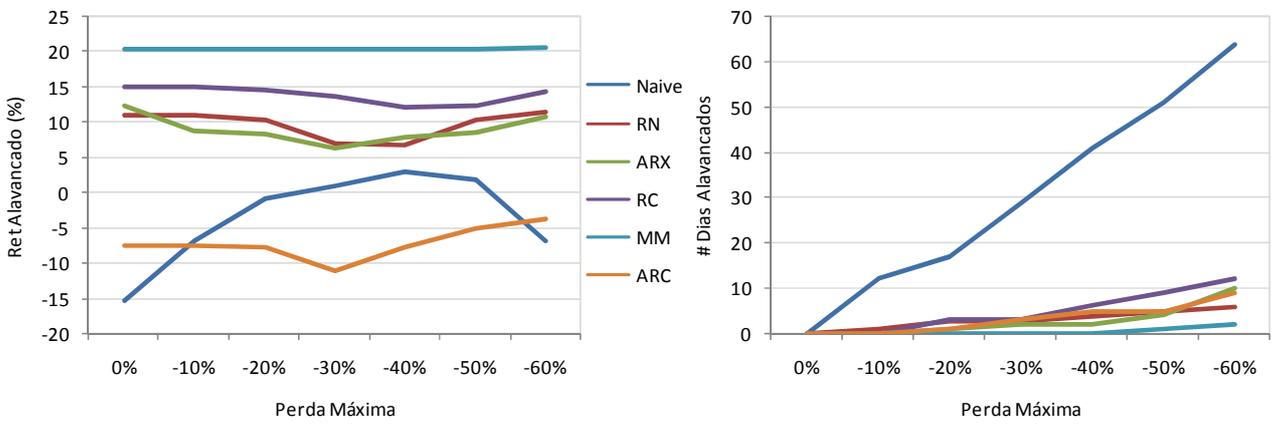


Figura A3.10: Retorno alavancado acumulado e Núm de Dias Alavancados HD

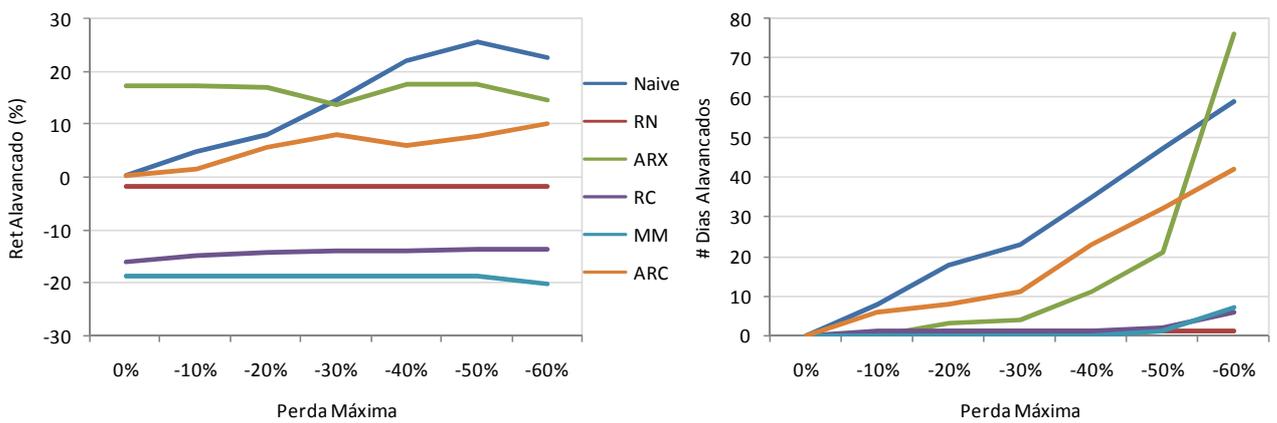


Figura A3.11: Retorno alavancado acumulado e Núm de Dias Alavancados HOM

