

**ANÁLISE DE MODELOS DE SÉRIES TEMPORAIS PARA
A PREVISÃO MENSAL DO IMPOSTO DE RENDA**

Alan Vasconcelos Santos

FORTALEZA – CEARÁ

2003

UNIVERSIDADE FEDERAL DO CEARÁ
CURSO DE PÓS-GRADUAÇÃO EM ECONOMIA - CAEN

**ANÁLISE DE MODELOS DE SÉRIES TEMPORAIS PARA
A PREVISÃO MENSAL DO IMPOSTO DE RENDA**

ALAN VASCONCELOS SANTOS

Dissertação submetida à coordenação do
Curso de Pós-Graduação em Economia –
CAEN, como requisito parcial para a
obtenção do grau de Mestre.

Orientador: Luiz Ivan de Melo Castelar

FORTALEZA – CEARÁ

2003

**ANÁLISE DE MODELOS DE SÉRIES TEMPORAIS PARA A PREVISÃO
MENSAL DO IMPOSTO DE RENDA**

ALAN VASCONCELOS SANTOS

Esta dissertação foi submetida como parte dos requisitos necessários à obtenção do grau de Mestre em Teoria Econômica, outorgado pela Universidade Federal do Ceará, e encontra-se à disposição dos interessados na Biblioteca do Curso de Mestrado em Economia da referida Universidade.

Dissertação aprovada em 03/07/2003.

BANCA EXAMINADORA

Prof. PhD. Luiz Ivan de Melo Castelar (Orientador)
Universidade Federal do Ceará

Prof. Dr. Emerson Luís Lemos Marinho
Universidade Federal do Ceará

Prof. Dr. Lauro Gomes de Oliveira
Universidade Federal do Maranhão

AGRADECIMENTOS

A toda minha família que sempre esteve presente nos momentos mais difíceis. Em particular, à minha esposa e ao meu filho, pois foram as pessoas que mais acreditaram e as que mais se sentem orgulhosas pela conclusão deste trabalho. A eles, à minha família, eu dedico esta dissertação.

À tia Marister, ao tio José Dário e aos primos Benedito, Kilderye e Darlano pelo conforto, material e espiritual, que recebi durante todo o período em que com eles residi.

Ao CNPq por me ter acolhido como bolsista e à Procuradoria Geral de Justiça do Estado do Maranhão por ter me concedido licença para dedicação integral ao curso.

Aos professores, tanto da graduação como da pós-graduação, que acompanharam e que viveram de perto cada etapa desta jornada. Ao professor Ivan Castelar que, além de ter sido meu orientador, contribuiu consideravelmente para a realização deste trabalho. Aos professores Emerson Marinho e Lauro Oliveira pelas pertinentes sugestões. Agradeço ainda a todos os professores e funcionários do CAEN que sempre estiveram à disposição para ajudar no que fosse necessário.

Finalmente, deixo como último agradecimento aos amigos. Aos fiéis amigos que ficaram em São Luís e aos amigos que compuseram a melhor turma de pós-graduação em economia do CAEN dos últimos tempos: Alexandre, Andrei, Campos, Carlos Eduardo, Danilo, Francis, Mariana, Paulo, Régis, Roberto e Soares. Sem eles, no mínimo, a vida aqui seria muito mais difícil.

SUMÁRIO

<u>1</u>	<u>INTRODUÇÃO</u>	11
<u>2</u>	<u>ASPECTOS DE TRIBUTAÇÃO</u>	13
2.1	<u>Conceitos de Tributação</u>	13
2.2	<u>Princípios de Tributação</u>	15
2.2.1	<u>Princípio do Benefício</u>	16
2.2.2	<u>Princípio da Habilidade de Pagamento</u>	17
2.3	<u>Categorias de Tributação</u>	18
2.4	<u>Sistemas de Tributação</u>	18
2.5	<u>Imposto de Renda e Proventos de Qualquer Natureza (IR)</u>	19
2.5.1	<u>Competência</u>	20
2.5.2	<u>Função</u>	20
2.5.3	<u>Fato Gerador</u>	21
2.5.4	<u>Contribuinte</u>	21
2.5.5	<u>Base de Cálculo</u>	21
<u>3</u>	<u>CONCEITOS BÁSICOS DE SÉRIES TEMPORAIS</u>	24
3.1	<u>Modelos Determinísticos de Séries Temporais</u>	27
3.1.1	<u>Modelo de Alisamento Exponencial Simples (AES)</u>	27
3.1.2	<u>Modelo de Alisamento Exponencial Duplo (AED)</u>	30
3.1.3	<u>Modelo de Alisamento Exponencial Biparamétrico de Holt (AEH)</u>	31
3.1.4	<u>Modelo de Alisamento Exponencial Sazonal de Holt-Winters (HW)</u>	32
3.2	<u>Modelos Estocásticos de Séries Temporais</u>	33
3.2.1	<u>Modelos ARIMA de Box-Jenkins</u>	34
3.2.2	<u>Modelos de Correção de Erro</u>	45
3.3	<u>Combinação de Previsões</u>	49
<u>4</u>	<u>RESULTADOS EMPÍRICOS</u>	53
<u>5</u>	<u>CONCLUSÕES</u>	75
	<u>REFERÊNCIA BIBLIOGRÁFICA</u>	78
	<u>ANEXO 1</u>	80
	<u>ANEXO 2</u>	87
	<u>ANEXO 3</u>	89
	<u>ANEXO 4</u>	91

LISTA DE GRÁFICOS

Gráfico 01: Séries IR e IRHWAD (período: 2000:12 a 2001:12).....	55
Gráfico 02: Séries IR, IRHWAD e IRHWMU (período: 2000:12 a 2001:12).....	56
Gráfico 03: Séries IR e IRHWAD2 (período:1990:01 a 2002:12).....	59
Gráfico 04: Série IR (período: 1990:01 a 2001:12).....	60
Gráfico 05: Primeira diferença da série IR (período: 1990:01 a 2001:12).....	60
Gráfico 06: Diferença sazonal da série IR (período: 1990:01 a 2001:12).....	61
Gráfico 07: Primeira diferença da série IR desazonalizada (período: 1990:01 a 2001:12).....	61
Gráfico 08: Séries IR, IR01 e IR02 (período: 2000:12 a 2001:12).....	63
Gráfico 09: Séries IRSA e PIBSA (período: 1994:08 a 2001:12).....	67
Gráfico 10: Resíduos do Modelo IR01 (SARIMA(0,1,1)(0,1,2) ₁₂).....	88

LISTA DE TABELAS

Tabela 01: Resultado de estimação da série IR pelo método do alisamento exponencial Holt-Winters aditivo (período: 1990:01 a 2000:12).....	54
Tabela 02: Resultado de estimação da série IR pelo método do alisamento exponencial Holt-Winters multiplicativo (período: 1990:01 a 2000:12).....	55
Tabela 03: Comparação para a escolha do modelo de alisamento exponencial.....	57
Tabela 04: Resultado de estimação da série IR pelo método do alisamento exponencial Holt-Winters aditivo (período: 1990:01 a 2001:12).....	58

Tabela 05: Resultados de previsão para o ano de 2002 (Método: Alisamento Exponencial – Holt-Winters Aditivo).....	58
Tabela 06: Modelos SARIMA selecionados.....	62
Tabela 07: Comparação para a escolha do modelo SARIMA.....	62
Tabela 08: Resultados de previsão para o ano de 2002 (Método: Box-Jenkins).....	64
Tabela 09: Resultado do teste DF para a série IRSA.....	65
Tabela 10: Resultado do teste DF para a série PIBSA.....	65
Tabela 11: Resultado do teste DF para a primeira diferença da série IRSA.....	66
Tabela 12: Resultado do teste DF para a primeira diferença da série PIBSA.....	66
Tabela 13: Resultado do teste de Johansen para as séries IRSA e PIBSA.....	67
Tabela 14: Comparação para a escolha do modelo de correção de erro.....	68
Tabela 15: Resultados de previsão para o ano de 2002 (Método: Modelo de correção de erro).....	69
Tabela 16: Resultado do cálculo dos pesos do modelo de combinação de previsões.....	70
Tabela 17: Resultados de previsão para o ano de 2001 com respectivo cálculo do EPAM.....	70
Tabela 18: Resultados de previsão para o ano de 2002 (Método: modelo de combinação de previsões).....	71
Tabela 19: Resultados de previsão do modelo de combinação para o ano de 2001.....	72
Tabela 20: Comparação dos valores observados e previstos para o ano de 2002.....	73
Tabela 21: Correlograma de IR.....	81

Tabela 22: Correlograma de D(IR).....	82
Tabela 23: Correlograma de IR(-12).....	83
Tabela 24: Correlograma de D(IR(-12)).....	84
Tabela 25: Correlograma dos resíduos do modelo IR01.....	85
Tabela 26: Correlograma dos resíduos do modelo IR02.....	86
Tabela 27: Estimação do modelo IR01 (SARIMA(0,1,1)(0,1,2) ₁₂).....	88
Tabela 28: Estimação do modelo de correção de erro.....	90
Tabela 29: Série Imposto de Renda.....	92
Tabela 30: Série PIB.....	96

RESUMO

O presente trabalho objetiva realizar previsões mensais da série do imposto de renda para o período de 2002. A metodologia empregada para alcançar essa finalidade consiste na utilização da técnica de combinação de previsões. Especificamente, combinam-se os resultados de previsão advindos de três métodos diferentes: técnica do alisamento exponencial, metodologia de Box-Jenkins (modelos ARIMA) e modelos vetoriais de correção de erro. Obtida a previsão final, compara-se este resultado com os valores reais observados da série do imposto de renda para o ano de 2002 a fim de verificar o desempenho e a acurácia do modelo.

Palavras-chaves: Alisamento exponencial, combinação de previsão, imposto de renda, modelos ARIMA, modelo de correção de erro, previsão.

ABSTRACT

The main objective of this work was to generate predictions, at a monthly frequency, from 1990 to 2001, of income tax revenue. The methodology used was the one of forecast combining. Specifically, exponential smoothing, an ARIMA and VAR with error correction models were pooled to obtain final prediction. Ex-post forecast errors were used to test the performance of the model. Results indicated that combining performs better than individual models, and errors are in an acceptable interval for this type of prediction.

Key words: Exponential smoothing, forecast combining, income tax revenue, ARIMA models, VAR with error correction model, forecast.

1 INTRODUÇÃO

Um dos aspectos primordiais dos métodos e técnicas econométricas está em seu poder de criar modelos de previsão confiáveis, principalmente os de curto prazo. Uma previsão nada mais é que uma estimativa quantitativa sobre eventos futuros baseados em informações de períodos passados e recentes. Assim o planejamento, o controle e a elaboração de políticas econômicas são bastante facilitados se podem contar com ferramentas que possibilitem antecipar valores de certas variáveis econômicas.

O presente trabalho tem por finalidade principal desenvolver um modelo de previsão mensal da série temporal imposto de renda (IR) para o ano de 2002. Para atingir este objetivo utiliza-se a técnica de combinação de previsões. Isto é, combinam-se os resultados de previsão advindos de três métodos diferentes: i) da técnica do alisamento exponencial (Método Sazonal de Holt-Winters); ii) dos modelos ARIMA de séries temporais (Metodologia de Box-Jenkins); iii) e do modelo de correção de erro. Dessa forma, para se obter o resultado final de previsão, combinam-se as previsões geradas por três metodologias.

