

MODELOS ESTRUTURAIS PARA PREVISÃO DAS PRODUÇÕES BRASILEIRAS DE CARNE DE FRANGO E OVOS¹

JOSÉ R. VICENTE²

RESUMO - Modelos Estruturais Básicos (BSM) foram ajustados para as séries de produção brasileira de ovos e carne de frango. Após efetuar diagnósticos dos resultados e da qualidade dos ajustes, previsões foram efetuadas doze meses à frente. As previsões foram comparadas com as fornecidas por modelos ARIMA e consideradas melhores do que as desses últimos modelos.

Termos para indexação: previsão, modelos estruturais, filtro de Kalman.

STRUCTURAL MODELS FOR FORECAST OF BRAZILIAN EGG AND CHICKEN MEAT PRODUCTIONS

ABSTRACT - Basic structural models were adjusted for Brazilian egg and chicken productions time series. After diagnostics and measures of goodness of fit, forecast twelve months ahead were made. The forecasts were compared to those of ARIMA models, and considered better than these.

Index terms: forecasting, structural models, Kalman filter.

INTRODUÇÃO

Grandes avanços foram conseguidos nas áreas de análise e previsão de séries temporais a partir da década de 70, com o desenvolvimento dos modelos Box & Jenkins; como é normal no processo de aperfeiçoamento científico, críticas a essa metodologia apareceram, procurando defender métodos alternativos. Harvey & Todd (1983) levantaram alguns pontos, como o fato de os correlogramas e funções de autocorrelações parciais nem sempre serem muito informativos, especialmente em pequenas amostras, e de as dificuldades de interpretação intensificarem-se quando as séries forem diferenciadas, o que é um procedimento normal nos modelos ARIMA, resultando freqüentemente no ajuste de modelos inapropriados. Tentativas de seleção de modelos por procedimentos automáticos, como o AIC (Akaike Information Criterion), podem também levar a maus resultados, com bons ajustes no período da amostra não resultando em boas previsões. Como alternativa, foi proposta a formulação de modelos de decomposição da série analisada em termos de tendência, sazonal-

¹ Recebido em 30.11.92.

Aceito para publicação em 10.03.93.

² Eng.-Agr., Mestre, aluno do Curso de Doutorado em Economia do Instituto de Pesquisas Econômicas (IPE-FEA-USP) e Pesquisador Científico do Instituto de Economia Agrícola (IEA/SAAESP), Caixa Postal 8114, CEP 01051 São Paulo, SP.

lidade, ciclo (quando necessário) e componente irregular; esses componentes são estocásticos, enquanto nos modelos econométricos clássicos seriam determinísticos. Os modelos estruturais, apesar de baseados num conceito antigo dentro da análise de séries temporais – admitir a existência de componentes básicos não-observáveis da tendência (movimentos de longo prazo de uma série, que podem ser extrapolados para o futuro), sazonalidade (parte da série que, quando extrapolada, repete-se dentro do período de um ano e tem média zero neste período) e ciclo (movimentos oscilatórios transitórios em torno da tendência) –, ganharam formalmente espaço na literatura a partir da década de 80, com os trabalhos de Harvey (Souza, 1989).

Os objetivos deste trabalho são, através do ajuste de modelos estruturais, efetuar previsões e compará-las com outras provenientes de modelos ARIMA. Como esse tipo de modelo (especialmente os de Box & Jenkins) fornece melhores resultados para grandes amostras, foram escolhidas as séries das produções mensais de ovos e de carne de frangos no Brasil, publicadas sem interrupções pela Associação Paulista de Avicultura (APA), a primeira desde janeiro de 1984, e a segunda a partir de janeiro de 1981. Todos os modelos foram ajustados com dados até agosto de 1991, para permitir a aferição da qualidade das previsões até um ano à frente.

METODOLOGIA

A formulação estrutural mais utilizada em séries econômicas é a conhecida como Modelo Estrutural Básico (BSM), constituído por tendência, sazonalidade e componente irregular (Harvey, 1989):

$$y_t = \mu_t + \gamma_t + \varepsilon_t \quad (1)$$

com $t = 1, \dots, T$.