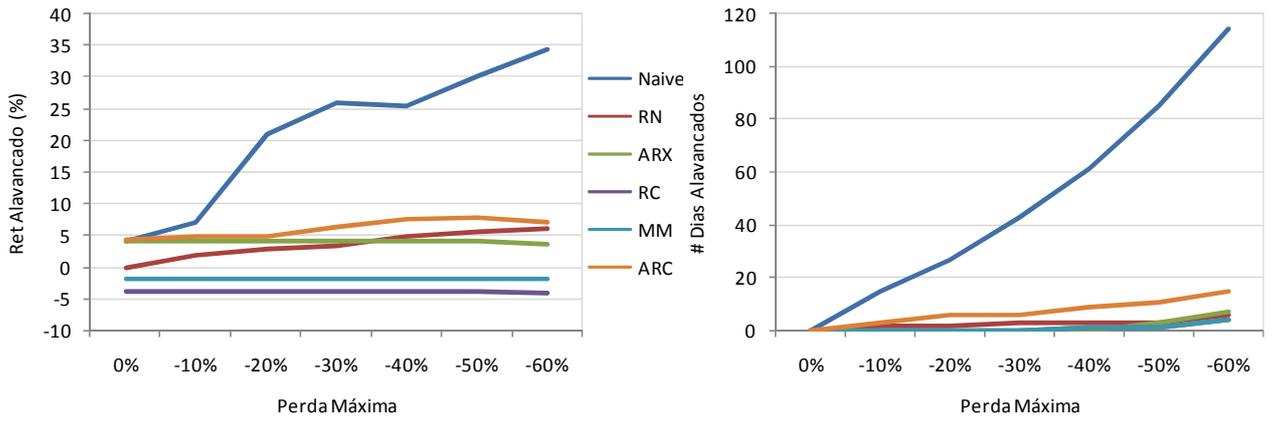


Figura A3.12: Retorno alavancado acumulado e Núm de Dias Alavancados IBM

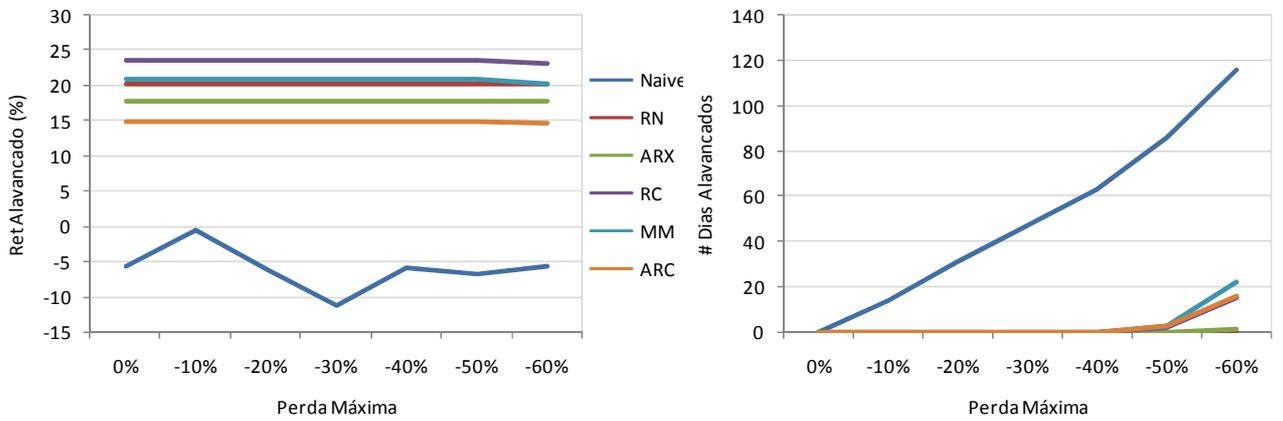


Figura A3.13: Retorno alavancado acumulado e Núm de Dias Alavancados JNJ