A escolha de se fazer previsões da variável imposto de renda decorre do fato de, além da mesma ser responsável por uma das maiores fontes de receita tributária do Governo Federal (função fiscal), este imposto se constitui em um importante instrumento de intervenção do Poder Público no campo econômico (função extrafiscal) principalmente no tocante à distribuição de renda. Desta forma, dado que a previsão constitui-se em um meio de fornecer informações para uma conseqüente tomada de decisões, a previsão desse tributo pode auxiliar o governo em suas decisões que visem o aumento do bem-estar econômico.

A estrutura deste trabalho está dividida em três etapas principais além desta primeira introdutória. A segunda etapa, que compreende os capítulos dois e três, inicia com uma abordagem teórica acerca do assunto proposto. Especificamente, o capítulo dois trata de questões relacionadas aos aspectos de tributação onde alguns conceitos, princípios, categorias e sistemas de tributação são brevemente comentados. Neste capítulo ainda se faz considerações sobre o imposto de renda onde se destaca sua

competência, funções, fato gerador, contribuinte e base de cálculo. A idéia central é atentar para a importância que o imposto de renda possui dentro do sistema econômico particularmente como mecanismo de redistribuição de renda.

O terceiro capítulo, que compõe ainda a segunda etapa da dissertação, aborda questões teóricas sobre modelos econométricos utilizados pela Ciência Econômica para efetuar previsões. Neste capítulo as quatro metodologias empregadas no trabalho para a obtenção dos valores futuros da série do imposto de renda são discutidas verificando-se as vantagens e as desvantagens de cada método. De uma forma geral, tal capítulo expõe, com base na bibliografia consultada, os principais aspectos teóricos dos modelos empregados na previsão do imposto de renda. Assim, discute-se os métodos de alisamento exponencial, da metodologia de Box-Jenkins, dos modelos de correção de erro e a análise da combinação de previsões.

A terceira parte do trabalho, composta pelo quarto capítulo, aborda os resultados empíricos de previsão obtidos. Para cada técnica individual mostram-se os critérios utilizados para a seleção dos modelos capazes de gerar previsões do imposto de renda e os seus principais resultados. Destacam-se neste capítulo os resultados de previsão oriundos do método de combinação de previsões, já que comparado com as demais técnicas o mesmo apresenta melhor performance (menores erros de previsão). Ainda nesta etapa, como forma de analisar o desempenho do modelo de combinação proposto, faz-se dois tipos de comparações. Primeiramente, elabora-se a comparação dos resultados de previsão para o ano de 2001 da técnica de combinação de previsão com os resultados obtidos pelo modelo dinâmico de Siqueira (2002) na tentativa de averiguar qual modelo gera melhores previsões. A segunda comparação é feita, para o ano de 2002, dos valores reais observados para o imposto de renda com os valores previstos apresentados pelo modelo de combinação. Neste caso, busca-se mensurar a acurácia e o desempenho do modelo de combinação objetivando verificar se o mesmo apresenta resultados satisfatórios para realizar previsões do imposto de renda para o ano de 2002. Finalmente, a quarta etapa refere-se às conclusões do trabalho.

2 ASPECTOS DE TRIBUTAÇÃO

2.1 Conceitos de Tributação

Qualquer governo deve ter à disposição mecanismos que gerem recursos necessários para desenvolver suas funções.¹ Dentre as principais alternativas para o financiamento de recursos do governo, para a execução de suas tarefas, destacam-se: i) emissão de moeda; ii) lançamento de títulos públicos; iii) empréstimos bancários (interno e externo); iv) e tributação. Deve-se observar que a adoção de cada uma destas formas de financiamento implica em diferentes efeitos sobre a atividade econômica. O mecanismo de tributação, por exemplo, intervém diretamente na alocação de recursos, na distribuição de recursos na sociedade e pode, também, reduzir as desigualdades na riqueza, na renda e no consumo (Riani, 2002).

A arrecadação tributária representa, dentre os mecanismos de financiamento, a principal fonte de obtenção de receitas. Daí ser o foco mais relevante deste estudo na tributação, especificamente, na previsão da arrecadação do imposto de renda e proventos de qualquer natureza (IR).

Conforme o Código Tributário Nacional (CTN), tributo é toda prestação pecuniária compulsória, em moeda ou cujo valor nela se possa exprimir, que não constitua sanção de ato ilícito, constituída em lei e cobrada mediante atividade administrativa plenamente vinculada (CTN, art. 3º).

A fim de se ter uma melhor compreensão deste conceito, pode-se examinar separadamente os seus diversos elementos.² Inicialmente, o tributo é de natureza pecuniária porque assegura ao Estado os meios financeiros, expressos em moeda, de que necessita para a consecução de seus objetivos. É compulsória, pois o dever de pagar o tributo nasce independentemente da vontade, não se podendo afirmar que a prestação tributária é compulsória porque o pagamento do tributo é obrigatório (tome o exemplo de prestações contratuais, que são obrigatórias, mas que, entretanto, nascem da vontade

¹ Tais funções consistem basicamente em função alocativa, função distributiva e função estabilizadora. Para maiores detalhes ver Musgrave & Musgrave (1980), Giambiagi & Além (1999) e Riani (2002).

² Ver Machado (2002).

das partes constituintes do contrato). O tributo, ainda, não constitui sanção de ato ilícito, significando que a sua hipótese de incidência é sempre algo lícito, o que o distingue de penalidade, esta tendo como hipótese de incidência um ato ilícito. Assim, a lei não pode incluir na hipótese de incidência tributária o elemento ilicitude, ou seja, não pode estabelecer como necessária e suficiente à ocorrência da obrigação de pagar em tributo uma situação que não seja lícita (Machado, 2002). Por fim, atividade administrativa plenamente vinculada estabelece que a autoridade administrativa não goze de liberdade para apreciar a conveniência nem a oportunidade de agir.

Pode-se classificar os tributos, de acordo com o sistema tributário brasileiro, de quatro formas distintas: i) quanto à espécie; ii) quanto à competência impositiva; iii) quanto à vinculação com a atividade estatal; iv) quanto à função.

Quanto à espécie, os tributos podem ser: i) impostos; ii) taxas; iii) contribuições de melhoria; iv) contribuições sociais; v) empréstimos compulsórios.³

No que se refere particularmente aos impostos, segundo art. 16 do CTN, imposto é o tributo cuja obrigação tem por fato gerador uma situação independente de qualquer atividade estatal específica, relativa ao contribuinte. Diz-se, portanto, que o imposto é uma exação (exigência) não vinculada, isto é, independente de atividade estatal específica (Machado, 2002). Assim, a obrigação de pagar imposto não se origina de nenhuma atividade específica do Estado relativa ao contribuinte.

O CTN classifica os impostos levando em consideração a natureza do fato sobre o qual incidem, que são: i) impostos sobre o comércio exterior; ii) impostos sobre o patrimônio e a renda; iii) impostos sobre a produção e a circulação; iv) impostos especiais. A Constituição Federal, em contrapartida, elaborou uma classificação dos impostos a partir da competência tributária das diversas entidades integrantes da Federação. Deste modo, os impostos podem ser: i) federais; ii) estaduais; iii) municipais.

³ A caracterização aprofundada de cada espécie de tributo encontra-se em Machado (2002) e em Chimento (2001).

Quanto à competência impositiva, os tributos são: i) federais; ii) estaduais; iii) municipais. Competência tributária é o poder que a Constituição Federal atribui a determinado ente político para que este institua um tributo, descrevendo, legislativamente, sua hipótese de incidência, seu sujeito ativo, seu sujeito passivo, sua base de cálculo e sua alíquota (Chimento, 2001).

Quanto à vinculação com a atividade estatal, os tributos são: i) vinculados (as taxas, as contribuições de melhoria e as contribuições sociais); ii) não-vinculados (os impostos).

Por fim, quanto à função, os tributos são: i) fiscais; ii) extrafiscais; iii) parafiscais. Esta classificação decorre do fato de, no estágio atual das Finanças Públicas, o tributo não ser utilizado apenas como instrumento de arrecadação, pois o mesmo interfere de forma diversa na economia, estimulando atividades, setores econômicos ou regiões, desestimulando o consumo de certos bens. Tendo isto em vista, imposto fiscal é aquele em que o objetivo principal é a arrecadação de recursos financeiros para o Estado. O imposto extrafiscal é aquele em que seu objetivo principal é a interferência no domínio econômico, e não a simples arrecadação de recursos. Por fim, o imposto parafiscal é aquele em que seu objetivo é arrecadar recursos para o custeio de atividades que, em princípio, não integram funções próprias do Estado, mas que este as desenvolvem através de entidades específicas (Machado, 2002).

2.2 Princípios de Tributação

Dada a conceituação e classificação dos tributos, deve-se evidenciar como deveria funcionar o sistema tributário e quais objetivos o mesmo deveria tentar alcançar. De uma forma ampla, o sistema de tributação deveria seguir quatro pontos básicos⁴: i) obtenção de receitas para financiar os gastos do setor público; ii) cada indivíduo deve ser taxado conforme sua habilidade de pagamento (conceito da progressividade); iii) os tributos devem ser universais, no sentido de não haver distinção a indivíduos em situações similares (conceito da equidade); iv) os tributos devem ser escolhidos de

⁴ Esta abordagem inicial dos princípios de tributação encontra-se em Riani (2002).

forma a minimizar sua interferência no sistema econômico, não o tornando ineficiente (conceito da neutralidade).

Assim, para que o sistema de tributação seja o mais justo possível, aproximando-se do ideal, a análise da aplicação da tributação deve se basear no princípio dos benefícios e no princípio da habilidade de pagamento.⁵

2.2.1 Princípio do Benefício

O princípio do benefício estabelece que cada indivíduo deve contribuir com uma quantia proporcional aos benefícios gerados pelo consumo do bem público (Giambiagi & Além, 1999). Quanto maior o benefício, maior a contribuição do indivíduo, e vice-versa. Dessa forma, tal princípio associa a contribuição do indivíduo conforme os benefícios recebidos pelos bens e serviços oferecidos pelo governo.

Entretanto, este método de cálculo não é de fácil implementação, já que os benefícios decorrentes do consumo não são conhecidos pelo governo e, então, precisam ser revelados. Assim, não existe garantia, caso os indivíduos fossem obrigados a revelar seus benefícios (preferências), de que tais benefícios seriam verdadeiros. Em resumo, este princípio demonstra duas dificuldades intransponíveis que são: i) a existência dos “agentes caronas” ou *free riders*, o que mostra a ineficiência do princípio em evitar que alguns indivíduos não paguem pelo bem público; ii) e a dificuldade de se medir o benefício de cada indivíduo.

Deve-se destacar ainda, que alguns indivíduos estariam excluídos de consumir os bens oferecidos pelo governo por não possuírem renda suficiente se o princípio do benefício fosse aplicado. Neste sentido, uma das funções básicas do governo, a distributiva, não estaria sendo desempenhada satisfatoriamente.

Portanto, o mecanismo de tributação baseado apenas no princípio do benefício se mostra ineficiente, tanto sob a ótica econômica, quanto sob a ótica social. A solução

⁵ Juridicamente, os princípios da tributação são: i) legalidade; ii) anterioridade; iii) igualdade; iv) competência; v) capacidade contributiva; vi) vedação do confisco; vii) liberdade de tráfego.

seria a formulação de uma regra geral de tributação tal que torne a estrutura de tributação mais justa e menos ineficiente. Em outras palavras, busca-se um outro princípio para determinar, juntamente com o princípio dos benefícios, quanto cada indivíduo deve pagar de imposto. Este princípio é denominado princípio da capacidade ou habilidade de pagamento.

