

PONTIFÍCIA UNIVERSIDADE CATÓLICA DO RIO DE JANEIRO
DEPARTAMENTO DE ECONOMIA
MONOGRAFIA DE FINAL DE CURSO

MODELOS DE PREVISÃO: UM ESTUDO PARA O MERCADO
BRASILEIRO DE REFRIGERANTES

Pedro Rocha Lima Massa

MAT:9815854

ORIENTADOR: Marco Antonio F.de H. Cavalcanti

Dezembro 2002

"Declaro que o presente trabalho é de minha autoria que não recorri para realiza-lo, a nenhuma ajuda externa, exceto quando autorizado pelo professor tutor".

Assinatura_____

PONTIFÍCIA UNIVERSIDADE CATÓLICA DO RIO DE JANEIRO
DEPARTAMENTO DE ECONOMIA
MONOGRAFIA DE FINAL DE CURSO

MODELOS DE PREVISÃO: UM ESTUDO PARA O MERCADO
BRASILEIRO DE REFRIGERANTES

Pedro Rocha Lima Massa

MAT:9815854

ORIENTADOR: Marco Antonio F.de H. Cavalcanti

Dezembro 2002

"As opiniões expressas neste trabalho são de responsabilidade única e exclusiva do autor".

Assinatura _____

Agradecimentos ao professor Marco Antonio F. de H. Cavalcanti pela dedicação, compreensão e paciência, com que me ajudou a desempenhar este trabalho Monográfico.

ÍNDICE DOS CAPÍTULOS:

	Páginas
Capítulo I : Introdução _____	5
Capítulo II: O Mercado Brasileiro de Refrigerantes _____	7
Capítulo III: Modelos de Previsão _____	10
ARIMA _____	14
ADL _____	30
VAR e VEC _____	14
Capítulo IV: Conclusão _____	49
Referencia Bibliográfica _____	50

I- INTRODUÇÃO

O mercado brasileiro de refrigerantes é o terceiro maior do mundo, com uma produção superior a 11 bilhões de litros/ano movimentando cerca de R\$ 9,5 bilhões anuais. À frente do Brasil encontram-se apenas Estados Unidos e México¹:

As oscilações no consumo de refrigerantes são dependentes de uma série de fatores exógenos ao setor: a existência de bens substitutos, somado à não essencialidade do refrigerante como produto de consumo, faz com que a demanda tenha elevada sensibilidade em relação a alteração de preços e renda do consumidor. Pode-se dizer que, do ponto de vista do consumidor, a presente operação envolve os seguintes mercados relevantes de produto: cervejas, refrigerantes, águas, chás, isotônicos e sucos. Todos esses produtos são percebidos de forma distinta pelo consumidor. Com efeito, cada tipo de bebida é demandada em momentos específicos e, em vários casos, possuem públicos distintos. Pelo lado da demanda, importa saber se os produtos são substituíveis "aos olhos do consumidor", o que implica dizer que devem ser considerados fatores como preços, usos e qualidades do produto, e não somente sua possibilidade técnica de substituição. Esta possibilidade de substituição de consumo também está ligada a alterações nos hábitos alimentares da população que aumentou a demanda por alimentos e bebidas mais naturais e saudáveis que os tradicionais refrigerantes. Para verificar o grau de diferenciação da percepção do consumidor sobre a maior utilidade de determinada cesta, é preciso buscar evidências empíricas no padrão de consumo. Por outro lado, a demanda é influenciada por diversas variáveis de caráter aleatório (como o clima, por exemplo), o que torna difícil de enquadrar as vendas em modelos simples de previsão (além da presença de sazonalidade).

Assim, torna-se necessário encontrar um modelo ideal de previsão de demanda de refrigerantes para estimar a configuração do mercado nos próximos anos. No entanto, para um estudo econométrico de previsão de demanda, é preciso tomar algumas precauções:

- Estudo econométrico não é uma simples análise estatística. O ferramental matemático é o suporte para uma análise econômica, ou seja, ou as variáveis a serem estudadas são bem escolhidas, ou o estudo perde o sentido do ponto de vista econômico. Pouco importará que sejam encontradas altas correlações ou que todos os testes sejam atendidos, se as variáveis não forem relacionadas no mundo real. É possível encontrar

¹ Tendências 2002 AC Nielsen

(ou montar) várias séries de dados pouco relacionadas entre si e, ainda assim, obter-se resultados aparentemente consistentes;

- A base de dados deve ser adequada e de boa qualidade e a técnica a ser utilizada deve ser a apropriada para o tipo de estudo que se quer realizar.

Esse trabalho tem como objetivo encontrar um modelo que melhor se ajusta á previsão na prática.

II- O MERCADO BRASILEIRO DE REFRIGERANTES

No mercado Brasileiro de Refrigerantes, distinguem-se dois grupos estratégicos, com barreiras de mobilidade entre si, e conseqüentemente com diferentes condutas e estratégias competitivas.

O primeiro grupo é formado por um pequeno número de grandes empresas, que detêm cerca de 68% do mercado². Fazem parte deste grupo as marcas líderes com as da multinacional Coca-Cola e Ambev (hoje constituída pelas empresas Brahma e Antártica, além também de ser responsável por engarrafar e vender os produtos da Pepsi), que atuam em âmbito nacional e internacional, produzem em larga escala com forte esquema de distribuição e altos investimentos em propaganda e marketing para reforçar o processo de diferenciação transmitindo ao consumidor a idéia de que, por trás da marca, existe um sabor próprio, que não é encontrável na concorrência.

O segundo grupo é formado por um número grande de pequenas empresas, com atuação regional, responsáveis pela produção das Tubainas e refrigerantes de Marca Própria. Segundo dados do anuário Tendências do Instituto AC Nielsen, entre 1998 e 2000 as marcas líderes perderam participação em volume em 99 de 157 categorias de produtos pesquisadas, mas as perdas foram ainda mais intensas na categoria de refrigerantes. O fato é que a hegemonia das marcas líderes das grandes empresas já vem sendo minada desde 1995, o ano seguinte ao Real. Com a explosão de consumo que se seguiu ao plano, pequenos e médios fabricantes regionais ocuparam o espaço deixado pelas grandes marcas com preços acessíveis e marketing focado principalmente nos pontos-de-venda. As Tubainas chegam a custar nas prateleiras bem menos da metade do preço das marcas tradicionais, conquistando uma fatia de 32% do mercado.

Em 2000, as Tubainas já eram produzidas por 750 empresas, num volume de 4 bilhões de litros anuais. Em 1998, contavam-se menos de 50 fabricantes no país³. Paralelo ao aparecimento das Tubainas, os refrigerantes de Marca Própria também passaram a ganhar participação de mercado, limitando ainda mais a exposição nas prateleiras de marcas líderes como Coca-Cola e Guaraná Antártica.

² Fonte: AC Nielsen

³ Dados da Consultoria Trevisa

Na verdade, além do impulso dado ao mercado consumidor com o Plano Real, esses fabricantes locais foram muito favorecidos pela multiplicação das embalagens plásticas PET substituindo as embalagens retornáveis. Substituição essa, que foi estimulada principalmente pelas empresas líderes de mercado. Um dos principais fatores que propiciaram o crescimento da embalagem descartável foi a política cambial adotada pelo Brasil a partir de 1994. Com o fim da política cambial de valorização do real frente ao dólar, o preço da embalagem descartável aumentou, o que se refletiu na forma de aumento do preço relativo da lata e embalagens PET descartáveis para o consumidor e em menores margens de comercialização para o varejista e os fabricantes.

No entanto, não podemos analisar essa tendência de substituição de embalagens sem nos atentarmos para os canais de consumo. A razão é a grande diferença na tendência de crescimento do descartável no auto-serviço contra os canais tradicional e bar, indicando claramente que a estrutura de oferta e demanda dos canais de consumo tem grande influência nesse processo. Embora nosso estudo não pretenda avaliar e prever o consumo de refrigerante em diferentes canais, é de grande importância identificarmos para entendermos melhor o mercado de refrigerantes no Brasil.

Os canais de consumo, de acordo com metodologia da AC Nielsen, são agrupados em três grandes categorias: bar, tradicional e auto-serviço. O canal bar compreende os estabelecimentos comerciais aparelhados para a oferta de refrigerante a ser consumida no próprio local de venda, (bares, lanchonetes, restaurantes e casas noturnas). No canal tradicional, incluem-se os pontos de venda, como certas padarias e mercearias, em que não existe a possibilidade de consumo local além da presença do vendedor para auxiliar a compra. Já o canal auto-serviço caracteriza-se pela presença de caixas registradoras e pelo fato de que o consumidor "se auto-serve", (supermercados).

Nos canais tradicional e bar, as pequenas marcas sofrem uma pequena desvantagem, pois é condição essencial à concorrência o desenvolvimento de extensa e eficiente rede de distribuição. Além disso, esses canais têm reduzida possibilidade de estoque, exigindo visitas dos distribuidores com periodicidade bastante curta. Neles, as empresas fornecedoras realizam pesados investimentos em merchandising e propaganda, incluindo o oferecimento de freezers. Assim, as barreiras à entrada nesses dois canais são muito mais elevadas que no canal auto-serviço. Não é por outra razão que no canal auto-serviço é encontrada um leque muito maior de opções de marcas de refrigerantes.

Outra distinção relevante entre os canais diz respeito à embalagem predominante. No caso do canal auto-serviço, a embalagem predominante é a descartável PET. Já os canais tradicional e bar ainda comercializam embalagens retornáveis. Como consequência destas diferenças na estrutura de oferta, tem-se que o canal auto-serviço caracteriza-se por uma variedade maior de marcas de refrigerantes ofertadas, a um preço menor e com predominância de PET no tipo de embalagem vendida. Por outro lado, o preço, que é variável fundamental a ser considerada na demanda do consumidor por determinado produto, é sistematicamente mais elevado nos canais tradicional e bar. Nos supermercados, os consumidores estão colocados diante de uma situação quase ideal de concorrência, onde uma gama extensa de marcas encontra-se organizada à sua frente, com seus preços devidamente indicados. Isso tende a levar a uma maior racionalidade do consumidor nesse canal.

O consumo brasileiro per capita de refrigerante cresceu nos últimos anos, devido ao aumento do poder aquisitivo das classes de menor renda conquistado a partir da estabilização econômica trazida pelo Plano Real. Os fabricantes regionais ganharam poder e estrutura, mas a recente estagnação das vendas das Tubainas (que precisam se modernizar para continuar crescendo), a redução dos preços das marcas tradicionais e o lançamento de marcas mais populares por parte das empresas líderes fizeram com que o cenário para os próximos anos do mercado de refrigerantes ficasse cada vez mais incerto.

III- MODELOS DE PREVISÃO

Iniciaremos agora nossa análise a partir do estudo de quatro abordagens de previsão de demanda baseada nos seguintes modelos de séries temporais:

- i. Modelo auto-regressivo integrado de média móvel - ARIMA
- ii. Modelo auto-regressivo de defasagens distribuídas- ADL
- iii. Modelo auto-regressivo vetorial irrestrito - VAR
- iv. Modelo de correção de erros - VEC

Já possuímos todas as séries que serão utilizadas em nossa análise. Usamos como range o período de 1994:08 2002:07. Optamos por iniciar nossos modelos a partir de agosto de 1994 pois assim, evitaremos uma quebra estrutural ocasionada pelo Real. Como o padrão de consumo e a renda do consumidor mudaram muito depois do plano, os parâmetros do modelo também se alterariam.