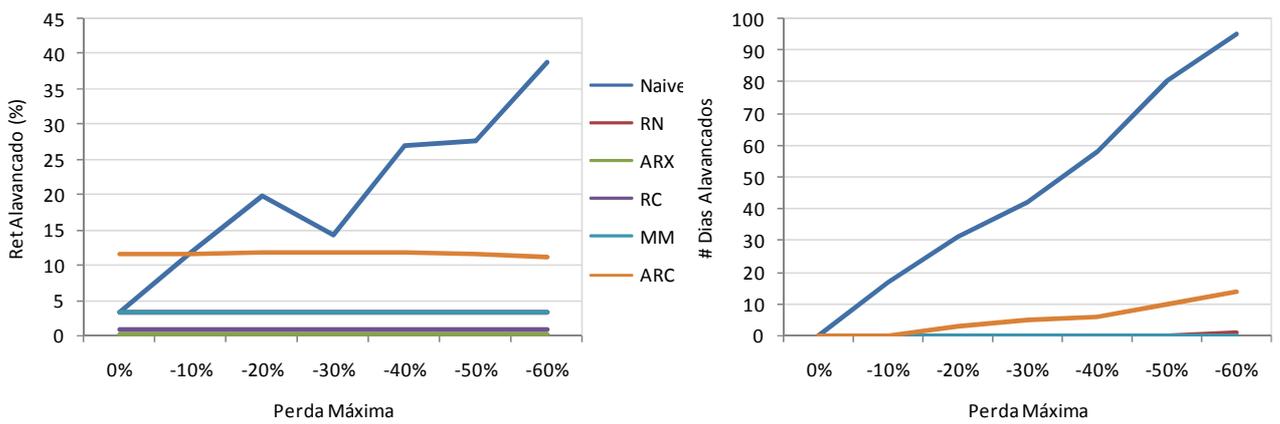


Figura A3.14: Retorno alavancado acumulado e Núm de Dias Alavancados JPM

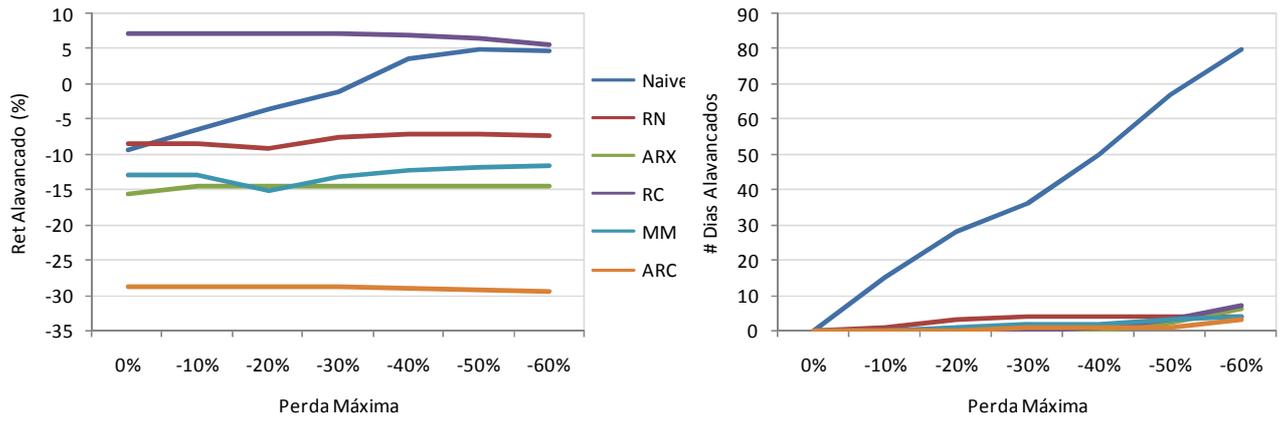


Figura A3.15: Retorno alavancado acumulado e Núm de Dias Alavancados KO