2.2.2 Princípio da Habilidade de Pagamento

O princípio da habilidade de pagamento estabelece que o indivíduo deve contribuir de acordo com sua capacidade de pagamento, medida, preferencialmente, pelo nível de renda. Sendo mais específico, este princípio determina que todo indivíduo deve contribuir no custo total da oferta de bens públicos em linha com sua habilidade de pagamento, isto é, indivíduos com habilidades iguais devem contribuir no mesmo montante, enquanto indivíduos com habilidades diferentes devem ter um pagamento diferenciado (Riani, 2002). Dessa forma, para que o sacrifício de pagamento entre os indivíduos seja igualado, deve existir a equidade horizontal (indivíduos com iguais capacidades de pagamento devem pagar o mesmo montante de tributo) e a equidade vertical (as contribuições dos indivíduos devem se diferenciar conforme suas diversas capacidades de pagamentos).

Esse princípio tem duas vantagens sobre o anterior: primeiro, permite que determinada pauta de serviços públicos seja oferecida à sociedade sem que haja exclusão ou discriminação, entre os indivíduos, quanto a seu uso e benefícios; segundo, ele se torna um princípio mais justo à medida que o sacrifício individual é feito na mesma proporção e de acordo com a habilidade de pagamento de cada um (Riani, 2002).

Em suma, a busca de um sistema de tributação ideal implica em tomar como base os princípios do benefício e da habilidade de pagamento.⁶ Então, a sociedade tem à sua disposição um instrumento de financiamento dos gastos públicos em que o governo obtém as condições necessárias para desempenhar suas funções que, em última análise, aumentará o bem-estar social.

⁶ Leva-se em consideração também os princípios jurídicos da tributação citados anteriormente.

2.3 Categorias de Tributação

De grande importância é a classificação dos tributos em diretos e indiretos. Os tributos diretos incidem sobre os rendimentos dos indivíduos e, assim, estão associados à capacidade de pagamento de cada contribuinte. Por outro lado, os tributos indiretos incidem sobre atividades ou objetos (consumo, vendas ou posse de propriedade), independentemente da capacidade de pagamento do indivíduo.

A importância de se definir estas categorias deve-se ao fato de que o peso de cada um, dentro da estrutura tributária, indica como os indivíduos são afetados pela incidência dos tributos. Especificamente, verifica-se que, quando é maior a participação relativa dos impostos indiretos, a carga tributária recai indiscriminadamente sobre todos, tendo em vista que o imposto indireto possui uma base de incidência principalmente sobre o consumo de bens e serviços. No caso contrário, em que a participação do imposto direto é maior, a implicação seria que o sistema de tributação estaria sendo utilizado com base na capacidade de pagamento, indicando que a maior parte das receitas seria originada das camadas mais ricas da população.⁷ De certa forma, o peso de cada um desses impostos afeta diretamente a eficácia do sistema de tributação como um instrumento de correção das desigualdades na distribuição da renda.

2.4 Sistemas de Tributação

O sistema tributário pode ser: i) proporcional; ii) progressivo; iii) ou regressivo. Eles se diferenciam entre si conforme o tratamento tributário dado às diversas camadas de renda da sociedade.

O sistema proporcional é o sistema em que a alíquota do tributo, para os diferentes níveis de renda, é a mesma. Neste sistema não há qualquer impacto sobre a redistribuição da renda na sociedade, tendo em vista que o perfil da renda da sociedade, após a aplicação do imposto, não altera a participação relativa da renda entre as camadas sociais.

⁷ No primeiro caso, são as camadas mais pobres que contribuem com a maior parte do bolo tributário.

O sistema progressivo, por outro lado, caracteriza-se pela imposição de maiores percentuais de impostos para as classes de renda mais alta, isto é, o percentual do imposto a ser pago aumenta com o aumento do nível de renda. No que tange ao seu poder de redistribuição de renda, tal sistema a torna menos desigual, pois após a aplicação do imposto, o percentual da renda disponível, para as camadas que detêm níveis de renda elevados, é menor. A magnitude dessa redistribuição da renda dependerá da diferenciação das alíquotas para as diversas classes de renda.

Por fim, o sistema regressivo possui características opostas ao do sistema progressivo, ou seja, dentro do sistema regressivo ocorre uma tributação mais forte nas camadas que possuem menores rendimentos. Assim, quanto menor o nível de renda, maior é o percentual do imposto pago. Não é difícil concluir que neste sistema tem-se uma maior concentração de renda, prejudicando, dessa forma, a distribuição de renda em favor dos mais pobres.

2.5 Imposto de Renda e Proventos de Qualquer Natureza (IR)

Esta etapa do trabalho trata do imposto de renda. Mais precisamente, se verificará sua competência tributária, função, fato gerador, base de cálculo, dentre outras especificidades que caracterizam tal imposto. A razão principal de estudar o imposto de renda é que o mesmo se configura como uma das maiores fontes de arrecadação de recursos tributários para o governo federal. Ressalte-se, ainda, que um percentual do IR destina-se ao Fundo de Participação dos Estados (FPE), ao Fundo de Participação dos Municípios (FPM) e ao Fundo de Manutenção e Desenvolvimento do Ensino Fundamental e de Valorização do Magistério (FUNDEF). Assim, algumas transferências governamentais estão fortemente atreladas ao montante arrecadado do imposto de renda. Considerando-se o fato de que muitos municípios das Regiões Norte e Nordeste têm no FPM sua maior fonte de arrecadação de receitas, percebe-se a grande importância deste imposto (e a sua conseqüente previsão), já que o imposto de renda possui uma função bastante relevante na distribuição da riqueza.

2.5.1 Competência

O imposto sobre renda e proventos de qualquer natureza pertence à competência da União Federal (CF, art. 153, inc. III, e CTN, art. 43).

É Conveniente, antes de expor as justificativas para que este imposto seja de competência da União, esclarecer dois conceitos intimamente relacionados: i) competência tributária; ii) competência financeira. O que a CF estabelece é a competência tributária que se refere à definição de qual nível de governo será responsável pela arrecadação e administração legal de determinado tipo de tributo. Tal arrecadação e administração são definidas ou atribuídas de acordo com a característica do tributo, em que se levam em consideração a maior eficiência e controle da arrecadação. Por outro lado, a competência financeira se refere à apropriação da arrecadação entre os níveis de governo, de modo que um tributo arrecadado em certo nível de governo deverá ser distribuído entre as outras esferas de governo. A idéia deste conceito é de evitar a concentração de recursos em um nível específico de governo.

Dessa forma, o imposto de renda pertence ao domínio da União, no que se refere à competência tributária, porque somente assim ele pode ser utilizado como um instrumento de distribuição de renda, buscando manter em equilíbrio o desenvolvimento econômico das diversas regiões (Machado, 2002). Constitui-se como uma outra razão, o fato de se evitar dupla ou múltipla tributação que certamente ocorreria se o imposto de renda fosse de competência dos Estados e Municípios.

2.5.2 Função

A função do imposto de renda é nitidamente fiscal, haja vista que representa uma das principais fontes de receita tributária da União Federal. Porém, como o IR constitui-se em um importante instrumento de intervenção do Poder Público no campo econômico, é inegável sua função extrafiscal. Portanto, pode-se afirmar que o imposto de renda tenha função predominantemente fiscal tendo, também, função extrafiscal bastante significativa.

2.5.3 Fato Gerador

O art. 43 do Código Tributário Nacional afirma que o âmbito material de incidência do imposto de renda é a aquisição da disponibilidade econômica ou jurídica da renda (assim entendido o produto do capital, do trabalho ou da combinação de ambos); e de proventos de qualquer natureza (assim entendidos os acréscimos patrimoniais não compreendidos no conceito de renda). Em outras palavras, a disponibilidade econômica decorre do recebimento do valor que se vem a acrescentar ao patrimônio do contribuinte. Já a disponibilidade jurídica decorre do simples crédito desse valor, do qual o contribuinte passa a juridicamente dispor, embora este não lhe esteja ainda nas mãos (Machado, 2002).

Deve-se atentar ao significado de renda e proventos. Na expressão do Código, renda é sempre um produto, um resultado, quer do trabalho, quer do capital, quer da combinação destes dois fatores. Proventos constituem os demais acréscimos patrimoniais que não se enquadram no conceito de renda. Assim os dois conceitos envolvem acréscimo patrimonial. Não se deve excluir, entretanto, a tributação da renda consumida.

Portanto, o fato gerador do imposto de renda não é a renda, mas a aquisição da disponibilidade da renda, ou dos proventos de qualquer natureza.

2.5.4 Contribuinte

O contribuinte do imposto de renda pode ser pessoa física ou jurídica, isto é, pode-se dizer que o imposto de renda se classifica em imposto de renda da pessoa física (IRPF) e imposto de renda da pessoa jurídica (IRPJ), entendendo-se por pessoa física a pessoa natural, o indivíduo; e por pessoa jurídica aquela criada pelo Direito.

2.5.5 Base de Cálculo

A base de cálculo do imposto de renda é o montante real, arbitrado ou presumido da renda ou dos proventos tributáveis (art. 44 do CTN). A determinação da base de cálculo varia conforme o tipo de contribuinte.

O imposto de renda incidente sobre a pessoa física tem como base de cálculo o rendimento bruto mensal auferido pela pessoa física, podendo-se admitir algumas deduções estabelecidas em lei.⁸ O IRPF apresenta as vantagens de se basear em uma medida abrangente da capacidade de pagamento e de permitir uma adaptação às características pessoais do contribuinte. Ou seja, ele é o imposto pessoal por excelência e, sendo assim, é aquele que mais se adapta aos princípios da equidade e progressividade, à medida que permite, de fato, uma discriminação entre os contribuintes no que diz respeito à sua capacidade de pagamento (Giambiagi & Além, 1999)

Em se tratando de pessoa jurídica, a base de cálculo do imposto é o lucro, que pode ser, conforme o critério de determinação, real, arbitrado ou presumido.

O lucro real pode ser entendido como o acréscimo real do patrimônio da empresa em determinado período. O Decreto-lei nº 1.598/77 (art. 6º) define como lucro real o lucro líquido do exercício ajustadas pelas adições, exclusões ou compensações prescritas ou autorizadas pela legislação tributária. De outra forma, o lucro líquido é determinado mediante escrituração contábil de todos os fatos com implicações patrimoniais, todas as receitas e todos os custos e despesas, observando-se, em tudo isto, as regras da legislação pertinente ao imposto de renda, que é extensa e complexa (Machado, 2002). Em suma, o lucro real é calculado pela diferença entre receitas e custos da empresa, em que esta mantém um sistema contábil de acordo com as exigências da legislação.

O lucro presumido é uma forma simplificada de tributação de firmas individuais e pessoas jurídicas cuja renda bruta anual não supere os limites estabelecidos pela autoridade fiscal, em que não ocorre a obrigatoriedade das firmas em fazer a escrituração contábil de suas transações.⁹ Este método é o mais indicado às empresas impossibilitadas de viabilizar a implementação de um sistema contábil organizado exigida pela legislação tributária.

⁸ As pensões alimentícias e os encargos por dependentes são alguns exemplos de deduções permitidas.