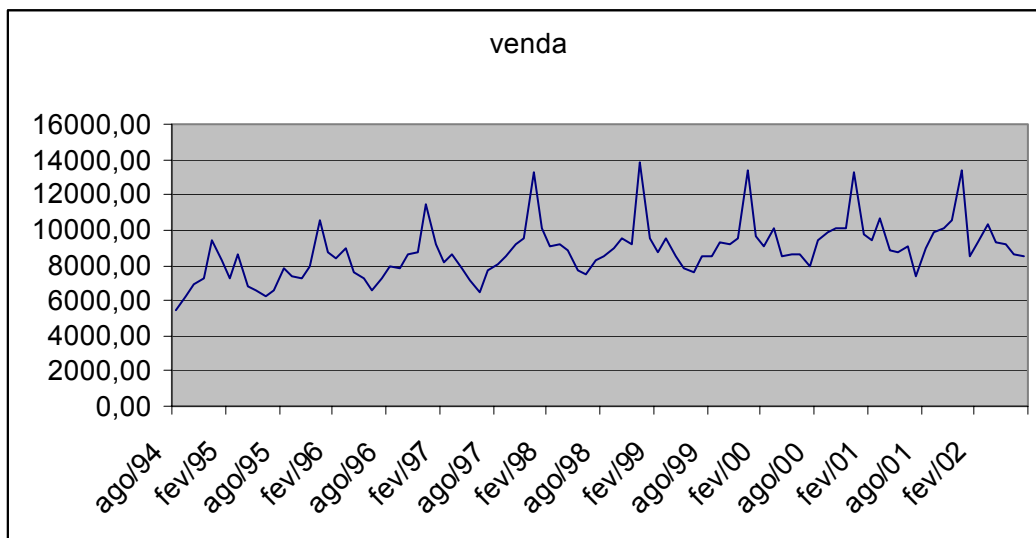
O intervalo de previsão será de Julho de 2001 à Julho de 2002, portanto teremos 1 ano para estimar as vendas de refrigerante.

As seguintes séries foram utilizadas para explicar as variações de volume:

- venda – Volume em mil litros de todos os fabricantes. Inclui portanto as vendas das Tubáinas além das grandes empresas como Coca-Cola e Ambev. Fonte: AC Nielsen.
- renda – Renda média real das pessoas ocupadas de 15 anos ou mais. Renda em R\$
Fonte:IBGE
- prod – Indicador de Produção de Bebida calculado pelo IBGE. Número Índice, 1991=100
- preço – Preço médio em real da categoria de refrigerante. Fonte AC Nielsen

Os dados do instituto AC Nielsen são dados amostrais sujeito a um erro padrão de 2,6% com um intervalo de confiança de 0,5%.

O modelo de previsão deve levar em consideração a demanda; mas se forem analisadas as séries históricas de produção industrial de bebidas, a demanda estará contida nessas séries. Isso decorre da presença de tendência de crescimento e de sazonalidade nas vendas: seus incrementos e sua distribuição no decorrer dos períodos podem ser captados através da análise de séries temporais. Portanto, optamos por não incluir a série do Indicador de Produção de Bebidas.



Examinando a série de vendas, por exemplo, temos a sensação de que ela não é estacionária. A média, a variância e as autocovariâncias das séries individuais não parecem variar com o tempo. Além disso, a série apresenta um claro ciclo de 12 meses atingindo o pico a cada dezembro, em virtude das vendas do Natal. Aparentemente, estamos a diante de um processo AR(12). A demanda por refrigerante no país é bastante sazonal, com picos acentuados nos meses de dezembro e janeiro e quedas de consumo nos meses de junho e julho.

Em nossos modelos, trabalharemos com a série de vendas com ou sem sazonalidade e compararemos os resultados. A série dessazonalizada tem o seguinte perfil:

Casualidade entre as Variáveis : GRANGER⁴

Nosso primeiro objetivo é verificar se as informações relevantes para previsão das variáveis de nosso modelo estão contidas exclusivamente nos dados de séries temporais dessas variáveis. Ou seja, realizaremos o teste de Granger para poder avaliar se estatisticamente podemos detectar uma relação de causa e efeito entre as Vendas e a Renda onde elas estariam se afetando reciprocamente com defasagens distribuídas.

O teste envolve a estimativa das seguintes regressões supondo que suas respectivas perturbações não sejam correlacionadas:

$$Venda_t = \sum_{j=1}^n \beta_j Venda_{t-j} + \sum_{i=1}^n \gamma_i Renda_{t-i} + u_{1t}$$

$$Renda_t = \sum_{j=1}^n \lambda_j Renda_{t-j} + \sum_{i=1}^n \alpha_i Venda_{t-i} + u_{2t}$$

Foram estimadas regressões com o uso de diferentes defasagens e chegamos a resultados diferentes pois esse teste é muito sensível ao número de defasagens utilizados.

Defasagens		F-Statistic	Probability	
4	Renda - Venda	1.13194	0.34718	Rejeita
	Venda- Renda	7.72259	2.40E-05	Não Rejeita
12	Renda - Venda	1.80076	0.06893	Rejeita
	Venda- Renda	14.1764	3.00E-13	Não Rejeita
15	Renda - Venda	2.69214	0.00446	Não Rejeita
	Venda- Renda	1.94206	0.04074	Rejeita

No caso de quinze defasagens, Renda causa Venda, mas Venda não causa Renda o que não parece acontecer na Economia. No entanto, ao testarmos com 4 e 12 defasagens temos que Renda não causa Venda e que Venda causa Renda.

Como não podemos ter muita confiança em nossos resultados, devemos ter muita cautela ao utilizarmos essa metodologia.

⁴ Gujarati, Damodar N. Basic Econometrics pg 626

Assim, decidimos por apenas mencionar o teste como um mecanismo de captar as relações causa-efeito entre as variáveis, mas não utilizaremos de seus resultados no restante de nosso trabalho.

Como calcular a Elasticidade-Renda da Demanda?

Um fator determinante do poder de mercado de uma empresa é a elasticidade da sua demanda. Assim, o cálculo dessa elasticidade passa a ter grande importância, para uma avaliação do poder de mercado da firma.

Em princípio, acreditamos que por não se tratar de um bem essencial para o consumo, e por ter alguns bens substitutos, uma variação negativa na renda do consumidor ocasiona uma diminuição da renda do consumidor. O seguinte modelo de regressão exponencial poderá nos dar o valor da elasticidade procurada.

$$\ln Y_i = \beta_1 X_i^{\beta_2} e^{u_i}$$

Que pode ser escrito como um modelo linear nos parâmetros da seguinte forma:

$$\ln Y_i = \alpha + \beta_2 \ln X_i + u_i$$

Onde o β_2 mede exatamente a elasticidade-renda

O mais provável é que a demanda seja renda-inelástica, pois refrigerante não é um bem de luxo, sua elasticidade é menor que 1. Para a elasticidade preço, deve-se usar o mesmo procedimento.

Mais tarde, quando tivermos os modelos corretamente estimados, poderemos saber em valores absolutos a magnitude da elasticidade, compreendendo assim o comportamento do consumidor de refrigerantes.

i) MODELO ARIMA

Essa metodologia envolve o uso de uma regressão para a investigação das relações de defasagem entre as variáveis das séries, com a finalidade de estabelecer a relação funcional mais apropriada para as previsões.

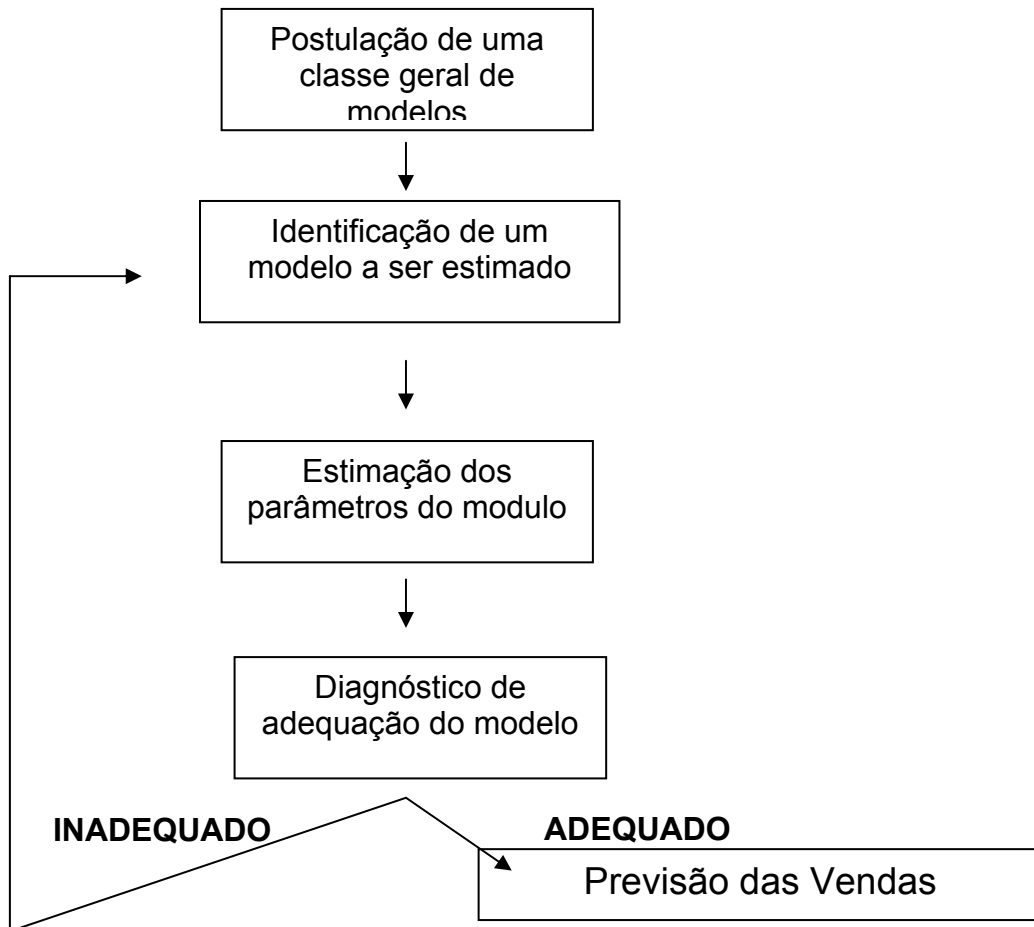
Na verdade, não poderemos tirar nenhuma conclusão econômica a partir do modelo ARIMA, que é conhecido como “ateórico”. Isto acontece pois Y só é explicado por seus valores defasados e dos termos do erro estocástico.

O modelo ARIMA(p,d,q) é um modelo auto-regressivo integrado de média móvel onde p é o número de termos auto-regressivos, d é o número de vezes que a série foi diferenciada para torna-la estacionária e q , o número de termos de média móvel.

No entanto, o primeiro passo para estimar o modelo é verificar a estacionariedade da série. Uma série é não estacionária quando sua média e variância não são constantes ao longo do tempo. Sem tomar as devidas precauções e trabalhando com séries desse tipo, os testes t e F não apresentarão as distribuições padrão, portanto não terão significado. Para não obtermos conclusões viesadas sobre a significância dos parâmetros de nossos modelos devemos verificar se a série é estacionária para enfim, podermos ter uma base válida para a previsão.

Após tornar as séries estacionárias, desenvolveremos detalhadamente a metodologia Box-Jenkins, que consiste no ajustamento de modelos auto-regressivos-integrados-médias móveis (ARIMA) a conjuntos de dados como segue o quadro a seguir⁵:

⁵ Apostila do Curso de Técnicas de Pesquisa em Economia, Marco Antonio F. de H.Cavalcanti e Fabrício Melo, PUC-Rio


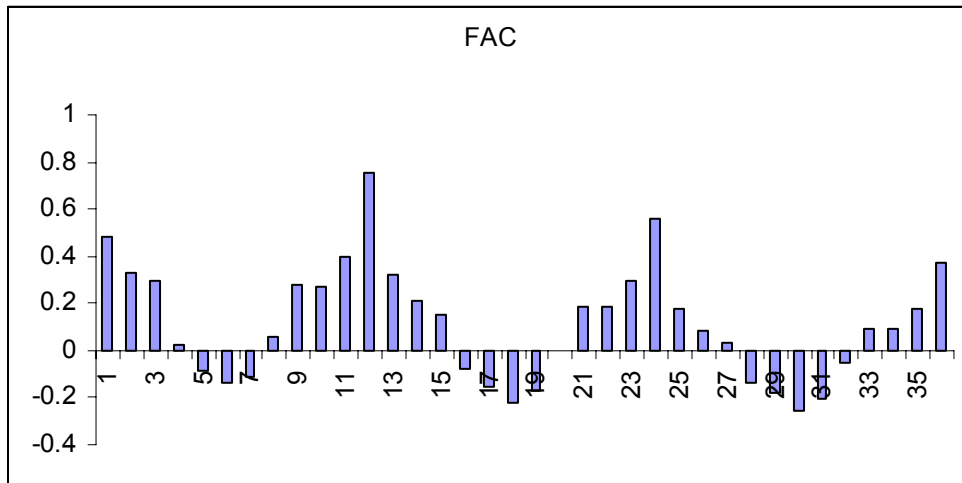


Na fase de identificação, verifica-se a estacionariedade das séries a serem modeladas. Caso essa condição não seja naturalmente satisfeita, deve-se tentar torná-las estacionárias através da diferenciação. É nessa fase que determinamos os valores de p , d e q , identificando qual processo será modelado. Na fase de estimação, os parâmetros do modelo são obtidos pela maximização da função de verossimilhança condicional. Isso equivale à estimação por mínimos quadrados, assumindo a normalidade dos resíduos.