O processo gerador da tendência é considerado como uma aproximação local a uma tendência linear:

$$\mu_t = \mu_{t-1} + \beta_{t-1} + \eta_t \quad (2)$$

$$\beta_t = \beta_{t-1} + \zeta_t \quad (3)$$

onde η_t e ζ_t são ruídos brancos não correlacionados entre si, e com variâncias σ_η^2 e σ_ζ^2 , respectivamente, e β é a declividade da tendência.

O componente sazonal é gerado por:

$$\gamma_t = -\sum_{j=1}^{s-1} \gamma_{t-y} + \omega_t \quad (4)$$

onde ω_t é ruído branco, com variância σ_ω^2 , e s é o número de fatores sazonais durante o ano. O padrão sazonal muda suavemente, por um mecanismo em que a soma dos componentes sazonais a cada s períodos consecutivos tem esperança zero e variância que permanece constante no tempo.³

A operacionalização do modelo⁴ é feita através de sua representação na forma de espaço de estado⁵. O espaço de estado de um modelo univariado de série temporal consiste em uma equação de transição:

$$\alpha_t = T_t \alpha_{t-1} + K_t \quad (5)$$

e de uma equação de medida:

$$y_t = Z_t \alpha_t + \varepsilon_t \quad (6)$$

onde y_t é o vetor das observações; α_t é o vetor de estado – em geral não observável – ($m \times 1$); z_t é um vetor de parâmetros ($m \times 1$) que relaciona a série observada ao vetor de estado; T_t é uma matriz ($m \times m$) de parâmetros que representa a evolução do vetor de estado. Assume-se que ε_t é ruído branco com média zero e variância $h_t = \sigma_\varepsilon^2$; k_t é ruído branco multivariado com média zero e matriz de covariância:

$$Q_t = \text{diag.} (\sigma_\eta^2, \sigma_\xi^2, \sigma_\omega^2, 0, 0) \quad (7)$$

³ A sazonalidade será representada aqui sob a forma de variáveis binárias (“dummies”); uma outra possibilidade é representá-la através de suas harmônicas significativas. O procedimento clássico, neste último caso, é modelar por uma combinação linear de funções trigonométricas (Souza, 1989).

⁴ Procedimento que possibilitará a obtenção de estimadores atualizados dos componentes não observáveis, a cada instante do tempo, a partir do único componente observável do modelo, que é a variável dependente.

⁵ A formulação em espaço de estados de um processo estocástico (estacionário ou não) baseia-se na propriedade de sistemas markovianos, em que o futuro do processo independe do passado, dado o presente; o estado do processo condensa, portanto, toda a informação do passado necessária para a previsão do futuro (Souza, 1989).

Adicionalmente, assume-se que o vetor de estado inicial (α_0) tem média a_0 e matriz de variâncias e covariâncias P_0 (mxm) e que os termos aleatórios são não-correlacionados entre si e com o vetor de estado inicial.

Para exemplificar apresenta-se a forma de espaço de estado de um BSM, supondo-se, por simplicidade, dados trimestrais ($s = 4$); a equação de transição fica sendo (Harvey, 1989):

$$\alpha_t = \begin{bmatrix} \mu_t \\ \beta_t \\ \gamma_t \\ \gamma_{t-1} \\ \gamma_{t-2} \end{bmatrix} = \begin{bmatrix} 1 & 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & -1 & -1 & -1 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \end{bmatrix} \bullet \begin{bmatrix} \mu_{t-1} \\ \beta_{t-1} \\ \gamma_{t-1} \\ \gamma_{t-1} \\ \gamma_{t-3} \end{bmatrix} + \begin{bmatrix} \eta_t \\ \zeta_t \\ \omega_t \\ 0 \\ 0 \end{bmatrix}$$