⁹ Trata-se de uma opção do contribuinte em apresentar ou não a escrita contábil.

Por último, quando a pessoa jurídica não possuía as condições para optar pela tributação com base no lucro presumido e, ao mesmo tempo, não dispõe de escrituração contábil para demonstrar seu lucro real, a mesma será tributada com base no lucro arbitrado.¹⁰ O lucro arbitrado será uma percentagem da receita bruta (se esta for conhecida) fixada pelo Ministro da Fazenda, em que se leva em consideração a atividade econômica do contribuinte. No caso de não se conhecer a receita bruta do contribuinte, a autoridade poderá arbitrar o lucro com base no valor do ativo, do capital social, do patrimônio líquido, da folha de pagamento dos empregados, das compras, do aluguel das instalações ou do lucro líquido auferido pelo contribuinte em períodos anteriores (Machado, 2002).

¹⁰ Para maiores informações sobre todos os métodos, inclusive acerca da exposição dos casos em que o método do lucro arbitrado pode ser aplicado, ver Machado (2002) e Chimento (2001).

3 CONCEITOS BÁSICOS DE SÉRIES TEMPORAIS

De uma forma bastante simples, uma série temporal é qualquer conjunto de observações ordenadas no tempo. Em outras palavras, consiste em um conjunto de observações geradas seqüencialmente no tempo. Uma série temporal pode ser discreta ou contínua, dependendo se o conjunto de observações é discreto ou contínuo, respectivamente. É possível, todavia, obter uma série temporal discreta por meio da amostragem de uma série contínua em intervalos de tempo iguais. As séries que serão estudadas e modeladas neste trabalho são discretas tendo em vista que as observações disponíveis são dadas em tempo discreto e em intervalos equidistantes no tempo.

Para uma definição formal de série temporal necessita-se primeiramente conceituar um processo estocástico. Um processo estocástico é qualquer fenômeno estatístico que evolui no tempo de acordo com as leis probabilísticas. Pode-se entendê-lo como um modelo que descreve a estrutura probabilística de uma seqüência de observações (Box, Jenkins & Reinsel, 1994). Neste sentido, uma série temporal é considerada uma realização particular produzida pelo mecanismo probabilístico, ou seja, é pura e simplesmente uma realização de um processo estocástico.

Dessa forma, assume-se que cada valor de uma série $y = (y_1, y_2, \dots, y_T)$ é extraído aleatoriamente de uma distribuição de probabilidade. Assim, se fosse possível especificar a função de distribuição de probabilidade de uma determinada série temporal, se poderia determinar também a probabilidade de um resultado futuro da série. A completa especificação da função de distribuição de probabilidade para uma série, no entanto, é uma tarefa geralmente impossível.

A fim de determinar um modelo que descreva o comportamento aleatório da série com o propósito de realizar previsões faz-se necessário supor que o processo gerador da série seja estacionário. Esta suposição indica que o processo estocástico que gerou determinada série é considerado invariante com respeito ao tempo. Em outras palavras, o processo estocástico é baseado na suposição de que o mesmo se encontra em um particular estado de equilíbrio estatístico. Se as características do processo estocástico mudam ao longo do tempo, então o processo é dito não-estacionário. Caso

contrário, se o processo é fixado no tempo, então se tem um processo estacionário e pode-se modelá-lo via uma equação com coeficientes fixos que podem ser estimados a partir das observações passadas. Em suma, assume-se que os processos aleatórios estão em equilíbrio em torno de um nível médio constante e que a probabilidade de uma dada flutuação do nível médio é a mesma em qualquer ponto do tempo.

Dado o conceito de estacionaridade das séries temporais, pode-se classificá-las tecnicamente de duas formas: i) estacionaridade estrita ou forte; ii) e estacionaridade fraca ou de segunda ordem. Um processo estocástico é estritamente estacionário se suas propriedades não são afetadas pela mudança da origem do tempo, ou seja, se a distribuição de probabilidade conjunta com m observações $y_{t_1}, y_{t_2}, \dots, y_{t_m}$, feitas em qualquer conjunto de tempo t_1, t_2, \dots, t_m , é a mesma que a associada com m observações $y_{t_1+k}, y_{t_2+k}, \dots, y_{t_m+k}$, feitas no tempo $t_1+k, t_2+k, \dots, t_m+k$. Assim, para um processo discreto ser estritamente estacionário a distribuição conjunta de qualquer conjunto de observações não deverá ser afetada pela alteração de todos os tempos de observação para qualquer constante k . Por outro lado, a estacionaridade fraca requer menos restrições, pois somente as condições listadas a seguir devem ser satisfeitas para que um processo seja fracamente estacionário: ¹¹

- i) $E[Y_t] = \mu = \text{constante}, \forall t$;
- ii) $E(Y_t - \mu)(Y_{t-j} - \mu) = \gamma_j, \forall t, j$

Portanto, diferentemente do processo estritamente estacionário, em que toda a estrutura probabilística deverá depender da diferença do tempo, no processo fracamente estacionário necessita-se apenas que os dois primeiros momentos da função densidade de probabilidade dependam da defasagem do tempo.

No tocante à previsão de séries temporais, esta se constitui em uma das finalidades mais importantes da construção de modelos estocásticos. Dentre outros objetivos da análise de séries temporais destacam-se, além de se elaborar previsões futuras de uma série, os seguintes: i) investigar o mecanismo gerador da série temporal;

¹¹ Ver Hamilton (1994).

ii) descrever o comportamento da série (construção de gráficos, histogramas, diagramas de dispersão, verificação de existência de ciclos, tendências e sazonalidades, etc); iii) e a de procurar periodicidades relevantes nos dados (a análise espectral pode ser de grande utilidade para que este objetivo seja alcançado). Dessa forma, uma suposição importante que se faz a respeito de uma série é a estacionaridade, isto é, que ela se desenvolva no tempo aleatoriamente ao redor de uma média constante, refletindo alguma forma de equilíbrio estável. Os modelos que serão desenvolvidos a partir de agora partem do princípio de que a série, cuja previsão será efetuada, é estacionária ou pode se tornar estacionária por meio de uma transformação dos dados.¹²

Finalmente, convém distinguir os principais procedimentos disponíveis para fazer previsões de séries econômicas. De uma forma ampla, existem em Economia dois métodos bastante utilizados para esta tarefa. São eles: i) Modelos Econométricos; ii) e Modelos de Séries Temporais. Um modelo, primeiramente, consiste em uma descrição probabilística de uma série temporal, cabendo ao usuário decidir o modo como utilizá-lo, dado seus objetivos. Deve-se salientar que a previsão não se constitui um fim em si, mas apenas um meio de fornecer informações para uma conseqüente tomada de decisões, visando a determinadas finalidades (Morettin & Tolo, 1987). Retornando aos métodos utilizados em Economia, o método econométrico é fortemente baseado na teoria econômica para a construção do modelo, onde há a inclusão de várias variáveis relacionadas entre si (relação causal). Por sua vez, os métodos de análise de séries temporais consideram o padrão de movimentos passados de uma variável e utiliza essas informações para prever valores futuros dessa variável. Ou seja, na construção do modelo “os dados falam por si”, pois não se utiliza teoria econômica alguma. Pode-se, ainda, classificar os métodos de análise de séries temporais em dois subgrupos: i) determinísticos; ii) ou estocásticos.¹³ Os modelos determinísticos são aqueles que não consideram nenhuma fonte ou natureza aleatória da série. São denominados também de métodos automáticos de previsão, pois não existe um tratamento estatístico adequado, embora apresentem resultados satisfatórios em muitas aplicações. Os modelos estatísticos pressupõem que uma série tenha sido gerada por um processo estocástico,

¹² A transformação mais comum consiste em tomar diferenças sucessivas da série original. Este tipo de série não estacionária, mas que pode se tornar estacionária, é denominada série não estacionária homogênea.

¹³ Ver Ferreira (1996).

em que cada observação da variável em estudo é realizada aleatoriamente a partir de uma distribuição de probabilidade.

3.1 Modelos Determinísticos de Séries Temporais

Os modelos de séries temporais a serem enumerados a seguir são do tipo determinísticos, pois não fazem referência alguma à fonte de aleatoriedade da série. Esses modelos fornecem previsões de uma série com base em seu comportamento passado e o motivo de serem aqui explicitados decorre do fato de serem simples, de baixo custo e ainda adequados para realizar previsões.

Especificamente, serão tratados alguns modelos de alisamento exponencial. Estes modelos são na verdade métodos simples de previsões adaptativas, no sentido de que automaticamente ocorre um ajuste para a inclusão de dados mais recentes. Uma das características principais deste método de previsão é que o mesmo fornece uma previsão efetiva mesmo quando se dispõe de poucas observações. Além disso, diferentemente do que acontece com os modelos de regressão, os quais se utilizam de coeficientes fixos, as previsões obtidas através dos modelos de alisamento exponencial são baseadas nos erros de previsão passados.

A seguir breves considerações teóricas serão expostas acerca dos métodos de alisamento exponencial mais utilizados para a realização de previsões, que são: i) Alisamento Exponencial Simples (AES); ii) Alisamento Exponencial Duplo (AED); iii) Alisamento Exponencial Biparamétrico de Holt (AEH); iv) e o Alisamento Exponencial Sazonal de Holt-Winters (HW).

3.1.1 Modelo de Alisamento Exponencial Simples (AES)

A técnica do alisamento exponencial simples (AES) representa uma classe de modelos determinísticos de médias móveis tendo como principal característica a utilização de diferentes pesos para as observações na obtenção do valor alisado. Mais precisamente, diferentemente do que acontece com o modelo determinístico de média móvel, tal modelo atribui maior ponderação às observações mais recentes e menor ponderação (decrecendo exponencialmente) às observações mais antigas, eliminando,

dessa forma, uma das desvantagens do modelo de média móvel. Este método é apropriado para séries que possuem uma trajetória aleatória em torno de uma média constante. Sendo assim, não é indicado para realizar previsões de uma série temporal que apresente tendência ou algum padrão sazonal. Analiticamente, pode-se descrever uma série exponencialmente alisada \tilde{y}_t como:

$$\tilde{y}_{t+1} = \alpha y_t + \alpha(1-\alpha)y_{t-1} + \alpha(1-\alpha)^2 y_{t-2} + \Lambda \quad (\text{eq. III-01})$$

O parâmetro α da equação acima é denominado coeficiente ou constante de alisamento e pode assumir qualquer valor entre 0 e 1 (isto é, $0 \leq \alpha \leq 1$). Quanto menor for o valor de α mais estáveis serão as previsões finais, uma vez que a utilização de baixo valor de α implica na atribuição de maiores pesos às observações passadas e, conseqüentemente, qualquer flutuação aleatória no presente contribui com menor importância para a obtenção da previsão.

Com base na equação anterior pode-se entender a razão desse método se chamar alisamento exponencial. Nota-se que a previsão da série y_t (ou série alisada) é uma média ponderada dos valores passados de y_t , onde os pesos atribuídos declinam exponencialmente com o decorrer do tempo.