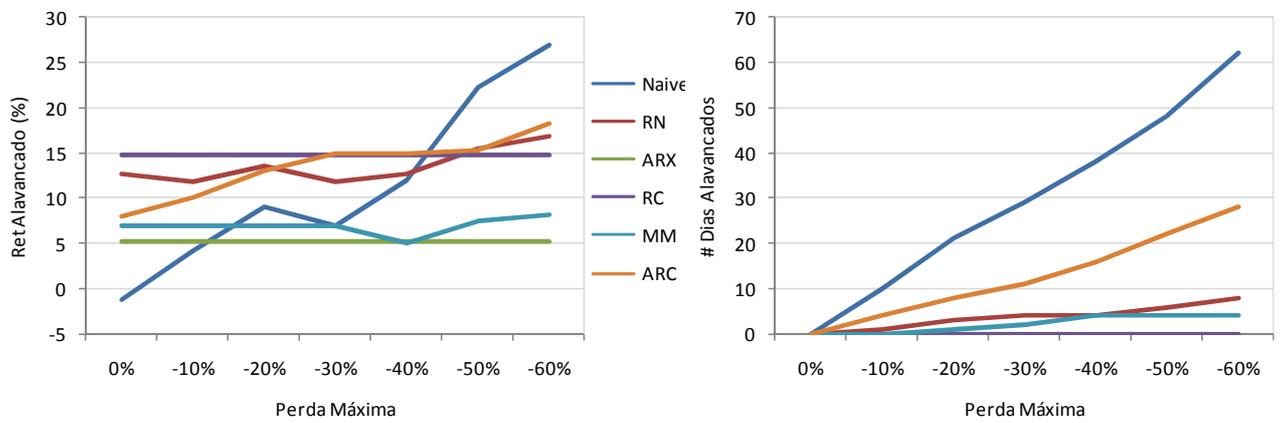


Figura A3.16: Retorno alavancado acumulado e Núm de Dias Alavancados MCD

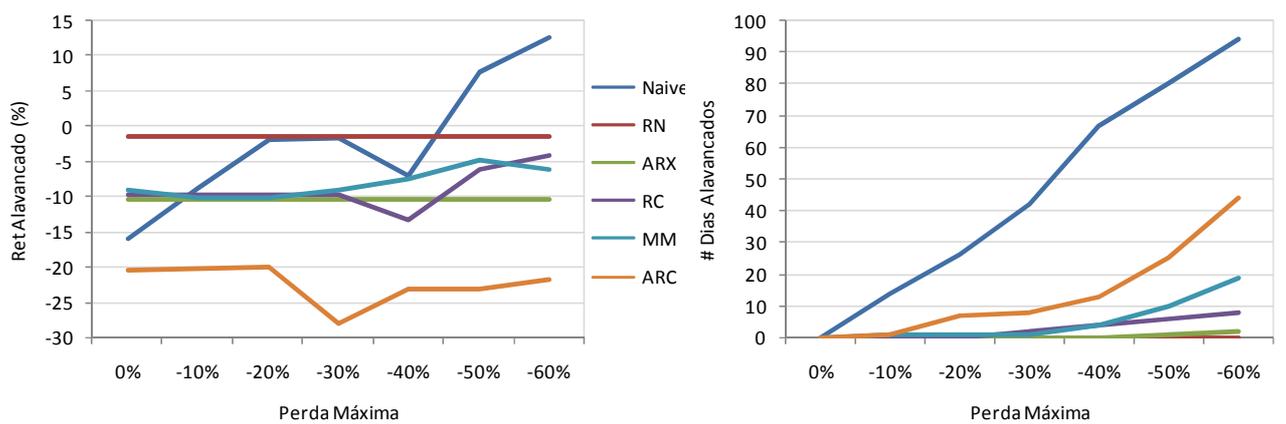


Figura A3.17: Retorno alavancado acumulado e Núm de Dias Alavancados MMM