O próximo passo é verificar se o modelo escolhido se ajusta razoavelmente aos dados. Os testes de aderência têm por finalidade verificar se a seqüência dos resíduos estimados caracteriza-se como um "ruído branco", isto é, não exista autocorrelação entre eles. Na hipótese de ausência da autocorrelação, considera-se o modelo adequado; caso contrário, volta-se ao estágio inicial da identificação para a seleção de outra alternativa.

Nosso ponto agora é verificar as Funções de auto-correlação (FAC) e funções de auto-correlação parcial (FACP) através dos correlogramas.


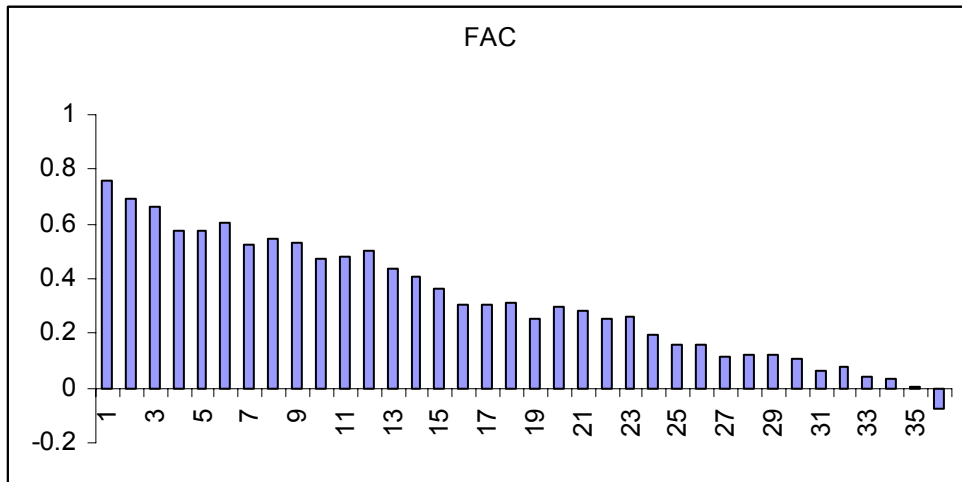
Observando o gráfico e o correlograma abaixo da série de Vendas, podemos observar que as FAC's nas defasagens 1, 2, 3, 9, 10, 11, 12, 13 e 24 parecem ser estatisticamente diferentes de zero. Na FACP, todas defasagens com exceção das 1, 12 e 13.



Date: 11/29/02 Time: 17:16
 Sample: 1994:08 2002:07
 Included observations: 96

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
. ****	. ****	1	0.484	0.484	23.156	0.000
. ***	. *	2	0.331	0.126	34.104	0.000
. **	. *	3	0.294	0.123	42.825	0.000
. . .	** . .	4	0.022	-0.244	42.876	0.000
. *	. *	5	-0.088	-0.115	43.672	0.000
. *	. *	6	-0.141	-0.083	45.762	0.000
. *	. *	7	-0.111	0.102	47.058	0.000
. . .	. **	8	0.061	0.249	47.461	0.000
. **	. ***	9	0.280	0.358	55.965	0.000
. **	. . .	10	0.271	0.011	64.018	0.000
. ***	. *	11	0.400	0.107	81.727	0.000
. *****	. *****	12	0.750	0.595	144.81	0.000
. **	*** . .	13	0.321	-0.380	156.45	0.000
. **	. *	14	0.212	-0.092	161.61	0.000
. *	. *	15	0.152	-0.090	164.30	0.000
. *	. . .	16	-0.077	0.045	165.00	0.000
. *	. *	17	-0.151	-0.128	167.71	0.000
. **	. *	18	-0.225	-0.097	173.81	0.000
. *	. . .	19	-0.172	0.034	177.41	0.000
. . .	. *	20	0.002	-0.088	177.41	0.000
. *	. . .	21	0.185	0.001	181.69	0.000
. *	. . .	22	0.186	0.039	186.08	0.000
. **	. . .	23	0.296	0.009	197.33	0.000
. ****	. . .	24	0.558	0.046	238.07	0.000
. *	. *	25	0.178	-0.108	242.29	0.000
. *	. . .	26	0.085	-0.024	243.26	0.000
.	27	0.035	0.044	243.43	0.000
. *	. *	28	-0.140	0.081	246.13	0.000
. *	. . .	29	-0.178	0.014	250.56	0.000
. **	. . .	30	-0.254	-0.036	259.72	0.000
. **	. *	31	-0.207	-0.085	265.95	0.000
. . .	. *	32	-0.049	-0.065	266.30	0.000
. *	. . .	33	0.095	-0.033	267.63	0.000
. *	. . .	34	0.092	0.012	268.92	0.000
. *	. . .	35	0.176	-0.048	273.70	0.000
. ***	. *	36	0.369	-0.067	295.03	0.000

A título de ilustração, analisaremos as FAC e FACP da série dessazonalizada das vendas. A FAC diminui exponencialmente e até a 24 defasagem elas são estatisticamente significantes diferentes de 0. Este é o padrão tipo de uma série não estacionária. A FACP diminui drasticamente depois da primeira defasagem



Date: 11/29/02 Time: 17:24
 Sample: 1994:08 2002:07
 Included observations: 96

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
*****	*****	1	0.762	57.466	0.000
*****	**	2	0.696	105.89	0.000
*****	*	3	0.665	150.66	0.000
****	.	4	0.577	184.65	0.000
****	*	5	0.572	218.45	0.000
*****	**	6	0.607	257.01	0.000
****	*.	7	0.528	286.45	0.000
****	*	8	0.544	318.06	0.000
****	.	9	0.533	348.81	0.000
****	.	10	0.470	372.96	0.000
****	.	11	0.480	398.46	0.000
****	*	12	0.505	427.02	0.000
***	*.	13	0.439	448.87	0.000
***	*	14	0.410	468.17	0.000
***	*	15	0.367	483.86	0.000
**	.	16	0.305	494.78	0.000
**	.	17	0.306	505.96	0.000
**	.	18	0.310	517.52	0.000
**	*	19	0.254	525.43	0.000

. **		. *		20	0.299	0.121	536.51	0.000
. **		. .		21	0.286	0.015	546.74	0.000
. **		. .		22	0.250	0.003	554.67	0.000
. **		. .		23	0.259	0.006	563.30	0.000
. *		. *		24	0.195	-0.151	568.26	0.000
. *		. .		25	0.160	-0.002	571.63	0.000
. *		. .		26	0.156	-0.036	574.91	0.000
. *		. .		27	0.116	-0.003	576.73	0.000
. *		. *		28	0.121	0.069	578.74	0.000
. *		. .		29	0.122	-0.036	580.85	0.000
. *		. .		30	0.104	0.027	582.39	0.000
. .		. *		31	0.060	-0.122	582.91	0.000
. *		. .		32	0.076	0.060	583.77	0.000
. .		. .		33	0.042	-0.044	584.03	0.000
. .		. .		34	0.032	-0.031	584.18	0.000
. .		. *		35	0.004	-0.089	584.18	0.000
. *		. *		36	-0.073	-0.157	585.02	0.000

Não devemos apenas nos basear nos padrões das FAC's e FACP's para verificar a presença ou não de estacionariedade nas séries. Devemos também realizar o teste de raiz unitária de Dickey-Fuller (DF) (ou Dickey-Fuller Aumentado (ADF), para corrigir autocorrelação nos erros).

O teste depende da equação estimada, de quantas defasagens em primeira diferença da variável devem ser incluídas, e se também há inclusão de tendência e intercepto. Deve-se, antes de mais nada, observar a significância dos parâmetros começando com um modelo mais geral com tendência, intercepto e um número considerável de defasagens que deve ser reduzido enquanto não se estiver rejeitando a hipótese de raiz unitária. Se não chegar a um valor mínimo de defasagens e não se consiga rejeitar a hipótese nula de raiz unitária, bem como a tendência não seja significativa, deve-se retirá-la e reestimar novamente apenas com o intercepto e um número grande de defasagens...assim por diante.

Logo, temos que a série de Vendas é estacionária. Pois rejeitamos a hipótese nula de não estacionariedade a um nível de significância de 5%, conforme segue o teste abaixo:

ADF Test Statistic	-3.673923	1% Critical Value*	-4.0686
		5% Critical Value	-3.4626
		10% Critical Value	-3.1574

*MacKinnon critical values for rejection of hypothesis of a unit root.

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(VENDA)
 Method: Least Squares
 Date: 11/29/02 Time: 18:25
 Sample(adjusted): 1995:07 2002:07
 Included observations: 85 after adjusting endpoints

Variable	Coefficient	Std. Error	t-Statistic	Prob.
VENDA(-1)	-1.831689	0.498565	-3.673923	0.0005
D(VENDA(-1))	0.775356	0.461055	1.681702	0.0970
D(VENDA(-2))	0.682945	0.423907	1.611073	0.1115
D(VENDA(-3))	0.907778	0.370976	2.447000	0.0168
D(VENDA(-4))	0.821950	0.322038	2.552336	0.0128
D(VENDA(-5))	0.632874	0.281568	2.247676	0.0277
D(VENDA(-6))	0.208724	0.254846	0.819020	0.4155
D(VENDA(-7))	-0.100539	0.225658	-0.445536	0.6573
D(VENDA(-8))	-0.219480	0.203505	-1.078499	0.2844
D(VENDA(-9))	0.036419	0.165704	0.219782	0.8267
D(VENDA(-10))	-0.030742	0.119812	-0.256588	0.7982
C	13946.25	3685.386	3.784203	0.0003
@TREND(1994:08)	47.32383	14.89806	3.176510	0.0022
R-squared	0.643775	Mean dependent var	26.78500	
Adjusted R-squared	0.584404	S.D. dependent var	1591.360	
S.E. of regression	1025.897	Akaike info criterion	16.84442	
Sum squared resid	75777506	Schwarz criterion	17.21800	
Log likelihood	-702.8879	F-statistic	10.84329	
Durbin-Watson stat	2.045977	Prob(F-statistic)	0.000000	

Desse modo, não precisaremos tornar a séries estacionárias. Com as FAC's e FACP's analisadas e a estacionariedade da série testada, estamos aptos para identificar o Modelo ARIMA a ser usado na previsão. Podemos concluir que no nosso caso, o parâmetro d é zero, pois trata-se de uma série estacionária.

