

4

Impacto das durações sobre a volatilidade instantânea

4.1

Metodologia

Neste capítulo estimaremos o modelo proposto por Engle[8], equação (3-18), cuja volatilidade depende da variação dos preços e da duração entre os negócios. As durações seguem um processo ACD(1,1) e os preços seguem um processo GARCH(1,1).

Inicialmente, fazendo uso das durações dessazonadas, estimaremos os modelos ACDs utilizando a equação (3-13) sob restrições adequadas para a estimar casos particulares da Gama Generalizada (Exponencial e Weibull). Em seguida, realizaremos testes estatísticos para verificar a adequabilidade dos modelos aos dados. As durações previstas pelo modelo mais adequado servirão de insumo como variáveis explicativas para a análise do efeito impactante sobre a volatilidade instantânea - estimada por um modelo GARCH(1,1) de acordo com a equação (3-17).

As variáveis explicativas de duração, como mencionado anteriormente, são $\frac{x_i}{\psi_i}$, x_i e ψ_i^{-1} , as quais são o efeito de causalidade entre a volatilidade e as durações, o impacto contemporâneo e o efeito inversamente proporcional médio, respectivamente.

O efeito de cada variável será estudado isoladamente e conjuntamente, sendo os resultados obtidos comparados com a literatura.

Na seção 4.2 estimaremos os modelos de duração - Exponencial (EACD(1,1)), Weibull (WACD(1,1)) e o Gama Generalizada (GACD(1,1)) - maximizando a log-verossimilhança, equação (3-13). O algoritmo usado para maximização será o ‘BFGS’; descrito em Nocedal & Wright [7].

A seguir, na seção 4.3 estimaremos o modelo GARCH(1,1) com as variáveis explicativas usando o algoritmo ‘BHHH’; mais detalhes vide Berndt, Hall, Hall & Hausman [2].

4.2

Estimação das durações

A partir desta seção estimaremos os modelos de duração. Porém, antes de seguirmos com a parte prática devemos atentar para o fato do tamanho da amostra, o qual influencia diretamente a significância dos testes estatísticos usados para validar o modelo.

No presente trabalho o tamanho da amostra usada é de 59.878 observações. Desta forma, é esperado que os testes estatísticos indiquem que os parâmetros são estatisticamente significantes. Assim além da significância estatística devemos considerar a relevância dos parâmetros em estudo.

4.2.1

Modelo ACD com Distribuição Exponencial

Iniciaremos com o modelo exponencial EACD(1,1). A fim de realizarmos a estimação devemos inserir as seguintes restrições na equação (3-13); $\kappa = \gamma = 1$.

Na tabela 4.1 apresentamos o resultado da estimativa do modelo. Os parâmetros apresentaram-se todos estatisticamente significantes, sendo a soma de α e β igual a 0.99 indicando uma forte persistência nas durações.

EACD(1,1)			
Parâmetro	Estimativa	DP	t
ω	0.0086659	0.0010812	8.015
α	0.0241117	0.0016638	14.492
β	0.9667139	0.0024345	397.08
Estatística dos Resíduos			
Média	1.0000	DP	0.82764
Ljung-Box (15lags)	286.14	Teste Engle	-8.9295

Tabela 4.1: Parâmetros estimados para o modelo EACD(1,1)

As autocorrelações e a estatística de Ljung-Box são apresentadas na tabela 4.2: a hipótese de independência é fortemente rejeitada no nível de significância de 5%, sugerindo que a dependência não é somente causada pela componente sazonal determinística. Tal observação é justificada pelos altos valores da estatística t dos parâmetros α e β no modelo, os quais, por construção, capturam a dependência temporal.

	Duração		Duração dessazonada	
	FAC	FACP	FAC	FACP
lag 1	0,071	0,071	-0,010	-0,010
lag 2	0,088	0,084	0,035	0,035
lag 3	0,112	0,101	0,054	0,055
lag 4	0,113	0,094	0,064	0,064
lag 5	0,103	0,077	0,057	0,055
lag 6	0,103	0,071	0,053	0,048
lag 7	0,096	0,059	0,044	0,036
lag 8	0,104	0,063	0,050	0,040
lag 9	0,108	0,064	0,054	0,043
lag 10	0,089	0,041	0,038	0,025
lag 11	0,095	0,045	0,040	0,025
lag 12	0,091	0,038	0,039	0,023
lag 13	0,096	0,042	0,043	0,027
lag 14	0,082	0,027	0,041	0,025
lag 15	0,090	0,033	0,038	0,022
Ljung-Box (15)=8401.6		Ljung-Box (15)=1858.0		