A equação de medida é:

$$y_t = [1 \ 0 \ 1 \ 0 \ 0] \alpha_t + \varepsilon_t \quad (8)$$

A representação do modelo em forma de espaço de estado torna possível a aplicação do filtro de Kalman (cujas equações são apresentadas em Harvey, 1989 e em Souza, 1989), um procedimento recursivo que permite obter estimadores ótimos (de menor erro quadrático médio) atualizados do vetor de estado, com base nas informações disponíveis até o instante t . Como o método supõe conhecidos h_t e as matrizes z_t , T_t e Q_t , esses parâmetros (chamados de hiperparâmetros) têm que ser estimados: pela abordagem clássica (de Harvey), a estimação é feita diretamente da série histórica, por máxima verossimilhança, geralmente no domínio do tempo⁶. Também os valores de a_0 e de P_0 têm que ser conhecidos a priori, podendo ser calculados a partir das primeiras observações ou obtidos a partir de uma priori difusa (Souza, 1989), fazendo, por exemplo, $a_0 = 0_{m \times 1}$ e $P_0 = cI_{m \times m}$, onde c é um número real finito mas muito grande.

Assim que os parâmetros do modelo estiverem estimados, previsões de valores futuros podem ser efetuadas a partir da forma de espaço de estado. A função de previsões consiste em uma tendência local superposta pelos compo-

⁶ Comparações entre os resultados de estimações efetuadas no domínio do tempo e no domínio da frequência podem ser vistas em Harvey & Peters (1990). Tratamento dos hiperparâmetros segundo a abordagem bayesiana é apresentado em Souza (1989).

nentes sazonais locais.

Após a apresentação dos resultados dos modelos estruturais, as previsões efetuadas três, seis, nove e doze passos à frente serão comparadas com outras provenientes de modelos ARIMA (Vandaele, 1983), através dos seguintes indicadores: raiz quadrada do erro quadrático médio, desvio absoluto médio (percentual) e coeficiente de desigualdade (U_2) de Theil (1966). Esse último indicador tem a fórmula:

$$U_2 = \sqrt{\frac{\sum_{t=1}^T (\Delta P_t - \Delta A_t)^2}{\sum_{t=1}^T \Delta A_t^2}} \quad (9)$$

onde P_t é a variação prevista em relação à observação anterior, e A_t é a variação efetivamente realizada. a interpretação de U_2 é simples: se for igual a zero, as variações previstas são iguais às observadas (previsões perfeitas); quanto menor for o valor de U_2 , portanto, melhor o procedimento de previsão.

RESULTADOS E DISCUSSÃO

A significância dos valores dos hiperparâmetros resultantes do ajuste do BSM para a série de produção de ovos indicam que o modelo poderia ser reajustado com uma tendência determinística, uma vez que o nível da mesma aparece como não-estocástico ($\sigma_\epsilon^2 = 0$)⁷; a declividade da tendência e a sazonalidade, por sua vez, aparentam comportamento aleatório (Tabela 1).

Para o BSM da série de produção de carne de frangos, cujos dados originais foram transformados por logaritmos, os resultados dos hiperparâmetros apontam uma tendência com nível aleatório e inclinação determinística ($\sigma_\epsilon^2 = 0$), enquanto a discussão sobre o componente estocástico associado à sazonalidade está prejudicada, uma vez que o teste do mesmo aparece como “missing” (erro-padrão muito próximo de zero, Tabela 1).

As estimativas dos parâmetros do vetor de estado para a última observação – agosto de 1991 – são significativas, tratando-se da série de ovos, para o nível da tendência e para os fatores sazonais de agosto, julho e junho (negativos), e abril, março, fevereiro e janeiro (positivos, Tabela 2)⁸. Para a série de

⁷ Essa tentativa foi efetuada, mas os resultados, tanto do ajuste como das previsões, foram substancialmente piores do que os do BSM; isso pode estar associado aos problemas de não-normalidade, que serão abordados à frente.

⁸ Embora a produção de ovos ocorra o ano inteiro, no outono e inverno a produção é menor devido ao ciclo biológico das aves, cujas atividades orgânicas estão reduzidas, havendo menor consumo de alimentos e menos postura. A renovação dos plantéis também se concentra nesses meses (Giulietti et al., 1981).

produção de carne de frangos, além do nível e da inclinação da tendência, são significativos os fatores sazonais dos meses de junho, abril e fevereiro (negativos), e janeiro, dezembro, novembro e outubro (positivos, Tabela 2).⁹

TABELA 1. Resultados da estimação dos hiperparâmetros.