Uma outra maneira de expressar o modelo de AES é por meio da diferença resultante entre a expressão (eq. III-01) e a equação

$$(1-\alpha)\tilde{y}_t = \alpha(1-\alpha)y_{t-1} + \alpha(1-\alpha)^2 y_{t-2} + \Lambda \quad (\text{eq. III-02})$$

de onde se obtém:

$$\tilde{y}_{t+1} = \alpha y_t + (1-\alpha)\tilde{y}_t \quad (\text{eq. III-03})$$

Em se tratando de previsão, pode-se obter o valor alisado de períodos à frente da seguinte forma:

$$\begin{aligned}\hat{y}_{T+1} &= \alpha y_T + \alpha(1-\alpha)y_{T-1} + \alpha(1-\alpha)^2 y_{T-2} + \Lambda \\ &= \alpha \sum_{i=0}^{\infty} (1-\alpha)^i y_{T-i}\end{aligned}$$

$$\begin{aligned}\hat{y}_{T+2} &= \alpha \hat{y}_{T+1} + \alpha(1-\alpha)y_T + \alpha(1-\alpha)^2 y_{T-1} + \Lambda \\ &= \alpha [\alpha y_T + \alpha(1-\alpha)y_{T-1} + \alpha(1-\alpha)y_{T-2} + \Lambda] + \alpha(1-\alpha)y_T + \alpha(1-\alpha)^2 y_{T-1} + \Lambda \\ &= \alpha^2 \sum_{i=0}^{\infty} (1-\alpha)^i y_{T-i} + \alpha(1-\alpha) \sum_{i=0}^{\infty} (1-\alpha)^i y_{T-i} \\ &= \alpha \sum_{i=0}^{\infty} (1-\alpha)^i y_{T-i}\end{aligned}$$

Generalizando, obtém-se a previsão para o período h:

$$\hat{y}_{T+h} = \alpha \sum_{i=0}^{\infty} (1-\alpha)^i y_{T-i} \quad (\text{eq. III-04})$$

Assim, partindo-se do período em que está disponível a observação mais recente, a previsão de valores à frente, independentemente do período futuro de que se faça a previsão, é constante. Porém, à medida que o modelo absorve novas observações, pode-se determinar uma equação de atualização de previsão em que o valor previsto consiste na soma da previsão do período imediatamente anterior e de uma proporção do erro de previsão do mesmo período anterior. Dessa maneira, a nova previsão pode ser obtida da anterior, adicionando-se um múltiplo do erro de previsão, indicando que a previsão está sempre alerta a mudanças no nível da série, revelada pelo erro de previsão (Moretтин & Toloι, 1987). Portanto, para a previsão do valor da série no período h à frente tem-se:

$$\hat{y}_{T+h} = \alpha(y_{T+h-1} - \hat{y}_{T+h-1}) + \hat{y}_{T+h-1} = \alpha(e_{T+h-1}) + \hat{y}_{T+h-1} \quad (\text{eq. III-05})$$

onde \hat{y}_{T+h-1} é o último valor previsto da série e (e_{T+h-1}) é o erro de previsão no período T+h-1.

Finalmente, deve-se salientar algumas vantagens e desvantagens do modelo de AES. Dentre as principais vantagens destacam-se o seu fácil entendimento e sua

aplicação não dispendiosa, bem como sua grande flexibilidade decorrente da variação da constante de alisamento α . Além disso, para fins de previsão, o modelo armazena somente os valores de y_t , \tilde{y}_t e α . Em contrapartida, a dificuldade em determinar o valor mais apropriado para a constante de alisamento α constitui-se em sua principal desvantagem.

3.1.2 Modelo de Alisamento Exponencial Duplo (AED)

O método de alisamento exponencial simples, quando aplicado às séries temporais que apresentam tendência linear positiva ou negativa entre as observações passadas, fornece prognósticos de predição subestimados ou superestimados dos valores reais da série. A fim de evitar tal erro sistemático, foram desenvolvidos métodos de alisamento exponencial com a propriedade de reconhecer a presença da tendência na série de dados. Serão descritos aqui superficialmente dois desses métodos: i) o alisamento exponencial duplo (AED); ii) e o alisamento exponencial biparamétrico de Holt (AEH).

A técnica de alisamento exponencial duplo (AED), também denominada de método de Brown, consiste, como o próprio nome deixa transparecer, simplesmente na aplicação repetida do método de alisamento exponencial simples (AES), utilizando-se do mesmo parâmetro de alisamento α . Tal técnica é resumida pelas equações abaixo:¹⁴

$$\tilde{y}_t = \alpha y_t + (1 - \alpha) \tilde{y}_{t-1}$$

$$\tilde{\tilde{y}}_t = \alpha \tilde{y}_t + (1 - \alpha) \tilde{\tilde{y}}_{t-1}$$

$$a_t = 2\tilde{y}_t - \tilde{\tilde{y}}_t$$

$$b_t = \frac{\alpha}{1 - \alpha} (\tilde{y}_t - \tilde{\tilde{y}}_t)$$

$$\hat{y}_{t+h} = a_t + hb_t$$

¹⁴ As deduções das fórmulas podem ser encontradas em Morettin & Tolo (1987).

onde: \tilde{y}_t é o valor exponencialmente alisado de y_t ;

$\tilde{\tilde{y}}_t$ é o valor exponencialmente alisado de \tilde{y}_t ;

α é a constante de alisamento ($0 < \alpha < 1$);

a_t é a diferença entre os valores exponencialmente alisados;

b_t é a medida de inclinação (fator de ajustamento);

h é o número de períodos à frente.

3.1.3 Modelo de Alisamento Exponencial Biparamétrico de Holt (AEH)

O AEH é outra técnica de alisamento exponencial dirigido para séries que apresentam tendência linear. Ao contrário do método de Brown, em que somente uma constante de alisamento é utilizada e os valores estimados da tendência são bastante sensíveis a influências aleatórias, o método de Holt utiliza dois coeficientes diferentes de alisamento e é descrito pelas equações dadas a seguir:

$$\begin{array}{ll} \tilde{y}_t = \alpha y_t + (1 - \alpha)(\tilde{y}_{t-1} + T_{t-1}) & \text{Série alisada exponencialmente } (0 < \alpha < 1) \\ T_t = \beta (\tilde{y}_t - \tilde{y}_{t-1}) + (1 - \beta)T_{t-1} & \text{Estimativa da tendência } (0 < \beta < 1) \\ \hat{y}_{t+h} = \tilde{y}_t + hT_t & \text{Previsão da série } h \text{ períodos à frente} \end{array}$$

onde: T_t é a tendência da série;

β é a constante de alisamento da estimativa da tendência.

O procedimento de determinação das constantes de alisamento deste modelo é análogo ao de determinação da constante de alisamento de um modelo AES, só que ao invés de se escolher o valor de α que torna a soma dos erros quadráticos de previsão mínimo, escolhe-se o valor do vetor (α, β) tal que isto ocorra (Morettin & Toloi, 1987). Deve-se atentar para o fato de que a determinação dos valores das constantes α e β constituem na maior desvantagem deste modelo.

3.1.4 Modelo de Alisamento Exponencial Sazonal de Holt-Winters (HW)

O modelo de alisamento exponencial sazonal de Holt-Winters (HW) possui aplicabilidade para a previsão de dados em séries temporais que apresentem um padrão de comportamento mais complexo. Em outras palavras, este método é apropriado para séries com tendência linear e variações sazonais. Existem dois tipos de procedimentos diferentes indicados para a previsão deste tipo de série e a sua utilização depende das características da série considerada. Especificamente, adota-se um determinado procedimento para séries que apresentam variação sazonal multiplicativa e um outro para séries que apresentam variação sazonal aditiva.

O primeiro procedimento (aplicado a séries com variação sazonal multiplicativa) segue de acordo com as expressões abaixo:

$$\tilde{y}_t = \alpha \frac{y_t}{S_{t-L}} + (1 - \alpha)(\tilde{y}_{t-1} + T_{t-1}) \quad \text{Série alisada exponencialmente } (0 < \alpha < 1)$$

$$T_t = \beta (\tilde{y}_t - \tilde{y}_{t-1}) + (1 - \beta)T_{t-1} \quad \text{Estimativa da tendência } (0 < \beta < 1)$$

$$S_t = \gamma \frac{y_t}{\tilde{y}_t} + (1 - \gamma)S_{t-L} \quad \text{Estimativa da sazonalidade } (0 < \gamma < 1)$$

$$\hat{y}_{t+h} = (\tilde{y}_t + hT_t)S_{t-L+h} \quad \text{Previsão da série h períodos à frente}$$

onde: α é a constante de alisamento;

β é a constante de alisamento da estimativa da tendência;

γ é a constante de alisamento da estimativa da sazonalidade;

T_t é a estimativa da tendência;

S_t é a estimativa sazonal;

L é a extensão da sazonalidade.

O segundo procedimento é utilizado quando a série temporal possui variação sazonal aditiva sendo resumido pelas equações a seguir:

$\tilde{y}_t = \alpha(y_t - S_{t-L}) + (1 - \alpha)(\tilde{y}_{t-1} + T_{t-1})$	Série alisada exponencialmente ($0 < \alpha < 1$)
$T_t = \beta(\tilde{y}_t - \tilde{y}_{t-1}) + (1 - \beta)T_{t-1}$	Estimativa da tendência ($0 < \beta < 1$)
$S_t = \gamma(y_t - \tilde{y}_t) + (1 - \gamma)S_{t-L}$	Estimativa da sazonalidade ($0 < \gamma < 1$)
$\hat{y}_{t+h} = \tilde{y}_t + hT_t + S_{t-L+h}$	Previsão da série h períodos à frente

Tanto para a sazonalidade multiplicativa quanto para a sazonalidade aditiva, os valores das constantes de alisamento são calculados de forma a minimizar a soma dos quadrados dos erros de previsão.

As formas multiplicativas e aditivas do algoritmo de Holt-Winters sazonal podem fornecer previsões bem diferentes. Se a série apresentar oscilações sazonais aproximadamente constantes, o modelo aditivo é mais indicado. Porém, se as oscilações sazonais forem proporcionais ao nível da série, o modelo multiplicativo é mais indicado. Alternativamente, pode-se utilizar os dois procedimentos e escolher aquele que fornece menor erro de previsão.

Finalmente, cabe alertar para as desvantagens que geralmente se encontra ao aplicar esta metodologia. As principais desvantagens são as dificuldades em determinar os valores mais apropriados das constantes de alisamento e a impossibilidade e/ou dificuldade de estudar as propriedades estatísticas, tais como média e variância de previsão e, conseqüentemente, construção de um intervalo de confiança.

3.2 Modelos Estocásticos de Séries Temporais

Os modelos estocásticos de séries temporais constituem o método mais sofisticado de extrapolação de uma série temporal. A idéia fundamental em que se baseia esta metodologia é de que a série a ser prevista é gerada por um processo estocástico cuja estrutura pode ser caracterizada e descrita. Tais modelos fornecem uma descrição da natureza aleatória do processo que gerou uma série temporal particular.

Dentre os principais modelos estocásticos de séries temporais que se destacam na tarefa de realizar previsões estão os modelos da metodologia Box-Jenkins, denominados comumente de modelos de série temporais os quais são objetos de estudo

da próxima seção. Esta metodologia se tornou bastante popular a partir de meados dos anos 70 em virtude de sua simplicidade e maior poder de previsão (em curto prazo) se comparados aos modelos econométricos.

3.2.1 Modelos ARIMA de Box-Jenkins

A metodologia mais difundida e utilizada para a realização de previsões de séries temporais geradas por um processo estocástico é a metodologia de Box-Jenkins, também conhecida como modelos ARIMA (autoregressivo integrado de média móvel). Essa metodologia consiste em uma classe de modelos que ignoram completamente as variáveis independentes, pois se utilizam de valores correntes e passados da variável dependente para produzir previsões.

