**PREVISÃO DE PREÇOS DE BOVINO, SUÍNO E FRANGO COM MODELOS
DE SÉRIES TEMPORAIS**

MIRIAN RUMENOS PIEDADE BACCHI

Orientador: Prof. Rodolfo Hoffmann

**Tese apresentada à Escola Superior
de Agricultura "Luiz de Queiroz",
da Universidade de São Paulo, para
obtenção do título de "Doutor" em
Agronomia. ÁREA DE CONCENTRAÇÃO:
Economia Agrária.**

**PIRACICABA
ESTADO DE SÃO PAULO - BRASIL
AGOSTO DE 1994**

Ficha catalográfica preparada pela Seção de Livros da
Divisão de Biblioteca e Documentação - PCLQ/USP

Bacchi, Mirian Rumenos Piedade
B116p Previsão de preços de bovino, suíno e frango com
 modelos de séries temporais. Piracicaba, 1994.
 172p.

Tese - ESALQ
Bibliografia.

1. Análise de série temporal 2. Carne - Mercado
3. Estatística aplicada 4. Preço agrícola - Previsão
I. Escola Superior de Agricultura Luiz de Queiroz,
Piracicaba

CDD 338.136

**PREVISÃO DE PREÇOS DE BOVINO, SUÍNO E FRANGO COM MODELOS
DE SÉRIES TEMPORAIS**

Mirian Rumenos Piedade Bacchi

Aprovada em: 10.10.1994

Comissão julgadora:

Prof.Dr. Rodolfo Hoffmann.....ESALQ/USP

Prof.Dra. Heloisa Lee Burnquist.....ESALQ/USP

Prof.Dra. Ana Lucia Kassouf.....ESALQ/USP

Prof.Dr. Francisco Alberto Pino.....IEA/SAASP

Prof.Dr. Pedro Valls Pereira.....IME/USP

Prof.Dr. Rodolfo Hoffmann

Orientador

Agradeço

ao Prof. Rodolfo Hoffmann pelo constante apoio, incentivo e orientação;

ao corpo docente do Departamento de Economia e Sociologia Rural da ESALQ pela amizade e valiosos ensinamentos oferecidos durante o Curso de Doutorado. Agradeço, particularmente, aos Profs. Dr. Geraldo Sant'Ana de Camargo Barros, Heloísa Lee Burnquist e Ana Lúcia Kassouf pelas sugestões apresentadas para o aperfeiçoamento deste trabalho. Neste sentido, agradeço, também, aos demais membros da banca examinadora;

aos funcionários do DESR/ESALQ pela inestimável colaboração e cordial acolhida;

aos colegas do Curso de Pós-Graduação que de uma forma ou outra contribuíram para a realização desse trabalho.

CONTEÚDO

	Página
LISTA DE TABELAS.....	v.
LISTA DE FIGURAS.....	ix.
RESUMO	xii.
SUMMARY.....	xv.
1.- INTRODUÇÃO	1
1.1- A Importância dos Modelos de Previsão	1
1.2.- Características Gerais da Séries de Preços de Bovino, Suíno e Frango	3
1.3.- Objetivo	14
2.- REVISÃO DE LITERATURA	16
3.- METODOLOGIA, PROCEDIMENTOS E DADOS	22
3.1- Modelos	22
3.1.1- Modelos Estocásticos Univariados	22
3.1.1.1- Modelos Estocásticos Univariados para Séries Estacionárias	22
3.1.1.2- Modelos Estocásticos Univariados para Séries Não Estacionárias	25
3.1.1.3- Modelos Estocásticos Univariados para Séries Sazonais	27
3.1.2- Modelos de Função de Transferência	30
3.1.3- Modelos de Intervenção	36
3.2.- Construção de Modelos de Box e Jenkins	43

3.2.1.-	Transformação dos Dados	43
3.2.2.-	Estrutura do Modelo	45
3.2.3.-	Autocorrelações	46
3.2.4.-	Autocorrelações Parciais	49
3.2.5.-	Determinação da Ordem dos Polinômios dos Modelos de Previsão	53
3.2.6.-	Estimativas Iniciais dos Parâmetros	62
3.2.7.-	Verificação	66
3.2.8.-	Previsões.....	72
3.2.8.1.-	Previsões com Base nas Formas Alternativas do Modelo ARIMA	80
3.2.8.2.-	Previsões com Modelos de Função de Transferência	82
3.2.8.3.-	Intervalo de Confiança para a Previsão	84
3.3.-	Relações Causais	85
3.4.-	Teste de Raiz Unitária e Co-integração	88
3.5.-	Critério para Comparação do Desempenho dos Modelos	99
3.6.-	Dados	100
4.-	RESULTADOS E DISCUSSÃO	102
4.1.-	Teste para Transformação de Dados	102
4.2.-	Teste de Causalidade	105
4.3.-	Teste de Raiz Unitária e de Co-integração	111
4.4.-	Resultados dos Modelos de Previsão	122
4.4.1.-	Previsão de Preços de Bovino	122

4.4.1.1.- Modelos Univariado e de Intervenção	122
4.4.1.2.- Modelo de Função de Transferência .	129
4.5.1.- Previsão de Preços de Suíno	136
4.5.1.1.- Modelos Univariado e de Intervenção	136
4.5.1.2.- Modelo de Função de Transferência .	142
4.6.1.- Previsão de Preços de Frango.....	149
4.6.1.1.- Modelos Univariado e de Intervenção	149
4.6.1.2.- Modelo de Função de Transferência .	155
5.- CONCLUSÕES	158
6.- REFERÊNCIAS BIBLIOGRÁFICAS	162
7.- APÊNDICE	172

LISTA DE TABELAS

Página

Tabela 1- Teste F para valores futuros dos coeficientes das regressões correlacionando as séries de preço de bovino (PB), preço de suíno (PS) e preço de frango (PF).....	106
Tabela 2- Coeficientes das variáveis das regressões ajustadas no teste de causalidade para preço de bovino versus preço de suíno.....	108
Tabela 3- Coeficientes das variáveis das regressões ajustadas no teste de causalidade para preço de bovino versus preço de frango.....	109
Tabela 4- Coeficientes das variáveis das regressões ajustadas no teste de causalidade para preço de suíno versus preço de frango.....	110
Tabela 5- Teste de raiz unitária para séries individuais (τ_{τ}).....	113
Tabela 6- Teste de raiz unitária para séries individuais (τ_{μ}).....	114
Tabela 7- Teste de raiz unitária para séries individuais (τ).....	115

Tabela 8- Teste de raiz unitária para séries individuais (PHILLIPS e PERRON).....	116
Tabela 9- Teste de raiz unitária sazonal para séries individuais ($\tau_{\mu d}$).....	118
Tabela 10- Autocorrelações e autocorrelações parciais estimadas para a série de preço de bovino.....	123
Tabela 11- Previsões para preço real da arroba de boi gordo e observações no mercado físico (período: julho de 1991 a junho de 1992). Índice de Theil(IT).....	126
Tabela 12- Matriz de correlação dos coeficientes estimados de modelo B.....	127
Tabela 13- Correlações cruzadas entre preço de bovino e preço de frango e entre preço de bovino e preço de suíno.....	131
Tabela 14- Previsões <u>um passo a frente</u> para preço real da arroba de boi gordo e observações no mercado físico (período: julho de 1989 a junho de 1989). Índice de Theil (IT).....	134
Tabela 15- Autocorrelações e autocorrelações parciais estimadas para a série de preço de suíno.....	137

Tabela 16- Previsões para preço real da arroba de suíno e observações no mercado físico (período: julho de 1991 a junho de 1992). Índice de Theil (IT).....	141
Tabela 17- Correlações cruzadas entre preço de suíno e preço de frango e entre preço de suíno e preço de bovino.....	143
Tabela 18- Previsões <u>um passo a frente</u> para preço real da arroba de suíno e observações no mercado físico (período: julho de 1991 a junho de 1992). Índice de Theil (IT).....	146
Tabela 19- Previsões <u>um passo a frente</u> para preço real da arroba de suíno e observações no mercado físico (período: julho de 1988 a junho de 1989). Índice de Theil (IT).....	148
Tabela 20- Autocorrelações e autocorrelações parciais estimadas para a série de preço de frango.....	150
Tabela 21- Previsões para preço real de frango (kg) e observações no mercado físico (período: julho de 1991 a junho de 1992). Índice de Theil (IT).....	153
Tabela 22- Matriz de correlação dos coeficientes estimados do modelo J.....	154

Tabela 23- Correlações cruzadas entre preço de frango e preço de suíno e entre preço de frango e preço de bovino..... 156

Tabela 24- Índices de Theil (IT) dos modelos de previsão um passo a frente de preço de frango (univariado e função de transferência). Período: julho de 1991 a junho de 1992 (1) e julho de 1988 a junho de 1989 (2)..... 156

LISTA DE FIGURAS

Página

Figura 1- Evolução dos preços reais de bovino, de janeiro de 1955 a junho de 1992.....	4
Figura 2- Média móvel de preços reais de bovino, suíno e frango, de janeiro de 1955 a junho de 1992...	7
Figura 3- Evolução dos preços reais de frango, de janeiro de 1960 a junho de 1992.....	10
Figura 4- Evolução dos preços reais de suíno, de janeiro de 1955 a junho de 1992.....	12
Figura 5- Efeitos dinâmicos simulados em análise de intervenção.....	41
Figura 6- Relações teóricas entre média e amplitude para alguns valores de λ	44
Figura 7- Exemplo de função de autocorrelação.....	48
Figura 8- Construções teóricas de funções de autocorrelação e autocorrelação parcial.....	55

Figura 9- Funções teóricas de correlação cruzada.....	60
Figura 10- Média e amplitude de sub-séries com 12 observações da série de preço de boi gordo, período 1978-91.....	103
Figura 11- Média e amplitude de sub-séries com 12 observações da série de preço de suíno, período 1978-91.....	103
Figura 12- Média e amplitude de sub-séries com 12 observações da série de preço de frango, período 1978-91.....	104
Figura 13- Previsões de preço real de boi gordo (arroba), de julho de 1991 a junho de 1992...	128
Figura 14- Previsões de preço real de boi gordo (arroba)- <u>um passo a frente</u> , de julho de a 1988 a junho 1989.....	135
Figura 15- Previsões de preço real de suíno (arroba), de julho de 1991 a junho de 1992.....	142
Figura 16- Previsões de preço real de suíno (arroba)- <u>um passo a frente</u> , de julho de 1991 a junho de 1992.....	147
Figura 17- Previsões de preço real de suíno (arroba)- <u>um passo a frente</u> , de julho de 1988 a junho de 1989.....	149

Figura 18-	Previsões de preço real de frango (kg),	
	de julho de 1991 a junho de 1992.....	154

PREVISÃO DE PREÇOS DE BOVINO, SUÍNO E FRANGO COM MODELOS
E SÉRIES TEMPORAIS

Mirian Rumenos Piedade Bacchi

Orientador: Prof. Rodolfo Hoffmann

RESUMO

No presente trabalho utilizaram-se modelos de séries temporais Box & Jenkins, na forma univariada e função de transferência (envolvendo variáveis explicativas), para previsão de preços de bovino, suíno e frango para o estado de São Paulo. Os modelos foram ajustados tomando-se as séries de preços reais de janeiro de 1978 a junho de 1991, nos logaritmos dos valores observados. Para a comparação do desempenho dos modelos foi utilizado o Índice de Theil calculado com 12 previsões.

Preliminarmente, foram feitos testes de causalidade entre as séries de preços de bovino, suíno e frango, visando uma orientação para a especificação dos modelos de função de transferência. Os resultados desses testes indicaram causalidade no sentido de preço de frango para preço de bovino e suíno. Não foi detectada causalidade no sentido de preço de

suíno para preço de bovino e preço de frango. Os testes indicaram, ainda, a possibilidade de existir uma relação causal no sentido de preço de bovino para preço de suíno e frango.

Foram também, preliminarmente, realizados testes de integração e cointegração para aquelas séries, tendo-se verificado, com esses testes, que elas são estacionárias nas diferenças de primeira ordem $[I(1)]$ e co-integradas. Com base nesses resultados especificaram-se os modelos de função de transferência incluindo um "termo de correção de erro".

Os modelos univariados para as séries de preços de bovino e suíno, nas diferenças de primeira ordem (com termos de intervenção para captar a variação estacional) e nas diferenças de primeira ordem simples e sazonal, forneceram, segundo o critério de Theil, boas previsões. O desempenho dos modelos univariados da série de preço de frango pode ser considerado razoável, tendo-se encontrado valores para o Índice de Theil da ordem de 0,6.

A inclusão da variável explicativa preço de frango nos modelos de previsão de preços de bovino e suíno (um passo a frente) teve efeito positivo e substancial na qualidade das previsões, no primeiro caso, e positivo mas pequeno, no segundo. O efeito da inclusão da variável preço de suíno nos

modelos de previsão de preço de bovino foi pequeno mas positivo. A inclusão da variável explicativa preço de suíno nos modelos de previsão de preço de frango não melhorou a "performance" preditiva destes modelos. O efeito da inclusão da variável preço de bovino nos modelos de previsão de preço de suíno e frango foi pequeno mas positivo nos dois casos.

BEEF CATTLE, HOG AND POULTRY PRICE MODELLING AND FORECASTING

Mirian Rumenos Piedade Bacchi

Adviser: Prof. Rodolfo Hoffmann

SUMMARY

Box and Jenkins time series models, in univariate and transfer function forms (including explanatory variables), were used for beef cattle, hog and poultry price modelling and forecasting in the state of São Paulo. The models were adjusted for the period of January 1978 to June 1991, taking prices in the logarithm form.

Comparison of model performance was done by the Theil Index calculated for 12 forecasted values.

Causality tests between beef cattle, hog and poultry price series were preliminarily performed in order to guide the specification of the transfer function models. The results of these tests indicated causality of poultry price on beef cattle and hog prices. Causality of hog price was not detected either on beef cattle or on poultry prices. The tests also indicated the possibility of a causal relation of beef cattle price on hog and poultry prices.

Integration and co-integration tests for the series were also preliminarily performed. These tests showed that the series are stationary in their first order differences $[I(1)]$ and co-integrated (they tend to move together at a common level over the long run). Based on these results, transfer function models were specified, including an error correction term.

The univariate models for beef cattle and hog price series, in their first order differences (with intervention terms to catch the seasonal variation), and in their simple and seasonal first order differences produced good forecasts, according to Theil's criteria. The performance of the univariate model for poultry price can be considered reasonable, showing a Theil Index of 0.6.

The inclusion of poultry price as explanatory variable in the forecasting models for beef cattle and hog prices (one step ahead) had a positive and substantial effect on the quality of forecasts, in the first case, and positive but small in the second. The inclusion of hog price variable on the forecasting models for poultry prices didn't improve their forecast performance. The effect of inclusion of beef cattle price variable in the forecasting models for hog and poultry prices was small but positive in both cases.

1.- INTRODUÇÃO

1.1- A Importância dos Modelos de Previsão

A grande instabilidade do sistema sócio-econômico no cenário atual e a conseqüente incerteza quanto ao comportamento de suas variáveis no futuro têm ocasionado a adoção de políticas inconsistentes por parte dos organismos governamentais, com altos custos para a sociedade. Isso tem resultado num crescimento da pressão social para um maior planejamento, aumentando dessa forma a importância das previsões.

O setor agrícola é particularmente afetado pelo risco. Produção incerta devido à dependência de condições ambientais e a baixa elasticidade-preço da demanda dos seus produtos promovem as bases para uma grande flutuação de preços nesse setor. Há, dessa forma, necessidade de se dispor de modelos que forneçam previsões que possam orientar os agentes desse

mercado.

Dentre os produtos agrícolas, as "carne e pescados" apresentam peso significativo no orçamento do consumidor brasileiro e, conseqüentemente, nos índices de preço que indexam a nossa economia. Aproximadamente 26 % do total de gastos da família brasileira com alimentação e cerca de 5 % a 12 % da despesa global das famílias, dependendo da região do Brasil, destinam-se a essa categoria de alimentos (FUNDAÇÃO INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA, 1978). Dada tal importância, torna-se necessária a realização de estudos que forneçam subsídios para a adoção de políticas que visem uma maior estabilização dos preços desses produtos. Previsões razoáveis de preço podem oferecer subsídios para a elaboração dessas políticas, além de auxiliarem produtores agrícolas e comerciantes a tomarem medidas que os protejam contra essas grandes oscilações.

A Estatística tem contribuído bastante para as atividades de previsão e planejamento e os modelos de previsão têm sido cada vez mais utilizados em aplicações práticas. Bons modelos de previsão para produtos agrícolas devem ser capazes de retratar os movimentos típicos dessas séries temporais, ou seja: tendência, que reflete o comportamento da série no longo prazo; variações cíclicas dentro do ano (sazonalidade), em função principalmente do período de safra e entressafra;

variações plurianuais e variações irregulares, causadas por fatos excepcionais de ordem climática, política, etc.

1.2.- Características Gerais das Séries de Preços de Bovino, Suíno e Frango

Os preços reais de carne bovina, obtidos com base no IGP-di da Fundação Getúlio Vargas, apresentam oscilações de curto e longo prazos que podem ser visualizadas na Fig.1. As de curto prazo resultam da flutuação, dentro do ano, na oferta de animais para abate, devido a fatores de ordem climática que afetam o desenvolvimento do gado. No fim do período das águas e início do período de seca a oferta de bovinos para abate cresce na tentativa de se evitar perda de peso dos animais durante a estiagem, quando ocorre queda na quantidade e valor nutritivo da forrageira. Nesse período de safra (janeiro a junho), os preços se mantêm em patamares baixos. Com a entrada do período das águas a produção de forragem aumenta, os produtores passam a reter o gado para obter maior peso e a oferta se reduz, caracterizando-se a entressafra (julho a dezembro). O índice de variação estacional médio, calculado por COSTA (1986), citado por MUELLER (1987), indica que o abate de bovinos em maio, época em que ocorrem valores máximos de abate, é 45,7% superior ao de janeiro-fevereiro e 80,3% superior ao de setembro-outubro, período em que ocorrem os valores mínimos.

Fonte: Instituto de Economia Agrícola IEA, São Paulo.
Nota: Valores de dezembro de 1991, com base no IGP-di.

Figura 1 - Evolução dos preços reais de bovino, de janeiro de 1955 a junho de 1992.

As flutuações cíclicas de longo prazo no preço de bovinos são causadas pelo fenômeno conhecido como "ciclo do gado" que tem origem na incompatibilidade entre a demanda final de carne bovina e a disponibilidade de animais para abate. Se a expectativa do produtor for a de que preços elevados, causados por situação de escassez, serão mantidos no futuro, ele tenderá a aumentar a sua capacidade produtiva através de redução no descarte de matrizes e aumento na retenção de novilhas, o que impulsiona o preço ainda mais para cima e amplia ainda mais os incentivos para a expansão da capacidade produtiva. O aumento da oferta de bovinos para abate, que acaba se concretizando após um período de aproximadamente três anos, faz com que se inicie uma reversão do processo. A capacidade produtiva do criador, que se expandiu durante o período de preços ascendentes, origina uma oferta mais do que suficiente para estabilizar os preços em níveis elevados e estes começam a cair. A tendência decrescente dos preços reais leva os criadores a reduzir sua capacidade produtiva, aumentando o descarte de matrizes e a venda de novilhas e bezerros, o que acentua o movimento decrescente dos preços. Com o tempo o rebanho se estabiliza a níveis mais baixos e o abate se reduz, freando o declínio dos preços. Outro ciclo tem início quando se verificar situação de escassez. LATTIMORE (1974) constatou a existência, no Brasil, de elasticidade negativa para a oferta de bovinos para abate, no curto prazo ($-0,113$ para machos e $-0,575$ para fêmeas), numa

confirmação da existência do " ciclo do gado ". Esse resultado reforçou o resultado pioneiro de DIAS (1968), que demonstrou, econometricamente, que no Brasil funciona um mecanismo desse tipo.

Existe relação entre as fases do ciclo de longa duração e amplitude da variância dos preços entre os meses de safra e entressafra, o que faz com que haja quebra da uniformidade da variação estacional de ano para ano.

A Fig. 2 mostra as variações da média móvel (aritmética) de 12 meses^{1/} para a série de preços reais de bovino representada na Fig. 1. Essa figura permite detectar seis ciclos desde 1955 e, apesar dos últimos terem sido afetados pela maior instabilidade da economia e não terem se repetido no padrão dos anteriores a 1980, ainda assim eles se encontram delineados. Segundo REZENDE (1990), "a retenção maior ou menor de matrizes após 1980 deixou de ser função apenas dos preços de bezerro e passou a depender também da maior ou menor atratividade dos ativos financeiros, um aspecto praticamente invariante antes de 1980". Na verdade, a sistemática da série de preço de boi gordo parece ter sido afetada, na década de

1/ As variações estacionais podem ser eliminadas com o procedimento de média móvel de número de termos igual ao período de flutuação da série, ficando mais fácil identificar os seus outros componentes.

Fonte: Instituto de Economia Agrícola IEA, São Paulo.
 Nota: Valores de dezembro de 1991, com base no IGP-di.

Figura 2 - Média móvel (aritmética) de preços reais de bovino, suíno e frango, de janeiro de 1955 a junho de 1992.

80, pelo aumento da procura por ativos reais, entre os quais se inclui o boi, decorrente dos riscos das aplicações financeiras próprios da situação econômica instável, provocada pelos choques heterodoxos iniciados em 1986 com o Plano Cruzado. Fatores que têm impacto sobre a demanda de carne e gado têm também contribuído para modificar o padrão dos ciclos. A recessão que se verificou no Brasil entre 1981 e 1984 fez com que o ponto de máximo do ciclo que se iniciou em 1982 atingisse, em 1984, nível bem menor que o dos ciclos anteriores em 1979 e 1974. De outro lado, o crescimento econômico retomado em 1985 e reforçado com o Plano Cruzado em 1986, que acentuou a expansão da renda e, conseqüentemente, da demanda, e causou drástica queda na atratividade dos ativos financeiros, tornando mais atraente outros investimentos, entre os quais a aquisição de gado bovino, fez com que o preço desse produto se elevasse significativamente no final de 1986. O ano de 1987, período descendente do ciclo, teve a queda dos preços acentuada pela retração da demanda causada pela perda do poder de compra dos salários.

As flutuações cíclicas do preço do gado junto ao produtor e as intervenções do governo no mercado, feitas muitas vezes de forma inconsistente, têm desestimulado os produtores a investir no setor, aumentando a sua capacidade, e a adotar métodos mais produtivos. A defasagem entre o crescimento da demanda, dado pelo aumento da população e

renda, e a produção, originou, no mercado interno, uma tendência ascendente no preço da carne bovina que remonta pelo menos a 1950. Em tempos recentes, todavia, marcados pelas crises econômicas e perda do poder aquisitivo do consumidor, bem como acentuada substituição da carne bovina pela de frango, que vem ocorrendo de forma progressiva desde o início dos anos 70, essa tendência parece ter se invertido. O comprometimento da uniformidade do comportamento dos preços de carne bovina nos últimos anos, no que se refere à tendência e também a ciclos, pode dificultar a obtenção de previsões razoáveis.

A série histórica de preço de frango apresenta nítida tendência decrescente (Fig.3), fato que pode ser atribuído ao marcante desenvolvimento da avicultura no Brasil nas últimas décadas, nos moldes da dos países desenvolvidos. Trata-se de uma atividade que vem experimentando importantes incrementos de produtividade com a introdução de linhagens que permitem melhor conversão alimentar e de práticas de manejo eficientes. A produção brasileira de carne de frango, que representa aproximadamente 97% do total de carne avícola (AVICULTURA - Agroanalysis, 1988), passou de 217,0 mil t em 1970 para 2627,7 mil t em 1991, crescendo a uma taxa média de 12,6% a.a. no período (PRODUÇÃO BRASILEIRA DE PINTOS DE CORTE, 1992 - APINCO e ETAC MERCADOS, 1987)

Fonte: Instituto de Economia Agrícola IEA, São Paulo.
Nota: Valores de dezembro de 1991, com base no IGP-di.

Figura 3 - Evolução dos preços reais de frango, de janeiro de 1960 a junho de 1992.

Estudos do comportamento do mercado de carnes, podendo-se citar, dentre outros, FERNANDES (1989) e BACCHI & BARROS (1992), têm demonstrado que os preços desses produtos encontram-se atrelados. A produção e os preços de frango acompanham as variações cíclicas dos preços de bovino (Fig.2). Nos períodos ascendentes do "ciclo do gado" a demanda de frango aumenta uma vez que seu preço torna-se mais atrativo, comparativamente ao da carne bovina; conseqüentemente, o preço do frango tende a crescer. Nas fases decrescentes do ciclo a demanda por frango se retrai e seu preço acompanha o movimento de queda do preço da carne bovina (MASCOLO & SOUZA, 1983). A elevação no preço do frango ocorrida nos períodos ascendentes do ciclo, foi, todavia, atenuada pela pronta resposta da produção frente ao aumento da demanda desse produto. A avicultura é uma atividade cuja produção praticamente independe das condições edafoclimáticas. Essa característica da avicultura, aliada à pequena duração do ciclo de produção, confere agilidade a essa atividade no controle da produção, fazendo com que o ajuste da oferta frente às sinalizações de mercado seja rápido.

A série histórica de preço de suíno apresenta ciclos de alta frequência (sazonalidade) e baixa frequência (longo prazo) (Fig.4). HOFFMANN (1969), com dados do período 1961-68, estimou o índice sazonal para preço de porco gordo, tendo os resultados indicado que os valores máximos (abril) são, em

Fonte: Instituto de Economia Agrícola IEA, São Paulo.
Nota: Valores de dezembro de 1991, com base no IGP-di.

Figura 4 - Evolução dos preços reais de suíno, de janeiro de 1955 a junho de 1992.

média, aproximadamente 20% superiores aos valores mínimos (novembro/dezembro).