Produto	Estimativa	Parâmetro	Desvio-padrão	t ¹
Ovos ²	.000	σ_{η}^2	1.0000	.0000
	411.4942	σ_{ζ}^2	74.7990	5.5013 a
	2.0245	σ_{ω}^2	1.4669	1.3801 c
	.0000	σ_{ε}^2	1.0000	.0000
Frangos ³	.0010758	σ_{η}^2	.0002731	3.9392 a
	.0000	σ_{ζ}^2	1.0000	.0000
	.0000020	σ_{ω}^2	.0000	Missing
	.00002084	σ_{ε}^2	.0001430	1.4578 c

¹ Teste t assintótico. Níveis de significância: a = 1%; c = 10%.

² Período de ajuste: janeiro de 1984 a agosto de 1991; 92 observações.

³ Período de ajuste: janeiro de 1981 a agosto de 1991; 128 observações.

Fonte: Resultados da pesquisa.

Uma série de testes, obtidos a partir dos resíduos, pode ser utilizada para o diagnóstico dos ajustes e a aferição da qualidade dos mesmos.¹⁰

O X^2 associado à normalidade é significativo para a série de produção de ovos (24,83, com 2 graus de liberdade), indicando que os resultados dessa modelagem devem ser vistos com cautela, especialmente as estimativas das variâncias¹¹. A série de produção de carne de frangos não apresentou esse problema ($X^2 = 0,26$, não-significativo).

⁹ Se houver interesse nos estimadores do vetor de estado em todos ou em determinados instantes da série, os mesmos podem ser obtidos a partir do procedimento de suavização, que consiste em aplicar o filtro de Kalman em sentido inverso (ver Souza, 1989).

¹⁰ Descrição completa dos testes apresentados a seguir encontra-se em Harvey (1989) e, mais sucintamente, em Souza (1989).

¹¹ Esse problema poderia, em princípio, ser devido à presença de "outliers" ou à necessidade de transformação dos dados originais; todavia, o reajuste com aplicação de logaritmos e raízes quadradas não alterou os resultados do teste. Mesmo sem a pressuposição de normalidade, a ausência de autocorrelação é suficiente para o filtro de Kalman fornecer previsões lineares ótimas (Harvey, 1989).

TABELA 2. Estimativas do vetor de estado ao final do período de ajuste.

Produto/Parâmetro	Estimativa	REQM ¹	t ²
Ovos³			
Tendência			
Nível	3165,6	12,3963	255,3648 a
Inclinação	13,4876	22,0287	,6123
Fatores sazonais			
agosto	-46,5668	12,3963	-3,7565 a
julho	-39,0792	11,9242	-3,2773 a
junho	-22,8090	11,9353	-1,9111 c
maio	2,4339	11,9521	,2036
abril	25,9687	11,9559	2,1720 b
março	38,0302	11,9448	3,1838 a
fevereiro	40,5564	12,0081	3,3774 a
janeiro	25,6913	12,1535	2,1139 b
dezembro	6,1419	12,1724	,5046
novembro	-2,1507	12,1383	-,1772
outubro	-11,4990	12,1449	-,9468
Frangos⁴			
Tendência			
Nível	5,3976	,0170	317,1606 a
Inclinação	,0058347	,0029178	1,9997 b
Fatores sazonais			
agosto	-,0092353	,0115	-,8030
julho	-,0042550	,0113	-,3750
junho	-,0317	,0113	-2,8106 a
maio	-,0172	,0113	1,5245
abril	-,0904	,0113	-8,0270 a
março	-,0178	,0113	-1,5789
fevereiro	-,0203	,0114	-1,7879 c
janeiro	,0257	,0114	2,2475 b
dezembro	,0674	,0116	5,8298 a
novembro	,0337	,0116	2,9097 a
outubro	,0464	,0116	4,0033 a

¹ Raiz quadrada do erro quadrático médio.

² Teste t assintótico. Níveis de significância: a = 1%; b = 5%; c = 10%.