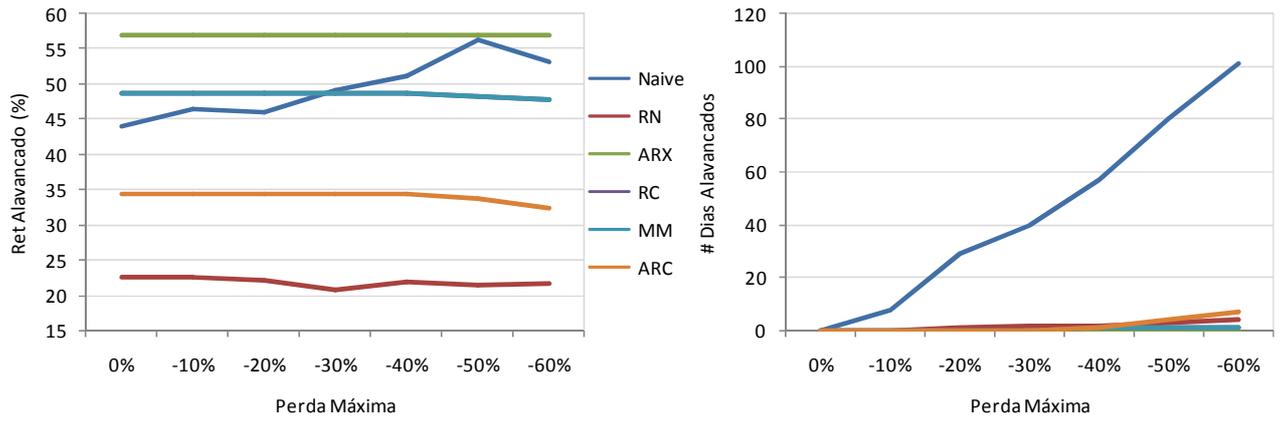


Figura A3.18: Retorno alavancado acumulado e Núm de Dias Alavancados MO

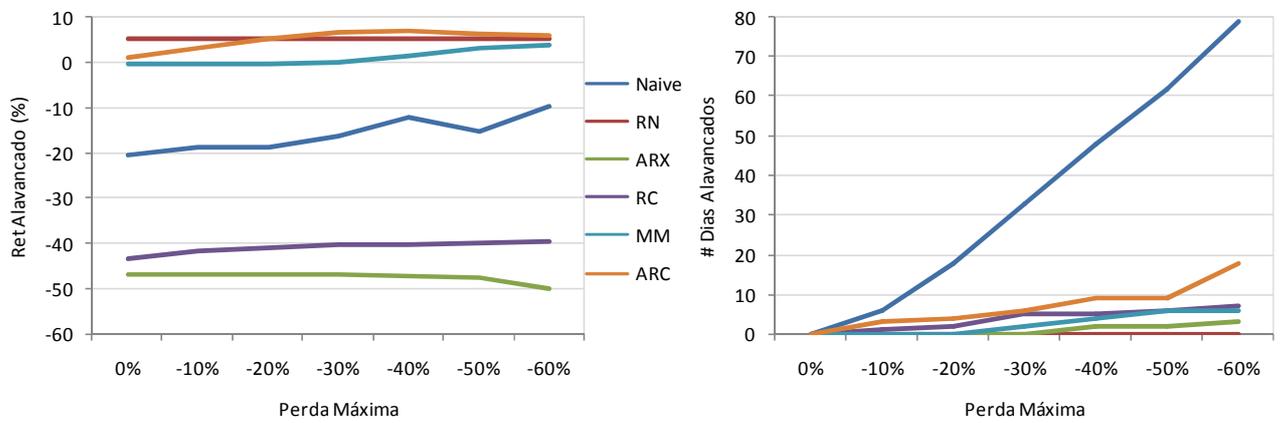


Figura A3.19: Retorno alavancado acumulado e Núm de Dias Alavancados MRK