A relação preço suíno/preço milho parece induzir a formação de ciclos de longa duração. Se a relação é favorável ao suíno, os produtores procuram aumentar o rebanho, o que causa inicialmente a elevação do preço e posteriormente a queda, quando se concretiza o aumento da oferta de animais para abate. O movimento se inverte quando a relação preço suíno/preço milho torna-se novamente favorável ao criador e existe expectativa de que essa relação favorável seja mantida. (SANTIAGO, 1989)

O preço de suíno mostra comportamento mais independente em relação ao de bovino do que o preço de frango, o que pode ser explicado, em parte, pelo grau de industrialização da carne suína^{2/}. Uma vez que as indústrias necessitam de quantidade mais ou menos fixa de matéria prima, pode-se esperar alta nos preços pagos ao produtor de carne suína quando a oferta desse produto diminui, apesar da tendência decrescente do preço da carne bovina. O ano de 1982, por exemplo, foi bastante favorável à suinocultura, apesar de não

2/ Estima-se que 70% do consumo de carne suína no Brasil sejam feitos sob a forma industrializada (ROPPA, 1988, citado SANTIAGO, 1989).

o ter sido para a bovinocultura e avicultura. Os resultados do trabalho de BRANDT *et alli* (1987) confirmam essa proposição. Esses autores estimaram, com dados do período 1970-84, medidas de integração entre mercados de carne para curto prazo (sazonal) e longo prazo (45 meses), sob a hipótese de que as variações nos preços de carne bovina tendem a liderar as variações nos preços das outras carnes e verificaram maior eficiência de ajuste do setor avícola que do setor da suinocultura, face às variações de preço da carne bovina (para a situação de curto prazo sazonal as elasticidades do preço da carne bovina em relação ao preço da carne suína e de aves são 0,403 e 0,773, respectivamente, e as correspondentes elasticidades para a situação de longo prazo são 0,192 e 0,586).

1.3.- Objetivo

O presente trabalho tem por objetivo modelar as séries de preços de bovino, suíno e frango, e obter previsões desses preços através dos modelos propostos por Box & Jenkins que serão expostos, em seus aspectos básicos, no capítulo "Metodologia, Procedimentos e Dados". Pretende-se verificar se a inclusão de variáveis explicativas nas equações, através de modelos de função de transferência, traz melhoria considerável na qualidade das previsões de preços resultantes de modelos

univariados.

As previsões obtidas serão comparadas com os preços do mercado físico com o intuito de avaliar o desempenho dos modelos.

2.- REVISÃO DE LITERATURA

Dentre os modelos paramétricos para séries temporais, os propostos por BOX & JENKINS (1976) têm recebido destaque devido à boa qualidade das previsões por eles fornecidas e à sua simplicidade - normalmente envolvem pequeno número de parâmetros e não requerem a interpretação da estrutura do fenômeno, sendo a escolha do modelo feita com base nos próprios dados. Tem sido salientado que os modelos estruturais, que enfatizam a descrição teórica das relações comportamentais entre variáveis, ainda que importantes na explicação do fenômeno, nem sempre superam, em termos de previsão, os modelos de Box & Jenkins (HALLAM, 1990 e MAKRIDAKIS, 1986). Nas últimas décadas popularizou-se o uso dessa metodologia, tendo sido adotada em alguns estudos na área de Economia Agrícola.

PINO (1980) utilizou-se da técnica de Box & Jenkins para modelar as séries de produção e produtividade de leite e as séries de preços, produção e produtividade de café do Estado

de São Paulo. As análises foram feitas com modelos univariados, de intervenção e função de transferência. O autor concluiu que essa técnica fornece boas previsões e que sua maior limitação está na fase de identificação do modelo que requer do pesquisador experiência e perspicácia.

CARVALHO & SILVA (1990), tratando de métodos para determinar preços de intervenção, utilizaram modelos ARIMA e SARIMA de Box & Jenkins para obter previsões de preço de arroz, feijão e milho para o mercado atacadista da cidade de São Paulo. Verificaram que para arroz e milho os modelos selecionados ofereceram boas previsões para curto prazo, sendo a maior variação, comparada ao mercado físico, da ordem de 35%. No caso do feijão as previsões não se mostraram adequadas, tendo havido dificuldade em se modelar a série. Os autores concluíram que as previsões obtidas com os modelos ARIMA, por incorporarem componentes de sazonalidade e/ou tendências, permitem, quando utilizadas para nortear as políticas de garantia de preços mínimos, que seja respeitada a dinâmica da série. Esse método seria vantajoso se comparado ao que tem sido adotado para essa política (média de preços reais de 60 meses).

Alguns trabalhos foram feitos no sentido de comparar o desempenho das previsões obtidas com a técnica de Box & Jenkins com o das previsões fornecidas por outras

metodologias. SCHIMITZ & WATTS (1970) compararam o desempenho do modelo ARIMA com o da técnica de alisamento exponencial para prever a produção de trigo nos Estados Unidos, Canadá, Argentina e Austrália, utilizando o Índice de Theil (IT) como indicador da precisão das previsões. Verificaram que o modelo ARIMA teve melhor desempenho para o caso dos Estados Unidos enquanto o método de alisamento exponencial foi o melhor no caso dos outros países considerados. Os autores concluíram que a escolha da técnica a ser utilizada depende do problema particular a ser modelado.

LEUTHOLD *et alii* (1970) analisaram o desempenho de vários modelos na previsão de preços diários e quantidade de suínos no mercado norte americano. Dentre os modelos testados para preços (modelo de média, caminho aleatório e estrutural), o estrutural, que incluía variáveis binárias, além de variáveis explicativas, forneceu as melhores previsões segundo o critério de Theil. As piores previsões de preços foram obtidas com o modelo de média. Para quantidade testou-se, além dos modelos utilizados para previsão de preços, o modelo ARIMA, tendo este apresentado quase tão bom desempenho quanto o econométrico, e sendo, segundo os autores, de mais fácil construção que este último.

ZAPATA & GARCIA (1990) compararam o desempenho de modelos ARIMA e modelos de Auto-regressão Vetorial (VAR) em

prever preços de gado nos EUA. Os resultados para longo prazo indicaram superioridade dos modelos VAR enquanto que no curto prazo os modelos ARIMA se mostraram melhores.

VICENTE (1992) utilizou modelos ARIMA e modelos estruturais básicos (BSM) para prever a produção brasileira de frango e ovos. No BSM a série analisada é decomposta em termos de tendência, sazonalidade, ciclo e componente irregular (estocástico) e a operacionalização do modelo é feita através da representação na forma de espaço de estado. Baseando-se nos critérios do erro quadrático médio de previsão, desvio absoluto médio (%) e Índice de Theil, o autor concluiu que as previsões obtidas com o BSM foram melhores às obtidas com os modelos ARIMA.

Tradicionalmente, os modelos para previsões têm sido tratados como distintos e competitivos, todavia alguns autores têm explorado a natureza complementar das diferentes abordagens.

Os primeiros trabalhos com enfoque híbrido fundamentaram-se em previsões compostas, tendo-se verificado que de modo geral as previsões combinadas têm uma variância de erro não maior que a variância de erro de previsões com modelos específicos (NEWBOLD & GRANGER, 1974 e MAKRIDAKIS & WINKLER, 1983, citados por MAKRIDAKIS, 1986).

BRANDT & BESSLER (1981) utilizaram três métodos individuais para obter previsões de preço de suínos nos Estados Unidos: ARIMA, estrutural e opinião de especialistas. Desses métodos individuais testados, as melhores previsões, comparadas aos valores do mercado físico, foram obtidas com o modelo ARIMA. A precisão dos modelos para prever o movimento dos preços de período para período (alta e baixa) foi estudada, tendo-se verificado que o modelo ARIMA foi também o que apresentou o melhor desempenho. Foram testados métodos de previsão compostos, baseados em combinações lineares das previsões obtidas com os métodos individuais e observou-se que os métodos compostos tendem a fornecer melhores previsões que os individuais. Os métodos compostos tiveram um desempenho semelhante aos individuais no que se refere à capacidade de prever mudanças na direção da série. Os autores concluíram que se deve considerar seriamente o uso de técnicas compostas de previsão como um meio de se diminuir o risco envolvido na utilização de um único método de previsão.

A natureza complementar de diferentes abordagens foi explorada também através da utilização de modelos mistos. KASSOUF (1988), utilizando modelos ARIMA e harmônicos com a finalidade de obter previsões de preço de bezerro, boi magro e boi gordo para o Estado de São Paulo, verificou que as melhores previsões foram fornecidas com um modelo contendo

componentes harmônicos associados aos do ARIMA, incluindo ainda variáveis binárias e tendência linear.

GOLDSZAL (1992) utilizou um modelo de tendência exponencial conjugado a processo ARMA, com o objetivo de verificar empiricamente a evolução de preços de exportação de três produtos primários exportados pelo Brasil - café, açúcar e cacau, em relação ao preço de um conjunto de produtos manufaturados produzidos em países desenvolvidos e transacionados no mercado internacional (movimentos relativos).

Um terceiro enfoque híbrido foi utilizado por CHEN & BESSLER (1990). Esses autores testaram o desempenho dos modelos estrutural e auto-regressivo para prever preços mensais de algodão, considerando dois períodos distintos: período de condições normais de mercado e período com choques políticos. A abordagem composta, testada pelos autores, consistiu em usar auto-regressão vetorial para determinar os valores futuros de variáveis exógenas do modelo estrutural. Resultados de simulação mostraram a superioridade do desempenho do modelo estrutural em manusear mudanças políticas, enquanto os modelos auto-regressivos apresentaram maior precisão em prever movimentos normais de preço. A abordagem composta, neste caso, não apresentou melhor desempenho que os modelos individuais quanto à precisão das previsões.

3.- METODOLOGIA, PROCEDIMENTOS E DADOS

3.1- Modelos

3.1.1- Modelos Estocásticos Univariados

A forma mais simples de previsão é aquela em que os valores futuros da série temporal em análise são obtidos somente através de informações do passado histórico da série. Os modelos utilizados em tal situação são chamados de Modelos Estocásticos Univariados.

3.1.1.1- Modelos Estocásticos Univariados para Séries Estacionárias

Se a série temporal é estacionária, isto é, se a série tem média e variância independentes do tempo e covariância dependendo apenas do intervalo de tempo, pode-se representá-la

por uma ampla classe de modelos chamados auto-regressivos e de média móvel (ARMA), cuja formulação é a seguinte:

$$\tilde{Z}_t = \phi_1 \tilde{Z}_{t-1} + \dots + \phi_p \tilde{Z}_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (1)$$

onde: $\tilde{Z}_t = Z_t - \mu$ (com μ sendo a média da série) e a_t é ruído branco.

Nessa formulação, o valor corrente da série é função de:

- a) valores prévios da série $\tilde{Z}_t$;
- b) Valores corrente e prévios do ruído branco a_t .

Alternativamente, introduzindo-se o operador:

$$B^j \tilde{Z}_t = \tilde{Z}_{t-j} \quad \text{para } j = 1, 2, 3, \dots$$

pode-se escrever o modelo ARMA da seguinte forma:

$$\tilde{Z}_t = \frac{\theta(B)}{\phi(B)} a_t = \frac{1 - \theta_1 B - \dots - \theta_q B^q}{1 - \phi_1 B - \dots - \phi_p B^p} a_t \quad (2)$$

com os parâmetros em (2) tendo que satisfazer as seguintes condições:

- a) as raízes da equação característica $\phi(B) = 0$ devem estar fora do círculo unitário, ou seja, devem ser, em módulo, maiores do que um, para que o operador auto-regressivo $\phi(B)$ seja estacionário;
- b) as raízes da equação característica $\theta(B) = 0$ devem estar fora do círculo unitário para que o operador de média móvel $\theta(B)$ seja invertível.

O modelo (2) representa a série $\tilde{Z}_t$ como a saída de um filtro linear cuja entrada é uma série com média zero e variância constante e finita. A função filtro de transferência é a razão de dois polinômios em B , cuja fatoração ajuda no entendimento dos mecanismos geradores da série.

A construção de modelos de Box & Jenkins deve fundamentar-se no princípio da "parcimônia", significando que na prática os modelos devem conter o menor número possível de parâmetros a serem estimados. Para isso é necessário, em geral, a inclusão de termos auto-regressivos e de média móvel. O uso de modelo auto-regressivo para representar uma série que é descrita, em parte, por um processo de média móvel, ou vice-versa, resulta em elevado número de parâmetros a serem estimados (JENKINS, 1979, p.98).

3.1.1.2- Modelos Estocásticos Univariados para Séries Não Estacionárias

Os modelos desenvolvidos por Box & Jenkins podem ser aplicados a séries que apresentem alguma forma de não estacionariedade, mas que sejam homogêneas, isto é, não tenham comportamento explosivo.

O método de eliminar a não estacionariedade de séries homogêneas depende do tipo de tendência temporal existente, determinística ou estocástica. No primeiro caso, assume-se, comumente, um modelo do tipo $Z_t = \beta_0 + \beta_1 t + u_t$ ou $Z_t = \beta_0 + \beta_1 t + \beta_2 t^2 + u_t$ e, no segundo, um modelo do tipo $Z_t - Z_{t-1} = \beta + e_t$ onde e_t é uma série estacionária com média zero e variância σ^2 . Normalmente serão necessárias uma ou duas diferenças para que uma série com tendência estocástica adquira estacionariedade. Frequentemente a primeira diferença $\Delta \tilde{Z}_t = \tilde{Z}_t - \tilde{Z}_{t-1} = (1 - B)\tilde{Z}_t$ é suficiente para tornar estacionárias as séries econômicas reais e a segunda diferença $\Delta^2 \tilde{Z}_t = (\tilde{Z}_t - \tilde{Z}_{t-1}) - (\tilde{Z}_{t-1} - \tilde{Z}_{t-2}) = (1 - 2B + B^2)\tilde{Z}_t$ é suficiente para tornar estacionárias as séries nominais (PEREIRA, 1991).

Seja o modelo:

$$\varphi(B)\tilde{Z}_t = \theta(B)a_t$$

onde $\varphi(B)$ é um operador auto-regressivo não estacionário. Calculando-se as diferenças:

$$\omega_t = \Delta^d \tilde{Z}_t = (1-B)^d \tilde{Z}_t$$

com d indicando o número de diferenças, é possível obter uma série transformada, estacionária, que pode ser representada pelo modelo ARMA visto anteriormente:

$$\tilde{\omega}_t = \frac{\theta(B)}{\phi(B)} a_t = \frac{1 - \theta_1 B - \dots - \theta_q B^q}{1 - \phi_1 B - \dots - \phi_p B^p} a_t \quad (3)$$

onde $\tilde{\omega}_t = \omega_t - \mu$

Usualmente representa-se o modelo com estacionariedade obtida por diferenças na forma:

$$\phi(B)\Delta^d \tilde{Z}_t = \theta(B)a_t$$

Este modelo geral denomina-se ARIMA(p, d, q). Os modelos ARIMA são, portanto, capazes de descrever séries estacionárias

e não estacionárias homogêneas. Nesse tratamento geral tem-se que um $ARIMA(p,0,0)$ corresponde a um modelo auto-regressivo de ordem p , um $AR(p)$; um $ARIMA(0,0,q)$ corresponde a um modelo de média móvel de ordem q , um $MA(q)$; um $ARIMA(p,0,q)$ corresponde a um modelo $ARMA(p,q)$ e o $ARIMA(0,d,q)$ a um modelo integrado de média móvel $IMA(d,q)$.

3.1.1.3- Modelos Estocásticos Univariados para Séries Sazonais

Séries contendo padrão sazonal podem ser descritas por uma classe de modelos chamados $ARIMA$ SAZONAL ou $SARIMA(p,d,q) \times (P,D,Q)_S$. O modelo é definido por:

$$\tilde{\omega}_t = \frac{\theta(B)\theta(B^S)}{\phi(B)\phi(B^S)} a_t \quad (4)$$

com $\tilde{\omega}_t = \omega_t - \mu$

e $\omega_t = \Delta^d \Delta_S^D Z_t$

onde:

$\phi(B)$, $\theta(B)$ são os operadores auto-regressivo e de média móvel, como apresentado no modelo $ARMA$, em (2);
 $\Delta^d = (1 - B)^d$ é o operador diferença;
 $\Delta^D = (1 - B^S)^D$ é o operador de diferença sazonal, onde D representa o número de diferenças sazonais e S é o período do ciclo sazonal;

$\Phi(B^S) = 1 - \phi_1 B^S - \phi_2 B^{2S} - \dots - \phi_P B^{PS}$ é o operador sazonal auto-regressivo, de ordem P , estacionário; e, $\Theta(B^S) = 1 - \theta_1 B^S - \theta_2 B^{2S} - \dots - \theta_Q B^{QS}$ é o operador sazonal de média móvel, de ordem Q , invertível.

Enquanto o modelo ARIMA é utilizado para representar séries com autocorrelações significativas em defasagens de baixa ordem, o modelo SARIMA é utilizado no ajuste de dados com autocorrelações significativas em defasagens múltiplas de um determinado período s .

O modelo sazonal (4) é capaz de representar uma larga classe de padrões sazonais estocásticos que ocorrem na prática. O modelo, que é multiplicativo com respeito a seus componentes sazonais, pode ser transformado em um modelo não multiplicativo, se houver, no estágio de identificação, indicação de que isso é necessário. Para transformar o modelo multiplicativo em um modelo não multiplicativo, substitui-se $\theta(B)\theta(B^S)$ por um operador de média móvel mais geral $\theta^*(B)$ e $\phi(B)\phi(B^S)$ por um operador geral auto-regressivo $\phi^*(B)$.

Considerando-se como exemplo o operador multiplicativo:

$$\theta(B)\theta(B) = (1-\theta_1 B)(1-\theta_1 B^{12})$$

tem-se o operador não multiplicativo:

$$\theta^*(B) = 1 - \theta_{11}B - \theta_{12}B^{12} - \theta_{13}B^{13}$$

Na prática, se o valor encontrado para θ_{13} do modelo não multiplicativo não diferir do valor obtido pela multiplicação de $\theta_1\theta_1$ encontrados no modelo multiplicativo, tem-se que o modelo multiplicativo é preferível ao não multiplicativo por apresentar-se mais parcimonioso (PINO, 1980).

É possível que a série em análise apresente vários componentes sazonais e, para expressar essa múltipla sazonalidade, o modelo deve ser elaborado de modo a incluir vários estágios de diferenças e vários operadores de média móvel e auto-regressivos sazonais.

As previsões obtidas com os modelos estocásticos univariados, com base somente no passado histórico da série, nem sempre são precisas a longo prazo. Todavia os modelos estocásticos univariados são importantes porque fornecem a base com a qual modelos mais refinados podem ser propostos. A presença de grandes resíduos pode corresponder a eventos anormais na série. Se esses eventos forem identificados, pode-se tomar decisões apropriadas e melhorar o ajuste do modelo e as previsões. Além disso, como já foi citado

anteriormente, esse modelo pode conduzir a um entendimento maior dos mecanismos básicos geradores da série. Por exemplo, a presença de operador auto-regressivo com raízes complexas é indicativo de alguma periodicidade da série.

3.1.2- Modelos de Função de Transferência

É possível melhorar o desempenho das previsões de uma variável dependente Z_t , obtidas com o método estocástico univariado, com a introdução de outras variáveis explicativas no modelo $(X_{1t}, X_{2t}, \dots, X_{nt})$. Isso irá ocorrer se as variáveis relacionadas a Z_t , introduzidas no modelo, contiverem informações que não estejam completamente contidas no passado da série Z_t .

Em modelos ARIMA pode-se incluir os efeitos de outras séries na série que vai ser modelada, através de funções de transferência, conforme propõe JENKINS (1979).

Suponha-se, para a elaboração do modelo de função de transferência, uma variável dependente Z_t para a qual se pretende fazer previsões, e uma variável explicativas X_t que explica parte das variações ocorridas em Z_t . A variável Z_t pode ser decomposta em duas partes:

$$Z_t = U_t + N_t \quad (5)$$

onde U_t contém a parte de Z_t que pode ser explicada em termos de X_t , e N_t é o erro ou o termo residual representando todas as variáveis não incluídas no modelo.

Considera-se, em primeiro lugar, a relação entre U_t e a variável X_t , que pode ser representada pela seguinte equação:

$$U_t - \delta_1 U_{t-1} - \dots - \delta_m U_{t-m} = c + \omega_0 X_{t-b} - \omega_1 X_{t-b-1} - \dots - \omega_l X_{t-b-l}$$

ou

$$(1 - \delta_1 B - \dots - \delta_m B^m) U_t = c + (\omega_0 - \omega_1 B - \dots - \omega_l B^l) X_{t-b} \quad (6)$$

tal que:

$$\begin{aligned} U_t &= c + \frac{\omega_0 - \omega_1 B - \dots - \omega_l B^l}{1 - \delta_1 B - \dots - \delta_m B^m} X_{t-b} = c + \frac{\omega(B)}{\delta(B)} X_{t-b} = \\ &= c + V(B) X_t \end{aligned} \quad (7)$$

A função de transferência $V(B)$ contém:

- um "operador de média móvel" $\omega(B)$
- um "operador auto-regressivo" $\delta(B)$

- um parâmetro b de defasagem representando o número completo de intervalos de tempo necessários para que a variável X_t produza algum efeito em Z_t .

A expressão (7) é chamada de função de transferência de ordem (m, l, b) , onde m é o número de termos auto-regressivos; l é o número de termos de média móvel e b é a defasagem. Pode-se ver que o modelo ARMA é um caso particular de função de transferência onde a entrada é o ruído branco.

Para que o sistema seja estável é preciso que a função de transferência $V(B)$ seja convergente. Isso irá ocorrer se as raízes das equações características $\delta(B) = 0$ e $\omega(B) = 0$ estiverem fora do círculo unitário.

Na prática o termo residual pode ser representado por um modelo ARIMA(p, d, q):

$$N_t = \frac{\theta(B)}{\phi(B)} a_t \quad (8)$$

Substituindo (7) e (8) em (5) obtém-se o modelo de função de transferência:

$$Z_t = c + \frac{\omega(B)}{\delta(B)} X_{t-b} + \frac{\theta(B)}{\phi(B)} a_t \quad (9)$$

Se necessário utilizam-se as variáveis nas diferenças tal que:

$$z_t = c + \frac{\omega(B)}{\delta(B)} x_{t-b} + \frac{\theta(B)}{\phi(B)} a_t$$

com

$$z_t = \Delta^d Z_t$$

e

$$x_t = \Delta^d X_t$$

A variável x deve ser corrigida na média para a obtenção da estimativa de c . Dessa forma tem-se:

$$z_t = c + \frac{\omega(B)}{\delta(B)} (x_{t-b} - \bar{x}) + \frac{\theta(B)}{\phi(B)} a_t \quad (10)$$

Generalizando, para n variáveis x :

$$z_t = c + \sum_{j=1}^n \frac{\omega_j(B)}{\delta_j(B)} (x_{j, t-b_j} - \bar{x}_j) + \frac{\theta(B)}{\phi(B)} a_t \quad (11)$$

com cada uma tendo uma função de transferência com seu próprio operador de média móvel $\omega_j(B)$, operador auto-regressivo $\delta_j(B)$ e de defasagem b_j .

Finalmente, se Z_t e X_{jt} são séries com período sazonal, pode-se obter um modelo de função de transferência sazonal

introduzindo-se em (11) operadores sazonais definindo adequadamente z_t e x_{jt} .

Existe relação entre modelos de função de transferência e o de ajuste parcial desenvolvido por NERLOVE (1958), que permite a obtenção de elasticidades de curto e longo prazos. Desse modo é possível, por analogia, o cálculo dessas elasticidades para alguns modelos de função de transferência utilizados em análise de séries temporais (OLIVEIRA & PINO, 1985).

A hipótese de ajustamento parcial formulada por NERLOVE (1958) pressupõe a existência de um nível desejado (situação de longo prazo) para uma variável, dado por:

$$z_t^* = \alpha x_t + u_t \quad (12)$$

Pressupõe também que o ajuste entre dois períodos ($z_t - z_{t-1}$) é proporcional à diferença entre o nível observado em $t - 1$ e o nível de equilíbrio de longo prazo. Tem-se então:

$$z_t - z_{t-1} = \delta(z_t^* - z_{t-1}) \quad 0 < \delta \leq 1 \quad (13)$$

onde δ representa a proporção da mudança de longo prazo que é realizada em um período.

De (12) e (13) obtém-se:

$$z_t = \frac{\alpha \delta}{1 - \beta B} x_t + \frac{\delta}{1 - \beta B} u_t \quad (14)$$

com $\beta = (1 - \delta)$

As elasticidades de curto e longo prazo são, respectivamente:

$$Ecp(z/x) = \frac{\partial z_t}{\partial x_t} \cdot \frac{x_t}{z_t} = \alpha \delta \frac{x_t}{z_t} \quad e$$

$$Elp(z/x) = \frac{\partial z_t^*}{\partial x_t} \cdot \frac{x_t}{z_t^*} = \alpha \frac{x_t}{z_t^*}$$

Como somente a elasticidade de curto prazo é observável, pode-se obter a elasticidade de longo prazo através da relação:

$$Elp = Ecp/\delta$$

Se a função de transferência for do tipo:

$$z_t = \frac{\omega_o}{1 - \gamma B} x_t + \frac{\theta(B)}{\phi(B)} a_t \quad (15)$$

têm-se, por analogia com a equação do modelo de NERLOVE, as

seguintes equivalências:

<u>Ajustamento Parcial</u>	<u>Função de Transferência</u>
α	$\omega_o / (1-\gamma)$
β	γ
δ	$1-\gamma$

Se o modelo de transferência for, por exemplo:

$$\ln z_t = \frac{0,41}{1 - 0,54} \ln x_t + \frac{\theta(B)}{\phi(B)} a_t$$

tem-se então:

$$Ecp(z/x) = 0,41$$

$$Elp(z/x) = 0,41 / (1 - 0,54)$$

3.1.3- Modelos de Intervenção

Eventos esporádicos independentes dos fatores geradores da série temporal podem ser incluídos nos modelos ARIMA através da análise de intervenção. A análise de intervenção tem sido utilizada para avaliar se acontecimentos externos contribuem significativamente para alterar o comportamento de uma série temporal. Nesse sentido, CARVALHO (1991) estimou os

efeitos de modificações introduzidas na Política de Garantia de Preços Mínimos (PGPM) sobre a dinâmica das séries de preços de arroz e milho, incluindo em modelos ARIMA variáveis binárias que representavam mudanças relevantes naquela política.

Para maior entendimento do processo, seja uma série temporal Z_t da qual se dispõe de n observações igualmente espaçadas no tempo. Define-se uma intervenção I como sendo um evento E , ao qual se associa uma variável aleatória X , cuja ocorrência num dado instante ou intervalo de tempo t pode ocasionar uma mudança na série Z_t , em especial em seu nível e/ou em sua inclinação^{3/}.

Se a variável Z_t para a qual se pretende fazer previsões for afetada por um ou mais eventos excepcionais independentes dos fenômenos que deram origem à série temporal, tem-se como resultado o aparecimento de grandes resíduos nos modelos estimados pelo método estocástico univariado. Esses eventos excepcionais têm o efeito de distorcer a estrutura do modelo experimental obtido no estágio de identificação, os valores dos parâmetros estimados e a magnitude da variância residual (JENKINS 1979).

3/ Variações na inclinação ocorrem quando as mudanças se manifestam gradativamente.

Através do modelo de intervenção pode-se introduzir variáveis que representem os efeitos anormais ou quaisquer outros efeitos difíceis de serem quantificados, visando um melhor ajustamento do modelo e a obtenção de melhores previsões.