³ Período de ajuste: janeiro de 1984 a agosto de 1991; 92 observações.

⁴ Período de ajuste: janeiro de 1991 a agosto de 1991; 128 observações.

Fonte: Resultados da pesquisa.

A existência de heterocedasticidade pode ser verificada através de um teste $F(h, h)$, em que h é aproximadamente igual a um terço da série. Para a série de produção de ovos, o valor encontrado é muito baixo e não-significativo ($F_{(26,26)} = 0,38$); já para a série de produção de carne de frangos, o valor encontrado ($F_{(38,38)} = 0,76$, também não-significativo) deve-se à transformação da série (aplicação de logaritmos), uma vez que o ajuste com os dados originais apresentou valor nas vizinhanças do crítico significativo a 5%, o que indicava uma tendência de a variância residual aumentar com o tempo.

Um teste conjunto para autocorrelação residual de ordem P pode ser efetuado através de uma estatística de Portmanteu (Q de Box-Ljung), com P sendo igual à raiz quadrada do número de observações e os graus de liberdade associados sendo $P-n$, onde n é o número de hiperparâmetros menos 1. Para a série de ovos o valor encontrado é $Q^{(10)} = 13,61$, não-significativo (o valor crítico de X^2 com 7 graus de liberdade a 5% é 14,07), e para a série de carne de frangos $Q_{(12)} = 7,16$, também não-significativo (valor crítico de X^2 a 5% com 9 graus de liberdade igual a 16,92).

Para testar o poder de previsão dos modelos após o período de ajuste pode ser empregada uma generalização do teste de Chow, que consiste em comparações das previsões um passo à frente com os valores observados disponíveis (pós-ajuste), e tem também a utilidade de indicar a existência de alterações estruturais ou heterocedasticidade após o período de estimação. Para a série de ovos, o valor obtido foi $F_{(12,79)} = 0,48$, e para a produção de carne de frangos, $F_{(12,115)} = 0,63$, ambos não-significativos, indicando que as previsões pós-período de ajuste não são piores do que as efetuadas dentro do mesmo.

A qualidade dos ajustes pode ser verificada através do coeficiente de determinação; todavia, essa medida somente é adequada para séries relativamente estacionárias, já que a existência de tendência acentuada costuma aproximá-la de 1 (um). Nos dois exemplos aqui considerados, os valores de R^2 são elevados: 0,997 para ovos e 0,968 para frangos. Harvey (1989) propõe duas outras medidas, o R^2_D e o R^2_S ; para a série de ovos, o R^2_D encontrado é igual a 0,807, e para a série de carne de frangos, igual a 0,487. Os valores positivos dessa medida indicam vantagens das especificações selecionadas em relação à modelagem de passeios aleatórios simples. O coeficiente R^2_S encontrado para a produção de ovos (0,786, positivo) indica que houve ganho na representação da sazonalidade como estocástica; já na produção de carne de frangos ($R^2_S = -0,053$), aparentemente os fatores sazonais poderiam ser representados como determinísticos.

As Figuras 1 e 2 apresentam os valores observados e estimados das séries, podendo-se considerar que os modelos propiciam estimativas bastante “aderentes” durante o período de ajuste (até agosto de 1991).

(Milh. de cx. de 30 dz.)