Inicialmente iremos supor um AR(24) onde não necessitaremos incluir os termos até 24, mas somente os que forem estatisticamente significativos. Assim, temos que nosso modelo AR identificado é o seguinte:

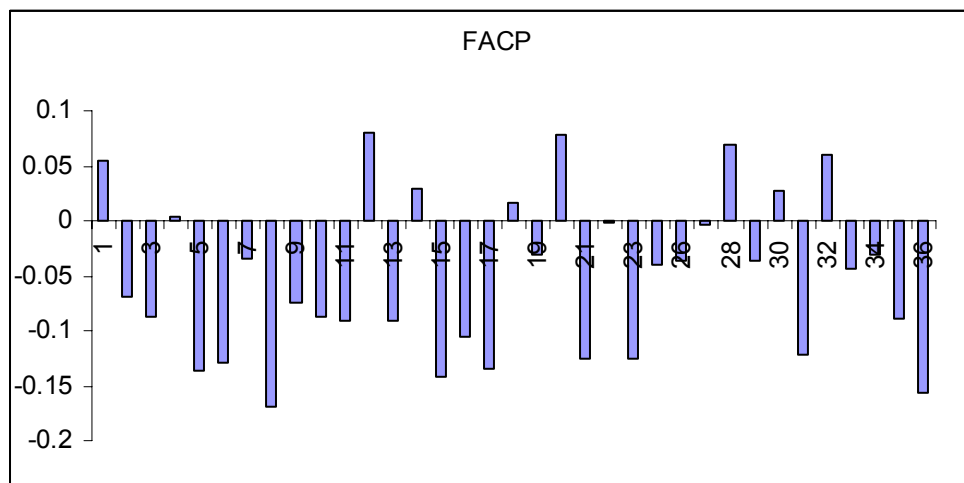
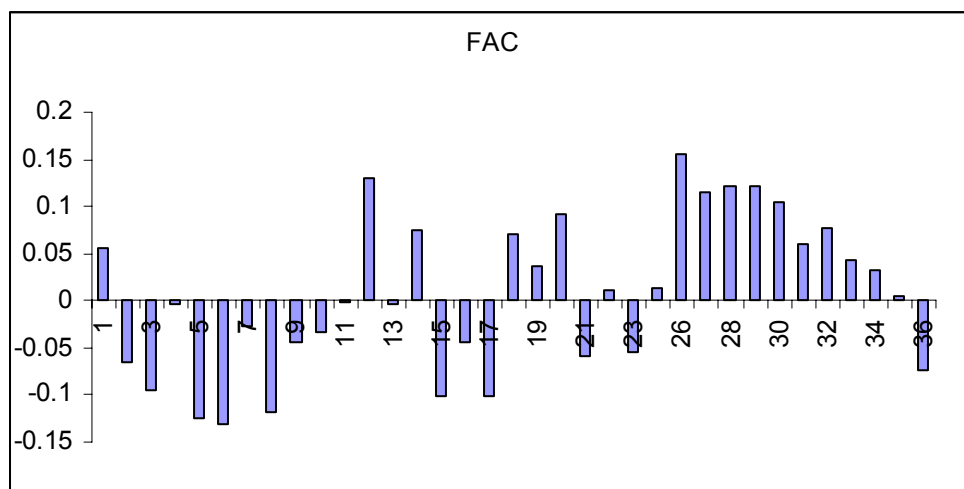
$$Y_t = \beta_1 + \beta_2 Y_{t-1} + \beta_3 Y_{t-2} + \beta_4 Y_{t-3} + \beta_5 Y_{t-9} + \beta_6 Y_{t-10} + \beta_7 Y_{t-11} + \beta_8 Y_{t-12} + \beta_9 Y_{t-13} + \beta_{10} Y_{t-24}$$

Dependent Variable: VENDA
 Method: Least Squares
 Date: 11/29/02 Time: 18:50
 Sample(adjusted): 1996:08 2001:06
 Included observations: 59 after adjusting endpoints

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	684.2768	993.9512	0.688441	0.4944
VENDA(-1)	0.258314	0.135909	1.900638	0.0632
VENDA(-2)	0.016234	0.054124	0.299948	0.7655
VENDA(-3)	0.000195	0.054825	0.003565	0.9972
VENDA(-9)	0.025017	0.057019	0.438758	0.6628
VENDA(-10)	-0.009474	0.055755	-0.169927	0.8658
VENDA(-11)	0.017769	0.054477	0.326183	0.7457

VENDA(-12)	0.864125	0.128109	6.745235	0.0000
VENDA(-13)	-0.321896	0.138622	-2.322119	0.0244
VENDA(-24)	0.106903	0.133741	0.799325	0.4280
R-squared	0.903218	Mean dependent var	9169.234	
Adjusted R-squared	0.885442	S.D. dependent var	1457.997	
S.E. of regression	493.4803	Akaike info criterion	15.39411	
Sum squared resid	11932616	Schwarz criterion	15.74623	
Log likelihood	-444.1262	F-statistic	50.81027	
Durbin-Watson stat	2.176516	Prob(F-statistic)	0.000000	

Para sabermos se o modelo tem um ajuste ideal o próximo passo é obter as FAC e FACP dos resíduos.



Nenhuma das autocorrelações individuais são estatisticamente significativas e o comportamento dos resíduos é puramente aleatório.

Date: 11/29/02 Time: 19:00
 Sample: 1996:08 2001:06
 Included observations: 59

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
. .	. .	1	0.055	0.055	0.1863	0.666
* .	* .	2	-0.066	-0.069	0.4587	0.795
* .	* .	3	-0.094	-0.087	1.0312	0.794
. .	. .	4	-0.003	0.003	1.0318	0.905
* .	* .	5	-0.124	-0.137	2.0490	0.842
* .	* .	6	-0.130	-0.129	3.1995	0.783
. .	. .	7	-0.026	-0.034	3.2451	0.861
* .	* .	8	-0.119	-0.169	4.2413	0.835
. .	* .	9	-0.044	-0.074	4.3831	0.884
. .	* .	10	-0.033	-0.087	4.4625	0.924
. .	* .	11	-0.002	-0.091	4.4630	0.954
. *	. *	12	0.129	0.080	5.7428	0.928
. .	* .	13	-0.004	-0.091	5.7441	0.955
. *	. .	14	0.074	0.029	6.1843	0.962
* .	* .	15	-0.101	-0.141	7.0135	0.957
. .	* .	16	-0.044	-0.105	7.1788	0.970
* .	* .	17	-0.102	-0.134	8.0705	0.965
. *	. .	18	0.071	0.016	8.5130	0.970
. .	. .	19	0.037	-0.030	8.6363	0.979
. *	. *	20	0.091	0.079	9.4051	0.978
* .	* .	21	-0.058	-0.125	9.7254	0.982
. .	. .	22	0.011	-0.002	9.7374	0.989
. .	* .	23	-0.055	-0.125	10.039	0.991
. .	. .	24	0.014	-0.040	10.058	0.994

Com o objetivo de se achar um melhor modelo , retiraremos as defasagens com maior p-valor e observaremos o efeito da extração dessas defasagens sobre os critérios de informação de Akaike e Schwarz.

Variáveis retiradas	Akaike info criterion	Schwarz criterion
	15.39411	15.74623
3	15.36021	15.67712
10	15.32693	15.60863
11	15.29472	15.5412
2	15.26383	15.4751
9	15.23315	15.40921
24	15.13744	15.26593
1	15.17674	15.2731

Dependent Variable: VENDA
 Method: Least Squares
 Date: 11/29/02 Time: 19:33
 Sample(adjusted): 1995:09 2001:06
 Included observations: 70 after adjusting endpoints

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	991.0131	387.5175	2.557338	0.0129
VENDA(-1)	0.230553	0.107091	2.152872	0.0350
VENDA(-12)	0.969411	0.042785	22.65790	0.0000
VENDA(-13)	-0.279389	0.104733	-2.667637	0.0096
R-squared	0.907463	Mean dependent var		8986.155
Adjusted R-squared	0.903257	S.D. dependent var		1465.437
S.E. of regression	455.8026	Akaike info criterion		15.13744
Sum squared resid	13711897	Schwarz criterion		15.26593
Log likelihood	-525.8105	F-statistic		215.7435
Durbin-Watson stat	2.156070	Prob(F-statistic)		0.000000

Os resíduos dessa série também apresentam padrão aleatório como segue:

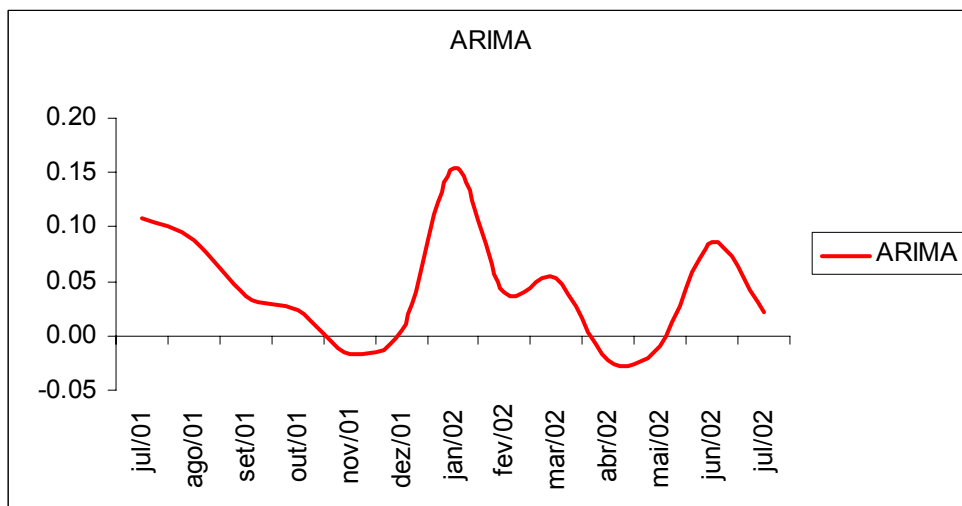


Date: 11/29/02 Time: 19:36
 Sample: 1995:09 2001:06
 Included observations: 70

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
. .	. .	1	0.019	0.019	0.0268	0.870
. .	. .	2	0.006	0.006	0.0296	0.985
* .	* .	3	-0.104	-0.105	0.8509	0.837
. .	. .	4	-0.004	0.000	0.8519	0.931
** .	** .	5	-0.191	-0.192	3.6833	0.596
* .	* .	6	-0.095	-0.103	4.3951	0.623
. .	. .	7	-0.022	-0.022	4.4322	0.729
* .	* .	8	-0.091	-0.141	5.1046	0.746
. .	. .	9	-0.016	-0.043	5.1268	0.823
. .	. .	10	0.016	-0.035	5.1478	0.881
. .	* .	11	-0.031	-0.110	5.2318	0.919
. * .	. .	12	0.077	0.051	5.7469	0.928
. .	. .	13	0.007	-0.055	5.7515	0.955
* .	. .	14	0.066	0.015	6.1429	0.963
* .	* .	15	-0.083	-0.089	6.7680	0.964
. .	. .	16	0.016	-0.036	6.7933	0.977
* .	* .	17	-0.144	-0.149	8.7731	0.947
. * .	* .	18	0.097	0.079	9.6922	0.941
. .	* .	19	-0.042	-0.068	9.8687	0.956
. * .	. .	20	0.081	0.040	10.526	0.958
* .	* .	21	-0.087	-0.108	11.311	0.956
. * .	. * .	22	0.127	0.079	13.011	0.933
* .	* .	23	-0.077	-0.099	13.655	0.936
. .	. .	24	0.020	0.003	13.699	0.953

Portanto já temos o nosso modelo de vendas definido:




A partir de agora, podemos realizar a previsão:



O Modelo ARIMA calculado, apresenta um bom ajuste às variações no volume, no entanto, não conseguiu prever a forte queda de volume acontecida em Janeiro de 2002. Mas para verificar a acuracidade das previsões feitas, devemos observar a estatística "Theil Inequality Coefficient"


Supondo que a amostra estimada é $t=S, S+1, \dots, S+h$ e denotando o valor atual e estimado no período t como y_t e ψ_t , a estatística é reportada da seguinte forma:




Ela varia de 0 a 1, sendo o menor valor um ajuste perfeito entre a variável estimada e a previsão.

O erro médio previsto é ser decomposto em:


Bias Proportion – o quão distante a média da estimativa está da média real:



Variance Proportion – o quão distante a variância da estimativa está da variância real:



Covariance Proportion - mede a existência de erros não previstos:



Root Mean Squared Error	596.2563
Mean Absolute Error	470.0604
Mean Abs. Percent Error	5.331428
Theil Inequality Coefficient	0.030320
Bias Proportion	0.439329
Variance Proportion	0.073918
Covariance Proportion	0.486753


Observando nossa previsão podemos observar a partir das estatísticas mencionadas que a série de vendas encontra-se com um Theil Inequality Coefficient muito baixo, a proporção da variância também muito baixa mas com um proporção de viés considerável indicando que a média da estimativa não está muito próxima das vendas reais. Na verdade, o mês de Janeiro contribuiu gravemente para essa estatística, o que pode ter acontecido devido a uma falha de execução das firmas de refrigerante ou de um fator econômico que não conseguimos filtrar com esse modelo. No entanto, chegamos a conclusão de que o modelo de previsão está corretamente estimado e portanto nos leva a uma boa previsão das vendas futuras para os anos posteriores.