Basicamente, a construção de modelos de intervenção consiste em acrescentar aos modelos ARIMA, já descritos anteriormente, o efeito de variáveis exógenas, através de função de transferência. Conceitualmente o modelo de intervenção equivale a um modelo de função de transferência onde a série de entrada é binária (variável "dummy").

A mudança na série Z_t provocada por um evento anormal pode ser imediata ou só ocorrer depois de algum tempo (defasada) e pode ser temporária ou permanente. As variáveis "dummy" utilizadas para representar diferentes comportamentos dos eventos excepcionais quanto à sua duração no tempo são:

- variável pulso - atribui-se valor 1 (um) à observação referente ao momento da intervenção (podendo ser considerado, quando o caso, defasagem) e 0 (zero) aos demais momentos. Chamando-se de T o tempo em que ocorreu a intervenção, pode-se representar a função da seguinte forma:

$$\varepsilon_t = P_t^{(T)} = \begin{cases} 0, & t \neq T \\ 1, & t = T \end{cases} \quad (16)$$

- variável degrau - atribui-se valor 0 (zero) para as observações referentes aos momentos anteriores a uma determinada mudança e 1 (um) às observações referentes aos momentos posteriores à mudança. Nesse caso a intervenção age do momento T em diante, podendo ser chamada de contínua. Tem-se então:

$$\varepsilon_t = S_t^{(T)} = \begin{cases} 0, & t < T \\ 1, & t \geq T \end{cases} \quad (17)$$

Há ainda um caso intermediário em que a intervenção se dá durante um intervalo de tempo iniciado em T_1 e findo em T_2 . Tem-se, nesse caso:

$$\varepsilon_t = \begin{cases} 0, & t < T_1 \text{ e } t > T_2 \\ 1, & T_1 \leq t \leq T_2 \end{cases} \quad (18)$$

Para estudar o efeito de uma variável de intervenção ε_t sobre a variável que está sendo modelada, o seguinte termo deve ser acrescentado ao modelo (11):

$$\frac{\omega(B)}{\delta(B)} \varepsilon_{t-b} \quad (19)$$

sendo b a defasagem.

Exemplos de efeitos dinâmicos simulados em análise de intervenção com variáveis pulso e degrau são apresentados na Figura 5.

A estrutura do modelo de intervenção deve ser sugerida pelo conhecimento apriorístico do evento anormal e de seu possível efeito sobre a variável Z_t . A análise dos dados pode, muitas vezes, por si só, fornecer informações sobre efeitos desconhecidos a priori. Evidência suplementar de ocorrência de fenômeno anormal pode ainda ser obtida através da análise dos resíduos do modelo ajustado sem a incorporação de efeito de intervenção.

Para ilustrar a situação de intervenção JENKINS (1979) apresenta o seguinte exemplo:

Suponha-se um modelo univariado da forma:

$$\Delta_{12} Z_t = (1 - \theta B)(1 - \theta B^{12}) a_t \quad (20)$$

Figura 5 - Efeitos dinâmicos simulados em análise de intervenção. Extraída de VANDAELE (1983).

e um mecanismo de intervenção da forma:

$$\Delta Z_t = \omega_0 \varepsilon + N_t \quad (21)$$

onde N_t descreve o comportamento da série na ausência do evento anormal. Se $\omega_0 = 0$, isto é, se nenhum efeito anormal tivesse ocorrido, a estrutura de N_t corresponderia à estrutura de ΔZ_t . Obter-se-ia, então, de (20) e (21):

$$\Delta_{12} N_t = (1 - \theta B)(1 - \theta B^{12}) a_t \quad (22)$$

e

$$\Delta \Delta_{12} Z_t = \omega_0 \Delta_{12} \varepsilon_t + (1 - \theta B)(1 - \theta B^{12}) a_t \quad (23)$$

que é o modelo de intervenção a ser ajustado.

É possível que seja necessária a introdução de vários termos de intervenção no modelo para representar efeitos anormais relacionados à série em análise.

As variáveis binárias podem ser utilizadas para representar variações estacionais de séries temporais. Nesse sentido a sua utilização pode substituir modelos harmônicos.

3.2.- Construção de Modelos de Box & Jenkins

3.2.1.- Transformação dos Dados

Além da não estacionariedade da série em relação à média, pode ocorrer um crescimento da variância da série ou de suas diferenças à medida que o tempo passa. Nesse caso a transformação dos dados é necessária para a obtenção de resíduos com variância homogênea. Se houver efeito sazonal multiplicativo a transformação dos dados torna-o aditivo (CHATFIELD, 1984).

Uma classe simples de transformações (Box & Cox) pode ser assim representada (JENKINS 1979):

$$Z_t^{(\lambda)} = \begin{cases} Z_t^\lambda & \lambda \neq 0 \\ \ln Z_t & \lambda = 0 \end{cases}$$

onde λ é um vetor de parâmetros definindo a transformação.

A estimativa da transformação apropriada é dada pela relação entre a amplitude e a média de sub-séries, envolvendo os seguintes passos:

- divide-se a série em sub-séries considerando o período sazonal (sub-séries com 4 à 12 observações são usuais);

- relaciona-se graficamente a amplitude (ordenada) e a média (abscissa) das sub-séries. Se os pontos estiverem casualmente espalhados em torno de uma linha reta horizontal, nenhuma transformação é necessária ($\lambda = 1$). Se os pontos estiverem casualmente espalhados em torno de uma linha reta inclinada, a transformação indicada é a logarítmica. Outras transformações são propostas quando os pontos que relacionam a média e a amplitude das sub-séries geram o ajuste de uma linha côncava ou convexa. O λ , nesse caso, deve ser estimado. JENKINS (1979) apresenta graficamente as relações teóricas entre média e amplitude para alguns valores de λ (Fig.6).

Figura 6 - Relações teóricas entre média e amplitude para alguns valores de λ . Extraída de JENKINS (1979).

Alguns conjuntos de dados são insensíveis à transformações. Quando isso ocorre, os gráficos que relacionam amplitude e média das sub-séries dos dados originais e transformados são muito semelhantes.

Existe, no entanto, discussão a respeito da necessidade da transformação dos dados originais. NELSON (1976) e MAKRIDAKIS & HIBON (1979), citados por MORETTIN & TOLOI (1985), concluíram que a transformação dos dados não melhora ou tem somente pequeno efeito sobre o desempenho de previsões.

3.2.2.- Estrutura do Modelo

A escolha da estrutura do modelo ARIMA univariado é baseada nos próprios dados. Os passos para a obtenção do modelo são:

- identificação: feita principalmente com base na análise das autocorrelações e autocorrelações parciais. Tem sido apontado que a maior limitação da utilização dos modelos de Box & Jenkins está nessa fase de identificação, que exige do pesquisador perspicácia e experiência (MORETTIN & TOLOI, 1985 e PINO, 1980);

- estimação: os parâmetros do modelo identificado são estimados;

- verificação: feita através da análise de resíduos e dos erros de previsão. Caso o modelo não seja adequado, o ciclo é repetido, voltando-se à fase de identificação. O procedimento que muitas vezes é utilizado é o da identificação de vários modelos que são ajustados e verificados.

O objetivo da identificação é determinar os valores de (p, d, q) do modelo $ARIMA(p, d, q)$; $(p, d, q)(P, D, Q)_s$ do $ARIMA$ sazonal e a ordem dos polinômios $\omega(B)$ e $\delta(B)$ e da constante de defasagem dos modelos de função de transferência representados pela equação (11).

A identificação, no caso de modelos univariados, é feita através da análise das autocorrelações e autocorrelações parciais.

3.2.3.- Autocorrelações

Os momentos de baixa ordem de uma série temporal podem ser assim definidos:

- Média:

$$\mu = E(Z_t) \quad (24)$$

- Variância:

$$\sigma^2 = E((Z_t - \mu)^2) \quad (25)$$

- Autocovariância com defasagem k :

$$\gamma_k = E((Z_t - \mu)(Z_{t+k} - \mu)) \quad (26)$$

- Autocorrelação com defasagem k :

$$\rho_k = \frac{E((Z_t - \mu)(Z_{t+k} - \mu))}{E((Z_t - \mu)^2)} \quad (27)$$

Seja $\bar{Z}$ a média de Z_t na série de dados observados e convencionando que $\tilde{Z}_t = Z_t - \bar{Z}$, tem-se de (27) que a estimativa da autocorrelação com defasagem k é dada por:

$$r_k = \frac{\sum_{t=k+1}^n \tilde{Z}_t \tilde{Z}_{t-k}}{\sum_{t=1}^n \tilde{Z}_t^2} \quad (28)$$

Obtém-se a representação gráfica da função de autocorrelação relacionando-se os valores de r_k com as defasagens k , como mostrado na Figura 7 (correlograma). Como o

gráfico é simétrico, pode-se considerar apenas os valores a partir da defasagem 0.

Figura 7 - Exemplo de função de autocorrelação. Extraída de BOX & JENKINS (1976).

Para caracterizar a função de autocorrelação testa-se se os valores de ρ_k são zero. Para se efetuar esse teste, proposto por BARTLETT (1946) (ver MAKRIDAKIS, 1976), obtém-se inicialmente a estimativa do desvio padrão da autocorrelação estimada (r_k), que é dada por:

$$\hat{\sigma}(r_k) = \sqrt{\frac{1}{n} \left(1 + 2 \sum_{v=1}^{k-1} r_v^2 \right)} \quad \text{onde } k = \text{defasagem}$$

Para $k = 1$, tem-se $\hat{\sigma}(r_k) = \sqrt{1/n}$.

Na prática pode-se considerar r_k como sendo significativamente diferente de zero se $|r_k| > t_\gamma \hat{\sigma}(r_k)$, onde t_γ é o valor da estatística t de Student com $n-1$ graus de liberdade a 95% de probabilidade (≈ 2 para n grande).

Se a série temporal é estacionária os coeficientes de autocorrelação caem rapidamente para zero. Se isso não ocorre, as primeiras diferenças podem ser utilizadas para tornar a série estacionária.

Através da função de autocorrelação identifica-se também a existência de sazonalidade da série. Se o padrão sazonal da série tem período s , então os coeficientes de autocorrelação com defasagens $s, 2s, 3s, \dots$ são relativamente altos.

3.2.4.- Autocorrelações Parciais

A seguir será desenvolvida a função de autocorrelação parcial (facp), que pode facilitar o processo de identificação da estrutura do modelo ARIMA a ser ajustado.

Considere-se um modelo $AR(p)$:

$$\tilde{Z}_t = \phi_1 \tilde{Z}_{t-1} + \phi_2 \tilde{Z}_{t-2} + \dots + \phi_p \tilde{Z}_{t-p} + a_t$$

Multiplicando-se por $\tilde{Z}_{t-k}$ e aplicando-se esperança, obtém-se:

$$\gamma_k = \phi_1 \gamma_{k-1} + \phi_2 \gamma_{k-2} + \dots + \phi_p \gamma_{k-p} \quad \text{para } k > 0 \quad (29)$$

sendo:

$$E(\tilde{Z}_{t-k} a_t) = 0 \quad \text{para } k > 0$$

Dividindo-se (29) por γ_0 resulta em:

$$\rho_k = \phi_1 \rho_{k-1} + \phi_2 \rho_{k-2} + \dots + \phi_p \rho_{k-p} \quad \text{para } k > 0 \quad (30)$$

Indicando por ϕ_{kj} o j -ésimo coeficiente de um processo AR(k) de tal modo que ϕ_{kk} seja o último coeficiente, pode-se escrever, de acordo com (30):

$$\rho_j = \phi_{k1} \rho_{j-1} + \phi_{k2} \rho_{j-2} + \dots + \phi_{kk} \rho_{j-k}$$

com $\rho_j = \rho_{-j}$, tem-se, para $j = 1, 2, \dots, k$:

$$\rho_1 = \phi_{k1} + \phi_{k2} \rho_1 + \phi_{k3} \rho_2 + \dots + \phi_{kk} \rho_{k-1}$$

$$\rho_2 = \phi_{k1} \rho_1 + \phi_{k2} + \phi_{k3} \rho_1 + \dots + \phi_{kk} \rho_{k-2}$$

.....

$$\rho_k = \phi_{k1} \rho_{k-1} + \phi_{k2} \rho_{k-2} + \phi_{k3} \rho_{k-3} + \dots + \phi_{kk}$$

Esse sistema é denominado equações de YULE - WALKER e pode ser escrito da seguinte forma matricial:

$$\begin{pmatrix} 1 & \rho_1 & \rho_2 & \dots & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & \dots & \rho_{k-2} \\ . & & & & \\ . & & & & \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \dots & 1 \end{pmatrix} \cdot \begin{pmatrix} \phi_{k1} \\ \phi_{k2} \\ \\ \phi_{kk} \end{pmatrix} = \begin{pmatrix} \rho_1 \\ \rho_2 \\ \\ \rho_k \end{pmatrix}$$

Segue-se que:

$$\phi_{11} = \rho_1$$

$$\phi_{22} = \frac{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & \rho_2 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & 1 \end{vmatrix}} = \frac{\rho_2 - \rho_1^2}{1 - \rho_1^2}$$

$$\phi_{33} = \frac{\begin{vmatrix} 1 & \rho_1 & \rho_2 \\ \rho_1 & 1 & \rho_1 \\ \rho_2 & \rho_1 & \rho_3 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 \\ \rho_1 & 1 & \rho_1 \\ \rho_2 & \rho_1 & 1 \end{vmatrix}}, \text{ etc}$$

e, em geral:

$$\phi_{kk} = \frac{P_k^*}{P_k} ,$$

onde P_k é o determinante da matriz de autocorrelações e P_k^* é o determinante da matriz de autocorrelações com a última coluna substituída pelo vetor:

$$\begin{bmatrix} \rho_1 \\ \rho_2 \\ . \\ . \\ \rho_k \end{bmatrix}$$

Pode-se demonstrar que ϕ_{kk} é igual à correlação parcial entre as variáveis Z_t e Z_{t-k} ajustadas às variáveis intermediárias $Z_{t-1}, \dots, Z_{t-k+1}$, isto é, ϕ_{kk} mede a correlação remanescente entre Z_t e Z_{t-k} depois de eliminada a influência de $Z_{t-1}, \dots, Z_{t-k+1}$.

A estimativa da autocorrelação parcial $\hat{\phi}_{kk}$ é obtida substituindo ρ_k pelas suas estimativas r_k .

QUENOUILLE (1949), citado por MAKRIDAKIS (1976), estendeu o teste de BARTLETT (1946) para o caso da distribuição das autocorrelações parciais. Mostrou que, se as estimativas das autocorrelações parciais são independentemente

distribuídas após uma ordem p , a estimativa do desvio padrão é dada por:

$$\hat{\sigma}[\hat{\phi}_{kk}] = 1/\sqrt{n} \quad \text{para } k > p$$

A significância das estimativas pode então ser testada. Considera-se ϕ_{kk} diferente de zero se:

$$|\hat{\phi}_{kk}| > 2\hat{\sigma}[\hat{\phi}_{kk}] \quad \text{para } k > p$$

3.2.5.- Determinação da Ordem dos Polinômios dos Modelos de Previsão

Modelos ARMA

Examinando as autocorrelações e autocorrelações parciais da série convenientemente diferenciada pode-se identificar o modelo experimental (AR, MA ou ARMA) e a sua ordem $(1, 2, 3, \dots, p; 1, 2, 3, \dots, q)$. Em geral a função de autocorrelação de um processo $AR(p)$ decai de acordo com exponenciais e/ou senóides amortecidas após a defasagem p . A função de autocorrelação parcial de um $AR(p)$ tem $\phi_{kk} \neq 0$ para $k \leq p$ e $\phi_{kk} = 0$ para $k > p$. Um processo $MA(q)$ tem função de autocorrelação que se comporta como a função de

autocorrelação parcial de um $AR(p)$, tendo todas correlações iguais a zero após a defasagem q . A função de autocorrelação parcial de um processo $MA(q)$, por sua vez, identifica-se com a função de autocorrelação de um $AR(p)$. No caso do processo ARMA, que contém um componente autorregressivo de ordem p e um componente de média móvel de ordem q , tem-se a função de autocorrelação decaindo de acordo com exponenciais e senóides amortecidas após a defasagem $q - p$. A função de autocorrelação parcial de um ARMA é também dominada por uma mistura de exponenciais e senóides amortecidas após a defasagem $q - p$ (MAKRIDAKIS, 1976). Na Figura 8 podem ser visualizadas as funções de autocorrelação e autocorrelação parcial teóricas para processos $AR(1)$, $MA(1)$, $AR(2)$ e $MA(2)$.

Modelos Sazonais

Não há, em princípio, nenhuma dificuldade adicional na identificação de modelos sazonais. Fazendo $\omega_t = \Delta^d \Delta_{12}^D Z_t$ (considerando, por exemplo, uma série sazonal com período $s = 12$) obtém-se os valores de d e D que tornam a série estacionária. Depois, inspecionam-se as funções de autocorrelação e autocorrelação parcial da série ω_t nas defasagens $1, 2, 3, \dots$ para obter valores p e q e nas defasagens $12, 24, 36, \dots$ para obter valores de P e Q . Seleciona-se, desse modo, um modelo experimental.

Função de Autocorrelação
AR(1)

Função de Autocorrelação Parcial
AR(1)

Função de Autocorrelação
AR(2)

Função de Autocorrelação Parcial
AR(2)

Função de Autocorrelação
MA(1)

Função de Autocorrelação Parcial
MA(1)

Função de Autocorrelação
MA(2)

Função de Autocorrelação Parcial
MA(2)

Figura 8 - Construções teóricas de funções de autocorrelação e autocorrelação parcial. Extraída de VANDAELE 1983.

Modelos de Função de Transferência

A identificação do modelo de função de transferência deve ser feita através da função de correlação cruzada obtida com as séries Z_t e X_t ($t = 0, 1, 2, \dots$) pré-filtradas. Altos coeficientes de correlação computados da forma usual podem ser encontrados para séries autocorrelacionadas, mas independentes. Existe, todavia, discussão sobre a melhor forma de se fazer a filtragem das variáveis. Alguns autores propõem que cada variável seja filtrada com o seu próprio processo ARIMA, enquanto que outros pensam que a série da variável dependente deve ser filtrada com o mesmo processo ARIMA utilizado para a variável explanatória. Segundo VANDAELE (1983), se o modelo é unidirecional (sem o contexto de equações simultâneas) a pré-filtragem da série da variável dependente deve ser feita com o processo ARIMA que transforma a variável explanatória em ruído branco. Então, o procedimento para a filtragem da série consiste no seguinte: através de um modelo estocástico univariado converte-se a série X_t (variável explicativa) em uma série casual α_t . Utilizando-se o mesmo filtro, converte-se a série Z_t (variável dependente) em uma série β_t . A função de correlação cruzada pré-filtrada é definida como a correlação de α_t e β_t para diferentes defasagens (JENKINS, 1979).

A correlação cruzada é definida como:

$$\rho_{\alpha\beta}(k) = \frac{\gamma_{\alpha\beta}(k)}{\sigma_{\alpha}\sigma_{\beta}} \quad k = 0, \pm 1, \pm 2, \dots \quad (31)$$

onde $\gamma_{\alpha\beta}(k) = E[(x_t - \mu_{\alpha})(y_{t+k} - \mu_{\beta})]$ e σ_{α} e σ_{β} são os desvios padrão das séries α e β , respectivamente.

Como a função de correlação cruzada não é simétrica, as correlações cruzadas devem ser calculadas para defasagens positivas e negativas. Valores elevados de $\rho_{\alpha\beta}(k)$, $k > 0$, indicam que α_t é o preditor de β_t e valores elevados de $\rho_{\alpha\beta}(k)$, $k < 0$, indicam que β_t é o preditor de α_t . No entanto, o procedimento recomendado de filtragem prévia das variáveis (com o processo ARIMA da variável explicativa) limita a análise ao campo negativo ou positivo, dependendo do sentido de causalidade proposto.

A função de correlação cruzada, além de permitir a determinação do tipo de relação existente entre as variáveis, permite uma reavaliação a respeito da estacionariedade das séries. Se a função de correlação cruzada não declina rapidamente para zero, há evidência de que pelo menos uma das duas séries envolvidas não seja estacionária.

A significância da correlação cruzada é avaliada comparando o seu valor com o desvio padrão. Para duas séries

ruído branco, independentes, o desvio padrão aproximado da correlação cruzada é dado por:

$$\sigma[r_{\alpha\beta}(k)] = 1/\sqrt{n} \quad (32)$$

com base na fórmula de BARTLETT (1946).

HAUGH (1976), citado por VANDAELE (1983), demonstrou que para $|k|$ grande, relativamente a n , o desvio padrão aproximado, dado por:

$$\sigma[r_{\alpha\beta}(k)] = \frac{\sqrt{1 - |k/n|}}{\sqrt{n}} \quad (33)$$

é mais exato do que aquele dado por (32).

Conforme VANDAELE (1983), a ordem do operador autoregressivo (m), do operador de média móvel (l) e o valor da constante de defasagem (b), podem ser determinados pela análise da função de correlação cruzada, da seguinte forma:

- 1) O valor da constante b é igual à defasagem da primeira correlação cruzada significativa.
- 2) A ordem do denominador m pode ser identificada através da associação do padrão da correlação cruzada com o padrão da

função de autocorrelação de um modelo $AR(p)$. Se não existir padrão, $m = 0$.

3) A ordem do numerador l é o número de períodos que o padrão $AR(p)$ tarda a aparecer após a primeira correlação cruzada significativa. Por exemplo: se $r_{\alpha\beta}(3)$ é significativa, mas o padrão $AR(p)$ não se inicia até o período 4, então $l = 4 - 3$. Se não existir padrão sazonal na função de correlação cruzada, então os parâmetros do numerador devem corresponder ao número de correlações cruzadas significativas, menos um.

A Figura 9 mostra algumas funções teóricas de correlação cruzada que ajudam no entendimento do mecanismo de identificação dos modelos de função de transferência.

Supondo o seguinte modelo de função de transferência:

$$\beta_t = v_1(B)\alpha_{1t} + v_2(B)\alpha_{2t} + e_t \quad (34)$$

a identificação do processo é feita em tres passos:

1- Obtém-se a função de correlação cruzada para as séries α_{1t} e β_t com o objetivo de estimar a ordem dos polinômios do numerador e do denominador do termo $V_1(B)$ da equação (34). Estimam-se os pesos da função impulso-resposta $V_1(B)$ (onde $V_j(B) = V_{j0} + V_{j1}B + V_{j2}B^2 + \dots$ para $j = 1, 2, \dots, n$)

Figura 9 - Funções teóricas de correlação cruzada. Extraída de VANDAELE (1983).

com base em $\hat{V}_k = r_{\alpha\beta}(k) s_\beta / s_\alpha$. Essa representação para os pesos V_k é obtida da seguinte forma: tomando-se a esperança de $\beta_t = V(B)\alpha_t + u_t$ após multiplicar ambos os lados por α_{t-k} tem-se:

$$\gamma_{\alpha\beta}(k) = E(\alpha_{t-k} \beta_t) = V_k \sigma_\alpha^2 \quad \text{para } k = 0, 1, 2, \dots$$

(pressupondo u_t e α_t não correlacionados e $E(\alpha_{t-k} \alpha_t) = 0$ para todo t exceto $t' = t - k$)

e, resolvendo para V_k em termos da correlação cruzada:

$$V_k = \rho_{\alpha\beta}(k) \sigma_\beta / \sigma_\alpha \quad \text{para } k = 0, 1, 2, \dots$$

2- Repete-se o processo para as séries α_{2t} e β_t visando a estimativa da ordem dos polinômios do numerador e do denominador do termo $V_2(B)$ da equação (34). Obtém-se as estimativas dos pesos da função impulso-resposta $V_2(B)$.

3- Estima-se e_t em (34) após a substituição dos termos estimados para $V_1(B)$ e $V_2(B)$. Essa série de resíduos pode então ser analisada como um processo univariado, para a obtenção da ordem dos polinômios auto-regressivo e de média móvel referentes ao terceiro termo do segundo membro da equação (11).

3.2.6.- Estimativas Iniciais dos Parâmetros

No estágio de identificação obtêm-se também as estimativas preliminares dos parâmetros dos modelos experimentais, através de autocorrelações da série $w_t = \Delta^d Z_t$. Essas estimativas serão usadas como valores iniciais para o procedimento iterativo de estimação necessário para a resolução do sistema de equações não lineares. Considerando um sistema univariado, tem-se, para um AR(1), por exemplo,

$$\phi_1 = \rho_1$$

Para um AR(2)

$$\phi_1 = \frac{\rho_1(1 - \rho_2)}{1 - \rho_1^2}$$

$$\phi_2 = \frac{\rho_2 - \rho_1^2}{1 - \rho_1^2}$$

Para um AR(3)

$$\phi_1 = \frac{\begin{vmatrix} \rho_1 & \rho_1 & \rho_2 \\ \rho_2 & 1 & \rho_1 \\ \rho_3 & \rho_1 & 1 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 \\ \rho_1 & 1 & \rho_1 \\ \rho_2 & \rho_1 & 1 \end{vmatrix}}$$

$$\phi_2 = \frac{\begin{vmatrix} 1 & \rho_1 & \rho_2 \\ \rho_1 & \rho_2 & \rho_1 \\ \rho_2 & \rho_3 & 1 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 \\ \rho_1 & 1 & \rho_1 \\ \rho_2 & \rho_1 & 1 \end{vmatrix}}$$

$$\phi_3 = \frac{\begin{vmatrix} 1 & \rho_1 & \rho_1 \\ \rho_1 & 1 & \rho_2 \\ \rho_2 & \rho_1 & \rho_3 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 \\ \rho_1 & 1 & \rho_1 \\ \rho_2 & \rho_1 & 1 \end{vmatrix}}$$

Os parâmetros iniciais de um MA(q) podem ser determinados por:

$$\rho_k = \frac{-\theta_k + \theta_1 \theta_{k+1} + \theta_2 \theta_{k+2} + \dots + \theta_{q-k} \theta_q}{1 + \theta_1^2 + \theta_2^2 + \dots + \theta_q^2} \quad (35)$$

para $k = 1, 2, \dots, q$

que é obtida tomando-se o modelo:

$$\tilde{Z}_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}$$

multiplicando-se ambos os lados por $\tilde{Z}_{t-k}$ e tomando-se a esperança.