Para a escolha de um modelo adequado de previsão, o método de Box-Jenkins é baseado na aplicação de três etapas distintas: i) identificação; ii) estimativa; iii) e checagem de diagnóstico. Porém, antes de desenvolver os procedimentos de cada etapa, deve-se caracterizar a estrutura dos principais modelos destinados à previsão de séries temporais. Estes modelos (modelos ARIMA) são resultantes da combinação de três componentes ou “filtros”: i) o componente autoregressivo (AR); ii) o componente de integração (I); iii) e o filtro de média móvel (MA). As características específicas dos modelos ARIMA são decorrentes da presença ou não destes três elementos.

O primeiro modelo a ser descrito é o processo de médias móveis de ordem q , denotado MA(q) e escrito como:

$$y_t = \mu + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} \quad (\text{eq. III-06})$$

onde: μ , $\theta_1, \dots, \theta_q$ são constantes;

$$\varepsilon_t \text{ é um processo de ruído branco, isto é, } \begin{cases} E(\varepsilon_t) = 0 \\ E(\varepsilon_t^2) = \sigma^2 \\ E(\varepsilon_t \varepsilon_\tau) = 0, t \neq \tau \end{cases}$$

O termo média móvel advém do fato de que a série y_t é construída a partir de uma soma ponderada dos $q+1$ valores mais recentes de ε_t , muito embora tal denominação não seja estritamente correta.¹⁵

A média e a variância deste processo são dadas a seguir:

$$E(y_t) = E(\mu + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \Lambda + \theta_q \varepsilon_{t-q}) = \mu + E(\varepsilon_t) + \theta_1 E(\varepsilon_{t-1}) + \Lambda + \theta_q E(\varepsilon_{t-q}) = \mu$$

$$\gamma_0 = E(y_t - \mu)^2 = E(\varepsilon_t + \theta_1 \varepsilon_{t-1} + \Lambda + \theta_q \varepsilon_{t-q})^2 = \sigma^2 (1 + \theta_1^2 + \Lambda + \theta_q^2)$$

pois trata-se de um ruído branco em que os ε_t 's não são autocorrelacionados. Observa-se ainda que a restrição imposta ao modelo para que a variância seja finita, e conseqüentemente para que o processo seja estacionário, é que a seguinte condição seja satisfeita:

$$\sum_{i=1}^{\infty} \theta_i^2 < \infty$$

Pode-se, para caracterizar mais ainda este modelo, mostrar os valores das autocovariâncias deste processo:

$$\begin{aligned} \gamma_j &= E[(\varepsilon_t + \theta_1 \varepsilon_{t-1} + \Lambda + \theta_q \varepsilon_{t-q})(\varepsilon_{t-j} + \theta_1 \varepsilon_{t-j-1} + \Lambda + \theta_q \varepsilon_{t-j-q})] = \\ &= E[\theta_j \varepsilon_{t-j}^2 + \theta_{j+1} \theta_1 \varepsilon_{t-j-1}^2 + \theta_{j+2} \theta_2 \varepsilon_{t-j-2}^2 + \Lambda + \theta_q \theta_{q-j} \varepsilon_{t-q}^2] = \\ &= [\theta_{j+1} \theta_1 + \theta_{j+2} \theta_2 + \Lambda + \theta_q \theta_{q-j}] \sigma^2, \text{ para } j = 1, 2, \dots, q \end{aligned}$$

Para valores de j superiores a q , em virtude da esperança matemática do produto de ε_t 's em diferentes datas ser igual a zero, as autocovariâncias do modelo são iguais a zero.

Note que a média e as autocovariâncias do processo MA(q) não são funções do tempo t . Logo, pode-se afirmar que o mesmo é fracamente estacionário. Além disso, um

¹⁵ A soma dos pesos excede o valor um.

outro conceito intimamente relacionado com a estacionaridade de uma série é o conceito de ergodicidade. Diz-se que um processo fracamente estacionário é ergódico para a média se a média de uma realização particular de um processo estacionário converge em probabilidade para a média do conjunto de todas as trajetórias (“ensemble”) quando a dimensão da série T tende ao infinito ($T \rightarrow \infty$). Algebricamente, afirma-se que uma série estacionária é ergódica para a média se a condição abaixo for satisfeita:

$$\sum_{j=0}^{\infty} |\gamma_j| < \infty$$

Porém, se o processo estocástico, além de ser estacionário, é Gaussiano, então a condição acima é suficiente para garantir ergodicidade em todos os momentos.¹⁶ Portanto, para o caso específico de um processo MA(q), a condição de ergodicidade é satisfeita (implicando que o processo é ergódico para a média) e se o ruído branco ε_t for Gaussiano, o processo é ergódico também para todos os momentos.

Por fim, existem casos particulares do modelo de médias móveis. São os modelos MA(1) e MA(2) denominados de modelos de médias móveis de ordem um e dois, respectivamente, e que na prática são os mais utilizados.

O segundo tipo de modelo ARIMA é o composto pelo componente autoregressivo, isto é, a série é modelada com base em uma média ponderada de seus valores passados e por um erro aleatório (ruído branco). Especificamente, um processo autoregressivo de ordem p , denotado de AR(p), é expresso por:

$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t \quad (\text{eq. III-07})$$

onde: $c, \phi_1, \phi_2, \dots, \phi_p$ são constantes;

y_{t-1}, \dots, y_{t-p} são valores defasados da variável y_t .

¹⁶ Ver Hamilton (1994) para maiores detalhes sobre ergodicidade.

A média e as autocovariâncias do processo AR(p) são dados por:

$$\mu = E(y_t) = \frac{c}{1 - \phi_1 - \phi_2 - \Lambda - \phi_p}$$

$$\rho_j = \begin{cases} \phi_1 \gamma_{j-1} + \phi_2 \gamma_{j-2} + \Lambda + \phi_p \gamma_{j-p}, & j = 1, 2, \dots, K \\ \phi_1 \gamma_1 + \phi_2 \gamma_2 + \Lambda + \phi_p \gamma_p, & j = 0 \end{cases} \quad 17$$

Um terceiro tipo de modelo utilizado com bastante freqüência pela metodologia de Box-Jenkins é o que possui os dois filtros analisados até o momento, ou seja, consiste em um modelo expresso tanto por componentes de médias móveis quanto por componentes autoregressivos. Tais processos são denominados ARMA (autoregressivo com média móvel) e pode-se representá-lo da seguinte maneira:

$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \Lambda + \phi_p y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \Lambda + \theta_q \varepsilon_{t-q} \quad (\text{eq. III-08})$$

$$(1 - \phi_1 L - \Lambda - \phi_p L^p) y_t = c + (1 + \theta_1 L + \Lambda + \theta_p L^p) \varepsilon_t \quad (\text{eq. III-09})$$

E se as raízes da equação característica $(1 - \phi_1 z - \phi_2 z^2 - \Lambda - \phi_p z^p) = 0$ estiverem fora do círculo unitário a expressão acima ainda pode ser escrita como:

$$y_t = \mu + \psi(L) \varepsilon_t \quad (\text{eq. III-10})$$

$$\text{onde: } \psi(L) = \frac{(1 + \theta_1 L + \Lambda + \theta_q L^q)}{(1 - \phi_1 L - \Lambda - \phi_p L^p)}$$

$$\mu = \frac{c}{1 - \phi_1 - \Lambda - \phi_p}$$

$$\text{com: } \sum_{j=0}^{\infty} |\psi_j| < \infty$$

Novamente, comumente utiliza-se na prática modelos ARMA de pequena ordem (geralmente até segunda ordem).

¹⁷ Dividindo γ_j por γ_0 temos as equações de autocorrelações do processo AR(p). Tal conjunto de equações é denominado equações de Yule-Walker.

Antes de dar prosseguimento ao estudo de outro modelo, faz-se necessário esclarecer as condições de estacionaridade e invertibilidade dos processos até aqui analisados. Os modelos MA não necessitam de nenhuma condição para serem considerados estacionários. No entanto, para que os mesmos possam ser transformados ou representados por um modelo AR(∞) a condição necessária e suficiente é que as raízes unitárias da equação $(1 + \theta_1 z + \theta_2 z^2 + \dots + \theta_q z^q) = 0$, para o exemplo de um processo MA(q), estejam fora do círculo unitário (o que implica $|\theta_i| < 1, i = 1, \dots, q$). O inverso acontece com o processo AR, pois nenhuma restrição é necessária ser feita para o mesmo ser representado por um processo MA(∞) mas, em contrapartida, para assegurar que o processo seja estacionário as raízes da equação característica $(1 - \phi_1 z - \phi_2 z^2 - \dots - \phi_p z^p) = 0$ devem estar fora do círculo unitário.

A metodologia de Box-Jenkins pode ser ainda direcionada a séries não estacionárias, mas que podem se tornar estacionárias após a aplicação de diferenças. O número de diferenças necessário para tornar uma série estacionária constitui o terceiro componente ou filtro do modelo e é denominado ordem de integração d. Este modelo mais geral de séries temporais que contém os três filtros é chamado de ARIMA. Pode-se representá-lo como:

$$w_t = \phi_1 w_{t-1} + \phi_2 w_{t-2} + \dots + \phi_p w_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} \quad (\text{eq. III-11})$$

onde: $w_t = \Delta^d y_t = (1 - L)^d y_t$

Assim, pode-se escrevê-lo ainda como:

$$(1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p) w_t = c + (1 + \theta_1 L + \theta_2 L^2 + \dots + \theta_q L^q) \varepsilon_t$$

$$(1 - L)^d \Phi(L) y_t = \Theta(L) \varepsilon_t$$

Após a série ser integrada, ou seja, tornar-se estacionária, o processo resultante é um ARMA (p,q) apresentando as mesmas propriedades e características analisadas anteriormente. Existem ainda uma série de combinações possíveis dos modelos

apresentados (que dependem da presença ou não dos três filtros) ocasionando em diferentes modelos.

Após esta rápida caracterização da estrutura dos possíveis modelos ARIMA destinados à previsão de séries temporais, passa-se a analisar os procedimentos (instrumentos) necessários para alcançar o objetivo da previsão.¹⁸

A identificação do modelo constitui-se no primeiro passo quando esta metodologia é aplicada a séries econômicas. Em outras palavras, o que se busca nesta etapa é descobrir qual das versões dos modelos ARIMA melhor descreve o comportamento da série. Sendo ainda mais específico, nesta etapa procura-se determinar o valor dos três filtros (p, d, q) do modelo que irá servir de base para a realização de previsões. Com este propósito, a identificação de um modelo ARIMA é obtida por meio da análise de três instrumentos: i) gráfico; ii) função de autocorrelação (AC); iii) e função de autocorrelação parcial (PAC).

Rigorosamente, a análise gráfica da série poderá somente informar se a série é aparentemente estacionária e se apresenta algum tipo de tendência e/ou sazonalidade.