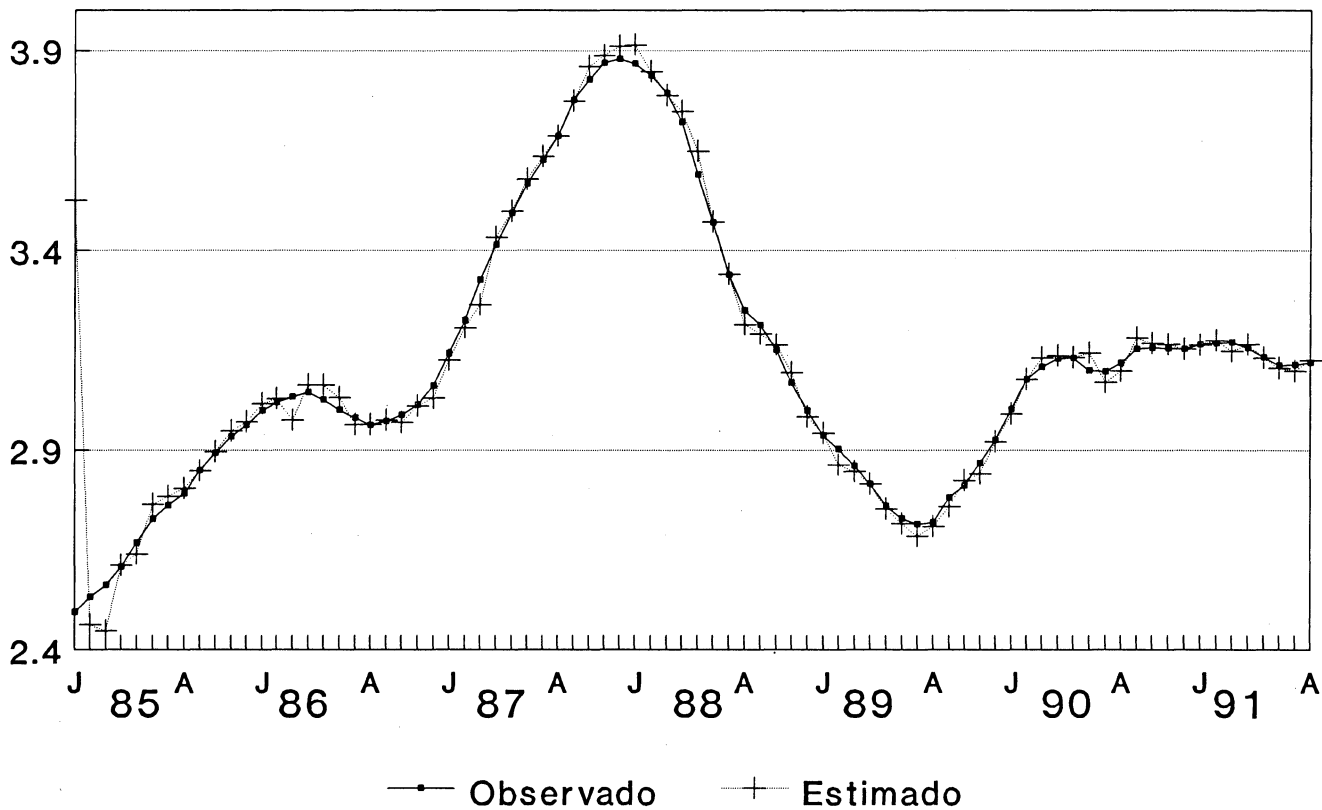


FIG. 1. Produção mensal de ovos, Brasil, 1985 a 1991.




FIG. 2. Produção mensal de carne de frangos, Brasil, 1982-91.

Avaliação das Previsões dos Modelos Estruturais

Para avaliar a capacidade de previsão dos modelos, como descrito anteriormente, alguns indicadores foram construídos tanto para as previsões provenientes dos BSM, como para as obtidas com a metodologia de Box & Jenkins (modelos sazonais multiplicativos gerais – SARIMA). Para a série de produção de ovos¹², o SARIMA utilizado foi um $(1,1,0) \times (2,0,1)_{12}$, e para a produção de carne de frangos, um SARIMA $(0,1,0) \times (0,1,1)_{12}$.

Os dois tipos de modelo fornecem, para a série de produção de carne de frangos, previsões que podem ser consideradas boas. Para a série de produção de ovos, enquanto as previsões do BSM também são boas, as do SARIMA são piores do que previsões ingênuas, iguais ao último valor observado (Figuras 3 e 4).

Os valores gerados a partir das previsões para a série de ovos indicam uma clara superioridade do BSM em relação ao SARIMA, segundo os três indicadores (Tabela 3); por exemplo, com desvio absoluto médio da ordem de 1,15% doze meses após o período de ajuste, tendo atingido um máximo de -2,18% no oitavo mês, enquanto o modelo SARIMA tem desvio absoluto médio de 7,2% e máximo de -9,58% no sétimo mês.