Tabela 4.2: Autocorrelação e autocorrelação parcial das durações

Para testar o excesso de dispersão utilizaremos o teste proposto por Engle & Russel[3]¹ baseado na estatística $\sqrt{N}(\frac{\hat{\sigma}_\varepsilon^2 - 1}{\sigma_v})$, onde $\hat{\sigma}_\varepsilon$ é a variância de $\hat{\varepsilon}$, a qual seria 1 sob a hipótese nula de não existência de excesso de dispersão e σ_v é o desvio padrão de $(\varepsilon_i - 1)^2$. Pelo Teorema Central do Limite a estatística de teste tende a uma distribuição Normal padrão. Sendo assim, pelo teste Engle não rejeitamos a hipótese de excesso de dispersão no nível de significância de 5%. Porém, quando testamos a sub-dispersão, rejeitamos a hipótese de não existência de sub-dispersão. Sendo este resultado uma forte evidência contra o modelo EACD(1,1).

Para testar a hipótese nula que as durações são i.i.d. contra a hipótese alternativa de dependência linear, não linear (na média e/ou variância) ou caos determinístico, utilizamos o teste BDS com distribuição aproximadamente $N(0, 1)$; detalhes sobre o teste vide Cromwell, Labys & Terraza [5].

Após filtrarmos a série dos resíduos do modelo EACD(1,1) de sua dependência linear aplicando um modelo AR(1) e confirmado que os resíduos são descorrelatados através do correlograma, Figura 4.1, aplicamos o teste BDS nos resíduos gerados pelo filtro e rejeitamos a hipótese nula. Sendo assim, temos evidências estatísticas da existência de algum tipo de relação não linear (na média e/ou variância). O resultado do teste para o EACD(1,1) encontra-se na Tabela 4.3.

A seguir estimaremos o modelo com distribuição Weibull tendo em vista que o modelo com distribuição Exponencial não conseguiu capturar a sub-dispersão.

4.2.2

Modelo ACD com Distribuição Weibull

O modelo com distribuição Weibull é resultante da seguinte restrição na equação (3-13); $\kappa = 1$. O parâmetro γ é estimado e em seguida realizado um teste estatístico de significância.

As estimativas do modelo com distribuição Weibull apresentam-se na tabela 4.4. O parâmetro estimado γ é 1,43. Ao testarmos a hipótese nula $H_0 : \gamma = 1$ utilizando a estatística t , rejeitamos H_0 com nível de significância de 5%; sendo assim, permanecemos com o modelo WACD(1,1). Os demais parâmetros se mostraram significativos sendo a soma de α e β igual 0.99 indicando forte persistência das durações.

A estatística de Ljung-Box rejeita a hipótese de independência dos resíduos. O mesmo resultado é verificado realizando o teste BDS, presente

¹A demonstração do teste se encontra no apêndice C.

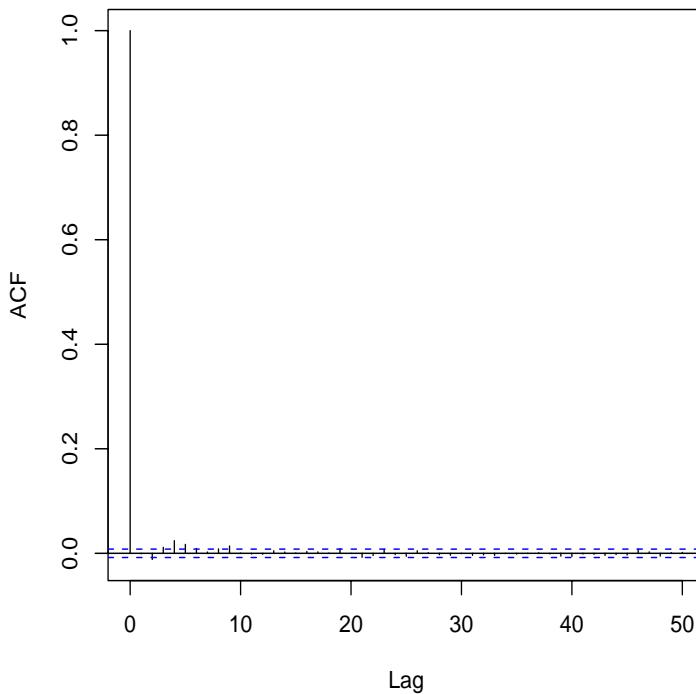


Figura 4.1: FAC dos resíduos filtrados do modelo EACD(1,1)