Similarmente são obtidos os parâmetros iniciais do processo ARIMA. Tem-se, por exemplo, para um ARIMA (1,d,1):

$$\rho_1 = \frac{(1 - \phi \theta) (\phi - \theta)}{1 + \theta^2 - 2 \phi \theta}$$

$$\rho_2 = \rho_1 \phi$$

As estimativas iniciais dos parâmetros do modelo de função de transferência relacionando em (11) são obtidas através da representação impulso-resposta:

$$Y_t = V_0 X_t + V_1 X_{t-1} + V_2 X_{t-2} + \dots + N_t$$

ou

$$Y_t = V(B) X_t + N_t$$

$$\text{onde: } V(B) = V_0 + V_1 B + V_2 B^2 + \dots$$

O polinômio $V(B)$, como indicado em (6), pode ser expresso em termos da razão de dois polinômios em B finitos:

$$V(B) = \frac{\omega(B)}{\delta(B)}$$

$$\text{com } \omega(B) = \omega_0 - \omega_1 B - \dots - \omega_l B^l \quad \text{e}$$

$$\delta(B) = 1 - \delta_1 B - \dots - \delta_m B^m$$

As relações entre a representação impulso-resposta e os parâmetros iniciais do numerador e denominador podem ser expressas de forma genérica como: (Ver VANDAELE, 1983)

$$\begin{aligned} V_k &= 0 & k < b \\ V_k &= \delta_1 V_{k-1} + \delta_2 V_{k-2} + \dots + \delta_m V_{k-m} + \omega_0 & k = b \\ V_k &= \delta_1 V_{k-1} + \delta_2 V_{k-2} + \dots + \delta_m V_{k-m} - \omega_{k-b} & b < k \leq b+1 \\ V_k &= \delta_1 V_{k-1} + \delta_2 V_{k-2} + \dots + \delta_m V_{k-m} & k > b+1 \end{aligned}$$

Para o modelo:

$$y_t = \frac{\omega_0 - \omega_1 B - \omega_2 B^2}{1 - \delta_1 B - \delta_2 B^2} x_{t-b} + e_t \quad \text{por exemplo, para } b = 3,$$

tem-se:

$$V_k = 0 \quad \text{para } k < 3$$

$$V_3 = \omega_0$$

$$V_4 = \delta_1 V_3 - \omega_1$$

$$V_5 = \delta_1 V_4 + \delta_2 V_3 - \omega_2$$

$$V_6 = \delta_1 V_5 + \delta_2 V_4$$

$$V_7 = \delta_1 V_6 + \delta_2 V_5$$

Dados os pesos $V_k = \rho_{\alpha\beta}(k) \sigma_\beta / \sigma_\alpha$, para $k = 0, 1, 2, \dots$ pode-se resolver o sistema para δ_1 , δ_2 , ω_1 e ω_2 , sucessivamente, com $\omega_0 = V_3$ sendo estimado diretamente.

As estimativas dos parâmetros do polinômio do termo residual são obtidas exatamente como as estimativas dos valores iniciais do modelo ARIMA univariado, analisando as autocorrelações da série e_t da equação (34).

3.2.7.- Verificação

Para verificar se o modelo estimado é adequado são propostos os seguintes testes:

a) Teste de superajustamento:

Consiste em estimar um modelo com parâmetros extras, testar se estes são estatisticamente significativos e verificar se a variância residual desse modelo alternativo diminuiu em relação à do original. Esse procedimento exige o conhecimento "a priori" da direção em que está ocorrendo a inadequação do modelo.

b) Teste para avaliar a redundância de parâmetros:

Uma forma para avaliar a adequação do modelo é verificar se estes não contêm parâmetros redundantes. Parâmetros redundantes são apontados pelo grande desvio padrão do coeficiente estimado resultando na sua não significância e pela alta correlação entre os coeficientes do modelo, o que pode ser verificado na matriz de correlação dos coeficientes estimados. A simplificação do modelo é recomendável quando parâmetros redundantes forem encontrados.

c) Teste de autocorrelação residual:

Partindo de um modelo:

$$\phi(B)Z_t = \theta(B)a_t \quad (36)$$

e estimando-se ϕ e θ , tem-se:

$$\hat{a}_t = \hat{\theta}^{-1}(B)\hat{\phi}(B)Z_t \quad (37)$$

onde $\hat{a}_t$ são os resíduos estimados.

Se o modelo for adequado a série de resíduos deverá ser ruído branco. Então, deve-se ter estimativas das autocorrelações dos $\hat{a}_t$ próximas de zero e com distribuição

aproximadamente normal e desvio padrão igual a $1/\sqrt{n}$. As estimativas das autocorrelações $r_k(\hat{a})$ são dadas por:

$$r_k(\hat{a}) = \frac{\sum_{t=k+1}^n \hat{a}_t \hat{a}_{t-k}}{\sum_{t=1}^n \hat{a}_t^2} \quad (38)$$

A comparação dos $r_k(\hat{a})$ com os limites $\pm 2/\sqrt{n}$ fornece uma indicação geral da adequação do modelo, tendo sido demonstrado, no entanto, que para valores pequenos de k o desvio padrão de $r_k(\hat{a})$ pode ser consideravelmente menor que $1/\sqrt{n}$. Nesses casos os limites $\pm 2/\sqrt{n}$ levam a subestimar a significância dos valores de $r_k(\hat{a})$ (BOX & JENKINS, 1976).

d) Teste BOX-PIERCE:

Este teste é aplicado às primeiras autocorrelações dos resíduos, indicando se esses valores são muito altos. Se o modelo é apropriado, a estimativa

$$Q(K) = n(n+2) \left[\sum_{k=1}^K \frac{1}{n-k} r_k^2(\hat{a}) \right] \quad (39)$$

tem distribuição χ^2 com $K - p - q$ graus de liberdade. Em geral basta tomar as 20 ou 25 primeiras $r_k(\hat{a})$, considerando o modelo

bem ajustado para valor de Q menor que o valor crítico da distribuição de χ^2 com $K - p - q$ graus de liberdade.

e) Teste da correlação cruzada:

Um teste auxiliar no procedimento de verificação é baseado na correlação cruzada entre valores prévios da série e o valor presente do ruído. Se o modelo é apropriado, a_t e Z_{t-k} são independentes para $k \geq 1$. A função de correlação cruzada (s_k), para valores estimados dos resíduos, é dada por:

$$s_k = \frac{\sum_{t=k+1}^n \hat{a}_t (Z_{t-k} - \bar{Z})}{\left[\sum_{t=1}^n \hat{a}_t^2 \sum_{t=1}^n (Z_t - \bar{Z})^2 \right]^{1/2}} \quad \text{para } k = 1, 2, \dots \quad (40)$$

Considera-se, para k grande, s_k significativamente diferente de zero se $|s_k| > 2/\sqrt{n}$.

A análise das autocorrelações $r_k(\hat{a})$ dá informação sobre novos termos de média móvel a serem incluídos no modelo. Se, por exemplo $|r_4| > 2/\sqrt{n}$, um termo $\theta_4 a_{t-4}$ deve ser incluído no modelo. Quando se tem $|s_k| \geq 2/\sqrt{n}$, termos auto-regressivos devem ser incluídos no modelo.

MORETTIN & TOLOI (1985) sugerem o seguinte procedimento para a identificação do modelo a ser ajustado :

1) começando com um $AR(p)$ de baixa ordem, pode-se incluir novos termos auto-regressivos, analisando as funções de correlações cruzadas (s_k);

2) quando todos os s_k não se apresentarem mais significativos, as correlações $r_k(\hat{a})$ podem indicar a necessidade da inclusão de termos de média móvel;

Respeitando essa sequência, procede-se de maneira iterativa até que todos os s_k e $r_k(\hat{a})$ não se apresentem mais significativos.

A verificação dos modelos de função de transferência é feita de forma análoga à verificação dos modelos univariados, consistindo em:

- 1- Análise de resíduo
- 2- Teste de superajustamento
- 3- Teste para verificação de redundância de parâmetros

A análise de resíduo do modelo de função de transferência envolve teste para autocorrelações individuais e para grupo de autocorrelações (teste Q de Ljung-Box) e teste

para correlações cruzadas entre o resíduo e as variáveis explicativas do modelo (pré-filtradas) individuais e para grupo de correlações. Se somente o termo de ruído é inadequado, os resíduos são autocorrelacionados, mas as correlações cruzadas do resíduo e variáveis explicativas são nulas. Quando o termo de função de transferência é inadequado (mesmo que o termo de resíduo seja adequado) não só as autocorrelações dos resíduos mas também as correlações cruzadas entre resíduos e variáveis explicativas são não nulas.

Se a função de transferência é corretamente especificada, a série de resíduos é ruído branco, com variância igual a $1/g$, com $g = n - u - p$ (u sendo o maior entre m e $l + b$). Considera-se significativa a autocorrelação se ela for maior que $2/\sqrt{g}$, isto é, maior que duas vezes o seu desvio padrão.

A estimativa Q de Ljung-Box é dada por:

$$Q(K) = g(g + 2) \left[\sum_{k=1}^K \frac{1}{g - k} r_k^2(\hat{a}) \right]$$

com distribuição de χ^2 com $K - p - q$ graus de liberdade (o número de parâmetros ω e δ não influencia os graus de liberdade da estatística Q).

De forma análoga à autocorrelação de resíduo considera-se a correlação cruzada significativa se ela for maior que $2/\sqrt{g}$. No caso de teste para grupos de correlações cruzadas tem-se:

$$Q(K) = g(g + 2) \left[\sum_{k=0}^K \frac{1}{g - k} s_k^2(\hat{\alpha}) \right]$$

com distribuição de χ^2 com $K - m - 1$ graus de liberdade (o número de graus de liberdade dessa estatística não depende do número de parâmetros do termo de resíduo do modelo de função de transferência).

3.2.8.- Previsões

A previsão de um valor Z_{t+h} com $h \geq 1$ através de observações $\dots, Z_{t-2}, Z_{t-1}, Z_t$, onde t é a origem da previsão e h o horizonte, pode ser denotada por $\hat{Z}_t(h)$ e expressa de várias maneiras, observando as formas alternativas do modelo ARIMA que são apresentadas a seguir:

- Forma de equações em diferenças

$\tilde{Z}_t$ é expresso em função de valores prévios da série e de valores prévios e correntes do ruído branco (a_t). Em sua forma compacta pode ser representado por:

$$\phi(B)(1 - B)^d \tilde{Z}_t = \theta(B)a_t$$

Fazendo:

$$\phi(B)(1 - B)^d = \xi(B) = 1 - \xi_1 B - \xi_2 B^2 - \dots - \xi_{p+d} B^{p+d}$$

o modelo pode ser escrito como:

$$\xi(B)\tilde{Z}_t = \theta(B)a_t \quad \text{ou} \quad (41)$$

$$\tilde{Z}_t = \xi_1 \tilde{Z}_{t-1} + \dots + \xi_{p+d} \tilde{Z}_{t-p-d} + a_t - \theta_1 a_t - \dots - \theta_q a_{t-q} \quad (42)$$

Para o caso particular do modelo ARIMA(1,1,1), tem-se:

$$(1 - \phi_1 B)(1 - B)\tilde{Z}_t = (1 - \theta_1 B)a_t$$

ou

$$[1 - (1 + \phi_1)B + \phi_1 B^2] \tilde{Z}_t = (1 - \theta_1 B)a_t$$

ou ainda

$$\tilde{Z}_t = (1 + \phi_1)\tilde{Z}_{t-1} - \phi_1 \tilde{Z}_{t-2} + a_t - \theta_1 a_{t-1}$$

Comparando-se essa expressão com (42) obtém-se:

$$\xi_1 = 1 - \phi_1$$

$$\xi_2 = -\phi_1$$

O modelo, na forma de equações em diferenças, é adequado para o cálculo de previsões.

- Forma de choques aleatórios

$\tilde{Z}_t$ é expresso em função dos valores atual e prévios de a_t :

$$\tilde{Z}_t = a_t + \psi_1 a_{t-1} + \psi_2 a_{t-2} + \dots \quad (43)$$

$$\text{com } \psi(B) = 1 + \psi_1 B + \psi_2 B^2 + \dots$$

$$\text{ou } \tilde{Z}_t = a_t + \sum_{j=1}^{\infty} \psi_j a_{t-j}$$

ou ainda, na forma compacta,

$$\tilde{Z}_t = \psi(B) a_t \quad (44)$$

Multiplicando-se a expressão (44) por $\xi(B)$ obtém-se:

$$\xi(B) \tilde{Z}_t = \xi(B) \psi(B) a_t \quad (45)$$

Comparando-se (45) com (41), verifica-se que:

$$\xi(B)\psi(B) = \theta(B)$$

ou

$$\begin{aligned} (1 - \xi_1 B - \dots - \xi_{p+d} B^{p+d}) (1 + \psi_1 B + \psi_2 B^2 + \dots) = \\ = (1 - \theta_1 B - \dots - \theta_q B^q) \end{aligned}$$

Os pesos ψ_j podem ser obtidos identificando-se os coeficientes de $B, B^2, \dots$. Dessa forma, tem-se:

$$\psi_1 - \xi_1 = -\theta_1$$

$$\psi_1 - \xi_1 \psi_1 - \xi_2 = -\theta_2$$

.

.

.

$$\psi_j - \xi_1 \psi_{j-1} - \dots - \xi_{p+d} \psi_{j-p-d} = -\theta_j$$

onde: $\psi_0 = 1$ e $\psi_j = 0$ para $j < 0$ e $\theta_j = 0$ para $j > q$

- Forma invertida

$\tilde{Z}_t$ é expresso em função de valores prévios de $\tilde{Z}_t$ e do valor atual de a_t .

$$\tilde{Z}_t = \pi_1 \tilde{Z}_{t-1} + \pi_2 \tilde{Z}_{t-2} + \dots + a_t$$

$$\text{ou } (1 - \pi_1 B - \pi_2 B^2 - \dots) \tilde{Z}_t = a_t$$

$$\text{ou ainda } \pi(B) \tilde{Z}_t = a_t \quad (46)$$

Substituindo (46) em (41) obtém-se:

$$\xi(B) \tilde{Z}_t = \theta(B) \pi(B) \tilde{Z}_t$$

$$\text{com } \xi(B) = \theta(B) \pi(B) \quad \text{ou}$$

$$\begin{aligned} (1 - \xi_1 B - \dots - \xi_{p+d}) &= \\ &= (1 - \theta_1 B - \dots - \theta_q B^q) (1 - \pi_1 B - \pi_2 B^2 - \dots) \end{aligned}$$

Reescrevendo as três formas do modelo ARIMA, com $t+h$ em lugar de t , tem-se:

1) forma de equação em diferenças:

$$\begin{aligned} Z_{t+h} &= \xi_1 Z_{t+h-1} + \dots + \xi_{p+d} Z_{t+h-p-d} - \theta_1 a_{t+h-1} - \theta_2 a_{t+h-2} - \\ &- \dots - \theta_q a_{t+h-q} + a_{t+h} \end{aligned} \quad (47)$$

2) forma de choques aleatórios:

$$Z_{t+h} = \sum_{j=-\infty}^{t+h} \psi_{t+h-j} a_j = \sum_{j=0}^{\infty} \psi_j a_{t+h-j} \quad \text{com } \psi_0 = 1 \quad (48)$$

3) forma invertida:

$$Z_{t+h} = \sum_{j=1}^{\infty} \pi_j Z_{t+h-j} + a_{t+h} \quad (49)$$

A previsão $\hat{Z}_t(h)$ pode ser considerada uma função linear das observações $Z_t, Z_{t-1}, Z_{t-2}, \dots$ e também uma função linear dos choques $a_t, a_{t-1}, a_{t-2}, \dots$.

Indiando a melhor previsão por:

$$\hat{Z}_t(h) = \psi_h^* a_t + \psi_{h+1}^* a_{t-1} + \psi_{h+2}^* a_{t-2} + \dots \quad (50)$$

pode-se determinar os pesos ψ_j^* que minimizam o erro quadrático médio de previsão (EQM) que é dado por:

$$E[Z_{t+h} - \hat{Z}_t(h)]^2 = E\left[\sum_{j=0}^{\infty} \psi_j a_{t+h-j} - \sum_{j=0}^{\infty} \psi_{h+j}^* a_{t-j}\right]^2$$

usando (48) e (50).

Uma vez que:

$$\sum_{j=0}^{\infty} \psi_j a_{t+h-j} = \sum_{j=-h}^{\infty} \psi_{h+j} a_{t-j} \quad e$$

$$\sum_{j=-h}^{\infty} \psi_{h+j} a_{t-j} = \sum_{j=-h}^{-1} \psi_{h+j} a_{t-j} + \sum_{j=0}^{\infty} \psi_{h+j} a_{t-j}$$

pode-se escrever o erro de previsão como:

$$e_t(h) = \sum_{j=-h}^{-1} \psi_{h+j} a_{t-j} + \sum_{j=0}^{\infty} (\psi_{h+j} - \psi_{h+j}^*) a_{t-j} \quad \text{ou}$$

$$e_t(h) = Z_{t+h} - \hat{Z}_t(h) = \psi_0 a_{t+h} + \psi_1 a_{t+h-1} + \dots \\ + \psi_{h-1} a_{t+1} + \sum_{j=0}^{\infty} (\psi_{h+j} - \psi_{h+j}^*) a_{t-j}$$

e, sendo a_t ruído branco:

$$E[e_t(h)]^2 = (1 + \psi_1^2 + \dots + \psi_{h-1}^2) \sigma_a^2 + \sum_{j=0}^{\infty} (\psi_{h+j} - \psi_{h+j}^*)^2 \sigma_a^2$$

Dessa forma tem-se que $E[e_t(h)]^2$ é minimizado se $\psi_{h+j}^* = \psi_{h+j}$.

Portanto, a previsão de EQM mínimo é obtida com:

$$\hat{Z}_t(h) = \psi_h a_t + \psi_{h+1} a_{t-1} + \dots = \sum_{j=0}^{\infty} \psi_{h+j} a_{t-j} \quad (51)$$

e o erro de previsão fica:

$$e_t(h) = a_{t+h} + \psi_1 a_{t+h-1} + \dots + \psi_{h-1} a_{t+1} \quad (52)$$

Tendo que :

$$Z_{t+k} = e_t(h) + \hat{Z}_t(h) \quad \text{para } h \geq 1$$

e, denotando por:

$$[Z_{t+h}] = E[Z_{t+h} | Z_t, Z_{t-1}, \dots]$$

a esperança condicional de um valor passado, presente ou futuro de uma variável, dadas as informações disponíveis até o instante t , conclue-se que:

$$\hat{Z}_t(h) = [Z_{t+h}]$$

ou seja, a previsão de EQM mínimo é a esperança condicional de Z_{t+h} , dadas as observações passadas da série.

De (52) tem-se que $E[e_t(h)] = 0$ e a variância do erro de previsão é :

$$V(h) = (1 + \psi_1^2 + \psi_2^2 + \dots + \psi_{h-1}^2) \sigma_a^2$$

O erro de previsão a um passo é dado por:

$$e_t(1) = Z_{t+1} - \hat{Z}_t(1) = a_{t+1}$$

Inferre-se daí que sendo a_t ruído branco, os erros de previsão a um passo são não correlacionados.

3.2.8.1- Previsões com Base nas Formas Alternativas do Modelo ARIMA

a) Previsão utilizando equações em diferenças:

Tomando-se a esperança condicional de (47) obtém-se:

$$\begin{aligned} \hat{Z}_t(h) = & \xi_1[Z_{t+h-1}] + \dots + \xi_{p+d}[Z_{t+h-p-d}] - \theta_1[a_{t+h-1}] - \\ & - \dots - \theta_q[a_{t+h-q}] + [a_{t+h}] \quad \text{para } h \geq 1 \end{aligned}$$

As previsões serão feitas com base nas seguintes informações:

$$[Z_{t+k}] = \hat{Z}_t(k) , \quad k > 0$$

$$[Z_{t+k}] = Z_{t+k} , \quad k \leq 0$$

$$[a_{t+k}] = 0 , \quad k > 0$$

$$[a_{t+k}] = a_{t+k} , \quad k \leq 0$$

Os valores de $\hat{Z}_t(h-1), \hat{Z}_t(h-2), \dots$, utilizados na obtenção de $\hat{Z}_t(h)$, são calculados recursivamente.

Supondo, para exemplificar, um modelo ARIMA (2,1,1):

$$(1 - \phi_1 B - \phi_2 B^2)(1 - B)Z_t = (1 - \theta_1 B)a_t$$

substituindo t por $t + h$, tem-se:

$$(1 - \phi_1 B - \phi_2 B^2)(1 - B)Z_{t+h} = (1 - \theta_1 B)a_{t+h}$$

ou, de outra forma:

$$\begin{aligned} Z_{t+h} = & (1 + \phi_1)Z_{t+h-1} - (\phi_1 - \phi_2)Z_{t+h-2} - \phi_2 Z_{t+h-3} + \\ & + a_{t+h} - \theta_1 a_{t+h-1} \end{aligned}$$

obtem-se:

$$\begin{aligned} \hat{Z}_t(1) &= (1 + \phi_1)Z_t - (\phi_1 - \phi_2)Z_{t-1} - \phi_2 Z_{t-2} - \theta_1 a_t \\ \hat{Z}_t(2) &= (1 + \phi_1)\hat{Z}_t(1) - (\phi_1 - \phi_2)Z_t - \phi_2 Z_{t-1} \\ \hat{Z}_t(3) &= (1 + \phi_1)\hat{Z}_t(2) - (\phi_1 - \phi_2)\hat{Z}_t(1) - \phi_2 Z_t \end{aligned}$$

e, para $h \geq 4$,

$$\hat{Z}_t(h) = (1 + \phi_1)\hat{Z}_t(h-1) - (\phi_1 - \phi_2)\hat{Z}_t(h-2) - \phi_2\hat{Z}_t(h-3)$$

b) Previsão utilizando a forma de choques aleatórios:

De (48), utilizando-se a esperança condicional, obtém-se:

$$\begin{aligned}\hat{Z}_t(h) &= a_{t+h} + \psi_1[a_{t+h-1}] + \psi_2[a_{t+h-2}] + \dots + \psi_{h-1}[a_{t+1}] + \\ &+ \psi_h[a_t] + \psi_{h+1}[a_{t-1}] + \dots\end{aligned}$$

c) Previsão utilizando a forma invertida:

De (49) obtém-se:

$$\hat{Z}_t(h) = \sum_{j=1}^{\infty} \pi_j[Z_{t+h-j}] + [a_{t+h}]$$

3.2.8.2- Previsões com Modelos de Função de Transferência.

Representando o modelo de função de transferência por:

$$(1 - B)^d Z'_t = \frac{\omega(B)}{\delta(B)} (1 - B)^d X_{t-b} + \frac{\theta(B)}{\phi(B)} a_t \quad \text{ou}$$

$$Z_t = \frac{\theta(B)(1-B)^d}{\delta(B)(1-B)^d} X_{t-b} + \frac{\theta(B)}{\phi(B)(1-B)^d} a_t$$

ou ainda

$$\delta(B)\phi(B)(1-B)^{d'} Z_t = \omega(B)\phi(B)(1-B)^d X_{t-b} + \theta(B)\delta(B) a_t$$

tem-se:

$$\delta^*(B) Z_t = \omega^*(B) X_{t-b} + \theta^*(B) a_t$$

com:

$$\begin{aligned} \delta^*(B) &= \delta(B)\phi(B)(1-B)^{d'} = 1 + \delta_1^* B + \dots + \delta_m^* B^{m^*} \\ \omega^*(B) &= \omega(B)\phi(B)(1-B)^d = \omega_0 + \omega_1^* B + \dots + \omega_l^* B^{l^*} \\ \theta^*(B) &= \theta(B)\delta(B) = 1 + \theta_1^* B + \dots + \theta_q^* B^{q^*} \end{aligned}$$

$$\text{sendo: } m^* = m + p + d', \quad l^* = l + p + d \quad \text{e} \quad q^* = q + m$$

Assumindo $b = 0$ pode-se escrever:

$$\begin{aligned} Z_{t+h} &= \delta_1^* Z_{t+h-1} + \delta_2^* Z_{t+h-2} + \dots + \delta_m^* Z_{t+h-m^*} + \omega_0^* X_{t+h} - \\ &\quad - \omega_1^* X_{t+h-1} - \omega_2^* X_{t+h-2} - \dots - \omega_l^* X_{t+h-l^*} + a_{t+h} - \\ &\quad - \theta_1^* a_{t+h-1} - \theta_2^* a_{t+h-2} - \dots - \theta_q^* a_{t+h-q^*} \end{aligned}$$

O valor esperado de Z_{t+h} , $E(Z_{t+h})$, pode ser obtido da seguinte forma:

- substituem-se os valores corrente e prévios de a_{t+j} , $j \leq 0$, pelos resíduos calculados;
- substituem-se os valores futuros de a_{t+j} , $0 < j \leq h$, pelas esperanças desses valores. Sendo a_t ruído branco os valores esperados para a_{t+j} , $0 < j \leq h$, são 0.
- substituem-se os valores corrente e prévios de X_{t+j} , $j \leq 0$, pelos valores observados;
- substituem-se os valores futuros de X_{t+j} , $0 < j \leq h$, por previsões que podem ser obtidas por modelos ARIMA;
- substituem-se os valores corrente e prévios de Z_{t+j} , $j \leq 0$, pelos valores observados; e
- substituem-se os valores futuros de Z_{t+j} , $0 < j \leq h$, pelas previsões apropriadas, calculadas de forma recursiva.

3.2.8.3.- Intervalo de Confiança para Previsão.

O intervalo de confiança, a 5% de probabilidade, para previsão é dado por:

$$\hat{Y}_t(h) \pm 1,96[\hat{V}(h)]^{1/2}$$

3.3.- Relações Causais

A especificação de modelos de função de transferência requer a identificação de relações causais entre variáveis. Considera-se que, se existe causalidade de uma variável X para uma variável Z , então os valores passados e corrente de X ajudam a prever Z . Se X causa Z , as variações de X tendem a preceder as variações em Z e isso pode ser detectado através do teste de causalidade.

Baseado nos conceitos de GRANGER (1969), SIMS (1972) desenvolveu um teste para causalidade que consiste em estimar as seguintes equações:

$$Z_t = \sum_{i=-k_1}^{k_2} \alpha_i X_{t-i} + u_t \quad (53)$$

$$X_t = \sum_{i=-k_1}^{k_2} \beta_i Z_{t-i} + v_t \quad (54)$$

que envolvem valores passados, presente e futuros da variável explicativa. Se os coeficientes dos valores futuros da variável explicativa forem nulos (estatisticamente não diferentes de zero) na equação (53) e não o forem na (54), a relação causal será de X para Z . O inverso indicará causalidade de Z para X . Se os coeficientes dos valores

futuros de ambas as variáveis forem diferentes de zero, haverá relação bicausal e, finalmente, se todos os coeficientes dos valores futuros de ambas as variáveis não forem estatisticamente diferentes de zero, haverá ausência de causalidade.