Para a série de produção de carne de frangos, o comportamento dos modelos foi mais equilibrado, apesar de ainda haver certa vantagem, segundo todos os indicadores, para o BSM (Tabela 3). O desvio absoluto médio desse exemplo atinge, 2,52%, considerando-se as doze previsões mensais, e um máximo de -6,21% no décimo-segundo mês. O modelo SARIMA, por sua vez, tem desvio absoluto médio de 3,62% para as previsões e um erro máximo de -8% no primeiro mês.

¹² Para a produção de ovos também foi testado o seguinte modelo de função de transferência (Vandaele, 1983):

onde,

le Y_t é a produção de ovos,

com X_t sendo o relativo de preços ovos-ração para poedeiras, e

Apesar de a defasagem inicial da relação de preços ser consistente com o tempo necessário para as poedeiras começarem a produzir (aproximadamente 120 dias, FIDERJ, 1978) e os parâmetros serem todos significativos, este modelo foi abandonado porque as previsões dele obtidas foram sensivelmente piores do que as do modelo univariado.

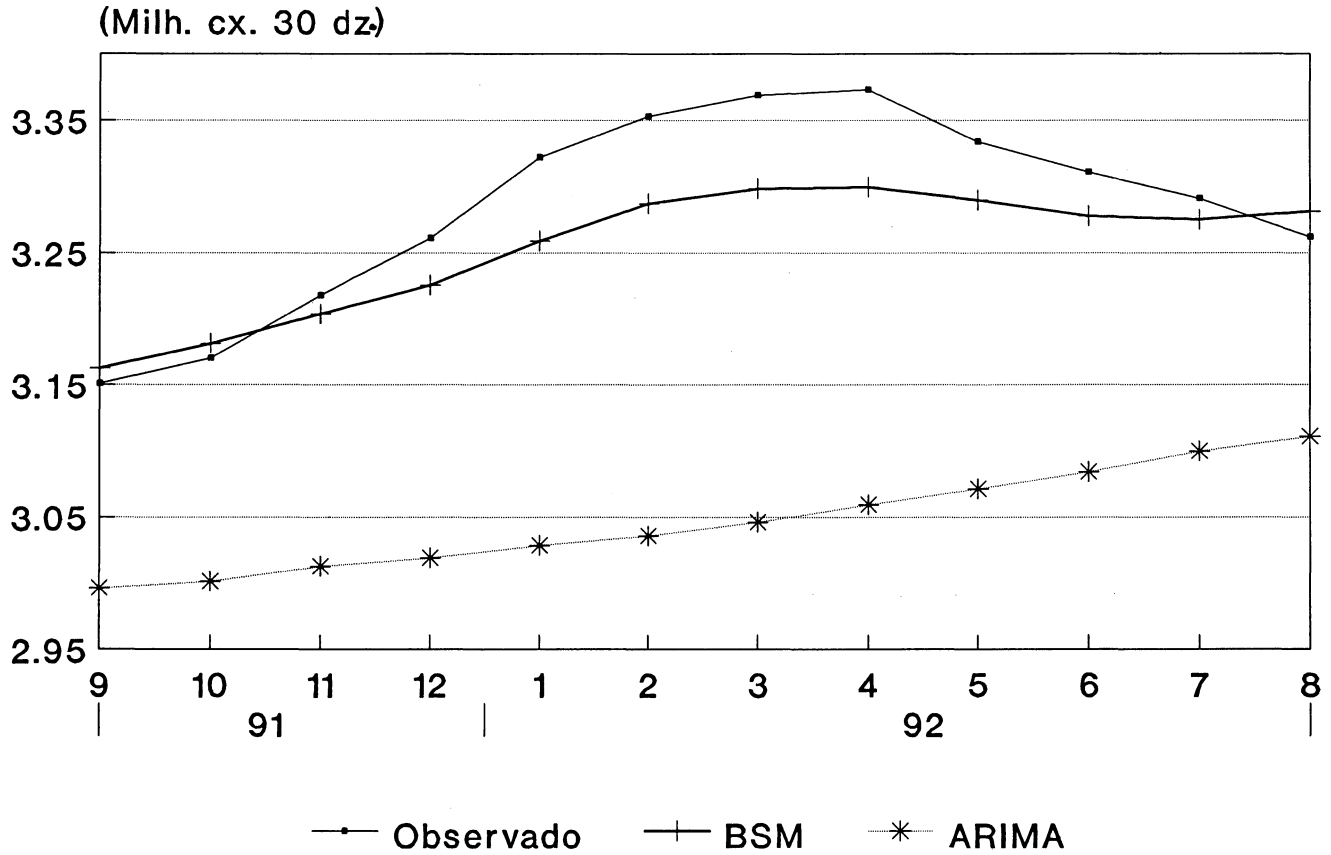


FIG. 3. Produção mensal prevista e observada de ovos, Brasil, setembro de 1991 a agosto de 1992.




FIG. 4. Produção mensal prevista e observada, carne de frangos, Brasil, setembro de 1991 a agosto de 1992.

TABELA 3. Indicadores da qualidade das previsões obtidas.

Indicador	Passos à frente	Ovos		Frangos	
		BSM ¹	ARIMA ²	BSM ¹	ARIMA ²
Raiz quadrada do erro quadrático médio	3	12,21	177,70	948	14,88
	6	40,94	238,09	7,41	12,09
	9	50,00	260,75	7,48	10,83
	12	44,94	245,45	7,89	10,75
Desvio absoluto mé- dio (%)	3	0,38	5,54	3,26	5,61
	6	1,02	7,06	2,33	4,04
	9	1,30	7,68	2,56	3,74
	12	1,15	7,20	2,52	3,62
Coeficiente de desi- gualdade de Theil (U ₂)	3	0,35	5,07	0,66	1,04
	6	0,99	5,77	0,53	0,86
	9	1,37	7,14	0,51	0,74
	12	1,33	7,24	0,58	0,78

¹ Modelo Estrutural Básico,

² Modelo Sazonal Univariado.