Epsilon for close points =	0.4138	0.8276	1.2414	1.6553
Standard Normal =	[0.4138]	[0.8276]	[1.2414]	[1.6553]
[2]	4.0933	88.6523	162.8663	260.7627
[3]	4.4838	196.2311	376.3639	1020.4729
[4]	4.7673	83.7358	461.2845	1133.7857
[5]	6.5405	153.7194	1158.4293	NaN
[6]	9.6723	110.7810	1518.7058	4697.0405
[7]	12.1743	171.6547	6760.9489	NaN
[8]	13.8737	159.7415	4970.6688	16436.9424
[9]	15.6675	225.6243	NaN	NaN
[10]	17.6509	243.0467	14732.5786	53445.5638
p-value =	[0.4138]	[0.8276]	[1.2414]	[1.6553]
[2]	0	0	0	0
[3]	0	0	0	0
[4]	0	0	0	0
[5]	0	0	0	NaN
[6]	0	0	0	0
[7]	0	0	0	NaN
[8]	0	0	0	0
[9]	0	0	NaN	NaN
[10]	0	0	0	0

Tabela 4.3: Valores do teste BDS para o modelo EACD(1,1)

na tabela 4.5, utilizando o mesmo procedimento que no modelo exponencial. Temos evidências estatísticas de não linearidade (na média e/ou variância) ou caos determinístico.

Realizamos o teste Engle para a sub-dispersão, resultando na rejeição da hipótese nula; sendo assim, o WACD(1,1) não consegue capturar a sub-dispersão sendo este fato uma forte evidência contra o modelo WACD(1,1). Desta forma, estimaremos o modelo GACD(1,1).

WACD(1,1)			
Parâmetro	Estimativa	DP	t
ω	0.011886	0.00098374	12.082
α	0.029935	0.00138948	21.544
β	0.957808	0.00208282	459.86
γ	1.432711	0.00395592	362.17
Estatística dos Resíduos			
Média	0.99263	DP	0.8196435
Ljung-Box (15lags)	307.01	Teste Engle	-9.5592

Tabela 4.4: Parâmetros estimados para o modelo WACD(1,1)

Epsilon for close points =	0.4098	0.8196	1.2295	1.6393
Standard Normal =	[0.4098]	[0.8196]	[1.2295]	[1.6393]
[2]	35.060	879.265	1.624.229	2.601.964
[3]	37.349	1.967.372	3.722.542	10.105.568
[4]	39.405	820.150	4.568.886	11.285.973
[5]	56.425	1.519.062	11.250.616	NaN
[6]	86.480	1.072.281	14.992.137	46.736.614
[7]	10.394	1.670.480	60.322.928	NaN
[8]	26.258	1.527.043	49.247.336	163.465.088
[9]	43.479	2.160.535	NaN	NaN
[10]	62.098	2.292.430	147.270.151	530.592.238
p-value =	[0.4098]	[0.8196]	[1.2295]	[1.6393]
[2]	5,00E-04	0	0	0
[3]	2,00E-04	0	0	0
[4]	1,00E-04	0	0	0
[5]	0,00E+00	0	0	NaN
[6]	0,00E+00	0	0	0
[7]	0,00E+00	0	0	NaN
[8]	0,00E+00	0	0	0
[9]	0,00E+00	0	NaN	NaN
[10]	0,00E+00	0	0	0

Tabela 4.5: Valores do teste BDS para o modelo WACD(1,1)

GACD(1,1)			
Parâmetro	Estimativa	DP	t
ω	0.0064621	0.000585773	11.03175
α	0.0189587	0.000947771	20.00346
β	0.9741156	0.001368832	711.64
κ	13.6323411	0.868752	15.69187
γ	0.3910194	0.01271181	30.76032
Estatística dos Resíduos			
Média	1.002850	DP	0.8320599
Ljung-Box (15lags)	290.3545	Teste Engle	-0.03533892

Tabela 4.6: Parâmetros estimados para o modelo GACD(1,1)

4.2.3

Modelo ACD com Distribuição Gama Generalizada

O modelo com distribuição Gama Generalizada foi estimado a partir da equação (3-13). No caso da otimização da equação (3-13) um importante resultado foi mostrado em Bowman & Shenton [11]; as variâncias assintóticas só existem se $\kappa > 2^2$. Após inserirmos esta restrição procedemos a estimação do modelo GACD(1,1).