As estimativas dessas equações requerem a realização prévia de filtragem das séries quando for detectada autocorrelação dos resíduos na regressão, indicada pelo teste de Durbin-Watson e teste Q de Ljung-Box. Para as filtrações das séries pode-se utilizar o filtro de Cochrane-Orcutt ^{4/}. Essa técnica de filtragem consiste no seguinte:

- Por mínimos quadrados ordinários (MQO) obtêm-se as estimativas de, por exemplo:

$$Z_t = \sum_{i=-k_1}^{k_2} \alpha_i X_{t-i} + u_t$$

onde X e Z são as variáveis testadas.

- Calculam-se os resíduos $\hat{u}_1, \hat{u}_2, \dots, \hat{u}_n$ e, a partir daí, $\hat{\rho}$, que para o caso de autocorrelação de primeira ordem é dado por:

4/ Ver KMENTA, 1988, p.338-39.

$$\hat{\rho} = \frac{\sum \hat{u}_t \cdot \hat{u}_{t-1}}{\sum \hat{u}_{t-1}^2}$$

-Constróem-se posteriormente novas variáveis:

$$Z_t^* = (Y_t - \hat{\rho} Y_{t-1}) \quad \text{e} \quad X_t^* = (X_t - \hat{\rho} X_{t-1})$$

e obtém-se a estimativa de:

$$Z_t^* = \sum_{i=-k_1}^{k_2} \alpha_i X_{t-i}^* + u_t$$

Essa sistemática deve ser repetida recursivamente para as defasagens que apresentarem autocorrelação elevada nos resíduos até que toda autocorrelação tenha sido removida. A eliminação da autocorrelação com defasagem n entre os erros é tida como completa quando o θ estimado na equação :

$$u_t = \theta(u_{t-n}) + v_t \quad n = 1, 2, \dots, j$$

apresentar-se estatisticamente não significativo, considerando um nível de 5% de probabilidade pela utilização do teste "t" de Student.

O teste de causalidade nas séries desprovidas de correlação nos resíduos (testa as hipóteses de serem nulos os coeficientes futuros da variável explicativa nas equações (53) e (54)), é feito através da estatística F .

3.4.- Teste de Raiz Unitária e Co-integração

A existência de co-integração entre variáveis deve ser considerada no caso de modelos que envolvam variáveis explicativas, como os de função de transferência.

O teste de co-integração é aplicado na investigação da hipótese de existir relação estável de longo prazo entre variáveis integradas de mesma ordem. Se essa relação se verifica pode-se, utilizando um mecanismo de correção de erro, contornar a problemática causada pela perda de informações de longo prazo quando se diferencia a série para torná-la estacionária.^{5/}

Antes de se testar co-integração, deve-se, então, estabelecer a ordem de integração das variáveis que serão relacionadas.^{6/}

5/ Quando se relacionam variáveis baseando-se na suposição de que o processo é estacionário quando ele não é, têm-se sérias consequências para as propriedades estatísticas dos estimadores e testes, como demonstrado na literatura sobre "regressões espúrias". Se duas séries são descritas por um processo "passeio casual", por exemplo, a regressão de uma contra outra, em nível, pode indicar relação entre as variáveis quando na verdade ela não existe. A utilização das séries nas diferenças tem sido recomendada para solucionar tal problema (HENDRY, 1986 ; PINDYCK & RUBINFELD, 1991 e CAMPBELL & PERRON, 1991).

6/ O termo integração refere-se à operação inversa da operação diferença, podendo as séries, após sofrerem diferenças, retornarem à forma original quando integradas.

Integração

Comforme definem ENGLE & GRANGER (1987), uma série sem componente determinístico, com representação ARMA, estacionária, invertível, após d diferenças, é dita ser integrada de ordem d , denotada por $x_t \sim I(d)$.

A ordem de integração de uma variável diz respeito, então, ao número de vezes que a série deve ser diferenciada (diferenças do tipo $x_t - x_{t-1}$) para que ela se torne estacionária, isto é, adquira propriedades estatísticas invariantes no tempo. Para cada raiz unitária tem-se a necessidade de uma diferença a mais.

Um exemplo bastante simples de série estacionária é a série ruído branco. Se os e_t (com $t = 1, 2, 3, \dots$) são independentes, com média zero e variância σ^2 , então a série e_t é $I(0)$, ou seja, integrada de ordem zero.

Supondo que o processo gerador de dados é um passeio casual dado por:

$$x_t = x_{t-1} + e_t$$

tem-se, por substituições sucessivas, que:

$$x_t = \sum_{j=1}^t e_j \quad \text{se } x_0 = 0$$

então, x_t é a somatória de e_t e, $\Delta x_t = e_t$ é $I(0)$. Nesse caso, x_t é $I(1)$ (integrada de ordem 1), pois uma diferença foi necessária para tornar a série estacionária.

Por outro lado, quando x_t é gerado pelo processo auto-regressivo:

$$x_t = \rho x_{t-1} + e_t$$

com $\rho \in (-1,1)$ ou $|\rho| < 1$ e e_t ruído branco,

a variável x_t é integrada de ordem 0, $I(0)$.

Diversos estudos tratam de estabelecer procedimentos para verificar a existência de raiz unitária em uma série temporal. (Discussão dessa literatura é apresentada em HENDRY, 1986, CAMPBELL & PERRON, 1991 e outros). Dentre esses procedimentos os de FULLER (1976) e DICKKEY & FULLER (1979 e 1981) têm sido bastante utilizados.

Suponha que o modelo que descreve o comportamento de uma série temporal seja:

$$x_t = \alpha + \rho_1 x_{t-1} + \rho_2 x_{t-2} + e_t \quad (55a)$$

ou

$$(1 - \rho_1 B - \rho_2 B^2) x_t = \alpha + e_t \quad (55b)$$

que, devidamente transformado para fins de ajuste, possa ser assim representado:

$$\Delta x_t = \alpha + (\rho_1 + \rho_2 - 1) x_{t-1} - \rho_2 \Delta x_{t-1} + e_t \quad (56)$$

O teste de raiz unitária (estatística τ_μ de FULLER, 1976) consiste em testar em (56) (estimada por mínimos quadrados ordinários) a hipótese nula $\rho_1 + \rho_2 - 1 = 0$ (estacionariedade exige $\rho_1 + \rho_2 - 1 < 0$).

O mesmo teste pode ser aplicado quando o polinômio em B da equação (56) tiver ordem maior do que a apresentada. Generalizando, tem-se:

$$\Delta x_t = \alpha + \left(\sum_{i=1}^p \rho_i - 1 \right) x_{t-1} + \sum_{i=1}^{p-1} \lambda_i \Delta x_{t-i} + e_t \quad (57)$$

$$\text{com } \lambda_i = - \sum_{j=i+1}^p \rho_j$$

Para se testar se na equação (57) $\sum_{i=1}^p \rho_i - 1 = 0$ deve-se

calcular o valor de t relativo a essa hipótese, da maneira usual. Entretanto, a distribuição dessa estatística não é a do t de Student, sendo necessário utilizar tabelas especiais com os valores críticos de τ_μ (FULLER, 1976). Se o valor calculado for negativo e maior, em módulo, que o valor crítico, considerando um determinado nível de probabilidade (1%, 5%, ou 10%), rejeita-se a hipótese nula (rejeita-se a hipótese de raiz unitária), e indica-se que a série é estacionária, ou seja, $I(0)$. Caso a hipótese de raiz unitária não seja rejeitada, testa-se raiz unitária no modelo:

$$\Delta\Delta x_t = \alpha + \left(\sum_{i=1}^p \rho_i - 1\right)\Delta x_{t-1} + \sum_{i=1}^{p-1} \lambda_i \Delta\Delta x_{t-i} + e_t \quad (58)$$

$$\text{com } \lambda_i = - \sum_{j=i+1}^p \rho_j$$

para verificar se a série é $I(1)$, estacionária nas primeiras diferenças. Se a hipótese mais uma vez não for rejeitada, repete-se o processo até que o teste apresente-se significativo.

Se em vez de (55a), considerar-se os modelos:

$$x_t = \rho_1 x_{t-1} + \rho_2 x_{t-2} + e_t \quad (59)$$

e

$$x_t = \alpha + \beta t + \rho_1 x_{t-1} + \rho_2 x_{t-2} + e_t \quad (60)$$

os testes para raiz unitária são baseados nas estatísticas τ e τ_τ de FULLER (1976), respectivamente .

FULLER (1976) formulou estes testes sob a hipótese de que os resíduos são idêntica e independentemente distribuídos. Na prática o número de defasagens da equação (58) é obtido por tentativas, até que se consiga resíduos não correlacionados. Quando os resíduos apresentam dependência serial, utilizam-se os testes propostos por PHILLIPS (1987) e PHILLIPS & PERRON (1988) que consistem nas estatísticas de FULLER submetidas a ajustes não-paramétricos que relaxam a hipótese de erros iid.

Testes de raiz unitária para séries sazonais

DICKEY; HASZA ; FULLER (1984) propuseram o seguinte modelo para testar raiz unitária em séries sazonais (estatística $\tau_{\mu d}$):

$$x_t = \sum_{i=1}^d \phi_i \delta_{it} + \rho_d x_{t-d} + e_t$$

onde $\delta_{it} = 1$ se $t = i + kd$, com k inteiro e $\delta_{it} = 0$ para os demais valores de t .

Tem-se $d = 12$ para as séries mensais $d = 2$ para séries semestrais e $d = 4$ para as séries trimestrais. A hipótese de raiz unitária é $H_0: \rho_d = 1$

As distribuições das estatísticas τ_μ , τ , τ_τ e $\tau_{\mu d}$ não são distribuições padrão, tendo os seus valores críticos sido obtidos por FULLER (1976) e DICKKEY; HASZA; FULLER (1984) (apêndice - Tabela 1). DICKKEY & FULLER (1979 e 1981) obtiveram as distribuições para as estatísticas $\tau_{\alpha\mu}$ ($H_0: \alpha = 0$ na equação 55a), $\tau_{\alpha\tau}$ ($H_0: \alpha = 0$ na equação 60) e $\tau_{\beta\tau}$ ($H_0: \beta = 0$ na equação 60) (apêndice - Tabela 1), além das estatísticas ϕ_1 , ϕ_2 , ϕ_3 : ϕ_1 para $(\alpha, \rho) = (0, 1)$ na equação 55a, ϕ_2 para $(\alpha, \beta, \rho) = (0, 0, 1)$ na equação 60 e ϕ_3 para $(\alpha, \beta, \rho) = (\alpha, 0, 1)$ na equação 60, obtidas utilizando a sistemática de calcular estatísticas F. Para os testes de PHILLIPS & PERRON utilizam-se os mesmos valores críticos obtidos por FULLER (1976).

Co-integração

Muitas variáveis podem ter relação estável no longo prazo. Suponha que um vetor de variáveis $y_t = (y_{1t}, \dots, y_{kt})$ tenha uma relação de equilíbrio no longo prazo dada por $c y_t = c_1 y_{1t} + \dots + c_k y_{kt} = 0$ com $c \neq 0$. Em algum período particular essa situação pode não se verificar e ocorrer $c y_t = w_t$, onde w_t é uma variável estocástica representando o desvio do equilíbrio. Se existir uma relação de equilíbrio no longo prazo, é plausível assumir que as variáveis de y_t movem-se juntas e que w_t é estacionária. Se isso ocorrer diz-se que as variáveis são co-integradas.

Para ENGLER & GRANGER (1987), componentes de um vetor y_t são ditos serem co-integrados de ordem d, b , denotado por $y_t \sim CI(d, b)$, se: (1) todos os componentes são $I(d)$; 2) existe um vetor $\alpha \neq 0$ tal que $w_t = \alpha' y_t \sim I(d-b)$, $b > 0$. O vetor α é chamado de vetor de co-integração. No caso em que $d = b = 1$, todos os componentes do vetor y_t são $I(1)$ e existe uma combinação linear desses componentes que resulta em $I(0)$.

Testar co-integração entre variáveis significa testar se w_t de uma equação de co-integração da forma:

$$y_{1t} = \theta + \gamma y_{2t} + w_t \quad (61)$$

é estacionária ou seja, se $w_t = y_{1t} - \theta - \gamma y_{2t}$ é $I(0)$. Também nesse caso se aplica teste de raiz unitária.

Dentre os testes existentes para esse fim o de Dickey-Fuller expandido (DFA), conforme especificado na equação (62) (representação simplificada de uma equação do tipo da 57) tem sido largamente utilizado.

$$\Delta w_t = \pi w_{t-1} - \sum_{j=1}^n \omega_j \Delta w_{t-j} + u_t \quad (62)$$

sendo Δw_t a primeira diferença de w_t e Δw_{t-j} a primeira diferença defasada de j períodos. Quando $\omega_j = 0$, para todos os j s, o teste corresponde ao de Dickey-Fuller (DF).

As estatísticas DF e DFE testam se $\pi = 0$ na equação (62) com e sem a restrição $\omega_j = 0$, para $j = 1, \dots, n$, respectivamente, isto é, testam a hipótese de nulidade de que as séries y_{1t} e y_{2t} não são co-integradas. Se os valores obtidos forem superiores aos respectivos valores críticos (Tabela 2 do apêndice), rejeita-se não co-integração.

Modelo de Correção de Erro

A relação entre co-integração e o mecanismo de correção de erro foi estabelecido por ENGLE & GRANGER (1987). Se as variáveis são co-integradas a relação entre elas deve ser especificada de forma a incluir a variável que mede o desvio em relação ao equilíbrio de longo prazo (defasada de um período), sem o que a equação não é corretamente especificada (LÜTKEPOL, 1991). O modelo de correção de erro permite que componentes de longo prazo obedeçam restrições de equilíbrio enquanto que componentes de curto prazo tenham uma especificação dinâmica flexível. Para estimar um modelo co-integrado, ENGLE & GRANGER (1987) sugerem um processo envolvendo duas etapas.

Na primeira etapa estima-se o modelo (61); obtém-se a série de resíduos e testa-se co-integração. Uma vez rejeitada a hipótese de que as variáveis não são co-integradas, passa-se a estimar o modelo de correção de erro, que consiste na segunda etapa do processo.

Supondo, por exemplo, que duas séries y_{1t} e y_{2t} sejam $I(1)$, tal que Δy_{1t} e Δy_{2t} sejam $I(0)$. A equação:

$$\Delta y_{1t} = \phi \Delta y_{2t} + \tau(y_{1t} - \theta - \gamma y_{2t}) + u_t \quad (63)$$

que é uma equação válida se $(y_{1t} - \theta - \gamma y_{2t})$ for $I(0)$, representa um modelo de correção de erro. A equação (63) descreve a dinâmica de curto prazo, enquanto a equação (61) é considerada uma relação de longo prazo.

Em vez do processo em duas etapas, que consiste em estimar a equação (61) para obter os resíduos $(y_{1t} - \theta - \gamma y_{2t})$ e utilizá-los na equação (63), WICKENS & BREUSCH (1988), citados por MADDALA (1988), propõem a estimação dos parâmetros de curto e longo prazos, simultaneamente, em uma equação do tipo:

$$y_{1t} = \theta + \gamma y_{2t} + (1/\tau)\Delta y_{1t} - (\phi/\tau)\Delta y_{2t} - u_t/\tau$$

que é obtida dividindo-se a equação (63) por τ e reorganizando-se os elementos.

Os testes de raiz unitária e de co-integração e os modelos de correção de erro (estabelecidos com base nas relações de co-integração entre variáveis) têm sido utilizados em diversos estudos relacionados à economia brasileira.

PORTUGAL (1992) estimou a demanda brasileira por importações (total, de bens de capital e de bens intermediários) utilizando modelos de correção de erro.

BURNQUIST (1992) utilizou modelos de correção de erro (VEC) como uma especificação particular dos modelos de auto-regressão vetorial (VAR), para detectar "overshooting" dos preços agrícolas em respostas às políticas monetária e cambial.

LIMA *et alli* (1993) utilizaram os testes de raiz unitária e de co-integração para identificar, com menor grau de arbítrio, modelos Auto-regressivos Estruturais (ARVE) para estudar o efeito de alterações inesperadas e permanentes da taxa de juros real e da taxa de crescimento da produtividade nas flutuações de curto prazo e tendência de longo prazo do nível de atividade econômica.

ZINI & CATI (1993), utilizando metodologia de raiz unitária e co-integração, testaram a hipótese de que a

Paridade do Poder de Compra explica o comportamento secular observado na taxa de câmbio real do Brasil e a hipótese de que a taxa de câmbio real pode ser afetada também pelos termos de troca.

Especificamente na área de economia agrícola, SANTANA & BRANDT (1991) utilizaram modelos de correção de erro para estudar o encadeamento de preços na pecuária de corte no mercado do Estado de Minas Gerais.

3.5.- Critério para a comparação do desempenho dos modelos.

Dentre os critérios para comparação do desempenho dos modelos de previsão, os que têm sido mais comumente utilizados são o Erro Quadrático Médio de Previsão e o Índice de Theil. O Índice de Theil é expresso pela razão entre a raiz quadrada do erro quadrático médio de previsão e a raiz quadrada do erro quadrático médio obtido pelo esquema "ingênuo" de previsão. No esquema "ingênuo" de previsão considera-se, em todo período de previsão, que o valor da variável é igual ao último valor observado. Quanto menor (mais próximo de zero) é o valor do Índice de Theil maior é a validade do modelo como instrumento de previsão. Valores próximos a um indicam um modelo com baixa capacidade de previsão (semelhante ao método "ingênuo").

3.6.- Dados

Os dados utilizados são os preços médios mensais recebidos pelo produtor para boi gordo, suíno de corte e frango de corte, publicados pelo Instituto de Economia Agrícola do Estado de São Paulo (INFORMAÇÕES ECONÔMICAS- IEA e SANTIAGO, 1990). Os preços nominais foram transformados em preços reais, em cruzeiros de dezembro de 1991, utilizando o Índice Geral de Preços (IGP - disponibilidade interna) da Fundação Getúlio Vargas como deflator.

Para o ajustamento dos modelos de previsão, bem como para os demais procedimentos estatísticos (teste de causalidade, de integração e de co-integração), foram utilizadas séries de preços do período de janeiro de 1978 a junho de 1991. Dados do período de julho de 1991 a junho de 1992 foram utilizados no cálculo do Índice de Theil, critério este aplicado na comparação do desempenho dos diversos modelos experimentais como instrumentos de previsão. Modelos de previsão um passo a frente foram também ajustados com dados do período de janeiro de 1978 a junho de 1989, tendo-se, neste caso, utilizado o período de julho de 1988 a junho de 1989 para o cálculo do Índice de Theil.

Foi utilizado o programa computacional RATS (Regression Analysis of Time Series) de DOAN & LITTERMAN (1981) nos procedimentos necessários para identificação, ajuste e verificação dos modelos.

4.- RESULTADOS E DISCUSSÃO

4.1.- Teste para Transformação de Dados

As séries de dados, objeto de estudo desse trabalho, foram divididas em sub-séries com 12 observações cada uma, tendo-se construído gráficos (Figuras 10, 11 e 12) relacionando a média e a amplitude de cada uma dessas sub-séries, com o intuito de se ter indicação do tipo de transformação necessária para obter homocedasticidade. A análise desses gráficos indicou a necessidade de se fazer transformação logarítmica nas séries de dados relativas ao preço de boi gordo e frango. No caso de preço de suíno, no entanto, não ficou evidente a necessidade de transformação dos dados. Mesmo assim, optou-se pela transformação logarítmica do preço de suíno, com a finalidade de dar o mesmo tratamento às séries que poderiam ser utilizadas conjuntamente nos modelos de função de transferência.

Nota: valores de dezembro de 1991.

Figura 10 - Média e amplitude de sub-séries com 12 observações da série de preço de boi gordo, período 1978-91.

Nota: valores de dezembro de 1991.

Figura 11 - Média e amplitude de sub-séries com 12 observações da série de preço de suíno, período 1978-91.

Nota: valores de dezembro de 1991.

Figura 12 - Média e amplitude de sub-séries com 12 observações da série de preço de frango, período 1978-91.

Daqui para a frente toda a análise estatística é feita com os logaritmos dos preços. Embora no texto, por simplicidade, seja mencionada, por exemplo, a "série de preços de frango", a análise estatística é feita com os logaritmos dos preços mensais de frango.

4.2.- Teste de Causalidade

Como a literatura sobre o mercado brasileiro de carnes indica que os preços desses produtos encontram-se relacionados, é pertinente testar se os movimentos de uma determinada série de preços de carne X precedem os movimentos de uma série Z , ou se os movimentos da série Z precedem os movimentos da série X , ou ainda, se os movimentos das séries X e Z são simultâneos.

No presente estudo especificaram-se, para o teste de causalidade, equações com doze valores futuros da variável explicativa, um presente e vinte e quatro defasados, além de constante, tendência e onze variáveis binárias para captar as variações sazonais das séries, fundamentando-se no trabalho de SIMS (1972). Para testar, por exemplo, a relação causal entre preço de boi gordo e suíno as seguintes equações foram estimadas:

$$PB_t = a_0 + \sum_{i=-12}^{24} a_{1i} PS_{t-i} + \sum_{j=1}^{11} a_{2j} D_j + a_3 t + e_t$$

$$PS_t = c_0 + \sum_{i=-12}^{24} c_{1i} PB_{t-i} + \sum_{j=1}^{11} c_{2j} D_j + c_3 t + e_t$$

onde:

PB_t = logaritmo do preço real do boi gordo.

PS_t = logaritmo do preço real de suíno.

D_j = variável binária.

t = variável tendência.

e_t = erro aleatório.

Os resultados para o teste de causalidade são apresentados na Tabela 1.

Tabela 1 - Teste F para valores futuros dos coeficientes das regressões correlacionando as séries de bovino (PB), de preço de suíno (PS) e de preço de frango (PF).

Variável dependente	Variável explicativa	F (1)
PB	PS	1,473 ⁽²⁾ (12,75)
PS	PB	0,749 (12,74)
PB	PF	0,834 (12,66)
PF	PB	1,855** (12,74)
PS	PF	0,552 (12,71)
PF	PS	1,670* (12,74)

(1) Entre parênteses estão os graus de liberdade do teste.

(2) Valor que deve ser considerado com reservas pois o teste Q para os resíduos é significativo a 4% de probabilidade.

** significativo a 5% de probabilidade.

* significativo a 10% de probabilidade.

Pelos valores do teste F (Tabela 1) observa-se que, no caso das regressões PF (dep.) versus PB (explic.) e PF (dep.) versus PS (explic.), rejeita-se a hipótese de que os coeficientes dos valores futuros da variável explicativa sejam nulos, o que indica causalidade de preço de frango para preço de bovino e suíno. Nas mesmas regressões especificadas de forma inversa, não se rejeita a hipótese de que os coeficientes dos valores futuros de PF sejam nulos, não se verificando, então, causalidade de preço de bovino ou de suíno em preço de frango. Para a regressão PS (dep.) versus PB (explic.) não se rejeita a hipótese de que os coeficientes dos valores futuros da variável preço de bovino sejam nulos, o mesmo ocorrendo com os coeficientes dos valores futuros da variável preço de suíno na regressão PB (dep.) versus PS (explic.), não se detectando, assim, a existência de causalidade entre preço de bovino e suíno.

Os valores dos coeficientes das regressões utilizadas no cálculo dos F 's com os respectivos valores do teste t são apresentados nas Tabelas 2, 3 e 4. Verifica-se que, apesar de F ser não significativo para as regressões PB (dep) versus PF (explic.) e, PB (dep) versus PS (explic.), alguns dos coeficientes dos valores futuros da variável explicativa apresentaram-se significativos, considerando a estatística t , o que indica que causalidade de preço de bovino para preço de suíno e frango não deve ser completamente descartada. Além do

Tabela 2 - Coeficientes das variáveis das regressões ajustadas no teste de causalidade para preço de bovino versus preço de suíno.⁽¹⁾

Defasagens	PB x PS		PS x PB	
-12	-0,058	(-1,578)	0,034	(0,538)
-11	-0,075	(-1,953)	0,095	(1,451)
-10	-0,067	(-1,713)	-0,023	(-0,346)
-9	0,026	(0,646)	-0,007	(-1,111)
-8	-0,003	(-0,070)	-0,058	(-0,849)
-7	-0,025	(-0,287)	-0,037	(-0,544)
-6	0,005	(0,055)	0,010	(0,139)
-5	0,050	(0,493)	0,031	(0,462)
-4	-0,063	(-0,602)	-0,029	(-0,423)
-3	0,026	(0,250)	-0,051	(-0,733)
-2	-0,272	(-2,654)	0,109	(1,599)
-1	0,060	(0,602)	0,113	(1,645)
0	0,876	(8,647)	0,637	(9,308)
1	-0,317	(-3,101)	0,195	(2,825)
2	0,196	(1,918)	-0,114	(-1,663)
3	0,141	(1,377)	-0,176	(-2,543)
4	-0,090	(-0,867)	0,026	(0,378)
5	0,125	(1,199)	-0,010	(-1,434)
6	-0,035	(-0,322)	0,038	(0,565)
7	-0,047	(-0,407)	-0,067	(-0,979)
8	0,112	(0,878)	-0,078	(-1,101)
9	0,037	(0,291)	-0,054	(-0,765)
10	-0,153	(-1,186)	-0,139	(-1,877)
11	0,198	(1,525)	0,014	(0,186)
12	-0,073	(-0,560)	0,012	(0,145)
13	0,089	(0,696)	0,021	(0,246)
14	0,017	(0,124)	0,026	(0,294)
15	-0,127	(-0,924)	0,064	(0,726)
16	0,072	(0,528)	-0,187	(-2,132)
17	0,068	(0,501)	-0,200	(-2,343)
18	-0,022	(-0,161)	-0,075	(-0,868)
19	0,121	(0,898)	-0,023	(-0,263)
20	-0,089	(-0,650)	-0,055	(-0,635)
21	0,084	(0,611)	0,062	(0,722)
22	0,091	(0,655)	-0,002	(-0,024)
23	0,263	(1,862)	-0,040	(-0,465)
24	-0,221	(-1,790)	0,208	(2,449)

(1)- A primeira variável de cada relação é a dependente e a segunda a explicativa.

Obs: As regressões foram ajustadas com os dados nos logaritmos. Os valores entre parênteses são os respectivos valores de "t".