Um previsão é razoável quando a proporção do bias e da variância são pequenas sendo a maior parte da tendência concentrada na proporção da covariância⁶.



⁶ Pindyck, Robert S. and Daniel L. Rubinfeld (1998) *Econometric Models and Economic Forecasts*, 4th edition, Mc Graw -Hill

ii) MODELO SAZONAL MULTIPLICATIVO

Quando analisamos a FAC e a FACP da série das vendas, analisamos um forte perfil de sazonalidade:



Agora, aplicaremos um modelo sazonal multiplicativo específico para séries sazonais onde:
SARIMA(1,0,0) X (1,0,0)₁₂



Dependent Variable: VENDA

Method: Least Squares

Date: 11/30/02 Time: 15:49



Sample(adjusted): 1995:09 2001:06

Included observations: 70 after adjusting endpoints

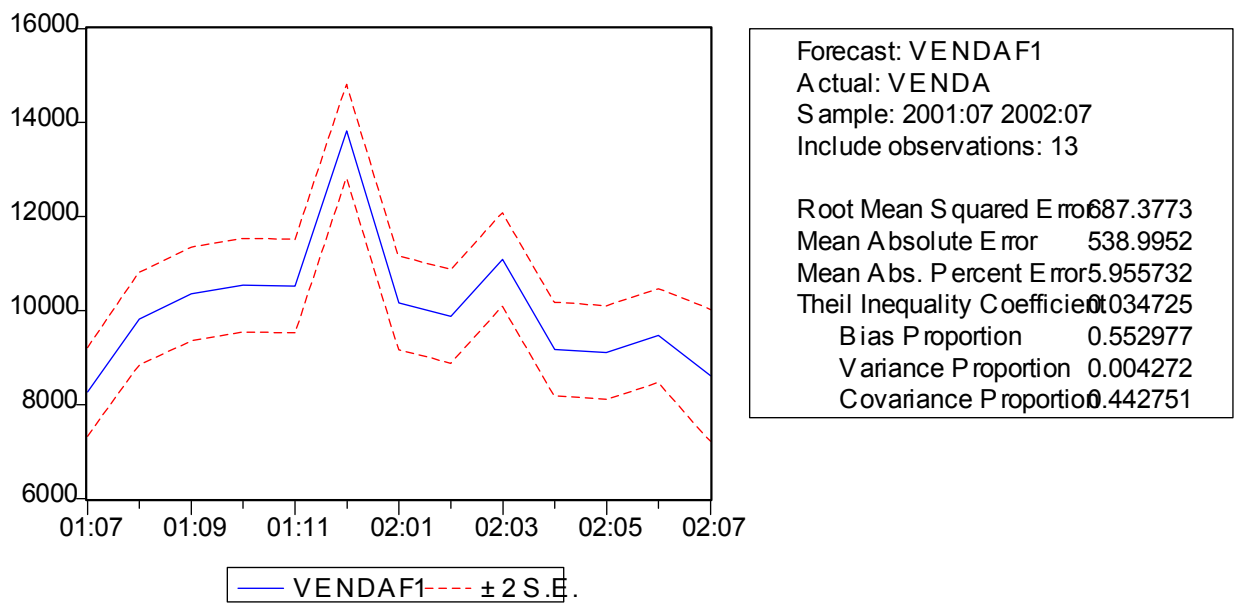
Convergence achieved after 8 iterations

VENDA=C(1)*VENDA(-1)+C(2)*VENDA(-12)-C(1)*C(2)*VENDA(-13)

	Coefficient	Std. Error	t-Statistic	Prob.
C(1)	0.318783	0.101454	3.142139	0.0025
C(2)	1.042516	0.009473	110.0538	0.0000
R-squared	0.897853	Mean dependent var		8986.155
Adjusted R-squared	0.896351	S.D. dependent var		1465.437
S.E. of regression	471.7915	Akaike info criterion		15.17911
Sum squared resid	15135934	Schwarz criterion		15.24335
Log likelihood	-529.2687	F-statistic		597.7072
Durbin-Watson stat	2.253686	Prob(F-statistic)		0.000000



Root Mean Squared Error	687.3773
Mean Absolute Error	538.9952
Mean Abs. Percent Error	5.955732
Theil Inequality Coefficient	0.034725
Bias Proportion	0.552977
Variance Proportion	0.004272
Covariance Proportion	0.442751



Podemos perceber que o modelo sazonal multiplicativo superestimou o volume numa proporção maior que o modelo ARIMA calculado anteriormente. No entanto, ambos modelos apresentam um baixo Theil Inequality Coefficient e um Bias Proportion indicando que a média da estimativa está um pouco distante da média real. A proporção na variância é muito baixa, mas no geral o modelo SARIMA apresenta um bom ajuste aos dados reais. Nosso próximo passo portanto, é incluir em nossa análise um modelo que inclua variáveis exógenas e possam explicar as vendas a partir de seus valores defasados bem como de variáveis econômicas que possam influenciar o comportamento do consumidor. Assim, daremos início a estimação de um modelo de defasagens distribuídas – ADL.

iii) MODELO ADL

Como o modelo auto-regressivo é “ateórico” e não pode ser relacionado a ele nenhuma teoria econômica, não podemos identificar nele o comportamento do consumidor frente à mudanças das principais variáveis macro-econômicas.

Assim, torna-se necessário um modelo em função dos valores defasados nas vendas, dos valores contemporâneos e defasados de variáveis exógenas além do distúrbio aleatório.

Desenvolveremos um modelo de defasagens distribuídas – ADL

Iniciaremos a estimação com um número grande de defasagens respeitando a homocedasticidade dos resíduos. Em seguida, as defasagens de maior valor devem ser retiradas com atenção nos critérios de informação para depois verificar se os dados são consistentes com a teoria econômica.

Dependent Variable: VENDA
 Method: Least Squares
 Date: 11/30/02 Time: 16:48
 Sample(adjusted): 1995:09 2001:06
 Included observations: 70 after adjusting endpoints

Variable	Coefficient	Std. Error	t-Statistic	Prob.
VENDA(-1)	0.213785	0.148511	1.439523	0.1572
VENDA(-2)	0.228818	0.129135	1.771926	0.0835
VENDA(-3)	0.086288	0.128433	0.671854	0.5053
VENDA(-4)	-0.363426	0.132184	-2.749387	0.0087
VENDA(-5)	0.084334	0.135578	0.622034	0.5372
VENDA(-6)	0.067015	0.131836	0.508316	0.6138
VENDA(-7)	-0.036516	0.129160	-0.282721	0.7787
VENDA(-8)	-0.072379	0.117500	-0.615987	0.5412
VENDA(-9)	0.244982	0.107529	2.278290	0.0277
VENDA(-10)	-0.016811	0.111257	-0.151102	0.8806
VENDA(-11)	0.030522	0.115296	0.264725	0.7925
VENDA(-12)	0.532799	0.118029	4.514129	0.0000
VENDA(-13)	0.071739	0.135348	0.530033	0.5988
RENDA	69.41129	33.91746	2.046477	0.0469
RENDA(-1)	-12.38771	49.74901	-0.249004	0.8045
RENDA(-2)	-98.48228	45.05509	-2.185819	0.0343
RENDA(-3)	20.34571	44.61094	0.456070	0.6506
RENDA(-4)	116.3770	44.55565	2.611948	0.0123
RENDA(-5)	-47.75481	46.64595	-1.023772	0.3117

RENDA(-6)	-69.34391	45.66867	-1.518413	0.1362
RENDA(-7)	51.11893	46.43929	1.100769	0.2771
RENDA(-8)	66.75903	44.95780	1.484927	0.1449
RENDA(-9)	-80.21014	41.29157	-1.942531	0.0586
RENDA(-10)	-14.56140	41.71161	-0.349097	0.7287
RENDA(-11)	-25.07220	40.71967	-0.615727	0.5413
RENDA(-12)	101.9878	46.52617	2.192053	0.0338
RENDA(-13)	-81.16977	32.81609	-2.473475	0.0174
R-squared	0.955597	Mean dependent var	8986.155	
Adjusted R-squared	0.928749	S.D. dependent var	1465.437	
S.E. of regression	391.1677	Akaike info criterion	15.06028	
Sum squared resid	6579522.	Schwarz criterion	15.92756	
Log likelihood	-500.1099	F-statistic	35.59255	
Durbin-Watson stat	1.823416	Prob(F-statistic)	0.000000	

Retirando as defasagens com maior p-valor, temos um novo modelo:

	Variáveis retiradas	Akaike info criterion	Schwarz criterion
		15.06028	15.92756
venda	10	15.03224	15.8674
venda	11	15.00496	15.80799
renda	1	14.97854	15.74946
venda	5	14.95553	15.69432
venda	7	14.92829	15.63496
renda	3	14.90233	15.57688
venda	8	14.88493	15.52735
venda	6	14.8602	15.47051
venda	13	14.84156	15.41974
renda	10	14.83972	15.38578
renda	5	14.85674	15.37068

Method: Least Squares

Date: 11/30/02 Time: 17:00

Sample(adjusted): 1995:09 2001:06

Included observations: 70 after adjusting endpoints

Variable	Coefficient	Std. Error	t-Statistic	Prob.
VENDA(-1)	0.233350	0.068916	3.386023	0.0013
VENDA(-2)	0.242526	0.078687	3.082176	0.0033
VENDA(-3)	0.153406	0.049936	3.072083	0.0034
VENDA(-4)	-0.292712	0.068287	-4.286504	0.0001
VENDA(-9)	0.208041	0.060918	3.415067	0.0012
VENDA(-12)	0.525248	0.094677	5.547803	0.0000
RENDA	66.00359	20.13625	3.277849	0.0018
RENDA(-2)	-88.38706	28.16268	-3.138446	0.0028
RENDA(-4)	91.11809	25.55067	3.566172	0.0008
RENDA(-5)	-25.25110	16.05823	-1.572470	0.1218
RENDA(-6)	-51.08943	18.20469	-2.806388	0.0070
RENDA(-7)	31.50666	17.84514	1.765560	0.0832
RENDA(-8)	43.68938	17.90655	2.439854	0.0181
RENDA(-9)	-59.26652	23.78968	-2.491271	0.0159
RENDA(-11)	-38.39584	14.85242	-2.585157	0.0125
RENDA(-12)	101.8178	31.85165	3.196626	0.0023
RENDA(-13)	-74.86784	22.27319	-3.361343	0.0014
R-squared	0.952608	Mean dependent var	8986.155	

Adjusted R-squared	0.938301	S.D. dependent var	1465.437
S.E. of regression	364.0037	Akaike info criterion	14.83972
Sum squared resid	7022430.	Schwarz criterion	15.38578
Log likelihood	-502.3901	F-statistic	66.58344
Durbin-Watson stat	1.912452	Prob(F-statistic)	0.000000


Os resíduos são “bem comportados”, ou seja, não apresentam nenhum sinal de autocorrelação, conforme podemos observar no correlograma a seguir:

Date: 11/30/02 Time: 17:02
Sample: 1995:09 2001:06
Included observations: 70

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
. .	. .	1	-0.024	-0.024	0.0431	0.836
.* .	.* .	2	-0.131	-0.132	1.3232	0.516
.* .	.* .	3	-0.077	-0.086	1.7737	0.621
. .	.* .	4	-0.040	-0.064	1.8933	0.755
. * .	. * .	5	0.142	0.120	3.4624	0.629
.* .	.* .	6	-0.112	-0.128	4.4467	0.616
. .	. .	7	0.037	0.061	4.5537	0.714
. * .	. * .	8	0.099	0.091	5.3488	0.720
. .	. .	9	0.039	0.056	5.4721	0.791
. .	. .	10	-0.046	-0.044	5.6467	0.844
. .	. * .	11	0.027	0.095	5.7075	0.892
* .	* .	12	-0.098	-0.127	6.5472	0.886
. * .	. * .	13	0.113	0.122	7.6744	0.864
.* .	.* .	14	-0.074	-0.108	8.1681	0.880
.* .	.* .	15	-0.160	-0.137	10.525	0.785
. .	.* .	16	-0.018	-0.095	10.555	0.836
.* .	.* .	17	-0.103	-0.116	11.567	0.826
. * .	. .	18	0.132	0.021	13.259	0.776
. .	. .	19	0.040	0.053	13.414	0.817
. .	. .	20	-0.022	0.002	13.462	0.857
. .	. .	21	-0.021	-0.015	13.507	0.890
. .	. .	22	-0.023	0.033	13.563	0.916
* .	* .	23	-0.069	-0.066	14.078	0.925
* .	* .	24	-0.115	-0.122	15.517	0.905

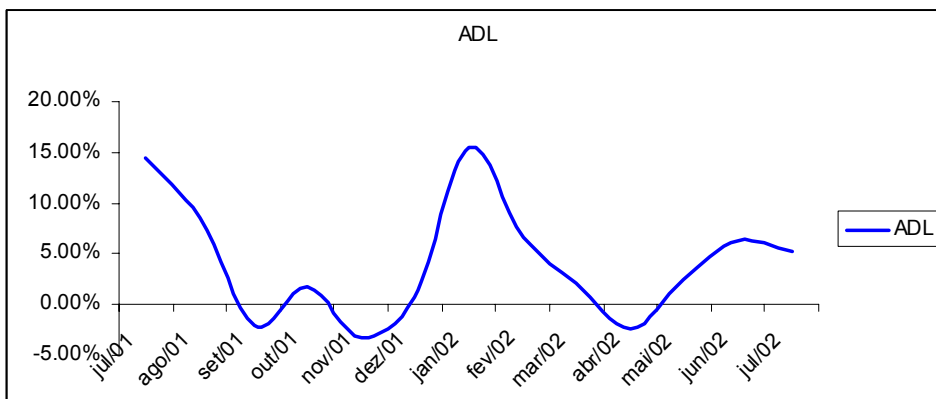

Com a hipótese de homocedasticidade satisfeita, devemos nos concentrar se o fundamento teórico é satisfeito.