Na tabela 4.6, apresentamos os parâmetros estimados do modelo GACD(1,1). Observamos que os parâmetros $\kappa = 13,63$ e $\gamma = 0,39$ apresentam-se altamente significantes, com nível de significância de 5%.

Podemos observar, utilizando o teste Engle, que o modelo captura a sub-dispersão, não rejeitamos a hipótese nula com nível de significância de 5%. Isto é uma forte evidência estatística em favor do modelo com distribuição Gamma Generalizada. O Ljung-Box rejeita a hipótese de independência e temos evidências de não linearidade (na média e/ou variância) ou caos utilizando o BDS aplicando o procedimento descrito anteriormente.

A fim de verificar a adequabilidade do modelo GACD(1,1) construímos um histograma e plotamos a densidade gama:

²A matriz Hessiana é $H = \begin{pmatrix} \frac{\kappa}{\gamma^2} & \frac{1}{\gamma} & \frac{1}{[\gamma(\kappa-1)]} \\ \frac{1}{\gamma} & \psi(\kappa) & \frac{1}{[\gamma(\kappa-1)]} \\ \frac{1}{[\gamma(\kappa-1)]} & \frac{1}{[\gamma^2(\kappa-2)]} & \end{pmatrix}$, onde $\psi(\kappa) = \frac{d}{d\kappa} \ln \Gamma(\kappa)$

Podemos notar que a existência das variâncias assintóticas são condicionadas ao valor de $\kappa > 2$.

Epsilon for close points =	0.4160	0.8321	12.481	16.641
Standard Normal =	[0.416]	[0.8321]	[1.2481]	[1.6641]
[2]	4,67E+04	899.289	1.635.364	2.613.939
[3]	5,24E+04	1.969.117	3.802.338	10.275.558
[4]	5,60E+04	858.670	4.662.023	11.394.468
[5]	7,45E+04	1.563.055	11.884.083	NaN
[6]	1,07E+05	1.149.035	15.417.821	47.289.819
[7]	1,33E+05	1.771.989	74.707.718	NaN
[8]	1,51E+05	1.677.912	50.460.066	165.831.383
[9]	1,70E+05	2.367.452	NaN	NaN
[10]	1,91E+05	2.588.829	149.102.541	540.762.124
p-value =	[0.416]	[0.8321]	[1.2481]	[1.6641]
[2]	0	0	0	0
[3]	0	0	0	0
[4]	0	0	0	0
[5]	0	0	0	NaN
[6]	0	0	0	0
[7]	0	0	0	NaN
[8]	0	0	0	0
[9]	0	0	NaN	NaN
[10]	0	0	0	0

Tabela 4.7: Valores do teste BDS para o modelo GACD(1,1)

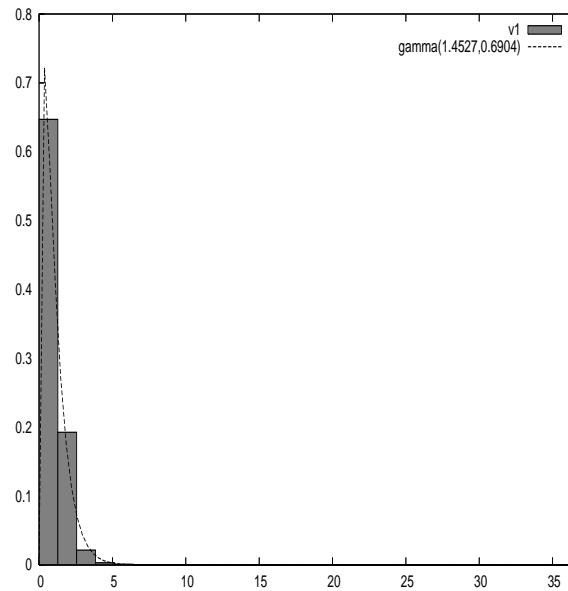


Figura 4.2: Histograma dos resíduos junto com a densidade Gama

Na Figura 4.2, podemos observar que os resíduos seguem aproximadamente uma distribuição gama, sendo assim, o modelo GACD(1,1) se mostrou o mais adequado para modelar as durações.