Fonte: Dados da pesquisa.

CONCLUSÕES

Os modelos estruturais básicos (BSM) ajustados às séries de produção de ovos e carne de frangos permitiram obter previsões da produção doze meses à frente, com níveis de erro muito pequenos (respectivamente, de cerca de 1% e 2,5% em média). Segundo os indicadores utilizados, essas previsões são melhores do que as fornecidas por modelos ARIMA.

Pela relativa facilidade de estimação, possível de ser efetuada em micro-computadores com o software adequado, é provável que a utilização desse tipo de modelo torne-se cada vez mais freqüente na análise e previsão de séries temporais.

AGRADECIMENTOS

O autor agradece a colaboração de Vera Lúcia Fava, da Faculdade de Economia, Administração e Contabilidade (FEA/USP), de Julie Witcover e

Stephen A. Vosti, do International Food Policy Research Institute (IFPRI), e de um relator anônimo da Revista de Economia e Sociologia Rural.

REFERÊNCIAS

- FIDERJ. **Avicultura**. Rio de Janeiro: Fundação Instituto de Desenvolvimento Econômico e Social, 1978. 280p.
- GIULIETTI, N. et al. Avicultura no Brasil, 1970-78: contribuição para um programa de desenvolvimento. **Agricultura em São Paulo**, v.28, n.1 e 2, p.107-291, 1981.
- HARVEY, A.C. **Forecasting, structural time series models and the Kalman filter**. Cambridge: Cambridge University Press, 1989. 554p.
- HARVEY, A.C. & PETERS, S. Estimation procedures for structural time series models. **Journal of Forecasting**, v.9, n.2, p.89-108, Mar./Apr. 1990.
- SOUZA, R.C. **Modelos estruturais para previsão de séries temporais: abordagens clássica e bayesiana**. Rio de Janeiro: CNPq/IMPA, 1989. 171p.
- THEIL, H. **Applied economic forecasting**. Amsterdam: North-Holland, 1966. 474p.
- VANDAELE, W. **Applied time series and Box-Jenkins models**. Orlando: Academic Press, 1983. 417p.