Tabela 3 - Coeficientes das variáveis das regressões ajustadas no teste de causalidade para preço de bovino versus preço de frango.⁽¹⁾

Defasagens	PB x PF		PF x PB	
-12	-0,171	(-2,293)	0,137	(1,781)
-11	0,087	(1,102)	-0,011	(-0,135)
-10	-0,140	(-1,788)	0,061	(0,775)
-9	-0,012	(-0,154)	-0,096	(-1,205)
-8	0,134	(1,524)	-0,028	(-0,344)
-7	-0,039	(-0,447)	-0,031	(-0,381)
-6	0,078	(0,887)	0,161	(1,991)
-5	0,006	(0,066)	-0,059	(-0,722)
-4	0,039	(0,455)	0,107	(1,299)
-3	-0,058	(-0,676)	0,022	(0,260)
-2	-0,080	(-0,980)	-0,004	(-0,049)
-1	0,022	(0,273)	0,262	(3,198)
0	0,591	(7,163)	0,612	(7,503)
1	0,161	(1,882)	0,075	(0,891)
2	0,131	(1,553)	-0,221	(-2,620)
3	0,194	(2,298)	-0,113	(-1,320)
4	0,068	(0,811)	0,055	(0,641)
5	-0,082	(-0,947)	0,159	(1,875)
6	0,018	(0,209)	0,103	(1,210)
7	-0,143	(-1,617)	-0,213	(-2,517)
8	0,086	(0,984)	-0,119	(-1,392)
9	-0,056	(-0,630)	0,126	(1,447)
10	0,066	(0,743)	0,008	(0,093)
11	-0,010	(-0,107)	0,110	(1,189)
12	0,039	(0,389)	0,057	(0,556)
13	0,177	(1,722)	-0,323	(-2,849)
14	-0,087	(-0,777)	0,238	(2,103)
15	-0,065	(-0,564)	-0,055	(-0,472)
16	0,054	(0,474)	0,016	(0,138)
17	-0,142	(-1,223)	-0,128	(-1,142)
18	0,308	(2,548)	-0,042	(-0,377)
19	-0,052	(-0,430)	0,013	(0,119)
20	0,030	(0,248)	-0,066	(-0,586)
21	0,018	(0,166)	0,223	(2,000)
22	-0,086	(-0,780)	0,011	(0,097)
23	-0,013	(-0,115)	-0,010	(-0,094)
24	-0,294	(-2,891)	0,100	(0,966)

(1)- A primeira variável de cada relação é a dependente e a segunda a explicativa.

Obs: As regressões foram ajustadas com os dados nos logaritmos. Os valores entre parênteses são os respectivos valores de "t".

Tabela 4 - Coeficientes das variáveis das regressões ajustadas no teste de causalidade para preço de suíno versus preço de frango.⁽¹⁾

Defasagens	<i>PS x PF</i>		<i>PF x PS</i>	
-12	-0,094	(-1,338)	-0,070	(-1,795)
-11	0,076	(1,078)	-0,426	(-1,013)
-10	-0,071	(-0,971)	0,018	(0,416)
-9	0,047	(0,660)	0,038	(0,863)
-8	0,022	(0,289)	-0,100	(-1,907)
-7	-0,006	(-0,083)	0,019	(0,199)
-6	-0,011	(-0,151)	-0,015	(-0,154)
-5	0,040	(0,559)	0,074	(0,726)
-4	0,012	(0,165)	0,004	(0,037)
-3	0,041	(0,555)	0,160	(1,002)
-2	-0,248	(-0,248)	-0,235	(-2,258)
-1	0,029	(0,409)	0,224	(2,214)
0	0,550	(7,634)	0,692	(6,763)
1	0,284	(3,889)	-0,193	(-1,868)
2	0,014	(0,190)	-0,080	(-0,777)
3	0,060	(0,822)	0,107	(1,031)
4	0,028	(0,384)	0,033	(0,317)
5	-0,025	(-0,341)	0,191	(1,816)
6	-0,100	(-1,371)	-0,089	(-0,813)
7	-0,041	(-0,543)	-0,086	(-0,728)
8	-0,049	(-0,654)	-0,035	(-0,274)
9	-0,148	(-1,926)	0,194	(1,495)
10	-0,053	(-0,668)	-0,121	(-0,925)
11	-0,057	(-0,717)	0,266	(2,029)
12	0,080	(0,938)	-0,287	(-2,184)
13	0,085	(0,976)	-0,086	(-0,666)
14	0,076	(0,837)	0,181	(1,293)
15	-0,027	(-0,295)	0,041	(0,294)
16	-0,125	(-1,340)	-0,051	(-0,365)
17	-0,141	(-1,506)	0,174	(1,262)
18	-0,011	(-0,114)	-0,267	(-1,917)
19	-0,090	(-0,970)	0,052	(0,379)
20	0,012	(0,131)	0,037	(0,262)
21	-0,028	(-0,304)	0,267	(1,920)
22	-0,147	(-1,570)	0,188	(1,322)
23	-0,158	(-1,700)	-0,004	(-0,025)
24	-0,111	(-1,165)	-0,125	(-0,958)

(1)- A primeira variável de cada relação é a dependente e a segunda a explicativa.

Obs: As regressões foram ajustadas com os dados nos logaritmos. Os valores entre parênteses são os respectivos valores de "t".

mais, é possível que existam relações causais entre variáveis que não possam ser econometricamente captadas, não tendo, dessa forma, o teste de causalidade, quando não significativo, caráter conclusivo. Por exemplo, se o comportamento estacional de uma série de preço afetar de alguma forma o movimento de outra série de preço e, estando os testes de causalidade especificados de forma a incluir variáveis binárias para modelar o comportamento estacional da série cujo efeito de causação está sendo testado (para evitar que relações expúrias afetem os resultados), é possível que não se detecte o efeito quando na verdade ele existe.

4.3.- Teste de Raiz Unitária e de Co-integração

Teste de raiz unitária

Os modelos utilizados para testar raiz unitária (estatísticas τ_τ , τ_μ , e τ) foram ajustados com 12 defasagens da variável dependente, sendo considerados como modelos alternativos aqueles onde o número de defasagens é igual a ordem do último coeficiente significativo dos modelos ajustados inicialmente (CAMPBELL & PERRON, 1991, p.155).

A estatística τ_τ (Tabela 5) sinaliza que a série de preço de bovino é $I(1)$, isto é, estacionária nas primeiras diferenças (com o modelo 1 não se rejeita a hipótese de raiz unitária mas com o modelo 2 rejeita-se), enquanto que no caso

das séries de preços de frango e suíno os resultados são dependentes das defasagens envolvidas no modelo. Os resultados dos modelos com 12 defasagens indicam que essas séries são $I(1)$, enquanto que os resultados dos modelos com 2 defasagens indicam que essas séries poderiam ser consideradas $I(0)$. A estatística $\tau_{\beta\tau}$ apresentou-se em todos os casos não significativa e a estatística $\tau_{\alpha\tau}$ apresentou-se significativa nos casos das séries de preço de suíno e frango quando o número de defasagens considerado era 2. Os resultados da estatística τ_{μ} (Tabela 6) indicam que as séries de preços de bovino e frango são $I(1)$. No caso da série de preço de suíno o resultado depende, também, das defasagens envolvidas no modelo. Ao considerar-se o modelo com 12 defasagens, aceita-se raiz unitária, mas ao considerar-se o modelo com 2 defasagens, tem-se que a série é $I(0)$. A estatística $\tau_{\alpha\mu}$ indicou, neste último caso, significância da constante. A estatística τ (Tabela 7) apresentou-se em todos os casos não significativa no modelo 1 e significativa no modelo 2.

Os resultados dos testes de raiz unitária de PHILLIPS & PERRON, apresentados na Tabela 8, indicam que as séries de preço de bovino e de suíno são $I(1)$. No caso de preço de frango, o modelo sem tendência indica que a série é $I(1)$ enquanto o modelo com tendência indica que ela é $I(0)$ depois de extraída a tendência, considerando um nível de

Tabela 5 - Teste de raiz unitária para séries individuais (τ_τ)

$$\text{Mod.1: } \Delta y_t = \alpha + \theta t + \rho y_{t-1} - \sum_{i=1}^n \beta_i \Delta y_{t-i} + e_t \quad H_0: \rho = 0$$

Variáveis	n	" t "	Q(36)
Preço de bovino	12	- 2,611	41,268
	6	- 2,812	49,259
Preço de suíno	12	- 3,291	24,595
	2	- 3,892**	30,012
Preço de frango	12	- 2,490	22,972
	2	- 3,634**	23,886

$$\text{Mod.2: } \Delta \Delta y_t = \lambda + \gamma t + \pi \Delta y_{t-1} - \sum_{i=1}^n \psi_i \Delta \Delta y_{t-i} + e_t \quad H_0: \pi = 0$$

Variáveis	n	" t "	Q(36)
Preço de bovino	12	- 3,484*	41,701
	6	- 7,135**	47,930
Preço de suíno	12	- 3,613**	29,531
	2	- 7,306**	33,371
Preço de frango	12	- 4,006**	29,299
	2	- 8,708**	30,619

** Significativo a 1% de probabilidade.

* Significativo a 5% de probabilidade.

Nota: Valores críticos da estatística τ_τ são apresentados na Tabela 1 do apêndice.

Tabela 6 - Teste de raiz unitária para séries individuais (τ_μ)

Mod.1: $\Delta y_t = \alpha + \rho y_{t-1} - \sum_{i=1}^n \beta_i \Delta y_{t-i} + e_t$ $H_0: \rho = 0$			
Variáveis	n	" t "	$Q(36)$
Preço de bovino	12	- 1,435	41,782
	6	- 1,462	51,117
Preço de suíno	12	- 2,208	25,806
	2	- 3,142*	29,277
Preço de frango	12	- 1,484	25,527
	2	- 2,439	24,609
Mod.2: $\Delta \Delta y_t = \lambda + \pi \Delta y_{t-1} - \sum_{i=1}^n \psi_i \Delta \Delta y_{t-i} + e_t$ $H_0: \pi = 0$			
Variáveis	n	" t "	$Q(36)$
Preço de bovino	12	- 3,500**	41,876
	6	- 7,109**	48,386
Preço de suíno	12	- 3,627**	29,550
	2	- 7,326**	33,321
Preço de frango	12	- 4,019**	29,242
	2	- 8,725**	30,453

** Significativo a 1% de probabilidade.

* Significativo a 5% de probabilidade.

Nota: Valores críticos da estatística τ_μ são apresentados na Tabela 1 do apêndice.

Tabela 7 - Teste de raiz unitária para séries individuais (τ)

$$\text{Mod.1: } \Delta y_t = \rho y_{t-1} - \sum_{i=1}^n \beta_i \Delta y_{t-i} + e_t \quad H_0: \rho = 0$$

Variáveis	n	" t "	Q(36)
Preço de bovino	12	- 0,945	43,229
	6	- 0,690	53,853
Preço de suíno	12	- 0,499	30,701
	2	- 0,373	35,565
Preço de frango	12	- 1,196	29,581
	2	- 0,713	30,498

$$\text{Mod.2: } \Delta \Delta y_t = \pi \Delta y_{t-1} - \sum_{i=1}^n \psi_i \Delta \Delta y_{t-i} + e_t \quad H_0: \pi = 0$$

Variáveis	n	" t "	Q(36)
Preço de bovino	12	- 3,399**	41,656
	6	- 7,087**	47,656
Preço de suíno	12	- 3,610**	28,912
	2	- 7,343**	33,139
Preço de frango	12	- 3,883**	27,317
	2	- 8,722**	30,328

** Significativo a 1% de probabilidade.

Nota: Valores críticos da estatística τ são apresentados na Tabela 1 do apêndice.

Tabela 8 - Testes de raiz unitária para séries individuais
(PHILLIPS E PERRON)

Variáveis	modelo I (série em nível)	
	com constante e tendência	com constante
Preço de bovino	- 3,136	- 2,089
Preço de suíno	- 2,999	- 2,480
Preço de frango	- 3,853*	- 2,581

	modelo II (série nas primeiras diferenças)	
	com constante e tendência	com constante
Preço de bovino	- 10,728**	- 10,664**
Preço de suíno	- 7,256**	- 7,257**
Preço de frango	- 11,975**	- 11,949**

** significativo a 1% de probabilidade.

* significativo a 5% de probabilidade.

Nota: Valores críticos apresentados na Tabela 1 do apêndice
(estatísticas τ_μ e τ_τ de FULLER)

significância de 5%.

Como no caso da série de preço de bovino os testes são unânimes em indicá-la como apresentando raiz unitária (resultado corroborado pela análise gráfica da série), os testes de co-integração podem auxiliar na definição da ordem de integração das variáveis que apresentaram resultados

ambíguos. Se duas séries forem co-integradas e se uma delas for $I(1)$ a outra deverá ser também $I(1)$. Então os testes de co-integração entre as séries de bovino e suíno e entre as séries de bovino e frango podem ajudar na definição da ordem de integração das séries de preços de suíno e frango, dado que a série de preço de bovino é tomada como $I(1)$.

Teste de raiz unitária para séries sazonais

Os resultados do teste de integração para séries sazonais (Tabela 9) indicam a não existência de raiz unitária para $d = 12$, nas séries de preço de bovino, suíno e frango. Os modelos propostos por DICKEY; HASZA; FULLER (1984) não incluem defasagens da variável dependente, como os modelos tradicionais para teste de raiz unitária numa abordagem não sazonal. Quando, experimentalmente, introduziram-se defasagens da variável dependente nos modelos devidamente transformados para fins de ajuste, observou-se diminuição significativa dos valores dos testes t e Q , mostrando a sensibilidade dos resultados a esta modificação, podendo levar a conclusões diferentes. Como a teoria sobre raiz unitária em série sazonal não se encontra bem desenvolvida, os resultados devem ser tomados com reservas. De qualquer forma, o alto valor do teste $\tau_{\mu d}$ dos modelos 2 indica que provavelmente a ordem máxima de integração das variáveis é 1.

Tabela 9 - Teste de raiz unitária sazonal para séries individuais ($\tau_{\mu d}$)

$\text{Mod.1: } \Delta_{12} y_t = \rho_d y_{t-12} + \sum_{i=1}^{12} \vartheta_i \delta_{it} + e_t \quad H_0: \rho_d = 0$		
Variáveis	" t "	Q(36)
Preço de bovino	- 6,747**	546,491
Preço de suíno	- 9,368**	590,274
Preço de frango	- 6,912**	505,518
$\text{Mod.2: } \Delta_{12} \Delta_{12} y_t = \pi_d \Delta y_{t-12} + \sum_{i=1}^{12} \epsilon_i \delta_{it} + e_t \quad H_0: \pi_d = 0$		
Variáveis	" t "	Q(33)
Preço de bovino	17,662**	510,008
Preço de suíno	19,947**	462,508
Preço de frango	18,511**	375,148

* Significativo a 1% de probabilidade.

Nota: Valores críticos da estatística $\tau_{\mu d}$ são apresentados na Tabela 1 do apêndice.

Teste de co-integração.

Uma análise exploratória foi feita com a finalidade de testar co-integração entre as variáveis que poderiam ser envolvidas nos modelos de função de transferência. Seis regressões foram estimadas para verificar essa possibilidade: preço de boi gordo (PB) em função de preço de suíno (PS),

preço de boi gordo (*PB*) em função de preço de frango (*PF*), e preço de suíno (*PS*) em função de preço de frango (*PF*), e os inversos. As estatísticas *DF* e *DFA* foram obtidas com regressões auxiliares, com base nos resíduos dessas regressões citadas. Para o *DFA*, três defasagens da variável dependente (primeira diferença do resíduo) foram incluídas entre as variáveis explicativas no caso das regressões envolvendo preço de bovino e preço de suíno e das regressões envolvendo preço de suíno e preço de frango. Para as relações entre preço de bovino e preço de frango foram consideradas quatro defasagens da variável dependente.

Os seguintes resultados foram obtidos, podendo-se verificar, considerando a estatística *DFA*, que as variáveis são co-integradas (valores críticos - Tabela 2 do apêndice):

$$PB = 1,645 + 0,859 PS$$

(2,954) (15,441)

$$R^2 = 0,598 \quad DF = 2,910 \quad DFA = 4,465$$

$$PS = 2,874 + 0,697 PB$$

(6,215) (15,441)

$$R^2 = 0,598 \quad DF = 2,962 \quad DFA = 4,541$$

$$PB = 3,394 + 1,000 PF$$

(10,654) (21,506)

$$R^2 = 0,743 \quad DF = 4,938 \quad DFA = 4,649$$

$$PF = -0,762 + 0,743 PB$$

$$(-2,153) \quad (21,506)$$

$$R^2 = 0,743 \quad DF = 5,292 \quad DFA = 4,621$$

$$PS = 4,173 + 0,852 PF$$

$$(12,745) \quad (17,845)$$

$$R^2 = 0,666 \quad DF = 3,707 \quad DFA = 3,811$$

$$PF = -0,968 + 0,781 PS$$

$$(-2,208) \quad (17,845)$$

$$R^2 = 0,666 \quad DF = 4,083 \quad DFA = 3,360$$

* Entre parênteses, abaixo dos coeficientes das regressões, encontram-se os valores da estatística *t* de Student.

A estatística DFA parece ser, em todos os casos, a mais apropriada, porque as regressões que geraram a estatística DF apresentaram valor do teste *Q* elevado. Partindo de uma especificação geral e fazendo simplificações sucessivas, o número de defasagens para cada regressão foi então determinado em função do valor desse teste e da significância dos coeficientes.

Através do ajuste de equações correlacionando preço de boi gordo com preço de suíno e preço de frango, preço de suíno com preço de bovino e preço de frango e, preço de frango com preço de bovino e preço de suíno, foi testada co-integração para o conjunto das três variáveis. Os seguintes resultados

foram encontrados, com as regressões, para cálculo do DFA, sendo ajustadas com três defasagens da variável dependente:

$$PB = 2,420 + 0,801 PF + 0,233 PS$$

$$(5,494) \quad (10,228) \quad (3,117)$$

$$R^2 = 0,758 \quad DF = 4,546 \quad DFA = 5,311$$

$$PS = 3,335 + 0,247 PB + 0,606 PF$$

$$(8,002) \quad (3,117) \quad (6,603)$$

$$R^2 = 0,685 \quad DF = 3,329 \quad DFA = 3,754$$

$$PF = -1,783 + 0,496 PB + 0,355 PS$$

$$(-5,086) \quad (10,228) \quad (6,603)$$

$$R^2 = 0,798 \quad DF = 5,487 \quad DFA = 4,965$$

* Entre parênteses, abaixo dos coeficientes das regressões, encontram-se os valores da estatística *t* de Student.

A estatística DFA indica co-integração entre as variáveis (também neste caso a estatística DFA foi a mais apropriada, pois as regressões que geraram a estatística DF apresentaram, em todos os casos, valor do teste *Q* elevado).

Como os testes de co-integração relacionando as variáveis duas a duas indicaram que elas são co-integradas, pode-se inferir que as variáveis preço de frango e preço de suíno são *I*(1), da mesma maneira que o preço de bovino.

4.4.- Resultados dos Modelos de Previsão

4.4.1.- Previsão de Preços de Bovino

4.4.1.1.- Modelos Univariado e de Intervenção

Foi utilizada inicialmente a técnica univariada de Box & Jenkins, onde as previsões são geradas unicamente a partir da série histórica de dados. Termos de intervenção foram muitas vezes incluídos nos modelos experimentais univariados visando melhorar o ajustamento das equações. Na Tabela 10 são apresentados os valores das 24 primeiras autocorrelações e autocorrelações parciais da série de preços de bovino (Y_t), de sua primeira diferença (ΔY_t) e primeiras diferenças simples e sazonal ($\Delta\Delta_{12} Y_t$), com os dados transformados em logaritmos. Com base nos valores das autocorrelações foram estabelecidos modelos experimentais.

A análise das autocorrelações da série de preço de bovino (Y_t) indica a sua não estacionariedade (a fac não tem seus valores caindo rapidamente para zero), o que corrobora os resultados dos testes de raiz unitária. Uma vez que a metodologia proposta por Box & Jenkins requer a utilização de séries estacionárias, estabeleceram-se modelos experimentais na primeira diferença, dado que os testes de integração indicaram que a série de preço de bovino é $I(1)$. Considerando ainda que a série de preço de bovino possa ter raiz unitária sazonal, estabeleceram-se também modelos experimentais nas

Tabela 10 - Autocorrelações e autocorrelações parciais estimadas para a série de preço de bovino.

defasagens		autocorrelações (r_k)							
Y_t	1-8	0,913*	0,796*	0,677*	0,566*	0,479*	0,418*	0,396*	0,401*
	9-16	0,403*	0,413*	0,410*	0,395*	0,356*	0,278	0,167	0,075
	17-24	0,001	-0,037	-0,033	-0,005	0,045	0,095	0,126	0,136
ΔY_t	1-8	0,184*	0,015	-0,043	-0,148	-0,178*	-0,279*	-0,149	0,071
	9-16	-0,022	0,042	0,068	0,178	0,188	0,198*	-0,115	-0,082
	17-24	-0,201*	-0,304*	-0,154	-0,168	0,053	0,184	0,096	0,218
$\Delta\Delta_{12} Y_t$	1-8	0,064	-0,122	0,025	-0,192*	0,007	0,040	0,024	0,286*
	9-16	-0,056	-0,096	-0,058	-0,513*	0,085	0,218*	-0,169	0,047
	17-24	-0,052	-0,153	-0,000	-0,198	0,100	0,163	-0,072	0,046
defasagens		autocorrelações parciais (ϕ_{kk})							
Y_t	1-8	0,913*	-0,228*	-0,041	-0,032	0,076	0,053	0,155	0,095
	9-16	-0,055	0,084	-0,037	0,002	-0,105	-0,182*	-0,219*	0,089
	17-24	-0,017	0,081	0,113	0,002	0,084	0,041	0,014	-0,042
ΔY_t	1-8	0,184*	-0,020	-0,043	-0,137	-0,129	-0,246*	-0,094	0,076
	9-16	-0,114	-0,037	-0,033	0,107	0,115	0,219*	-0,177*	-0,013
	17-24	-0,129	-0,176*	-0,020	-0,167*	-0,031	0,006	-0,020	0,046
$\Delta\Delta_{12} Y_t$	1-8	0,064	-0,126	0,043	-0,218*	0,053	-0,026	0,052	0,255*
	9-16	0,097	0,002	-0,104	-0,481*	0,173*	0,041	-0,218*	-0,056
	17-24	-0,053	-0,100	0,025	-0,036	-0,002	-0,007	-0,028	-0,265*

* Valor significativo

primeiras diferenças simples e sazonal.

Todos os modelos ajustados para a série ΔY_t com enfoque univariado não apresentaram bom desempenho em termos de previsão (apesar de muitos deles apresentarem-se adequados do ponto de vista dos testes estatísticos), não conseguindo captar a variação estacional da série. Visando a melhora desse ajuste sazonal foram incluídas no modelo variáveis binárias (δ_{it}). O modelo com melhor desempenho, conforme o critério de Theil, foi:

$$\begin{aligned} \Delta \tilde{Y}_t = & \theta + a_t + 0,1348 \underset{(1,6134)}{a_{t-1}} + 0,2017 \underset{(2,3857)}{a_{t-8}} + 0,2249 \underset{(2,5097)}{a_{t-14}} + \\ & + \sum_{i=1}^{11} \phi_i \delta_{it} \end{aligned} \quad \Rightarrow \text{(eq. modelo A)}$$

com $\sigma = 0,1038^{6/}$.

Esse modelo apresentou todas as 25 primeiras correlações de resíduos e correlações cruzadas não significativas e

6/ Como os dados são expressos nos logaritmos pode-se inferir que o desvio padrão do resíduo (σ) é de aproximadamente 10,38% do nível da série.

$Q(33) = 27,67$ ^{7/}. O coeficiente do termo $MA|1|$ mostrou-se não significativo (valores dos testes t apresentados abaixo dos respectivos coeficientes), todavia quando eliminado do modelo obtiveram-se previsões levemente piores^{8/}.

Na Tabela 11 são apresentadas as previsões obtidas com os modelos estabelecidos para a série de preço de bovino bem como os valores encontrados para o Índice de Theil. Na Figura 13 as previsões são representadas graficamente junto com os valores observados no mercado físico.

As melhores previsões de Y_t com base em $\Delta\Delta_{12}Y_t$ foram obtidas com o modelo:

$$\begin{aligned} (1 - 0,7516 B)(1 + 0,0580 B^{12})\Delta\Delta_{12}\tilde{Y}_t &= \\ (-9,0005) \quad (0,7002) & \\ &= \theta + (1 - 0,7136 B - 0,2019 B^2)(1 - 0,9533 B^{12})a_t \\ (-6,2493) \quad (-2,2242) \quad (-19,2663) & \\ &\Rightarrow (\text{eq. modelo B}) \end{aligned}$$

com $\sigma = 0,1154$ e $Q(34) = 33,85$.

7/ O programa computacional RATS utiliza, para a obtenção do valor de "Q", $K = \min(n/2 \text{ e } 3\sqrt{n})$ sendo K o número de autocorrelações utilizadas e n o número de observações.

8/ Utilizou-se a simbologia $MA|q|$ ou $AR|p|$ para expressar um termo específico q ou p do modelo. Essa simbologia foi utilizada também para representar modelos incompletos. Por exemplo um $AR|2|$ é um modelo só com um termo com defasagem 2.

Tabela 11 - Previsões para preço real da arroba de boi gordo e observações do mercado físico (período: julho de 1991 a junho de 1992)^{1/}. Índice de Theil (IT)^{2/}

Período	Observado	Modelo A	Desvio %	Modelo B	Desvio %
1991 jul	18755,3	18159,9	3,17	18088,1	3,56
ago	21531,9	20536,1	4,62	19629,7	8,8
set	20900,6	21743,3	-4,03	22262,7	-6,52
out	24275,4	21176,1	12,76	21989,9	9,41
nov	23214,7	22178,9	4,42	22426,7	3,39
dez	18920,0	20345,1	-7,53	20840,4	10,15
1992 jan	20229,7	18179,2	10,14	19903,8	1,61
fev	18814,2	16694,0	11,27	18221,3	-3,20
mar	16345,7	16190,0	0,90	17008,1	-4,05
abr	18726,8	16580,0	11,46	17039,6	9,01
mai	19211,1	16615,0	13,51	16946,8	11,79
jun	17121,8	16797,0	1,90	16805,3	1,85
IT		0,448		0,375	

1/ - Valores de dezembro de 1991

2/ - Índice de Theil obtido com 12 previsões.

A matriz de correlações entre estimativas dos parâmetros do modelo B (Tabela 12) indicou correlação elevada, em valores absolutos, entre os coeficientes do termo $MA|1|$ e $MA|2|$, sugerindo que um desses termos poderia ser eliminado. Adotando-se esse procedimento obteve-se, todavia, pior desempenho, tanto no ajustamento quanto na previsão, o mesmo tendo ocorrido quando se eliminou do modelo o termo $SAR|1|$,

Tabela 12- Matriz de correlações dos coeficientes estimados do modelo B.

	AR 1	SAR 1	MA 1	MA 2	SMA 1
AR 1	1,0	0,1163	-0,6571	0,3015	0,0469
SAR 1		1,0	0,0568	-0,0890	-0,3029
MA 1			1,0	-0,8364	-0,0078
MA 2				1,0	0,0011
SMA 1					1,0

que não se apresentou significativo (com o modelo sem o termo SAR|1| obteve-se Índice de Theil igual a 0,396).