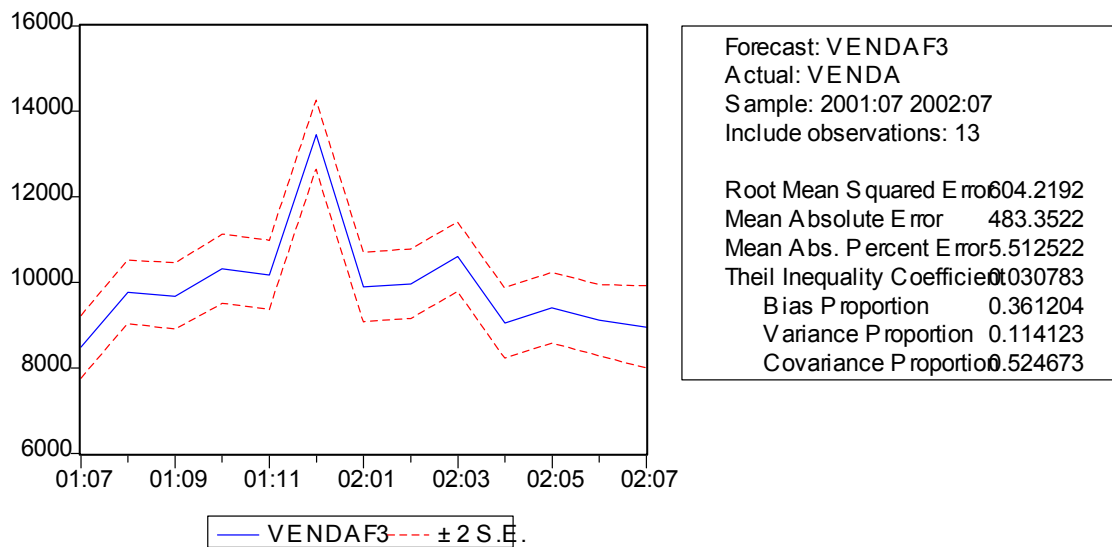
Para isso, calcularemos e analisaremos o multiplicador de longo prazo das vendas em relação a renda do consumidor:



Como um aumento na renda do consumidor acarreta em um aumento na venda de refrigerante, temos que o sinal do multiplicador deve ser positivo, que é confirmado pois em nosso caso, o multiplicador é de 44.69.

Como todos os aspectos foram satisfeitos, já podemos usar o modelo para fins de previsão.





Root Mean Squared Error	604.2192
Mean Absolute Error	483.3522
Mean Abs. Percent Error	5.512522
Theil Inequality Coefficient	0.030783
Bias Proportion	0.361204
Variance Proportion	0.114123
Covariance Proportion	0.524673

Assim como os outros modelos, o nosso modelo ADL apresentou um ótimo Theil Inequality Coefficient e uma concentração de erros na covariância. Além disso, erros na variância também foram significativos nesse modelo. Vale ressaltar, que como o modelo ADL leva em consideração valores defasados de variáveis exógenas, o mais correto seria a estimação dessas variáveis. Em nosso caso, estamos realizando a previsão com dados reais da renda média real para o período da previsão. Assim, o modelo ADL pode apresentar um melhor ajuste aos dados reais nesse caso, pois ele está “ganhando informação”.

Nos modelos até agora analisados, tivemos que as vendas eram variáveis endógenas e a renda do consumidor como variável exógena. Nosso próximo passo é analisar outros modelos de previsão como o VAR e o VEC onde não existe distinção entre variáveis endógenas ou exógenas.

iii) MODELOS DE AUTO-REGRESSÃO VETORIAL IRRESTRITO (VAR)
iv) MODELOS DE CORREÇÃO DE ERRO (VEC)

Nos modelos de Auto-Regressão vetorial, não existe qualquer distinção entre as variáveis endógenas ou exógenas. Em nosso modelo, as vendas de refrigerante são explicadas em termos de seus próprios valores defasados e dos valores defasados de Renda e do Preço. Assim, não precisamos determinar quais variáveis são exógenas ou endógenas, todas elas são endógenas.

O modelo VAR para duas variáveis endógenas (Venda e Preço), segue a seguinte forma:

$$\begin{bmatrix} \Delta V_t \\ \Delta P_t \end{bmatrix} = \begin{bmatrix} \alpha_{11} & \alpha_{12} \\ \alpha_{21} & \alpha_{22} \end{bmatrix} \begin{bmatrix} V_{t-1} \\ P_{t-1} \end{bmatrix} + \begin{bmatrix} \epsilon_{1t} \\ \epsilon_{2t} \end{bmatrix}$$

Onde os ϵ_{it} são os termos de erro estocástico, mais conhecidos como impulsos.


Em nosso estudo, adotaremos um modelo com 3 variáveis endógenas: Venda, Renda e Preço. Analisaremos diferentes modelos, a partir da série de Vendas Dessazonalizada e Sazonalizada além do modelo Irrestrito e o Modelo com o Mecanismo de Correção de Erros. Assim, teremos 4 modelos diferentes e analisaremos os resultados de cada um separadamente.

O Mecanismo de Correção de Erro (MCE) é um meio de reconciliar o comportamento a curto prazo de uma variável com o seu comportamento de longo prazo. Ele permite calcular qual proporção de desequilíbrio de uma variável em um determinado período é corrigida no próximo período.

Inicialmente estimamos um modelo com um numero grande de defasagens e retiramos as defasagens, sempre observando o efeito da extração sobre os critérios de formação de Akaike e Schwarz.

1) Modelo Irrestrito – Série de Vendas Dessazonalizada

Defasagens	Akaike Information Criteria	Schwarz Criteria
10	16.21025	19.12823
9	16.13999	18.75542
8	16.05325	18.37073
7	15.92309	17.94714
6	15.75734	17.49237
5	15.86018	17.31047



Date: 11/23/02 Time: 14:05
 Sample(adjusted): 1995:02 2001:06
 Included observations: 77 after adjusting endpoints
 Standard errors & t-statistics in parentheses


	VENDASA	RENDA	PRECO
VENDASA(-1)	0.250695 (0.12882) (1.94610)	-0.000461 (0.00121) (-0.38065)	1.79E-06 (5.4E-06) (0.33194)
VENDASA(-2)	0.275533 (0.12943) (2.12886)	-0.000537 (0.00122) (-0.44176)	9.09E-07 (5.4E-06) (0.16767)
VENDASA(-3)	0.298413 (0.13424) (2.22295)	-0.000130 (0.00126) (-0.10321)	1.60E-06 (5.6E-06) (0.28533)
VENDASA(-4)	-0.159880 (0.13699) (-1.16712)	0.000772 (0.00129) (0.59946)	-3.37E-07 (5.7E-06) (-0.05868)
VENDASA(-5)	0.041608 (0.13100) (0.31763)	0.000475 (0.00123) (0.38619)	1.14E-05 (5.5E-06) (2.07871)
VENDASA(-6)	0.245696 (0.12141) (2.02372)	-0.001347 (0.00114) (-1.18093)	-1.21E-05 (5.1E-06) (-2.37326)
RENDA(-1)	10.91227 (13.5041)	0.591169 (0.12692)	-0.001407 (0.00057)

	(0.80807)	(4.65796)	(-2.48833)
RENDA(-2)	-9.117945 (15.6114) (-0.58406)	0.156323 (0.14672) (1.06544)	0.003534 (0.00065) (5.40568)
RENDA(-3)	7.540617 (18.9317) (0.39831)	-0.141246 (0.17793) (-0.79384)	0.000345 (0.00079) (0.43523)
RENDA(-4)	-14.95998 (17.9028) (-0.83562)	0.088011 (0.16826) (0.52308)	-0.001695 (0.00075) (-2.26123)
RENDA(-5)	-6.641118 (18.3836) (-0.36125)	0.034288 (0.17278) (0.19845)	0.000641 (0.00077) (0.83204)
RENDA(-6)	5.657849 (16.0199) (0.35318)	0.116317 (0.15056) (0.77256)	-0.001080 (0.00067) (-1.61016)
PRECO(-1)	-2456.974 (2990.40) (-0.82162)	23.02131 (28.1049) (0.81912)	0.896318 (0.12524) (7.15685)
PRECO(-2)	6057.310 (3931.74) (1.54062)	-31.94467 (36.9518) (-0.86450)	0.079942 (0.16466) (0.48549)
PRECO(-3)	-1690.473 (3759.60) (-0.44964)	9.409355 (35.3340) (0.26630)	-0.062275 (0.15745) (-0.39551)
PRECO(-4)	1399.289 (3759.50) (0.37220)	3.877851 (35.3331) (0.10975)	0.130714 (0.15745) (0.83020)
PRECO(-5)	-3562.920 (3308.73) (-1.07682)	-4.544606 (31.0966) (-0.14614)	-0.105401 (0.13857) (-0.76063)
PRECO(-6)	680.4245 (2487.99) (0.27348)	1.187078 (23.3830) (0.05077)	-0.093107 (0.10420) (-0.89356)
C	790.8974 (2048.53) (0.38608)	28.55545 (19.2528) (1.48318)	0.124288 (0.08579) (1.44870)
R-squared	0.792083	0.636978	0.870595
Adj. R-squared	0.727557	0.524317	0.830434
Sum sq. resids	9921903.	876.3906	0.017403
S.E. equation	413.6028	3.887182	0.017322
F-statistic	12.27539	5.653896	21.67801
Log likelihood	-562.2666	-202.8905	213.9468
Akaike AIC	15.09783	5.763390	-5.063555
Schwarz SC	15.67617	6.341732	-4.485213
Mean dependent	8769.175	122.8540	1.270093

S.D. dependent	792.4015	5.636063	0.042065
Determinant Residual Covariance		318.3625	
Log Likelihood		-549.6576	
Akaike Information Criteria		15.75734	
Schwarz Criteria		17.49237	

2) Modelo Irrestrito – Série de Vendas com sazonalidade

Defasagens	Akaike Information Criteria	Schwarz Criteria
10	15.92687	18.84485
9	15.80344	18.41887
8	16.45938	18.77686



Date: 11/23/02 Time: 14:13
Sample(adjusted): 1995:05 2001:06
Included observations: 74 after adjusting endpoints
Standard errors & t-statistics in parentheses