Concluímos esta seção com resultados compatíveis encontrados nos trabalhos de Engle & Russel [10] [3] [8] e Zhang, Russel & Tsay [9]. Eles

concluíram que as durações possuem uma natureza não-linear e que o modelo com distribuição Gama Generalizada captura o excesso de dispersão.

Na próxima seção, passaremos à estimativa da volatilidade instantânea, tendo como insumo as durações estimadas pelo modelo GACD(1,1). A justificativa para usarmos uma configuração linear em detrimento da não-linear é o objetivo de comprovar alguns ‘fatos empíricos’ dos impactos das durações sobre a volatilidade instantânea como em Engel [8].

4.3

Estimação do modelo proposto por Engle

O objetivo desta seção é apresentar um método para estimar uma medida de volatilidade instantânea usando os dados de duração como variáveis explicativas verificando como impactam a volatilidade.

Primeiramente, determinamos o processo GARCH(1,1), dado pela equação (3-17), que melhor descreve a volatilidade. Estimaremos modelo GARCH(1,1) com distribuição Normal e com distribuição t de Student com o intuito de determinar o melhor modelo para a volatilidade instantânea.

Após a escolha do processo GARCH, acrescentamos as variáveis explicativas ξ_{i-1} , $\frac{x_i}{\psi_i}$, x_i e ψ_i^{-1} , representando persistência, o efeito de dependência entre a volatilidade e as durações, o impacto contemporâneo e o efeito inversamente proporcional médio, respectivamente.

A seguir, a tabela 4.8, temos os resultados da estimação do modelo GARCH(1,1) normal.

GARCH(1,1)			
Coeficientes	Estimativas	DP	t
ω	0.2584	0.002057013	88,84
α	0.2094	0.00167320	125,19
β	0.6480	0.003335	194,6
Estatísticas dos Resíduos			
	Valor		
Ljung-Box (15 lags)	10.44799		
Jarque-Bera	287548.4		

Tabela 4.8: Resultados das estimativas dos parâmetros do GARCH(1,1) com distribuição Normal

Utilizando o nível de significância de 5%, podemos observar na tabela 4.8 que todos os parâmetros do modelo são estatisticamente significativos. Pelo teste Ljung-Box não rejeitamos a hipótese nula de independência dos resíduos. Porém, rejeitamos fortemente a hipótese de normalidade dos resíduos pelo teste de Jarque-Bera. Sendo assim, concluímos que o modelo com distribuição Normal não é adequado, motivando a estimativa do modelo GARCH-t(1,1).

Seguindo a análise apresentamos na tabela 4.9 os resultados do modelo GARCH-t(1,1) utilizando uma distribuição t com 10 g.l.³.

³Os graus de liberdade foram estimados pelo *software* usado. Mais detalhes sobre o método de estimação vide Venables & Ripley [6]

GARCH-t(1,1)			
Coeficientes	Estimativas	DP	t
ω	0.2894	0.002057013	141,17
α	0.2397	0.001999520	125,79
β	0.6052	0.002703133	302,6
Estatísticas dos Resíduos			
	Valor		
Ljung-Box (15)	10.44799		
Jarque-Bera	287548.4		

Tabela 4.9: Resultados das estimativas dos parâmetros do GARCH-t(1,1) com distribuição Normal

Observando a tabela 4.9 todos os coeficientes estimados do modelo são estatisticamente significativos utilizando a t de *Student*. Pelo teste Ljung-Box não possuímos evidências estatísticas para rejeitarmos a hipótese nula de independência dos resíduos dado o nível de 5% de significância. A fim de observarmos a qualidade do ajuste plotamos um *QQ-plot* dos resíduos padronizados, Figura 4.3.