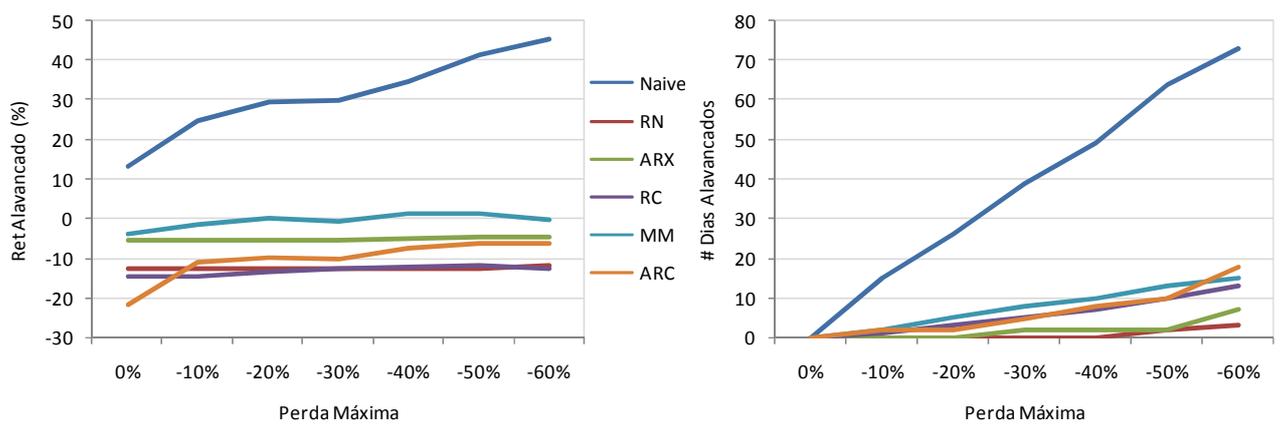


Figura A3.20: Retorno alavancado acumulado e Núm de Dias Alavancados PFE

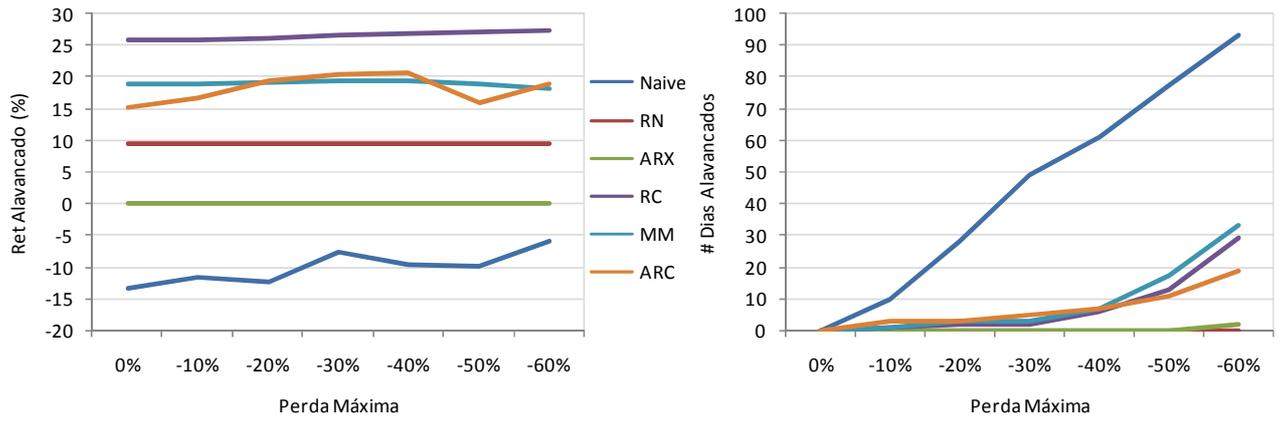


Figura A3.21: Retorno alavancado acumulado e Núm de Dias Alavancados PG