Observou-se, com o modelo B, autocorrelação de resíduo significativa na defasagem 8 e correlações cruzadas significativas nas defasagens 8, 14, 15 e 18. Quando, no entanto, introduziram-se no modelo os coeficientes cujas defasagens apresentaram-se significativas, o seu desempenho, em termos de previsão, piorou.

Modelos não multiplicativos, equivalentes aos modelos multiplicativos que apresentaram boas previsões foram ajustados, não tendo, entretanto, superado o desempenho do modelo B.

Visando um melhor ajustamento das equações, tentou-se modelar, através de termos de intervenção, a variação não sistemática das séries de preços ocorrida no período pós Plano Cruzado. A diferenciação das séries, no entanto, torna difícil a modelagem do padrão daquela variação, não se tendo conseguido, dessa forma, resultados satisfatórios.

Figura 13 - Previsões de preço real de boi gordo (arroba), de julho de 1991 a junho de 1992

4.4.1.2.- Modelo de Função de Transferência

Os resultados dos testes de integração e co-integração indicaram que os modelos de função de transferência deveriam ser do tipo correção de erro, com as variáveis sendo expressas nas diferenças. Deixou-se de especificar modelos de função de transferência com diferenças sazonais, não estando a teoria sobre co-integração sazonal suficientemente desenvolvida.

Para a identificação da ordem dos polinômios m e l e da constante de defasagem b dos termos de transferência dos modelos experimentais de previsão de preço de bovino, foram obtidas correlações cruzadas das séries de preço de bovino e preço de frango e das séries preço de bovino e preço de suíno (nas primeiras diferenças). As séries das variáveis dependente e explicativa foram filtradas, conforme recomenda a metodologia, com o processo ARIMA que transforma a série da variável explicativa em ruído branco. Escolheu-se para filtro o modelo mais parcimonioso dos que apresentaram valor da estatística Q não significativo.

No caso da relação preço de bovino versus preço de frango

9/
o seguinte filtro foi usado:

$$Y_{filtrada} = \Delta Y_t - 0,181 \Delta Y_{t-1} + 0,303 \Delta Y_{t-2}$$

e no caso da relação preço de bovino versus preço de suíno o filtro utilizado foi:

$$Y_{filtrada} = \Delta Y_t - 0,523 \Delta Y_{t-1} + 0,226 \Delta Y_{t-2}$$

com Y expressando tanto a variável explicativa quanto a dependente.

Na Tabela 13 encontram-se os resultados desses testes de correlação cruzada. Como as correlações cruzadas contemporâneas apresentaram-se significativas nos dois casos (preço de bovino versus preço de frango e preço de bovino versus preço de suíno), o modelo de função de transferência para previsão de preço de bovino deveria ser especificado com as constantes de defasagem b (ver equação 11) iguais a zero. Isso entretanto implicaria na utilização de previsões das variáveis explicativas para a previsão da variável dependente, o que envolve, provavelmente, maior erro. Como a finalidade

9/ O filtro é utilizado somente nas fases de identificação e verificação dos modelos. Para o ajustamento das equações as séries não são filtradas.

Tabela 13- Correlações cruzadas entre preço de bovino e preço de frango e entre preço de bovino e preço de suíno.

defasagens		correlações cruzadas						
		preço de bovino versus preço de frango						
-13 a -7	0,149	0,020	-0,009	-0,075	0,020	0,035	-0,161	
-6 a 0	-0,116	0,020	0,091	-0,119	-0,318*	0,169*	0,605*	
		preço de bovino versus preço de suíno						
-13 a -7	0,184	0,081	-0,055	-0,126	-0,035	0,056	-0,045	
-6 a 0	-0,114	-0,051	-0,100	-0,264*	-0,192*	0,352*	0,684*	

* Valor significativo

dos modelos é a de gerar previsões e não a de estudar as relações comportamentais entre as variáveis, optou-se por deixar de incluir a relação contemporânea na equação, isto é, optou-se por considerar $b = 1$ e obter previsões um passo a frente com base em valores observados das variáveis explicativas.

A identificação do termo residual do modelo de função de transferência foi feita através da análise de resíduo de equações incluindo 11 binárias, as variáveis explicativas preço de frango e de suíno (nas primeiras diferenças), individualmente e em conjunto (com $b = 1$ e m e l sendo determinados de acordo com as informações contidas nas funções

de correlação cruzada) e o respectivo resíduo da equação de cointegração. Em todos os casos houve indicação da necessidade de se construir o termo residual da função de transferência com coeficientes representando defasagens de período 8 e 14, tendo-se observado, posteriormente, que a inclusão de coeficiente com defasagem de primeira ordem melhorava o ajustamento dos modelos e as previsões, assim como ocorreu no caso univariado. Considerou-se, então, que o termo residual do modelo de função de transferência para previsão de preço de bovino, com a série na primeira diferença, tem a mesma estrutura do modelo univariado, isto é, é um $MA|1,8,14|$.

Os modelos experimentais de função de transferência estabelecidos foram comparados entre si através de Índice de Theil calculado com 12 previsões um passo a frente. Para verificar se a inclusão das variáveis explicativas no modelo melhorava a qualidade das previsões, os Índices de Theil dos modelos de função de transferência foram comparados ao obtido com previsões um passo a frente com um modelo univariado com a mesma estrutura do estabelecido para a série ΔY_t (modelo A), o qual denominou-se de modelo A^* .

Observou-se que as previsões obtidas para julho de 1991 a junho de 1992 com os modelos experimentais de função de transferência não eram significativamente melhores que as previsões obtidas com o modelo univariado A^* . Atribuindo esse

resultado a uma possível distorção da relação entre os preços das variáveis consideradas nesse período, repetiram-se os ajustamentos dos modelos calculando-se o Índice de Theil com previsões de julho de 1988 a junho de 1989 (um passo a frente), com os mesmos modelos anteriormente estabelecidos, uma vez que os testes estatísticos de identificação não sugeriam que qualquer mudança devesse ser feita. O desempenho dos modelos de função de transferência, nesse caso, foi melhor que o do modelo univariado.

Na tabela 14 e figura 14 pode-se comparar, para o período de julho de 1988 a junho de 1989, as previsões um passo a frente obtidas com o modelo univariado A^* e as obtidas com o modelo de função de transferência que apresentou o melhor desempenho :

$$\begin{aligned} \Delta Y_t = & \theta + a_t + \underset{(1,7175)}{0,2528} a_{t-1} + \underset{(2,1982)}{0,2531} a_{t-8} + \underset{(1,4819)}{0,1838} a_{t-14} + \\ & + \underset{(0,8114)}{0,0967} \Delta Z_{t-1} - \underset{(-1,6393)}{0,2310} \Delta X_{t-1} - \underset{(-3,7875)}{0,3560} w_{t-1} + \sum_{i=1}^{11} \alpha_i \delta_{it} \end{aligned}$$

⇒ (eq. modelo C)

com $Q(27) = 23,4121$ e $\sigma = 0,0818$.

(Obs: Os coeficientes apresentados referem-se ao resultado do primeiro ajustamento da série de ajustamentos realizados com o modelo C para a obtenção das 12 previsões um passo a frente.)

onde: Y_t = preço de bovino
 Z_t = preço de suíno
 X_t = preço de frango
 a_t = ruído branco
 δ_t = variável binária
 w_t = resíduo da equação de co-integração

$$Y_t = \theta + \beta Z_t + \gamma X_t + w_t$$

Tabela 14 - Previsões um passo a frente para preço real da arroba de boi gordo e observações do mercado físico (período: julho de 1988 a junho de 1989)^{1/}. Índice de Theil (IT)^{2/}.

Período	Observado	Modelo A*	Desvio %	Modelo C	Desvio %
1988-jul	21754,4	22171,8	-1,92	21241,7	2,36
ago	22135,2	22112,3	0,10	21889,7	1,11
set	24996,9	24813,7	3,52	24254,5	2,97
out	26427,0	24116,2	6,10	25803,8	2,36
nov	29337,8	28017,7	4,50	28382,7	3,26
dez	29149,0	28541,5	2,08	28330,8	2,81
1989 jan	22993,3	26150,1	-13,73	25763,3	-12,05
fev	21364,2	20514,8	3,98	21482,4	-0,55
mar	22004,0	19968,8	9,25	20577,6	6,48
abr	26201,6	22408,4	14,78	23863,7	8,92
mai	30264,5	27616,2	8,75	28029,6	7,38
jun	36335,5	30668,1	15,97	33449,1	7,94
IT		0,71		0,47	

1/ Valores de dezembro de 1991

2/ Índice de Theil obtido com 12 previsões

Figura 14 - Previsões de preço real de boi gordo (arroba) - um passo a frente - de julho de 1988 a junho de 1989.

A função de correlação cruzada obtida com o resíduo do modelo C e a variável preço de frango (na primeira diferença), pré-filtrada, apresentou, em todos os ajustamentos, valor significativo para a segunda correlação. No entanto, a inclusão no modelo de termo representando essa defasagem não melhorou as previsões. Os demais testes de verificação mostraram-se adequados.

É interessante mencionar que a exclusão da variável preço de suíno do modelo C teve efeito negativo mas bastante pequeno na qualidade das previsões (obteve-se com o modelo sem a variável preço de suíno $IT = 0,52$). Esse fato era esperado uma vez que os testes estatísticos de causalidade realizados não indicaram relação causal significativa no sentido de preço de suíno para preço de bovino.

4.4.2.- Previsão de Preços de Suíno.

4.4.2.1.- Modelos Univariado e de Intervenção.

Na tabela 15 são apresentadas as autocorrelações e autocorrelações parciais da série de preço de suíno (Z_t), de sua primeira diferença (ΔZ_t) e primeiras diferenças simples e sazonal ($\Delta\Delta_{12}Z_t$).

As autocorrelações, assim como os testes de raiz unitária, indicaram que a série de preço de suíno é não estacionária. Modelos experimentais foram então ajustados para a série na primeira diferença e primeiras diferenças simples e sazonal, com base nos resultados daqueles testes (série $I(1)$ e inconclusivo para raiz unitária sazonal).

Conforme sugeriam os valores de r_k e ϕ_{kk} , foi ajustado inicialmente, para a série ΔZ_t , o modelo $AR(1)$. Nos testes

Tabela 15 - Autocorrelações e autocorrelações parciais estimadas para a série de preço de suíno.

		defasagens		autocorrelações (r_k)					
z_t	1-8	0,902*	0,752*	0,611*	0,490*	0,386*	0,306*	0,252*	0,191*
	9-16	0,140	0,098	0,072	0,061	0,040	-0,010	-0,072	-0,126
	17-24	-0,158	-0,167	-0,133	-0,086	-0,038	-0,011	0,009	0,032
Δz_t	1-8	0,356*	0,006	-0,072	-0,115	-0,129	-0,120	-0,083	-0,068
	9-16	-0,124	-0,077	-0,007	0,053	0,139	0,078	0,030	-0,048
	17-24	-0,086	-0,135	-0,119	-0,085	0,073	0,033	-0,017	-0,043
$\Delta\Delta_{12} z_t$	1-8	0,334*	0,046	-0,007	-0,034	-0,077	-0,014	0,032	0,029
	9-16	-0,110	-0,100	-0,171*	-0,392*	-0,093	0,068	0,029	-0,038
	17-24	-0,055	-0,157	-0,153	-0,115	0,096	0,024	-0,039	0,030
		defasagens		autocorrelações parciais (ϕ_{kk})					
z_t	1-8	0,902*	-0,326*	-0,032	-0,011	-0,026	0,039	0,035	-0,100
	9-16	-0,018	0,049	0,009	0,035	-0,097	-0,169*	-0,025	0,010
	17-24	0,039	0,030	0,157	-0,044	0,067	-0,075	0,037	0,030
Δz_t	1-8	0,356*	-0,139	-0,029	-0,088	-0,072	-0,071	-0,041	-0,061
	9-16	-0,131	-0,028	-0,020	0,017	0,084	-0,042	0,000	-0,075
	17-24	-0,044	-0,114	-0,056	-0,065	0,107	-0,072	-0,042	-0,079
$\Delta\Delta_{12} z_t$	1-8	0,334*	-0,074	0,002	-0,032	-0,062	0,036	0,026	0,008
	9-16	-0,142	-0,022	-0,148	-0,340*	0,168*	0,020	-0,045	-0,066
	17-24	-0,079	-0,168*	-0,067	-0,074	0,041	-0,122	-0,141	-0,199*

* Valor significativo

de verificação as correlações cruzadas obtidas com esse modelo indicavam que um termo AR[2] deveria ser incluído. Também a 18^a correlação cruzada apresentou-se significativa.

O melhor desempenho em termos estatísticos e de previsão para a série ΔZ_t foi obtido com o modelo:

$$(1 - 0,4999 B + 0,2260 B^2 + 0,1892 B^{18}) \Delta \tilde{Z}_t = \theta + a_t + \sum_{i=1}^{11} \phi_i \delta_{it}$$

$\begin{matrix} (-5,8254) & (2,6475) & (2,1962) \end{matrix}$

⇒ (eq. modelo D)

com $\sigma = 0,0938$, $Q(30) = 28,8069$ e todas as autocorrelações de resíduos e correlações cruzadas não significativas.

Na Tabela 16 e Figura 16 o desempenho dos melhores modelos ajustados para a série de preço de suíno pode ser visualizado.

Com a exclusão do termo AR[18] do modelo D, as previsões obtidas foram piores (para o modelo D sem o termo AR[18] foi encontrado Índice de Theil igual a 0,835), assim como o desempenho estatístico.

O impacto da inclusão das variáveis binárias no modelo, apesar de positivo, foi pequeno (para o modelo D excluindo binárias foi encontrado Índice de Theil igual a 0,772).

Modelos alternativos derivados de um MA(1) foram ajustados para a série ΔZ_t , sem, entretanto, superarem o desempenho do modelo D.

Os resultados mostraram que a capacidade dos modelos ajustados para a série ΔZ_t de gerarem boas previsões não pode ser considerada grande, tendo estes apresentados elevados valores para o Índice de Theil

Para a série $\Delta\Delta_{12}Z_t$ um dos melhores desempenhos em termos de previsão foi obtido com o modelo:

$$\Delta\Delta_{12}Z_t = \theta + \underset{(5,6363)}{(1 + 0,4394 B)} \underset{(-18,9321)}{(1 - 0,9292 B^{12})} a_t$$

⇒ (eq. modelo E)

com $Q(34) = 33,974$ e, $\sigma = 0,1008$.

O teste t para a hipótese do coeficiente do termo MA{12} desse modelo ser igual a -1 apresentou-se significativo, indicando que o modelo não deveria ser modificado.

O modelo E apresentou correlações cruzadas elevadas nas

defasagens 9 e 18 e correlação de resíduo elevada na defasagem 3. Introduzindo-se no modelo os termos $AR\{9,18\}$ e $MA\{3\}$ não se obtiveram, no entanto, melhores previsões, apesar dos coeficientes relativos a esses termos apresentarem-se significativos e haver melhorado o desempenho estatístico do modelo. Os citados termos foram introduzidos de forma progressiva, mas também nenhum dos modelos intermediários foi melhor, em termos de previsão, do que o modelo E. O Índice de Theil obtido com esse modelo E foi, no entanto, bastante maior (indicando pior desempenho) do que o obtido com o modelo $SARIMA(0,1,9)(0,1,1)_{12}$ apesar deste apresentar diversos coeficientes não significativos e correlação cruzada elevada na defasagem 18.

São os seguintes os resultados do ajuste do modelo $SARIMA(0, 1, 9)(0, 1, 1)_{12} \Rightarrow$ (eq. modelo F):

Termo	Coeficiente	Estatística t
$MA\{1\}$	0,421	4,720
$MA\{2\}$	-0,036	-0,374
$MA\{3\}$	-0,277	-2,854
$MA\{4\}$	-0,174	-1,774
$MA\{5\}$	-0,207	-2,128
$MA\{6\}$	-0,186	-1,815
$MA\{7\}$	-0,143	-1,447
$MA\{8\}$	-0,086	-0,863
$MA\{9\}$	-0,157	-1,702
$MA\{12\}$	-0,866	-13,325

com $\sigma = 0,100$ e $Q(33) = 19,9114$.

Foram ajustados modelos alternativos só com os termos que se apresentaram significativos no modelo F, todavia as previsões foram piores.

Tabela 16 - Previsões para preço real da arroba de suíno e observações do mercado físico (período: julho de 1991 a junho de 1992)^{1/}. Índice de Theil (IT)^{2/}.

PERÍODO	OBSERV.	MOD. D	DESV. %	MOD. E	DESV. %	MOD. F	DESV. %
91 JUL	16463,7	16303,1	0,98	16030,9	2,63	16324,7	0,84
AGO	16863,8	17281,2	2,48	16210,4	3,87	16401,3	2,74
SET	15119,0	17957,3	-18,77	16110,8	-6,56	16183,9	-7,04
OUT	13799,4	17327,9	-25,57	15665,3	-13,52	14987,0	-8,61
NOV	13931,8	16238,6	-16,56	15258,4	9,52	14704,7	-5,55
DEZ	12985,6	15113,0	-16,38	15031,2	-15,75	14697,7	-13,18
92 JAN	12132,0	14422,3	-18,88	14604,9	-20,38	14462,5	-19,21
FEV	12959,7	14117,3	-8,93	14081,3	-8,65	13719,3	-5,86
MAR	12389,1	13933,8	-12,47	13984,6	-12,88	13300,6	-7,36
ABR	12633,8	14338,5	-13,49	14422,8	-14,16	13625,8	-7,85
MAI	13163,2	15487,0	-17,65	14589,0	-10,83	14196,2	-7,85
JUN	14436,0	16533,7	-14,53	14547,7	-0,77	14558,2	0,85
IT		0,710		0,503		0,383	

1/ - Valores de dezembro de 1991

2/ - Índice de Theil obtido com 12 previsões

Figura 15 - Previsões de preço real de suíno (arroba), de julho de 1991 a junho de 1992

4.4.2.2.- Modelo de Função de Transferência.

As correlações cruzadas das séries pré-filtradas de preço de suíno e bovino e das séries pré-filtradas de preço de suíno e frango são apresentadas na Tabela 17. O filtro utilizado para a obtenção da relação entre preço de suíno e preço de frango (modelo ARIMA que transforma a série de frango, variável explicativa, em ruído branco), foi

apresentado anteriormente quando se tratou de previsões de preço de bovino com modelos de função de transferência. No caso da relação entre preço de suíno e bovino, o filtro utilizado foi:

$$Z_{\text{filtrada}} = \Delta Z_t + 0,267 \Delta Z_{t-6} - 0,231 \Delta Z_{t-14} + 0,181 \Delta Z_{t-15} + \\ + 0,259 \Delta Z_{t-18}$$

com Z expressando tanto a variável explicativa quanto a dependente.

Tabela 17 - Correlações cruzadas entre preço de suíno e preço de frango e entre preço de suíno e preço de bovino.

defasagens		correlações cruzadas						
preço de suíno versus preço de frango								
13 a -7	0,173	-0,016	-0,115	-0,102	0,058	0,070	-0,079	
-6 a 0	-0,109	-0,046	0,039	-0,043	-0,278*	0,070	0,652*	
preço de suíno versus preço de bovino								
-13 a -7	0,237	0,153	0,103	-0,010	0,023	0,027	-0,140	
-6 a 0	-0,283*	-0,187*	-0,105	0,035	0,124	0,229*	0,682*	

* Valor significativo

Assim como no caso de preço de bovino, optou-se por não considerar a relação contemporânea (que se apresentou significativa) na especificação da constante b das variáveis explicativas dos modelos de função de transferência. Os valores de b foram tomados inicialmente como 1 e 2 para preço de bovino e de frango, respectivamente, conforme sugeriam as correlações cruzadas.

Os resultados do processo de identificação do termo residual do modelo de função de transferência indicavam para um AR(1), qualquer que fosse a estrutura experimental estabelecida para as variáveis explicativas das equações de função de transferência (que incluíam ainda 11 binárias e o termo de correção de erro).

Para testar o desempenho dos modelos experimentais de função de transferência para previsão de preço de suíno, da mesma forma que no caso da previsão de preço de bovino, foram estimados os Índices de Theil com 12 previsões um passo a frente. Esses índices foram contrapostos ao obtido com 12 previsões um passo a frente geradas pelo modelo univariado AR|1,2,18| (incluindo binárias para captar a variação estacional da série) $\Rightarrow$ (modelo D^{*}).

O modelo de função de transferência que apresentou o melhor desempenho em termos de previsão foi:

$$\begin{aligned}
 (1 - 0,5412 B) \Delta Z_t = \theta - 0,1766 X_{t-2} - 0,0074 \Delta Y_{t-1} - 0,2462 w_{t-1} + \\
 (-4,4543) \quad (-2,6564) \quad (-0,0862) \quad (-2,0688) \\
 + a_t + \sum_{i=1}^{11} \alpha_i \delta_{it} \quad \Rightarrow \text{(eq. modelo G)}
 \end{aligned}$$

com $Q(36) = 36,0354$ e $\sigma = 0,0902$.

(Obs: Os coeficientes apresentados referem-se ao resultado do primeiro ajustamento da série de ajustamentos realizados com o modelo G para a obtenção das 12 previsões um passo a frente.)

onde:

- Z_t = preço de suíno
- X_t = preço de frango
- Y_t = preço de bovino
- a_t = ruído branco
- δ_t = variável binária
- w_t = resíduo da equação de co-integração:

$$Z_t = \theta + \beta Y_t + \gamma X_t + w_t$$

Os testes de autocorrelação de resíduo e correlação cruzada (resíduo e variável dependente) mostraram valores significativos na defasagem de ordem 13 para todos os ajustamentos. A introdução no modelo de termo representando essa defasagem, no entanto, não melhorou a qualidade das previsões. Os demais testes estatísticos de verificação apontaram para a adequação do modelo.

As previsões obtidas com esse modelo G, e com o modelo univariado D* são apresentados na Tabela 18 e Figura 16, podendo-se verificar superioridade do modelo de função de transferência, comparativamente ao modelo univariado, como instrumental de previsão.

Adotando-se a mesma sistemática utilizada anteriormente no caso de preço de bovino, repetiram-se os ajustamentos dos modelos para preço de suíno, calculando-se os Índices de Theil

Tabela 18 - Previsões um passo a frente para preço real da arroba de suíno, observações do mercado físico (período: julho de 1991 a junho de 1992) ^{1/}. Índice de Theil (IT)^{2/}.

Período	Observado	Modelo D	Desv. %	Modelo G*	Desv. %
1991 jul	16463,7	16303,1	0,98	16094,3	2,24
ago	16863,8	17536,2	-3,99	16904,9	-0,24
set	15119,0	17182,0	-13,65	16736,9	-10,70
out	13799,4	13668,3	0,95	14090,3	-2,11
nov	13931,8	13039,0	6,41	13719,7	1,52
dez	12985,6	13715,7	5,62	13891,0	-6,97
1992 jan	12132,0	12192,6	0,50	12227,3	-0,79
fev	12959,7	11734,6	9,45	11958,4	7,73
mar	12389,1	13427,1	8,38	13315,1	-7,47
abr	12633,8	12299,0	2,65	12191,9	3,50
mai	13163,2	13677,8	3,91	13466,1	-2,30
jun	14436,0	13814,8	4,30	13917,2	3,59
IT		0,99		0,80	

1/ - Valores de dezembro de 1991.

2/ - Índice de Theil obtido com 12 previsões

com previsões de julho de 1988 a junho de 1989 (um passo a frente), obtidas com o modelo de função de transferência com a mesma estrutura do modelo G (modelo G^*) e com um modelo univariado com a mesma estrutura do modelo D ou D^* (modelo D^{**}). É importante mencionar que os testes estatísticos de identificação para o período agora considerado não sugeriram que qualquer alteração na estrutura dos modelos inicialmente propostos devesse ser feita. Os resultados desses

Figura 16 - Previsões de preço real de suíno (arropa) um passo a frente - de julho de 1991 a junho de 1992.

ajustamentos são apresentados na Tabela 19 e Figura 17, podendo-se verificar, também nesse caso, superioridade, apesar de pequena, do modelo de função de transferência como instrumental de previsão.

A exclusão da variável preço de bovino do modelo G^* teve efeito negativo na qualidade das previsões, tendo-se obtido com esse procedimento $IT = 0,84$.

Tabela 19 - Previsões um passo a frente para preço real de arroba de suíno, observações do mercado físico (período: julho de 1988 a junho de 1989)^{1/}. Índice de Theil (IT)^{2/}.

Período	Observado	Modelo D**	Desv. %	Modelo G*	Desv. %
1988 jul	17291,1	16589,5	4,06	16720,2	3,30
ago	16944,7	21536,0	-27,10	19255,7	-13,64
set	16826,1	17458,3	-3,76	16664,1	0,96
out	17731,3	17183,4	3,09	17122,6	3,43
nov	20613,2	17925,8	13,04	18429,2	10,60
dez	24760,8	22215,3	10,28	21792,0	11,99
1989 jan	23119,5	25005,1	-8,16	25924,3	-12,13
fev	23157,7	20767,5	10,32	20824,0	10,08
mar	23822,4	22948,7	3,67	23445,2	1,58
abr	28650,9	24213,3	15,49	23748,3	17,11
mai	36489,0	30499,5	16,41	30518,9	16,36
jun	41295,9	40099,2	2,90	39781,0	3,67
IT		0,85		0,81	

1/ - valores de dezembro de 1991

2/ - Índice de Theil obtido com 12 previsões

Figura 17 - Previsões de preço real de suíno (arroba) um passo a frente - de julho de 1988 a junho de 1989.