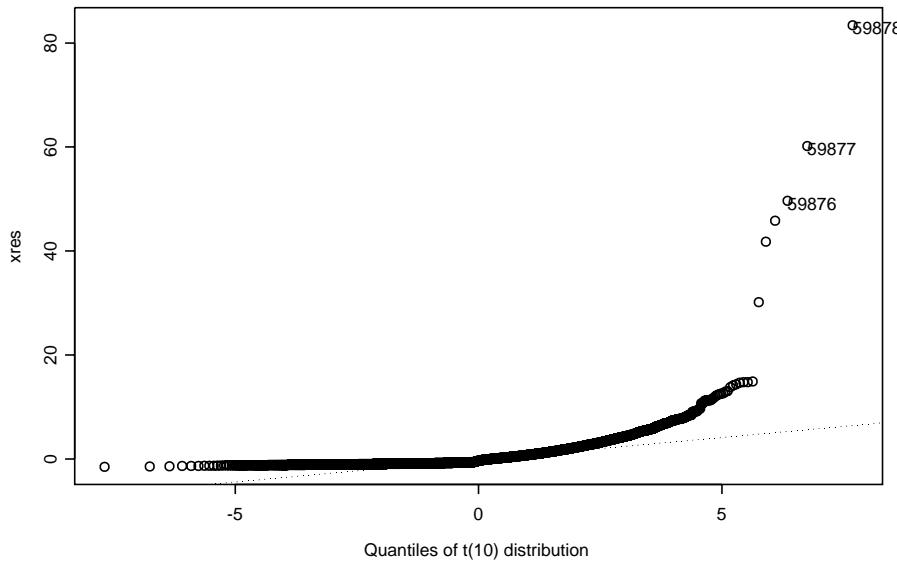


Figura 4.3: *QQ-plot* dos resíduos padronizados do GARCH-t(1,1) com distribuição t de *Student*

Desta forma, pelo *QQ-plot* temos que o GARCH-t com 10 g.l.⁴ se mostrou mais adequado do que o GARCH com distribuição Normal.

⁴Os graus de liberdade do melhor modelo foram obtidos pelo algoritmo de maximização utilizado, vide Venables & Ripley[6]

Neste momento, com o modelo GARCH adequado, passaremos a análise do impacto das durações sobre a volatilidade instantânea. Primeiramente, analisaremos o impacto de cada variável isoladamente e a seguir conjuntamente. Compararemos os resultados apurados com os obtidos por Engel[8].

O primeiro impacto na volatilidade que iremos analisar será os das durações contemporâneas x_i , onde o modelo é dado por:

$$\sigma_i^2 = \omega + \alpha e_{i-1}^2 + \beta \sigma_{i-1}^2 + \gamma x_i \quad (4-1)$$

As estimativas da equação (4-1) são dadas na tabela 4.10.

Modelo	coef	desvio padrão	$ t $
ω	0.14393	0.004860406	29,62
α	0.12603	0.004411387	28,64
β	0.75732	0.006825304	110,56
γ	-0.02714	0.0004612339	678,50

Tabela 4.10: Estimativas do modelo GARCH-t(1,1) com as durações contemporâneas como variável explicativa

As estimativas dos coeficientes do modelo se mostraram todas estatisticamente significantes dado o nível de significância de 5%. O sinal negativo do coeficiente de x_i demonstra o impacto negativo das durações na volatilidade instantânea, ou seja, longas durações indicam que não chegam notícias novas ao mercado implicando queda na volatilidade. Este resultado é corroborado por Easley & O'Hara *apud* Engel[8].

A seguir, estimamos o modelo, para analisar se o impacto das durações é inversamente proporcional a volatilidade instantânea:

$$\sigma_i^2 = \omega + \alpha e_{i-1}^2 + \beta \sigma_{i-1}^2 + \gamma \frac{1}{\psi_i} \quad (4-2)$$

cujas estimativas são dadas pela Tabela 4.11.

Modelo	coef	desvio padrão	$ t $
ω	0.04804	0.01184461	4,07
α	0.11702	0.004031301	29,25
β	0.77142	0.006455953	120,53
γ	0.05984	0.011135540	5,32

Tabela 4.11: Estimativas do modelo GARCH-t(1,1) tendo o efeito inversamente proporcional médio como variável explicativa

Os parâmetros do modelo (4-2) se mostraram todos estatisticamente significativos dado o nível de significância de 5%. O sinal do coeficiente do

efeito inversamente proporcional médio é positivo indicando que as durações são inversamente proporcionais a volatilidade instantânea, ou seja, quanto maiores as durações médias menor o impacto na volatilidade instantânea. Em contrapartida, quanto menores as durações médias maior o impacto na volatilidade instantânea. Este resultado é condizente com a equação (4-1) e semelhante ao encontrado por Engel [8].