	VENDA	RENDA	PRECO
VENDA(-1)	-0.235924 (0.19213) (-1.22797)	-0.002696 (0.00056) (-4.78272)	-3.72E-07 (3.8E-06) (-0.09892)
VENDA(-2)	0.424971 (0.25069) (1.69517)	0.000523 (0.00074) (0.71056)	8.10E-07 (4.9E-06) (0.16510)
VENDA(-3)	0.702126 (0.25805) (2.72089)	0.001208 (0.00076) (1.59488)	4.85E-06 (5.1E-06) (0.95983)
VENDA(-4)	0.024276 (0.23820) (0.10191)	0.000902 (0.00070) (1.29068)	-6.56E-06 (4.7E-06) (-1.40713)
VENDA(-5)	-0.090183 (0.21960) (-0.41067)	-0.000959 (0.00064) (-1.48856)	7.40E-06 (4.3E-06) (1.72252)

VENDA(-6)	-0.850621 (0.23500) (-3.61967)	-0.002255 (0.00069) (-3.26995)	-7.43E-06 (4.6E-06) (-1.61437)
VENDA(-7)	0.060523 (0.22827) (0.26514)	3.66E-05 (0.00067) (0.05465)	1.01E-05 (4.5E-06) (2.25672)
VENDA(-8)	-0.107345 (0.21789) (-0.49265)	-6.92E-05 (0.00064) (-0.10829)	-1.55E-06 (4.3E-06) (-0.36320)
VENDA(-9)	1.160558 (0.19678) (5.89787)	0.001881 (0.00058) (3.25822)	4.08E-07 (3.9E-06) (0.10590)
RENDA(-1)	138.5827 (75.1838) (1.84325)	0.997511 (0.22061) (4.52168)	-0.000374 (0.00147) (-0.25403)
RENDA(-2)	-104.6003 (94.1701) (-1.11076)	0.010521 (0.27632) (0.03807)	0.003814 (0.00184) (2.06890)
RENDA(-3)	-89.65634 (95.7092) (-0.93676)	-0.466337 (0.28083) (-1.66055)	-0.001937 (0.00187) (-1.03388)
RENDA(-4)	107.2792 (90.2141) (1.18916)	0.036010 (0.26471) (0.13604)	0.001691 (0.00177) (0.95751)
RENDA(-5)	-83.54914 (85.2823) (-0.97968)	0.075960 (0.25024) (0.30355)	-0.001405 (0.00167) (-0.84177)
RENDA(-6)	134.8273 (88.4082) (1.52505)	0.558590 (0.25941) (2.15331)	0.000721 (0.00173) (0.41652)
RENDA(-7)	-55.34126 (76.3062) (-0.72525)	-0.333520 (0.22390) (-1.48959)	-0.001917 (0.00149) (-1.28314)
RENDA(-8)	125.7554 (72.3313) (1.73860)	0.157369 (0.21224) (0.74148)	-0.000625 (0.00142) (-0.44115)
RENDA(-9)	-173.6270 (59.9650) (-2.89547)	-0.101331 (0.17595) (-0.57590)	0.000234 (0.00117) (0.19970)
PRECO(-1)	3222.213 (7786.37) (0.41383)	21.61374 (22.8470) (0.94602)	0.924846 (0.15241) (6.06797)
PRECO(-2)	-11435.73 (10140.8) (-1.12769)	-27.51821 (29.7555) (-0.92481)	-0.021631 (0.19850) (-0.10897)

PRECO(-3)	18004.00 (10000.1) (1.80038)	39.35490 (29.3426) (1.34122)	-0.041087 (0.19575) (-0.20990)
PRECO(-4)	-7209.898 (9394.70) (-0.76744)	-15.08699 (27.5662) (-0.54730)	0.202026 (0.18390) (1.09858)
PRECO(-5)	-1813.665 (9256.29) (-0.19594)	-10.39991 (27.1601) (-0.38291)	-0.240305 (0.18119) (-1.32628)
PRECO(-6)	-3425.144 (9466.81) (-0.36181)	-19.75991 (27.7778) (-0.71136)	0.106743 (0.18531) (0.57603)
PRECO(-7)	-3306.971 (9500.54) (-0.34808)	-4.095398 (27.8767) (-0.14691)	0.025860 (0.18597) (0.13906)
PRECO(-8)	1894.178 (8604.20) (0.22015)	14.84837 (25.2467) (0.58813)	-0.255168 (0.16842) (-1.51504)
PRECO(-9)	5230.904 (6415.41) (0.81537)	-0.099206 (18.8243) (-0.00527)	0.182534 (0.12558) (1.45355)
C	-2014.489 (5944.48) (-0.33888)	22.43612 (17.4424) (1.28629)	0.055169 (0.11636) (0.47412)
R-squared	0.769649	0.840925	0.889531
Adj. R-squared	0.634443	0.747555	0.824691
Sum sq. resids	38599375	332.3284	0.014790
S.E. equation	916.0332	2.687849	0.017931
F-statistic	5.692418	9.006357	13.71876
Log likelihood	-592.0947	-160.5776	210.1603
Akaike AIC	16.75932	5.096692	-4.923250
Schwarz SC	17.63112	5.968501	-4.051442
Mean dependent	8868.211	123.2641	1.270097
S.D. dependent	1515.073	5.349599	0.042825
Determinant Residual Covariance		151.3416	
Log Likelihood		-500.7273	
Akaike Information Criteria		15.80344	
Schwarz Criteria		18.41887	

3) Modelo Restrito – Mecanismo de Correção de Erro - Série com Sazonalidade

Defasagens	Akaike Information Criteria	Schwarz Criteria
11	14.39648	17.8383
10	15.86183	18.99224



Date: 11/23/02 Time: 14:25
 Sample(adjusted): 1995:08 2001:06
 Included observations: 71 after adjusting endpoints
 Standard errors & t-statistics in parentheses

Cointegrating Eq:		CointEq1		
VENDA(-1)		1.000000		
RENDA(-1)		44.60429		
		(12.0735)		
		(3.69441)		
PRECO(-1)		-535.5536		
		(1836.41)		
		(-0.29163)		
C		-13764.88		
Error Correction:		D(VENDA)	D(RENDA)	D(PRECO)
CointEq1		-0.394650	-0.003956	-1.10E-06
		(0.19933)	(0.00067)	(8.1E-06)
		(-1.97983)	(-5.87126)	(-0.13643)
D(VENDA(-1))		-0.566670	0.002167	1.60E-06
		(0.27497)	(0.00093)	(1.1E-05)
		(-2.06088)	(2.33171)	(0.14297)
D(VENDA(-2))		-0.506717	0.001775	8.80E-06
		(0.29652)	(0.00100)	(1.2E-05)
		(-1.70886)	(1.77093)	(0.73036)
D(VENDA(-3))		-0.474886	0.001612	1.98E-05
		(0.29281)	(0.00099)	(1.2E-05)
		(-1.62184)	(1.62844)	(1.66501)
D(VENDA(-4))		-0.868138	0.001674	1.26E-05


	(0.26381) (-3.29076)	(0.00089) (1.87723)	(1.1E-05) (1.17182)
D(VENDA(-5))	-0.726870 (0.23208) (-3.13195)	0.001219 (0.00078) (1.55458)	1.56E-05 (9.4E-06) (1.65415)
D(VENDA(-6))	-0.797162 (0.20073) (-3.97136)	0.000455 (0.00068) (0.67028)	1.09E-06 (8.2E-06) (0.13404)
D(VENDA(-7))	-0.741777 (0.19934) (-3.72110)	0.000493 (0.00067) (0.73213)	1.30E-05 (8.1E-06) (1.60088)
D(VENDA(-8))	-1.007726 (0.19541) (-5.15704)	-0.000598 (0.00066) (-0.90530)	1.00E-05 (7.9E-06) (1.26499)
D(VENDA(-9))	-0.852659 (0.20835) (-4.09251)	-0.000576 (0.00070) (-0.81767)	1.77E-05 (8.5E-06) (2.09616)
D(VENDA(-10))	-0.815969 (0.17337) (-4.70645)	-0.001300 (0.00059) (-2.21932)	1.80E-05 (7.0E-06) (2.55018)
D(VENDA(-11))	-0.797252 (0.16719) (-4.76844)	-1.75E-05 (0.00057) (-0.03105)	1.28E-05 (6.8E-06) (1.87920)
D(RENDA(-1))	-7.137531 (41.5358) (-0.17184)	-0.215461 (0.14038) (-1.53480)	0.000244 (0.00169) (0.14463)
D(RENDA(-2))	-54.77387 (43.1634) (-1.26899)	-0.278950 (0.14589) (-1.91212)	0.002549 (0.00175) (1.45391)
D(RENDA(-3))	-87.16962 (43.4370) (-2.00681)	-0.482535 (0.14681) (-3.28681)	2.76E-06 (0.00176) (0.00156)
D(RENDA(-4))	62.91263 (42.4412) (1.48235)	-0.427652 (0.14344) (-2.98132)	0.001943 (0.00172) (1.12683)
D(RENDA(-5))	6.500924 (50.0801) (0.12981)	-0.346510 (0.16926) (-2.04718)	-0.000304 (0.00203) (-0.14922)
D(RENDA(-6))	-20.45407 (51.4313) (-0.39770)	-0.206646 (0.17383) (-1.18879)	0.000696 (0.00209) (0.33306)
D(RENDA(-7))	-20.23084 (48.9512) (-0.41329)	-0.603406 (0.16545) (-3.64713)	-0.002303 (0.00199) (-1.15798)

D(RENDA(-8))	37.76557 (44.1975) (0.85447)	-0.390091 (0.14938) (-2.61140)	-0.001392 (0.00180) (-0.77509)
D(RENDA(-9))	-6.435047 (44.1576) (-0.14573)	-0.442353 (0.14925) (-2.96393)	-0.001581 (0.00179) (-0.88159)
D(RENDA(-10))	-55.98512 (41.4960) (-1.34917)	-0.262744 (0.14025) (-1.87340)	-0.002464 (0.00169) (-1.46152)
D(RENDA(-11))	-73.05357 (40.4555) (-1.80577)	-0.655619 (0.13673) (-4.79490)	-0.001568 (0.00164) (-0.95434)
D(PRECO(-1))	3967.758 (4198.85) (0.94496)	15.47768 (14.1914) (1.09064)	-0.003876 (0.17057) (-0.02272)
D(PRECO(-2))	-926.6594 (4181.05) (-0.22163)	6.548822 (14.1312) (0.46343)	-0.008744 (0.16985) (-0.05148)
D(PRECO(-3))	1688.618 (4266.57) (0.39578)	36.90851 (14.4203) (2.55949)	0.118060 (0.17333) (0.68115)
D(PRECO(-4))	7216.026 (4073.35) (1.77152)	34.35850 (13.7672) (2.49567)	0.224853 (0.16548) (1.35882)
D(PRECO(-5))	1832.268 (4160.83) (0.44036)	47.36813 (14.0629) (3.36831)	-0.032536 (0.16903) (-0.19248)
D(PRECO(-6))	13247.85 (3939.54) (3.36279)	28.05251 (13.3150) (2.10684)	-0.087970 (0.16004) (-0.54968)
D(PRECO(-7))	1871.119 (3632.83) (0.51506)	18.90758 (12.2783) (1.53991)	0.008375 (0.14758) (0.05675)
D(PRECO(-8))	3188.393 (3501.32) (0.91063)	30.32458 (11.8339) (2.56252)	-0.224971 (0.14224) (-1.58165)
D(PRECO(-9))	3223.110 (3636.26) (0.88638)	1.994985 (12.2899) (0.16233)	0.134242 (0.14772) (0.90876)
D(PRECO(-10))	-698.0243 (3637.96) (-0.19187)	9.586373 (12.2957) (0.77965)	0.160976 (0.14779) (1.08923)
D(PRECO(-11))	-1733.608 (3422.83) (-0.50648)	5.419396 (11.5686) (0.46846)	0.013923 (0.13905) (0.10013)

C	351.9809 (70.2972) (5.00704)	0.301635 (0.23759) (1.26955)	-0.002544 (0.00286) (-0.89080)
R-squared	0.956667	0.926969	0.631978
Adj. R-squared	0.915741	0.857994	0.284402
Sum sq. resids	7449654.	85.09917	0.012294
S.E. equation	454.9009	1.537487	0.018480
F-statistic	23.37564	13.43936	1.818245
Log likelihood	-511.1601	-107.1750	206.7315
Akaike AIC	15.38479	4.004930	-4.837506
Schwarz SC	16.50020	5.120335	-3.722100
Mean dependent	35.10980	-0.005493	0.000845
S.D. dependent	1567.143	4.079986	0.021846
Determinant Residual Covariance		17.12590	
Log Likelihood		-403.0749	
Akaike Information Criteria		14.39648	
Schwarz Criteria		17.83830	