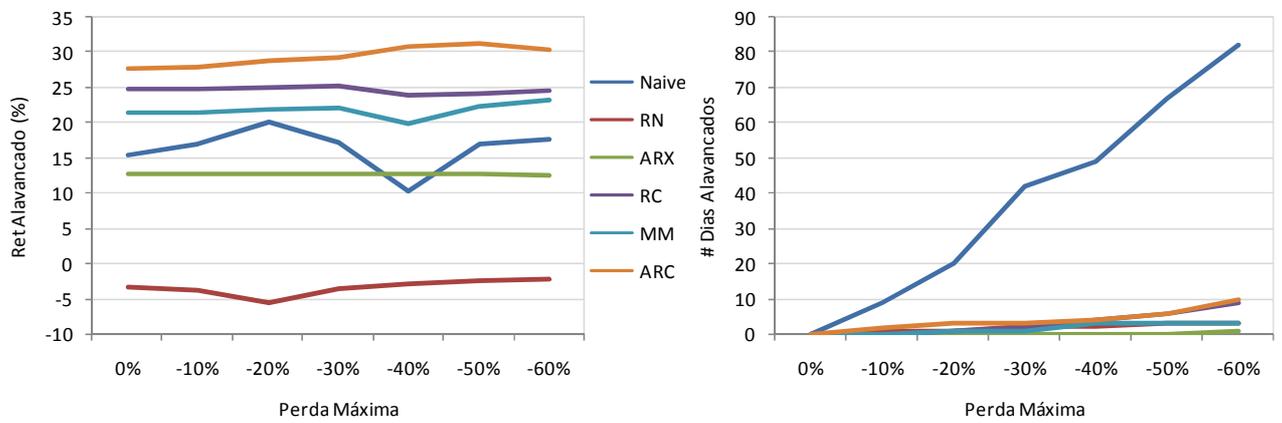


Figura A3.22: Retorno alavancado acumulado e Núm de Dias Alavancados UTX

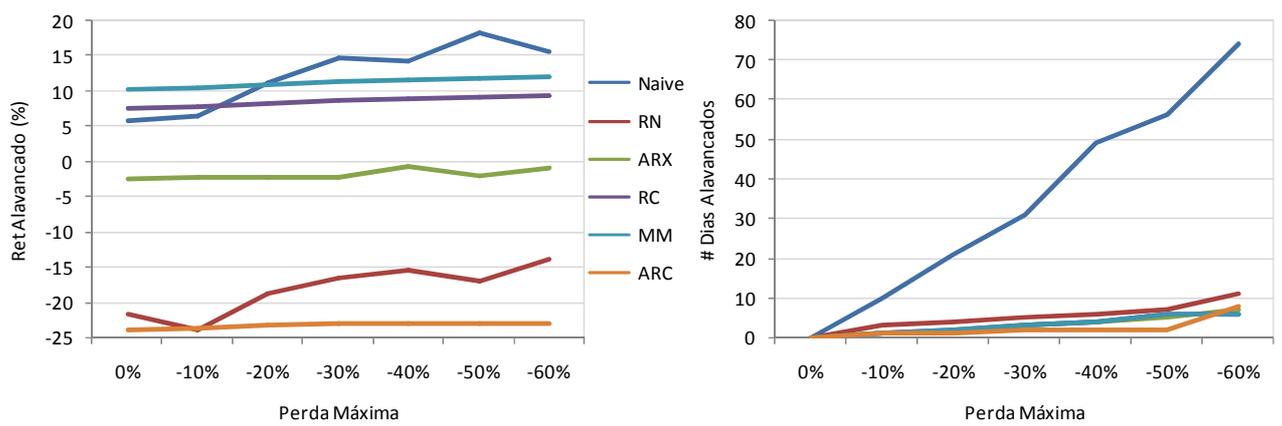


Figura A3.23: Retorno alavancado acumulado e Núm de Dias Alavancados WMT