A função de autocorrelação, por outro lado, se mostra extremamente útil na identificação porque fornece uma descrição parcial do processo ao qual se está querendo modelar. A mesma nos informa quanto de autocorrelação existe (e, assim, quanta independência existe) entre pontos de dados vizinhos de uma série (Pindyck & Rubinfeld, 1998). Esta função é definida da seguinte forma:

$$\rho_k = \frac{\gamma_k}{\gamma_0} = \frac{E[(y_t - \mu_y)(y_{t+k} - \mu_y)]}{\sigma_y^2}$$

Na prática, devido à limitação do número de observações, utiliza-se, para a descrição do processo estocástico, uma estimativa da função de autocorrelação que é a função de autocorrelação amostral denotada por:

¹⁸ Mais adiante serão caracterizados os modelos sazonais ARIMA ou modelos SARIMA.

$$r_k = \frac{\sum_{t=k+1}^T (y_t - \bar{y})(y_{t+k} - \bar{y})}{\sum_{t=1}^T (y_t - \bar{y})^2}$$

Conhecendo-se a distribuição de probabilidade de r_k pode-se construir intervalos de confiança e realizar testes de hipóteses para verificar se cada coeficiente separadamente é estatisticamente igual a zero. Bartlett (1946) demonstrou que se a série temporal foi gerada por um processo de ruído branco, os coeficientes de autocorrelação têm distribuição aproximadamente normal com média zero e variância $1/T$.¹⁹ Pode-se ainda testar conjuntamente se os primeiros k coeficientes são estatisticamente diferentes de zero. Para tanto, utiliza-se o teste Q de Ljung-Box que se distribui assintoticamente como uma $\chi^2(K)$ e cuja estatística é dada por:

$$Q_{LB} = T(T+2) \sum_{j=1}^k \frac{r_j^2}{T-j}$$

Desta forma, pode-se determinar se uma série econômica é estacionária ou não por meio da função de autocorrelação amostral, pois se a mesma converge rapidamente para zero quando o valor da defasagem k aumenta, então a série é considerada estacionária.²⁰ Além disso, através do comportamento desta função pode-se ainda determinar os componentes p e q dos modelos ARIMA.

O terceiro instrumento utilizado na identificação dos modelos ARIMA é a função de autocorrelação parcial. Esta função, diferentemente da função de autocorrelação, mensura a correlação entre pontos da série (y_t e y_{t-k} , por exemplo) descontando a influência exercida entre os pontos intermediários. Ou seja, a função de autocorrelação parcial mede a autocorrelação “líquida” entre duas observações.

¹⁹ O programa E-Views calcula o intervalo de confiança de aproximadamente $\pm 2/T^{1/2}$. Assim, se as autocorrelações estão neste intervalo, os mesmos não são significativamente diferentes de zero em um nível de 5% de significância.

²⁰ Séries não estacionárias apresentam fortes correlações seriais.

A etapa de identificação constitui-se em uma das mais importantes e difíceis da metodologia de Box-Jenkins. Muitas vezes, na realidade é o que geralmente acontece, são selecionados vários modelos capazes de gerar previsões de uma série específica. Esta dificuldade decorre do fato de as funções de autocorrelação e autocorrelação parcial utilizadas na identificação do modelo serem funções amostrais o que impede a sua exata identificação.

Selecionados alguns modelos na etapa de identificação parte-se para a segunda etapa que é a estimação desses modelos. Em outras palavras, o que se busca é a obtenção dos parâmetros ϕ e θ presentes nos modelos, bem como a obtenção da variância do erro σ_ε^2 . De uma forma geral, os modelos a serem estimados são escritos como:

$$\phi(L)\Delta^d y_t = \phi(L)w_t = \theta(L)\varepsilon_t \quad (\text{eq. III-12})$$

O método de estimação, seja ele qual for²¹, requer a minimização da soma dos erros ao quadrado, isto é:

$$S(\phi_1, K, \phi_p, \theta_1, K, \theta_q) = \sum_t \varepsilon_t^2 = \sum_t (\theta^{-1}(L)\phi(L)w_t)^2 \quad (\text{eq. III-13})$$

Para se estimar esses modelos é preciso atribuir valores a w_0, w_{-1}, K, w_{-p+1} e a $\varepsilon_0, \varepsilon_{-1}, K, \varepsilon_{-q+1}$. Uma alternativa é atribuir aos ε 's o valor zero que corresponde a suas esperanças não condicionais. Aos w 's passados atribui-se o valor médio da série \bar{w} . As estimativas obtidas por mínimos quadrados dependerão, portanto, dos valores atribuídos aos ε 's e aos w 's.

Caso algum termo de média móvel estiver presente no modelo o processo utilizado de estimação dos parâmetros envolverá métodos não-lineares (métodos dos mínimos quadrados não-lineares).

²¹ Usa-se normalmente o método dos mínimos quadrados e o método da máxima verossimilhança.

A estimação de modelos ARIMA por meio da função de máxima verossimilhança é obtida utilizando-se do fato de que os erros $\varepsilon_1, \dots, \varepsilon_T$ são, por hipótese, normalmente distribuídos e independentes com média zero e variância σ_ε^2 .²² Isto tem como principal implicação que ambos os métodos de estimação fornecem estimativas iguais para os parâmetros do modelo.

A terceira etapa da metodologia de Box-Jenkins consiste na checagem de diagnóstico do modelo. Nesta fase nada mais se faz que verificar se o modelo identificado e estimado é adequado para a realização de previsões. Caso o seja, faz-se a previsão da série. Caso contrário, inicia-se todo o processo de identificação e estimação novamente. Especificamente no que se refere a forma de como ocorre a verificação do modelo, a atenção se concentra no comportamento da estimativa de ε_t , ou seja, nos resíduos $\hat{\varepsilon}_t$ do modelo estimado. Como por suposição os distúrbios ε_t são distribuídos normalmente e independentes as estimativas de ε_t devem se comportar aproximadamente como um ruído branco para que o modelo esteja devidamente especificado. Assim, pode-se testar isoladamente ou conjuntamente a significância estatística dos coeficientes da função de autocorrelação amostral dos resíduos $\hat{\varepsilon}_t$ para verificar se os mesmos se comportam como um ruído branco. Estes coeficientes têm distribuição aproximadamente normal com média zero e variância $1/T$ ²³ e são expressos por:

$$r_k(\hat{\varepsilon}) = \frac{\sum_{t=k+1}^T \hat{\varepsilon}_t \hat{\varepsilon}_{t-k}}{\sum_{t=1}^T \hat{\varepsilon}_t^2}$$

Pode-se conjuntamente testar se os coeficientes são estatisticamente iguais a zero por meio de teste $Q^*(K)$ de Ljung-Box dado por:

²² Ver Pindyck & Rubinfeld (1998).

²³ Para valores pequenos de k , a variância de $r_k(\varepsilon_t)$ pode ser bem menor que $1/T$.

$$Q^*(K) = T(T+2) \sum_{j=1}^k \frac{r_k^2(\hat{\epsilon})}{T-k}$$

em que $Q^*(K)$ se distribui com uma $\chi^2(k-p-q)$.

Finalmente, como forma de auxílio na verificação dos resíduos pode-se observar o gráfico dos mesmos a fim de constatar se a variância permanece constante ao longo do tempo. Além disso, os critérios de Akaike (AIC) e o de Schwarz (BIC) podem ser utilizados quando restar dúvidas acerca da escolha do modelo. Estes critérios de seleção são baseados na variância estimada de ϵ_t , no tamanho da amostra e nos valores de p e q e cujas fórmulas são:

$$\text{AIC (Akaike's Information Criteria)} = \ln \hat{\sigma}_\epsilon^2 + \frac{2(p+q)}{T}$$

$$\text{BIC (Bayesian Information Criteria)} = \ln \hat{\sigma}_\epsilon^2 + \frac{(p+q) \ln T}{T}$$

onde: T é o tamanho da amostra;

$\hat{\sigma}_\epsilon^2$ é a variância estimada de ϵ_t .

Dentre os modelos selecionados na etapa de identificação escolhe-se aquele que apresentar o menor valor para os critérios acima, pois como se pode observar pelas fórmulas acima há uma punição para modelos mais complexos que apresentarem valores maiores para p e q (princípio da parcimônia).

Por último, cabe ressaltar que esta metodologia tem como objetivo final fornecer previsões de séries temporais. O que se deseja é, com base nas informações disponíveis, obter uma maneira de prever valores futuros de uma série econômica. Assim, a questão que se coloca é estabelecer qual o melhor previsor para a série y_t em instantes de tempo futuros. Este “previsor ótimo” é aquele que minimiza o erro quadrático médio de previsão, isto é, o que minimiza a expressão abaixo:

$$E[y_{T+l} - \hat{y}_T(l)]^2 = E[e_T^2(l)] \quad (\text{eq. III-14})$$

em que: y_{T+l} é o valor da série Y_t em T+l;

$\hat{y}_T(l)$ é a previsão da série Y_t em T+l.

A solução para este problema, cuja prova pode ser encontrada nos livros de referência²⁴, é dada pela esperança condicional de y_{T+l} , ou seja:

$$y_T(l) = E[y_{T+l} / y_T, y_{T-1}, \mathbf{K}, y_1] \quad (\text{eq. III-15})$$

Feitos alguns esclarecimentos a respeito das etapas da metodologia de Box-Jenkins, parte-se para a caracterização de modelos que, além de explorarem a correlação de valores observados da série em instantes de tempo consecutivos, exploram a correlação existente entre valores observados distantes por s ou múltiplos de s .²⁵ Esta nova classe de modelos ARIMA, em que são utilizados para a modelagem de séries que apresentam variações sazonais, é denominado modelo SARIMA.

Dentre os modelos SARIMA existem aqueles que consideram apenas as observações consecutivas não correlacionadas, isto é, levam em consideração somente as correlações existentes entre t , $t-s$, $t-2s$, ... (modelo puramente sazonal) e existem aqueles que, além de considerarem a correlação sazonal, incorporam a correlação entre instantes de tempo sucessivos (modelo sazonal multiplicativo geral). Este último tipo de modelo geral é denominado ARIMA $(p,d,q)(P,D,Q)_s$ e é escrito como:

$$\phi(L)\Phi(L^s)\Delta^d\Delta_s^D y_t = \theta(L)\Theta(L^s)\varepsilon_t \quad (\text{eq. III-16})$$

em que: $\phi(L) = (1 - \phi_1 L - \Lambda - \phi_p L^p)$;

$$\Phi(L^s) = (1 - \Phi_1 L^s - \Lambda - \Phi_p L^{ps})$$

$$\Delta^d = (1 - L)^d$$

$$\Delta_s^D = (1 - L^s)^D$$

²⁴ Para citar algumas obras ver Pindyck & Rubinfeld (1998) e Hamilton (1994).

²⁵ Neste outro tipo de correlação serial as séries têm periodicidade inferior a um ano.

$$\theta(L) = (1 - \theta_1 L - \Lambda - \theta_q L^q);$$

$$\Theta(L^s) = (1 - \Theta_1 L^s - \Lambda - \Theta_q L^{qs});$$

ε_t é um ruído branco.

Com exceção da etapa de identificação, as demais etapas aplicadas aos modelos sazonais são análogas àquelas descritas anteriormente para os modelos não sazonais. Isto é, inicialmente quando se deseja identificar a ordem dos filtros do modelo SARIMA (p,d,q,P,D,Q) utiliza-se as funções AC e PAC. Por exemplo, a análise da função AC da série original e das séries resultantes da aplicação de diferenças consecutivas e/ou sazonais indicará quais os valores de d e D. Dessa forma, se a primeira diferença da série (Δy_t) apresentar função AC com valores altos e que declinam lentamente nas ordens múltiplas de s, então é necessário aplicar à série uma diferença sazonal ($\Delta \Delta_s y_t$). Por outro lado, para se determinar os restantes dos elementos do modelo utiliza-se as funções AC e PAC observando agora não somente os coeficientes de autocorrelação consecutivos, mas também os coeficientes de autocorrelação de ordens múltiplas de s para realizar a identificação dos filtros sazonais. Após a elaboração das três etapas, realiza-se previsões para a série considerada.