4.4.3.- Previsão de Preços de Frango

4.4.3.1.- Modelos Univariado e de Intervenção

Modelos univariados experimentais foram estabelecidos para a série de preço de frango na primeira diferença (ΔX_t) e primeiras diferenças simples e sazonal ($\Delta\Delta_{12}X_t$), com base nos valores das autocorrelações e autocorrelações parciais (Tabela 20). As autocorrelações da série em nível indicaram, da mesma

Tabela 20 - Autocorrelações e autocorrelações parciais estimadas para a série de preço de frango.

		defasagens		autocorrelações (r_k)					
X_t	1-8	0,881*	0,732*	0,639*	0,575*	0,527*	0,485*	0,438*	0,392*
	9-16	0,365*	0,354*	0,335*	0,322*	0,297*	0,242*	0,186	0,140
	17-24	0,086	0,046	0,034	0,047	0,070	0,082	0,082	0,087
ΔX_t	1-8	0,139	-0,277*	-0,138	-0,021	-0,045	-0,005	-0,047	-0,013
	9-16	-0,050	-0,027	-0,020	0,053	0,107	-0,010	-0,015	0,077
	17-24	-0,059	-0,141	-0,176	-0,060	0,109	0,089	-0,039	0,007
$\Delta\Delta_{12}X_t$	1-8	0,104	-0,246*	-0,115	-0,068	0,017	0,096	0,068	0,016
	9-16	-0,052	0,038	-0,061	-0,422*	-0,041	0,107	-0,012	-0,047
	17-24	-0,042	-0,132	-0,116	-0,048	0,096	0,047	-0,022	0,019
		defasagens		autocorrelações parciais (ϕ_{kk})					
X_t	1-8	0,881*	-0,195*	0,175*	0,030	0,044	0,020	-0,028	0,010
	9-16	0,059	0,045	-0,034	0,072	-0,075	-0,108	-0,019	-0,050
	17-24	-0,094	0,031	0,049	0,094	0,060	-0,019	0,011	0,044
ΔX_t	1-8	0,139	-0,309*	-0,052	-0,080	-0,096	-0,021	-0,109	-0,109
	9-16	-0,115	-0,047	-0,081	0,009	0,057	-0,057	0,045	0,066
	17-24	-0,082	-0,082	-0,209*	-0,103	-0,103	-0,040	-0,076	-0,009
$\Delta\Delta_{12}X_t$	1-8	0,104	-0,260*	-0,061	-0,120	-0,007	0,045	0,043	0,038
	9-16	-0,020	0,089	-0,089	-0,428*	0,103*	-0,170	-0,064	0,008
	17-24	-0,066	-0,156	-0,122	-0,099	-0,019	-0,034	-0,099	-0,206*

* Valor significativo

forma que os testes de raiz unitária, que ela é não estacionária . Os testes de raiz unitária combinados aos testes de co-integração sinalizaram que a série de preço de frango é $I(1)$, não sendo conclusivos, no entanto, os testes de raiz unitária sazonal.

Para a série $\tilde{\Delta X}_t$ o modelo que apresentou o melhor desempenho em termos de previsão foi:

$$(1 - 0,1810 B + 0,3029 B^2) \tilde{\Delta X}_t = \theta + a_t \quad \Rightarrow \text{(eq. modelo H)}$$

(-2,3789) (3,9748)

com $Q(36) = 30,666$ e $\sigma = 0,1114$.

Todas as 25 primeiras autocorrelações de resíduos e correlações cruzadas apresentaram-se não significativas, exceto a de período 19, da última modalidade, e as estimativas dos parâmetros não apresentaram correlação elevada.

A inclusão do termo $AR|19|$ no modelo H teve efeito positivo mas bastante pequeno na qualidade das previsões (incluindo o termo $AR|19|$ no modelo encontrou-se Índice de Theil igual a 0,630), apesar do coeficiente deste apresentar-se significativo. Fundamentando-se no princípio da "parcimônia", que rege a construção dos modelos de BOX e JENKINS, deve-se então expressar o modelo que descreve o comportamento da série de preço de frango (na primeira

diferença) como um AR(2).

Ainda com relação ao modelo estabelecido para a série ΔX_t , é interessante mencionar que apesar das correlações não indicarem a necessidade de termo na defasagem 1, a sua inclusão no modelo AR(2) (incompleto) teve efeito positivo e significativo na qualidade das previsões.

Modelos incluindo binárias para essa série foram ajustados, sem resultados satisfatórios.

Na Tabela 21 e Figura 18 podem ser visualizadas as previsões obtidas com os melhores modelos estabelecidos para a série de preço de frango

Dentre os modelos experimentais estabelecidos para a série $\Delta\Delta_{12}X_t$, o que gerou as melhores previsões foi:

$$\begin{aligned}
 (1 - 0,1967 B + 0,3219 B^2 - 0,0939 B^{13})(1 + 0,1635 B^{12})\Delta\Delta_{12}X_t = \\
 \begin{matrix} (-2,2421) & (3,6095) & (-0,9726) & (1,3147) \end{matrix} \\
 = \theta + (1 - 0,7440 B^{12})a_t \quad \Rightarrow (\text{eq. modelo J}) \\
 \begin{matrix} (-8,0776) \end{matrix}
 \end{aligned}$$

com $Q(31) = 28,9309$, $\sigma = 0,1284$ e todas as 25 primeiras correlações de resíduos e correlações cruzadas não significativas.

Tabela 21 - Previsões para preço real de frango [kg] e observações do mercado físico (período: julho de 1991 a junho de 1992)^{1/}. Índice de Theil (IT)^{2/}

Período	Observado	Modelo H	Desv. %	Modelo J	Desv. %
1991 jul	590,4	574,4	2,71	563,2	4,607
ago	550,6	566,5	-2,89	604,5	-9,789
set	519,8	567,9	-9,25	601,3	-15,68
out	542,6	566,8	-4,46	562,2	-3,61
nov	557,2	563,1	-0,45	561,0	-0,68
dez	524,1	559,7	6,79	565,9	-7,98
1992 jan	546,4	557,1	1,96	540,4	1,10
fev	584,8	554,6	5,16	558,5	4,50
mar	488,9	551,9	-12,89	522,1	-6,79
abr	451,1	549,2	-21,75	494,0	-9,51
mai	573,0	546,5	4,62	524,1	8,53
jun	549,1	543,8	-0,97	535,8	2,42
IT		0,640		0,617	

1/ - Valores de dezembro de 1991

2/ - Índice de Theil obtido com 12 previsões

A matriz de correlações entre os parâmetros estimados (Tabela 22) indica correlação relativamente alta, em valores absolutos, entre os termos SAR(1) e SMA(1). Modelos alternativos onde eliminou-se um desses termos foram ajustados, tendo apresentado, no entanto, piores resultados em termos de previsão, o mesmo tendo ocorrido quando se eliminou do modelo o termo AR|13|, que não se apresentou significativo.

Figura 18 - Previsões de preço real de frango (kg), de julho de 1991 a junho de 1992

Tabela 22 - Matriz de correlação dos coeficientes estimados do modelo J.

	AR 1	AR 2	AR 3	SAR 1	SMA 1
AR 1	1,0	-0,1712	-0,0021	-0,0950	-0,0909
AR 2		1,0	0,0033	0,1441	-0,1599
AR 3			1,0	-0,0443	0,0474
SAR 1				1,0	-0,6192
SMA 1					1,0

A inclusão de termos sazonais nos modelos ajustados para a série $\Delta\Delta_{12}X_t$ apresentou efeito positivo no desempenho preditivo dos modelos (as autocorrelações e autocorrelações parciais indicavam a necessidade de tal inclusão bem como as correlações cruzadas dos modelos experimentais sem termos sazonais).

4.4.3.2.- Modelo de Função de Transferência

Na Tabela 23 encontram-se relacionadas as correlações cruzadas das séries de preço de frango e suíno e de preço de frango e bovino (nas diferenças de primeira ordem e pré-filtradas), com base nas quais especificaram-se modelos experimentais de função de transferência para previsão de preço de frango. Os filtros utilizados (que transformam as variáveis explicativas em ruído branco) foram apresentados anteriormente.

No caso de previsão de preço de frango, não se verificou superioridade dos modelos de função de transferência em relação aos modelos univariados (considerando os períodos julho de 1991 a junho de 1992 e junho de 1988 a julho de 1989), conforme pode-se observar na Tabela 24, que apresenta o valor do índice de Theil dos melhores modelos obtidos.

Tabela 23 - Correlações cruzadas entre preço de frango e preço de suíno e entre preço de frango e preço de bovino.

defasagens		correlações cruzadas						
preço de frango versus preço de suíno								
13 a -7	0,193	0,085	-0,667	-0,124	-0,115	-0,023	0,002	
-6 a 0	-0,075	-0,054	0,011	-0,113	-0,112	0,390*	0,655*	
preço de frango versus preço de bovino								
-13 a -7	0,221	0,147	0,081	0,036	0,001	0,058	-0,141	
-6 a 0	-0,227*	-0,186*	-0,055	0,024	-0,008	0,192*	0,560*	

* Valor significativo

Tabela 24 - Índices de Theil (IT) dos modelos de previsão de preços de frango (univariado e função de transferência)^{1/}
Período: julho de 1991 a junho de 1992 (1) e julho de 1988 a junho de 1989 (2).

modelos	IT	
	período 1	período 2
univariado (AR2)	0,94	0,94
AR2 + $Y_t(m = 1 = 0 \text{ e } b = 1) + Z_t(r = 1 = 0 \text{ e } b = 1) + \text{termo de correção de erro } (t-1)$	0,90	1,00
AR2 + $Y_t(r = 1 = 0 \text{ e } b = 1) + \text{termo de correção de erro } (t-1)$	0,88	0,89

1/ Índice de Theil calculado com 12 previsões um passo a frente, com as variáveis preço de frango (X_t), preço de bovino (Y_t) e preço de suíno (Z_t) nas diferenças de primeira ordem.

Esse resultado corroborou os obtidos com os testes de causalidade que indicaram fraca ou nenhuma relação causal no sentido de preço de suíno e bovino para frango.

5.- CONCLUSÕES

Os testes de causalidade indicaram que variações no preço de frango causam variações no preço de bovino e suíno. Esse resultado é compatível com a hipótese de que a tendência decrescente dos preços de bovino e suíno nos últimos anos, período em que o frango passa a ter representatividade na dieta do consumidor brasileiro, é decorrente da queda dos preços de frango, ocasionada pela adoção de tecnologia moderna na sua produção. De fato, a avicultura brasileira, caracterizada atualmente como uma atividade com elevado grau de integração vertical, tem acompanhado os avanços tecnológicos dos países desenvolvidos, que são os grandes produtores mundiais de frango. Enquanto isso, a bovinocultura e a suinocultura, setores onde a adoção de tecnologia não tem sido uniforme nas diferentes zonas criatórias, não tem obtido resultados satisfatórios.

Os testes de causalidade indicaram que relação causal no sentido de preço de bovino para preço de suíno e frango não

deve ser descartada, tendo-se encontrado valores significativos para alguns dos coeficientes dos valores futuros das variáveis explicativas das equações montadas para esse teste (apesar de teste F não significativo nesses casos). Não se identificou causalidade no sentido de preço de suíno para preço de bovino e frango.

Os resultados dos testes de integração indicaram que as séries de preços de bovino, suíno e frango são estacionárias nas primeiras diferenças $[I(1)]$. Os testes de autocorrelação e correlação cruzada, procedimento recomendado pela metodologia Box & Jenkins na fase de identificação dos modelos, corroboraram esses resultados. As autocorrelações das séries em nível não caíram rapidamente para zero, o mesmo tendo ocorrido com as correlações cruzadas. Com as séries nas primeiras diferenças esses testes sinalizaram estacionariedade. Os testes de co-integração indicaram que existe uma relação estável no longo prazo entre as variáveis preço de bovino, preço de suíno e preço de frango. Considerando co-integração entre essas variáveis, utilizou-se modelo de correção de erro para explicar a variável postulada como a dependente nos modelos de função de transferência.

Os testes de autocorrelação e autocorrelação parcial para as séries nas primeiras diferenças não indicaram a necessidade de inclusão de termos sazonais nos modelos de previsão, nem a necessidade de diferenças com defasagem de

necessidade de inclusão de termos sazonais nos modelos de previsão, nem a necessidade de diferenças com defasagem de período 12 . Quando, todavia, se fez essa diferença (criando-se correlações significativas em defasagem de período 12 e múltiplos), obtiveram-se modelos univariados que apresentaram melhor desempenho que os modelos univariados estabelecidos para as séries com diferenças somente de primeira ordem. Os modelos estabelecidos para previsão de preços de bovino e suíno (com as séries nas diferenças de primeira ordem), que incluíam variáveis binárias para captar a variação estacional (modelos de intervenção), também apresentaram melhor desempenho que os modelos univariados.

De maneira geral, obtiveram-se com os modelos univariados propostos para as séries de preço de bovino e suíno, boas previsões. A introdução da variável explicativa preço de frango nos modelos univariados um passo a frente estabelecidos para essas séries, melhorou as previsões. A exclusão da variável preço de suíno do modelo de função de transferência para previsão de preço de bovino teve efeito negativo, mas bastante pequeno, na qualidade das previsões, o mesmo tendo ocorrido quando se omitiu do modelo de função de transferência para previsão de preço de suíno a variável explicativa preço de bovino. Esses resultados eram previstos tendo por base os testes de causalidade.

preços de bovino e preço de suíno. Corroborando também os resultados dos testes de causalidade, não se verificou melhor desempenho, em termos de previsão, quando se introduziram nos modelos univariados um passo a frente, estabelecidos para a série de preço de frango, as variáveis explicativas preço de bovino e preço de suíno.

Os modelos de função de transferência para previsão de preços têm, comparativamente aos univariados, a desvantagem da limitação do horizonte de previsão, a menos que se esteja disposto a utilizar previsões das variáveis explicativas. Sendo assim, o custo/benefício de cada uma dessas formas de modelagem deve ser considerado na hora da opção.

Finalmente, vale lembrar que nem sempre se verificou associação entre o bom ajustamento dos modelos (satisfazendo os testes de autocorrelação, correlação cruzada e superajustamento) e a sua "performance" preditiva. Em alguns casos, a medida em que se introduziram termos que melhoraram o ajustamento do modelo, obtiveram-se piores previsões. Essa dicotomia entre bom ajustamento e boas previsões aumenta ainda mais a dificuldade de identificação correta dos modelos de previsão, fato reconhecido na literatura que trata da metodologia de séries temporais Box & Jenkins.

6.- REFERÊNCIAS BIBLIOGRÁFICAS

AVICULTURA. *Agroanalysis*, Rio de Janeiro, 12(1):2-6, 1988.

BACCHI, M.R.P. & BARROS, G.S.de. Demanda de carne bovina no mercado brasileiro. *R. Econ. Sociol. Rural*, 30(1):83-96, jan./mar., 1992.

BOX, G.E. & JENKINS, G.M. *Time series analysis: forecasting and control*. San Francisco. Holden - Day, 1976. 575p.

BRANDT, J.A. & BESSLER, D.A. Composite forecasting: an application with U.S. hog prices. *American Journal Agricultural Economics*, Iowa, 63(1):136-40, 1981.

BRANDT, S.A.O.; MARTINS, M.I.G.O.; MORO, S.; WONG, S. ; ALMEIDA, J.M.C.de. Ciclos de integração no mercado de carnes. *R. Econ. Rural*, Brasilia, 25(3):303-9, jul/set., 1987.

BURNQUIST, H.L. Identifying effects of the macro-economy on Brazilian agricultural prices. New York, 1992. 365p. (Doutorado - Cornell University)

CAMPBELL, J.Y. & PERRON, P. Pitfalls and opportunities: what macroeconomists should know about unit roots. In: National Bureau of Economic Research. Macroeconomics Annual - 1991. p.141-219.

CARVALHO, M.A.de. Estabilização dos preços agrícolas no Brasil: o caso dos preços mínimos. São Paulo, 1991, 203 p. (Doutorado - Escola de Administração de Empresas do Estado de São Paulo / FGV).

CARVALHO, M.A.de & SILVA, A.R.L.da. Um modelo para determinação de preços de intervenção. *Agricultura em São Paulo*, São Paulo, 37(3):183-98, 1990.

CHATFIELD, C. *The analysis of time series*. 3 ed. New York, Chapman and Hall Ltd., 1984. 286p.

CHEN, D.T. & BESSLER, D.A. Forecasting monthly cotton price: structural time series approaches. *International Journal of Forecasting*, Amsterdam, 6(1):103-113, 1990.

- DIAS, G.L.S.da. Alguns aspectos da pecuária de corte da região centro-sul. *Estudos AMPES*. São Paulo, n.7, 1968. 58p.
- DICKEY, D.A. & FULLER, W.A. Distribution of the estimator for auto-regressive time series with a unit root. *Journal of the American Statistical Association*, 74:427-31, 1979.
- DICKEY, D.A. & FULLER, W.A. Likelihood ratio statistics for auto-regressive time series with a unit root. *Econometrica*, Illinois, 49(4): 1057-72, 1981.
- DICKEY D.A.; HASZA, D.P.; FULLER, W.A. Testing for unit roots in seasonal time series. *Jornal of the American Statistical Association*. 79 : 355-67, 1984.
- DOAN, T.A. & LITTERMAN, R.B. User's manual: Rats. Minneapolis, MN: VAR Econometrics, 1981. 1v.
- ENGLE, R.F. & GRANGER, C.W.J. Co-integration and error correction representation, estimation and testing. *Econometrica*, Illinois, 55(2):251-76, 1987.
- ENGLE, R.F. & YOO, B.S. Forecasting and testing in co-integrated systems. *J. Econometrics*, 35:143-59, 1987.

ETAC MERCADOS. Curitiba, 3, set., 1987.

FERNANDES, S.G. Análise de alternativas de políticas para o setor de carnes no Brasil. *R. Econ. Sociol. Rural*. 27(4):437-59, out./dez., 1989.

FULLER, W.A. Introduction to statistical time séries. New York, John Wiler. 1976.

FUNDAÇÃO INSTITUTO DE GEOGRAFIA E ESTATÍSTICA. Estudo Nacional de Despesa Familiar, Rio de Janeiro, 1978.

GRANGER, C.W.J. Investigating causal relations by econometric models and cross spectral methods. *Econometrica*, Illinois, 37(3):424-38, 1969.

GOLDSZAL, E.de F. Movimentos de longo prazo no comércio internacional: um estudo de caso para café, açúcar e cacau. Boletim de Diplomacia Econômica. 11/12, maio/agosto, 1992.

HALLAN, D. *Econometric modelling of agricultural commodity markets*. London, Routlege, 1990. 191p.

HENDRY, D.F. Econometric modelling with co-integrated variables: an overview. *Oxford Bulletin of Economic Statistics*, 48:201-212, 1986.

HOFFMANN, R. Variação estacional dos preços dos produtos agropecuários no Estado de São Paulo, 1969. 184 p. (Doutorado - Escola Superior de Agricultura "Luiz de Queiroz" / USP).

INFORMAÇÕES ECONÔMICAS. São Paulo, Instituto de Economia Agrícola, 1988-1992.

JENKINS, G.M. *Practical experiences whith modelling and forecasting time series*. Jersey, Channel Island, 1979, 146p.

KASSOUF, A.L. Previsão de preços na pecuária de corte no Estado de São Paulo. Piracicaba, 1988. 102p. (Mestrado - Escola Superior de Agricultura " Luiz de Queiroz " / USP).

KMENTA, J. *Elementos de econometria*. 2 ed. São Paulo, Atlas, 1988. 2v.

LATTIMORE, R.G. An econometric study of the brazilian beef sector. Purdue, 1974. 176p. (Doutorado - Purdue University).

LEUTHOLD, R.; MACCORMICK, A.; SCHIMITZ, A.; WATTS, D. Forecasting daily hog prices and quantities: a study of alternative forecasting technics. *J. Amer. Statist. Assoc.*, 65:90-107, 1970.

LIMA, E.C.R.; LOPES, H.F.; MOREIRA, A.R.B. ; PEREIRA, P.L.V. Tendência estocástica do produto: efeito da flutuação de produtividade e de taxa de juros real. In: ENCONTRO BRASILEIRO DE ECONOMETRIA, 15., Belo Horizonte, 1993. *Anais*. Rio de Janeiro, SBE, 1993. V.2, p. 697-719.

LÜTKEPOHL, H. Introduction to multiple time series analysis. Springer-Verlag. Berlin, 1991. 545p.

MADDALA, G.S. *Introduction to econometrics*. New York, Macmillan Publishing Company, 1988. 472p.

MAKRIDAKIS, S.A. survey of time series. *International Statistical Review*, Voorburg - NE, 44(1):29-70, 1976.

MAKRIDAKIS, S. Time series analysis and forecasting: an update and evaluation. *International Statistical Review*, Voorburg-NE, 46(3):255-78, 1978.

MAKRIDAKIS, S. The art and science of forecasting: an assessment and future directions. *International Journal of Forecasting*, Amsterdam, 2:15-39, 1986.

MASCOLO, J.L. & SOUZA, A.L.S.P.de. A política comercial brasileira recente e seu impacto na agricultura de exportação. Rio de Janeiro, Fundação Centro de Comércio Exterior, 1983. 100p.(Relatório de pesquisa).

MORETTIN, P.V. & TOLOI, C.M.de C. *Previsão de séries temporais*. São Paulo. Atual Editora Ltda., 1985. 436p.

MUELLER, C.C. O ciclo do gado e as tentativas governamentais de controle do preço da carne. *Estudos Economicos*, São Paulo, 17(3):435-57, 1987.

NERLOVE, M. Distributed lags and demand analysis for agricultural and other commodities. Washington, Agricultural Marketing Service. Department of Agriculture, 1958. (Agricultural Handbook, 141)

- OLIVEIRA, A.X.de & PINO, F.A. Elasticidades em modelos de séries temporais. In: Encontro Brasileiro de Econometria, 7., Vitória, ES., 1985. *Anais*, Rio de Janeiro, Sociedade Brasileira de Econometria. p. 401-12.
- PEREIRA, P.L.V. Co-integração e suas representações: uma resenha. *Revista de Econometria*, 11(2):185-216, nov.1991.
- PHILLIPS, P.C.B. Time series regression with a unit root. *Econometrica*, 55:277-301, 1987.
- PHILLIPS, P.C.B. & PERRON, P. Testing for unit root in time series regression. *Biometrika*, 75(2): 335-46, 1988.
- PINDYCK, R.S. & RUBINFELD, D.L. Econometric models and economic forecasts. 3 ed. McGraw - Hill, Inc., 1991. 596 p.
- PINO, F.A. Análise de intervenção em séries temporais, aplicações em economia agrícola. São Paulo, 1980, 253p. (Mestrado - Instituto de Matemática e Estatística /USP).
- PORTUGAL, M. Um modelo de correção de erros para a demanda por importações brasileira. *Pesq. Plan. Econ.* 22(3):501-40, 1992.

PRODUÇÃO BRASILEIRA DE PINTOS DE CORTE. Campinas, Associação Brasileira dos Produtores de Pintos de Corte, nov.,1992.

REZENDE, G.C.de. Do cruzado ao Collor: os planos de estabilização e a agricultura. In: SEMINÁRIO SOBRE PROBLEMAS E PERSPECTIVA DA AGRICULTURA, 6., Piracicaba, 1990. *Anais*. Piracicaba, ESALQ/DERS, 1990. p.172-92.

SANTANA, A.C.de & BRANDT, S.A. Encadeamento de preços na pecuária de corte: uma aplicação do modelo de correção de erro. *R. Econ. Sociol. Rural*, 29(2):135-49, abr./jun.,1991.

SANTIAGO, M.M.D. Determinação do custo de produção de suínos no Estado de São Paulo e análise de rentabilidade do setor. Piracicaba, SP, 1989. 152p. (Mestrado - Escola Superior de Agricultura "Luiz de Queiroz" / USP.).

SANTIAGO, M.M.D., coord. Estatísticas de preços agrícolas no Estado de São Paulo. São Paulo, IEA, 1990. V.1.

SCHMITZ, A. & WATTS, D.G. Forecasting wheat yields: an application of parametric time series modelling. *American Journal Agricultural Economics*, Iowa, 52(2):247-254, 1970.

- SIMS, C.A. Money, income and causality. *Am. Econ. Rev.*,
Visconsin, 62(4):540-55, 1972.
- VANDAELE, W. *Applied time series and Box-Jenkins models*.
Academic Press, Inc., Florida, 1983. 417 p.
- VICENTE, J.R. Modelos estruturais para previsão das produções
brasileiras de carne de frango e ovos. *R. Econ. Rural*,
Brasilia, 25(3) : 305-19, out./dez. ,1992.
- ZAPATA, H.O. & GARCIA P. Price forecasting with time series
methods and nonstationary data: an aplication to monthly US
cattle price. *Wester Journal of Agicultural Economics
Association*, 15(1):123-132, 1990.
- ZINI, E.C.R. & CATI, R.C. Co-integração e taxa de câmbio:
teste sobre a PPP e os termos de troca do Brasil de 19855 a
1990. *Pesq. Plan. Econ.* 23(2):349-74, 1993.

APÊNDICE

Tabela 1 - Valores críticos das estatísticas τ_μ , τ , τ_τ e $\tau_{\mu d}$ para raiz unitária e estatísticas $\tau_{\alpha\mu}$, $\tau_{\alpha\tau}$ e $\tau_{\beta\tau}$.

Amostra	1 %	5%	10%
Est. τ_μ	(testar $\rho = 1$ em $Y_t = \alpha + \rho Y_{t-1} + e_t$)		
100	-3,51	-2,89	-2,58
250	-3,46	-2,88	-2,57
Est. τ	(testar $\rho = 1$ em $Y_t = \rho Y_{t-1} + e_t$)		
100	-2,60	-1,95	-1,61
250	-2,58	-1,95	-1,62
Est. τ_τ	(testar $\rho = 1$ em $Y_t = \alpha + \beta t + Y_{t-1} + e_t$)		
100	-4,04	-3,45	-3,15
250	-3,99	-3,43	-3,13
Est. $\tau_{\mu d}$			
120	-6,63	-5,86	-5,49
240	-6,47	-5,83	-5,49
Est. $\tau_{\alpha\mu}$	(testar $\alpha = 0$ em $Y_t = \alpha + \rho Y_{t-1} + e_t$)		$(\alpha, \rho) = (0, 1)$
100	-3,22	-2,54	-2,17
250	-3,19	-2,53	-2,16
Est. $\tau_{\alpha\tau}$	(testar $\alpha = 0$ em $Y_t = \alpha + \beta_t + \rho Y_{t-1} + e_t$)		$(\alpha, \beta, \rho) = (0, 0, 1)$
100	-3,78	-3,11	-2,73
250	-3,74	-3,09	-2,73
Est. $\tau_{\beta\tau}$	testar $\beta = 0$ em $Y_t = \alpha + \beta_t + \rho Y_{t-1} + e_t$		$(\alpha, \beta, \rho) = (0, 0, 1)$
100	-3,53	-2,79	-2,38
250	-3,49	-2,79	-2,38

Fonte: FULLER (1976) - estatísticas τ , τ_μ e τ_τ .DICKY & FULLER (1981) - estatísticas $\tau_{\alpha\mu}$, $\tau_{\alpha\tau}$ e $\tau_{\beta\tau}$.DICKY; HASZA; FULLER (1984) - estatística $\tau_{\mu d}$.

Tabela 2 - Valores críticos dos testes de co-integração (Dickey-Fuller e Dickey-Fuller expandido) ao nível de 0,01, 0,05 e 0,10 de probabilidade, para 100 observações.

Estatísticas	1%	5%	10%
DF (2 variáveis)	-4,07	-3,37	-3,03
DF (3 variáveis)	-4,45	-3,93	-3,59
DFA (2 variáveis)	-3,77	-3,17	-2,84

Fonte: ENGLE & GRANGER (1987) e ENGLE & YOO (1987).