Visando o estudo do efeito de contração das durações sobre a volatilidade instantânea, estimamos o seguinte modelo:

$$\sigma_i^2 = \omega + \alpha e_{i-1}^2 + \beta \sigma_{i-1}^2 + \gamma \frac{x_i}{\psi_i} \quad (4-3)$$

As estimativas do modelo são apresentadas na tabela 4.12.

Modelo	coef	desvio padrão	$ t $
ω	0.15292	0.004544153	38,23
α	0.10669	0.003448074	31,38
β	0.79101	0.005706330	158,20
γ	-0.03728	0.0003710495	123,33

Tabela 4.12: Estimativas do modelo GARCH-t(1,1) tendo o efeito de contração como variável explicativa

Observando a Tabela 4.12, verificamos que todos os coeficientes do modelo são significativos dado o nível de significância de 5%. O coeficiente do parâmetro $\frac{x_i}{\psi_i}$ revela que as durações possuem um efeito constante de contração da volatilidade instantânea permanente ligado a $\frac{x_i}{\psi_i} > 0$. Isto poderia explicar o fato de que em determinados momentos a volatilidade do ativo ser menor do que a esperada como mencionado em Engel [8].

O impacto do efeito da persistência, como descrito na página 28, das durações é verificado pelo modelo:

$$\sigma_i^2 = \omega + \alpha e_{i-1}^2 + \beta \sigma_{i-1}^2 + \gamma \xi_i \quad (4-4)$$

As estimativas das componentes são dadas abaixo:

Modelo	coef	desvio padrão	$ t $
ω	0.0261	0.008975758	2,93
α	0.1238	0.004403978	28,14
β	0.7411	0.007704726	96,25
γ	0.1449	0.014017327	10,35

Tabela 4.13: Estimativas do modelo GARCH-t(1,1) tendo o efeito de persistência das durações como variável explicativa

Na Tabela 4.13 todas as estimativas mostraram-se estatisticamente significantes no nível de 5%. Podemos observar que a persistência das durações possui um impacto positivo na volatilidade instantânea como comprovado por Engle[8].

Após estudarmos separadamente o impacto das variáveis ξ_i , $\frac{x_i}{\psi_i}$, x_i e ψ_i^{-1} , estaremos interessados no efeito conjunto estimado pela equação(3-18).

A seguir apresentamos as estimativas:

GARCH-t(1,1)				
Coefficientes	Estimativas	DP	t	$Pr(> t)$
ω	-0.26453	0.008144	-324.819	0.00000000
α	0.26852	0.023435	114.583	0.00000000
β	0.60719	0.020897	290.558	0.00000000
ξ_i	0.18188	0.043245	42.058	0.00001312
$\frac{x_i}{\psi_i}$	-0.14029	0.048477	-28.938	0.00190705
x_i	0.11198	0.051724	21.650	0.01520617
$\frac{1}{\psi_i}$	0.08088	0.060952	13.270	0.09227306

Tabela 4.14: Resultados das estimativas do GARCH-t(1,1) com distribuição t de student com 10g.l.

Na Tabela 4.14, a soma dos coeficiente α e β é 0.86, relativamente baixo para dados de alta freqüência. O mesmo resultado foi encontrado por Ghose & Kroner *apud* Engel[8] e Andersen & Bollerslev *apud* Engel[8] que verificaram que a persistência do modelo GARCH decai para os dados intra-diários.

As variáveis ξ_i e $\frac{x_i}{\psi_i}$ mostraram-se estatisticamente significativas tendo as mesmas interpretações que anteriormente relativas às equações (4-3) e (4-4).

Diferentemente de Engel[8][10], encontramos um impacto positivo das durações contemporâneas x_i , ou seja, altas durações implicam alta volatilidade, pois $\frac{x_i}{\psi_i}$ e x_i são altamente correlacionados logo há problemas de colinearidade. Este resultado não é corroborado por Easley & O'Hara *apud* Engel[8], que verificaram que longas durações indicam que não chegam notícias novas no mercado implicando em queda de volatilidade.

Por fim a variável $\frac{1}{\psi_i}$, ou seja, o impacto inversamente proporcional médio das durações não mostrou-se significativo dado o nível de significância de 5%.