4) Modelo Restrito – Mecanismo de Correção de Erro - Série Dessazonalizada

Defasagens	Akaike Information Criteria	Schwarz Criteria
13	14.4881	18.56777
12	14.36635	18.12455
11	14.68622	18.12804



Date: 11/23/02 Time: 14:35
Sample(adjusted): 1995:09 2001:06
Included observations: 70 after adjusting endpoints
Standard errors & t-statistics in parentheses

Cointegrating Eq:	CointEq1
VENDASA(-1)	1.000000
RENDA(-1)	52.14484 (18.1334) (2.87563)
PRECO(-1)	1479.747 (2838.04)


		(0.52140)		
C		-17175.55		
Error Correction:				
	D(VENDASA)	D(RENDA)	D(PRECO)	
CointEq1	-0.065426 (0.21720) (-0.30122)	-0.003153 (0.00089) (-3.52323)	-1.02E-05 (1.0E-05) (-1.02156)	
D(VENDASA(-1))	-0.733818 (0.25615) (-2.86480)	0.002706 (0.00106) (2.56409)	1.73E-05 (1.2E-05) (1.47519)	
D(VENDASA(-2))	-0.587946 (0.26862) (-2.18878)	0.003893 (0.00111) (3.51771)	1.93E-05 (1.2E-05) (1.56721)	
D(VENDASA(-3))	-0.327434 (0.30457) (-1.07508)	0.003826 (0.00125) (3.04903)	2.55E-05 (1.4E-05) (1.82584)	
D(VENDASA(-4))	-0.494894 (0.30299) (-1.63338)	0.003684 (0.00125) (2.95110)	1.34E-05 (1.4E-05) (0.96241)	
D(VENDASA(-5))	-0.297903 (0.30077) (-0.99048)	0.002955 (0.00124) (2.38433)	2.57E-05 (1.4E-05) (1.86235)	
D(VENDASA(-6))	-0.266591 (0.27219) (-0.97945)	0.002822 (0.00112) (2.51661)	8.27E-06 (1.2E-05) (0.66146)	
D(VENDASA(-7))	-0.461776 (0.27909) (-1.65458)	0.002250 (0.00115) (1.95684)	1.32E-05 (1.3E-05) (1.03409)	
D(VENDASA(-8))	-0.484389 (0.25009) (-1.93683)	0.000228 (0.00103) (0.22102)	1.20E-05 (1.1E-05) (1.04655)	
D(VENDASA(-9))	-0.413558 (0.23136) (-1.78755)	0.000498 (0.00095) (0.52221)	1.71E-05 (1.1E-05) (1.60710)	
D(VENDASA(-10))	-0.331370 (0.22497) (-1.47292)	0.001669 (0.00093) (1.80071)	3.01E-05 (1.0E-05) (2.91302)	
D(VENDASA(-11))	-0.357680 (0.23851) (-1.49962)	0.003110 (0.00098) (3.16471)	1.44E-05 (1.1E-05) (1.31421)	
D(VENDASA(-12))	0.240424 (0.23516) (1.02237)	0.000693 (0.00097) (0.71532)	1.20E-05 (1.1E-05) (1.10775)	

D(RENDA(-1))	6.226993 (26.9492) (0.23106)	-0.272158 (0.11104) (-2.45098)	-0.003167 (0.00124) (-2.55992)
D(RENDA(-2))	6.507418 (24.1040) (0.26997)	-0.276990 (0.09932) (-2.78893)	0.001300 (0.00111) (1.17484)
D(RENDA(-3))	1.878742 (23.6301) (0.07951)	-0.291637 (0.09736) (-2.99531)	0.000783 (0.00108) (0.72167)
D(RENDA(-4))	8.157304 (22.6334) (0.36041)	-0.249295 (0.09326) (-2.67317)	-0.000575 (0.00104) (-0.55304)
D(RENDA(-5))	4.725827 (23.5254) (0.20088)	-0.339333 (0.09693) (-3.50069)	9.67E-05 (0.00108) (0.08954)
D(RENDA(-6))	-7.177322 (26.7894) (-0.26792)	-0.507873 (0.11038) (-4.60105)	-0.001893 (0.00123) (-1.53947)
D(RENDA(-7))	-8.793130 (33.6371) (-0.26141)	-0.594962 (0.13860) (-4.29275)	-0.001819 (0.00154) (-1.17789)
D(RENDA(-8))	-12.30530 (36.9321) (-0.33319)	-0.419477 (0.15217) (-2.75656)	-0.001741 (0.00170) (-1.02706)
D(RENDA(-9))	-3.350683 (34.0187) (-0.09850)	-0.408791 (0.14017) (-2.91641)	-0.002375 (0.00156) (-1.52089)
D(RENDA(-10))	-5.523322 (34.2238) (-0.16139)	-0.388846 (0.14101) (-2.75748)	-0.002369 (0.00157) (-1.50809)
D(RENDA(-11))	-9.861478 (32.6097) (-0.30241)	-0.463225 (0.13436) (-3.44754)	-0.002277 (0.00150) (-1.52128)
D(RENDA(-12))	19.02879 (33.0028) (0.57658)	0.451506 (0.13598) (3.32030)	-0.003494 (0.00152) (-2.30641)
D(PRECO(-1))	-1209.479 (3671.92) (-0.32939)	5.661343 (15.1297) (0.37419)	0.034356 (0.16857) (0.20381)
D(PRECO(-2))	341.2603 (3639.19) (0.09377)	23.88625 (14.9948) (1.59297)	0.081614 (0.16707) (0.48851)
D(PRECO(-3))	1478.389 (3697.36)	46.29513 (15.2345)	0.034046 (0.16974)

	(0.39985)	(3.03884)	(0.20058)
D(PRECO(-4))	7880.246 (4013.22) (1.96357)	51.33160 (16.5359) (3.10424)	0.328064 (0.18424) (1.78065)
D(PRECO(-5))	-225.6023 (4309.37) (-0.05235)	42.56482 (17.7562) (2.39719)	-0.004433 (0.19783) (-0.02241)
D(PRECO(-6))	7874.655 (4687.65) (1.67987)	-5.561816 (19.3148) (-0.28796)	0.112903 (0.21520) (0.52464)
D(PRECO(-7))	-2441.945 (4017.31) (-0.60786)	6.726406 (16.5528) (0.40636)	-0.032929 (0.18443) (-0.17855)
D(PRECO(-8))	1894.041 (3401.72) (0.55679)	8.233982 (14.0163) (0.58746)	-0.103051 (0.15617) (-0.65989)
D(PRECO(-9))	-1251.392 (3336.76) (-0.37503)	0.433904 (13.7487) (0.03156)	0.173958 (0.15318) (1.13562)
D(PRECO(-10))	-1295.894 (3139.10) (-0.41282)	24.92250 (12.9342) (1.92686)	0.226221 (0.14411) (1.56979)
D(PRECO(-11))	-643.1084 (3378.79) (-0.19034)	8.243500 (13.9219) (0.59213)	-0.072139 (0.15511) (-0.46507)
D(PRECO(-12))	1576.319 (3123.07) (0.50473)	14.85946 (12.8682) (1.15474)	-0.096380 (0.14337) (-0.67223)
C	182.4504 (76.3169) (2.39069)	-0.563392 (0.31445) (-1.79165)	-0.003774 (0.00350) (-1.07710)
R-squared	0.716137	0.927862	0.687585
Adj. R-squared	0.387920	0.844452	0.326355
Sum sq. resids	4939505.	83.85997	0.010410
S.E. equation	392.8861	1.618834	0.018037
F-statistic	2.181903	11.12417	1.903454
Log likelihood	-490.0755	-105.6486	209.1458
Akaike AIC	15.08787	4.104244	-4.889879
Schwarz SC	16.30848	5.324856	-3.669267
Mean dependent	37.83928	-0.029000	0.000714
S.D. dependent	502.1838	4.104599	0.021975
Determinant Residual Covariance		12.30322	
Log Likelihood		-385.8222	
Akaike Information Criteria		14.36635	
Schwarz Criteria		18.12455	

IV- CONCLUSÃO

Na verdade, não existe um modelo melhor ou pior para a previsão de vendas no mercado de refrigerantes. Todos os modelos estudados, apresentaram um bom ajuste e tem suas vantagens e desvantagens.




	ARIMA	SARIMA	ADL
Root Mean Squared Error	596.256	687.377	604.219
Mean Absolute Error	470.06	538.995	483.352
Mean Abs. Percent Error	5.33143	5.95573	5.51252
Theil Inequality Coefficient	0.03032	0.03473	0.03078
Bias Proportion	0.43933	0.55298	0.3612
Variance Proportion	0.07392	0.00427	0.11412
Covariance Proportion	0.48675	0.44275	0.52467

- O modelo ARIMA apresentou melhores resultados que os demais
- Os estatísticas do modelo ADL podem estar superestimadas, pois sua previsão elvou em consideração valores reais da renda, e não valores estimados.
- Todos os modelos levam a um erro maior na proporção da variância, indicando que os erros de previsão que os erros de previsão do modelo são baseados em erros não sistêmicos.
- Erros de proporção na variância foram maiores no modelo ADL enquanto no modelo SARIMA a média dos valores estimados ficou distante da média dos valores reais.
- O mês de Janeiro não conseguiu ser reproduzido por nenhum modelo, mesmo o que levou em consideração variáveis exógenas, fazendo-nos supor que houve uma falha de

execução da indústria, ou falta de matéria prima, ou até mesmo uma antecipação das vendas de Dezembro, já que os modelos subestimaram as vendas desse mês.

Os modelos VAR e VEC também apresentam um bom ajuste da realidade.



Com base nesses resultados, podemos tirar diversas conclusões sobre a capacidade preditiva dos modelos:

- Todos os modelos superestima o volume de vendas na maioria dos meses.
- A capacidade preditiva dos modelos reduz-se bastante quando analisamos principalmente os meses de dezembro a fevereiro, onde as vendas foram muito menores do que o esperado (especialmente em Janeiro/02).
- Ambos modelos com séries dessazonalizadas apresentaram desempenho melhor que os demais.
- Os Modelos VEC com mecanismos de correção do erro também apresentaram melhores resultados, o que comprova que alterações de Curto Prazo no Preço e na Renda tem efeitos positivos significativos sobre as Vendas que são corrigidos mensalmente
- Na média, o modelo 3 (com sazonalidade das vendas e Mecanismo de Correção de Erro) apresentou resultados mais próximos da realidade.
- O modelo com o pior ajuste foi o modelo 1, com a série dessazonalizada e sem o MCE

IV- REFERÊNCIA BIBLIOGRÁFICA

- Enders; Walter [1995]- Applied Econometric Time Series; John Wiley & Sons, Inc, Nova Iorque*
- Allen; P.G. and Fildes, R. (2000) Econometric Forecasting, in Principles of Forecasting: A Handbook for Researchers and Practitioners, J.S. Armstrong (ed.): Norwell, MA: Kluwer Academic Publishers.*
- Clements, M.and Hendry, D. Intercept corrections and structural change, Journal of Applied Econometrics, 11(5), 475-494.*
- Granger, C.W.J.and Newbold, P. (1986) Forecasting Economic Time Series, 2nd edition, Academic Press.*
- Löf, M. and Franses, P.H. (2000) On Forecasting Cointegrated Seasonal Time Series, SSE/EFI Working Paper Series in Economics and Finance, No.350.*
- Lutkepohl, H. (1987) Forecasting aggregated Vector ARMA processes, Springer-Verlag, Berlin Heidelberg.*
- Meese, R. and Geweke, J. (1984) A comparison of autoregressive univariate forecasting procedures for macroeconomic time series, Journal of Business and Economic Statistics, 2, 191-200.*
- Pindyck, Robert S. Daniel L. Rubinfeld (1998) Econometric Models and Economic Forecasts, 4th eadition, McGraw-Hill*
- Apostila do Curso de Técnicas de Pesquisa em Economia ,Marco Antonio F. de H.Cavalcanti e Fabrício Melo, PUC-Rio*
- Gujarati,D.;Basic Econometric;McGraw Hill*