3.2.2 Modelos de Correção de Erro

As variáveis cointegrantes possuem a característica particular de que suas trajetórias são influenciadas pela extensão de qualquer desvio em relação ao equilíbrio de longo prazo. Em outras palavras, quando certas variáveis se cointegram existe algum processo de ajustamento que impede que os erros da relação de longo prazo dessas variáveis se tornem grandes. O modelo que tenta capturar a dinâmica das relações de curto prazo das variáveis, influenciadas pelos seus desvios do equilíbrio a longo prazo, é denominado modelo de correção de erro.

Os modelos vetoriais de correção de erro (VEC) constituem em um caso restrito dos modelos vetoriais autoregressivos (VAR) em que se incorporam na especificação do modelo relações cointegrantes entre as variáveis. Isto é, representa um modelo linear que apresenta uma estrutura para modelagem de relações multivariadas em que as variáveis presentes no modelo são não estacionárias e cointegrantes (tais variáveis

devem possuir a mesma ordem de integração). A idéia da incorporação das relações cointegrantes ao modelo é capturar o comportamento de longo prazo das variáveis envolvidas no modelo. Tais modelos correntemente representam a abordagem mais comum para situações em que se deseja incorporar tanto a teoria econômica das relações de longo prazo entre as variáveis como o comportamento de equilíbrio no curto prazo (Charemza & Deadman, 1997).

Especificamente, pode-se escrever um modelo de correção de erro, na sua forma mais simples, como:

$$\Delta y_t = \Pi y_{t-1} + \Gamma_1 \Delta y_{t-1} + \varepsilon_t \quad (\text{Forma Matricial})$$

Ou ainda:

$$\begin{aligned} \Delta y_{1t} &= \alpha_1 (y_{2(t-1)} - \beta y_{1(t-1)}) + \gamma \Delta y_{1(t-1)} + \eta \Delta y_{2(t-1)} + \varepsilon_{1t} \\ \Delta y_{2t} &= \alpha_2 (y_{2(t-1)} - \beta y_{1(t-1)}) + \kappa \Delta y_{1(t-1)} + \lambda \Delta y_{2(t-1)} + \varepsilon_{2t} \end{aligned}$$

em que: $(y_{2(t-1)} - \beta y_{1(t-1)})$ é o termo de correção de erro;

α_1 e α_2 são os coeficientes de ajustamento;

ε_{1t} e ε_{2t} são ruídos brancos que podem ser correlacionados.

No equilíbrio a longo prazo o termo de correção de erro é zero. No entanto, caso as variáveis y_{1t} e y_{2t} sofram algum desvio do estado de equilíbrio em um período de tempo particular, o termo de correção de erro é diferente de zero e cada variável se ajusta parcialmente no período posterior para restaurar a condição de equilíbrio. Os coeficientes α_1 e α_2 , por sua vez, medem a velocidade desse ajustamento.

Quando da elaboração de um modelo de correção de erro a etapa inicial constitui-se na determinação da ordem de integração das séries envolvidas no modelo a fim de verificar se as mesmas são cointegradas. Desta forma, os testes de raízes unitárias ADF²⁶, para a obtenção da ordem de integração das séries, são as ferramentas

²⁶ ADF: Augmented Dickey-Fuller.

necessárias para esta finalidade. No entanto, para séries que apresentam fortes padrões sazonais este teste tradicional não fornece resultados consistentes. Assim, em substituição aos testes ADF, pode-se utilizar o teste proposto por Dickey, Hasza e Fuller (1984), denominado teste DHF, em que se aplica a séries que apresentam comportamento sazonal.

O teste DHF baseia-se na estatística t da estimativa do parâmetro δ obtido da estimação por mínimos quadrados ordinários (OLS) da seguinte equação de regressão:

$$\Delta_s z_t = \delta z_{t-s} + \sum_{i=1}^k \delta_i \Delta_s y_{t-i} + \varepsilon_t \quad (\text{eq. III-17})$$

em que: y_t representa a série original a ser testada;

z_t é uma nova série construída conforme demonstrado abaixo.

Para realizar o teste DHF primeiramente é necessário regredir a equação eq. III-18, dada a seguir, para encontrar por OLS as estimativas dos parâmetros nela contida:

$$\Delta_s y_t = \sum_{i=1}^h \lambda_i \Delta_s y_{t-i} + \xi_t \quad (\text{eq. III-18})$$

Após a obtenção das estimativas de λ , representadas por $\hat{\lambda}_i$, a variável z_t é construída a partir da seguinte equação:

$$z_t = y_t - \sum_{i=1}^h \hat{\lambda}_i y_{t-i} \quad (\text{eq. III-19})$$

Realizada a construção da variável z_t e estimada a equação eq. III-19 o teste da ordem de integração é feito de forma similar aos testes ADF convencionais. Se a estimativa de δ é significativamente negativa rejeita-se a hipótese nula da existência de uma raiz unitária sazonal em favor da hipótese alternativa da não existência de sazonalidade estocástica. Caso a hipótese nula não for rejeitada é usual considerar a ordem de diferenciação não sazonal ao invés de considerar ordens maiores de integração

sazonal. Dessa forma, quando não se rejeita a hipótese nula a próxima etapa é verificar se a série é $SI_{12}(1,1)$ ou $SI_{12}(0,1)$ a partir de um teste ADF simples conforme demonstra a equação abaixo:

$$\Delta\Delta_s y_t = \delta\Delta_s y_{t-1} + \sum_{i=1}^k \delta_i \Delta\Delta_s y_{t-i} + \varepsilon_t \quad (\text{eq. III-20})$$

Neste caso a hipótese nula é de que a série é $SI_{12}(1,1)$. Se a mesma não for rejeitada, então se realiza outro teste em que a nova hipótese nula é $SI_{12}(2,1)$ e a hipótese alternativa é de que a série é $SI_{12}(1,1)$. O procedimento se repete até que se rejeite a hipótese nula.

Alguns pontos importantes do teste DHF devem ser examinados. O primeiro é que a escolha dos valores de k e h é análoga a escolha da defasagem do teste ADF aumentado (ADF), isto é, toma-se valores de k e h de forma que os resíduos ε_t e ξ_t se comportem como um ruído branco. O outro ponto diz respeito aos valores críticos do teste DHF que podem ser encontrados nas obras de referência ou em alguns pacotes econométricos.

Dada a identificação da ordem de integração das séries envolvidas no modelo de correção de erro, há o interesse, antes de realizar propriamente a previsão das variáveis endógenas do modelo, de se verificar se estas séries são cointegradas e, em caso afirmativo, determinar o equilíbrio de longo prazo (vetores cointegrantes) dessas variáveis. A metodologia mais empregada para alcançar esta finalidade consiste no teste de Johansen. Este teste se baseia na estimação dos coeficientes da matriz Π da equação VEC ilustrada abaixo e testa as restrições aplicadas ao posto desta matriz.

$$y_t = A_1 y_{t-1} + A_2 y_{t-2} + \Lambda + A_p y_{t-p} + \varepsilon_t \quad (\text{VAR})$$

$$\Delta y_t = \Pi y_{t-1} + \sum_{i=1}^{p-1} \Gamma_i \Delta y_{t-i} + \varepsilon_t \quad (\text{VEC})$$

$$\text{onde: } \Pi = \left(\sum_{i=1}^p A_i \right) - I$$

$$\Gamma_i = - \sum_{j=i+1}^p A_j$$

em que: y_t é um vetor não estacionário ($k \times 1$);

ε_t é um vetor de inovações ($k \times 1$);

Π é uma matriz de coeficientes ($k \times k$).

O Teorema da Representação de Granger²⁷ afirma que se a matriz Π possui posto $r < k$, então existem matrizes α e β , cada uma com posto r , tal que $\Pi = \alpha\beta'$ e $\beta'y_t$ seja estacionário. O número de relações cointegrantes é determinado pelo valor de r e cada coluna β constitui um vetor cointegrante.

Desta forma, se o modelo possui k variáveis endógenas, supondo-se que cada uma dessas variáveis possua uma raiz unitária, o número máximo de vetores cointegrantes independentes que podem existir é igual a $k - 1$. Caso o teste de Johansen indique $r = 0$, ou seja, a não existência de relações cointegrantes, então o modelo VAR pode ser aplicado em primeira diferença. No outro caso extremo, se o teste indicar o valor $r = k$, então nenhuma das séries que compõem o modelo possui raiz unitária e o modelo VAR pode ser especificado em nível. No caso do posto da matriz Π for $r < k$, então existem r relações cointegrantes e, assim, o modelo de correção de erro pode ser especificado e aplicado.

3.3 Combinação de Previsões

A técnica da combinação de previsões, como o próprio nome deixa transparecer, consiste em obter resultados de predição a partir de uma média (simples ou ponderada) dos valores de previsões realizados por diferentes métodos. O principal objetivo desta técnica é aprimorar o poder de previsão da variável em estudo já que estudos empíricos

²⁷ Este teorema diz que quaisquer séries cointegradas podem ser representadas por um modelo de correção de erro e que o inverso também é verdadeiro.

têm demonstrado que a mesma fornece resultados superiores, ou no mínimo iguais, quando comparada aos outros métodos de predição.

A atribuição dos pesos da combinação pode ser feita de duas maneiras distintas: i) por meio de pesos iguais; ii) ou por meio de pesos diferentes. No primeiro caso (média simples) não se considera qualquer informação sobre o desempenho relativo das previsões individuais (FERREIRA, 1996). Assim, não existe uma ponderação maior para os métodos que fornecem melhores previsões. No segundo caso, entretanto, considera-se a eficiência dos vários resultados de previsão, pois modelos que apresentam melhores resultados de predição recebem maior ponderação.

Dessa forma, a questão que se coloca é como determinar os pesos para cada método que compõe a técnica de combinação de previsões. Várias alternativas estão disponíveis na literatura para a derivação destes pesos. No caso de se utilizar ponderação igual, a forma mais fácil de obtenção dos pesos da combinação linear consiste em calcular a média simples para cada previsão individual. Por outro lado, quando se utilizam pesos diferentes (embora constantes) para combinar os diversos métodos de previsão, várias opções se encontram a disposição do econometrista.

Bates & Granger (1969) sugerem que os pesos sejam calculados, sob a hipótese de que as previsões que irão compor o modelo de combinação não apresentem viés, pelo método dos mínimos quadrados restritos da seguinte equação:

$$y_t = \beta_1 f_t^1 + \beta_2 f_t^2 + \Lambda + \beta_k f_t^k \quad (\text{eq. III-21})$$

onde: $\beta_1, \beta_2, \dots, \beta_k$ são as estimativas das ponderações para os respectivos k métodos de previsões que compõem o modelo de combinação (sendo que $\beta_k = 1 - \beta_1 - \beta_2 - \dots - \beta_{k-1}$);

$f_t^1, f_t^2, \dots, f_t^k$ são as previsões para o período t dos respectivos k métodos.

Demonstra-se que estes resultados produzem previsões não viesadas com menor erro quadrático médio quando comparadas aos modelos de previsões individuais que integram a técnica da combinação de previsão.

Entretanto, em geral não existe razão para assegurar que todas as previsões isoladas sejam não viesadas. Diante desta dificuldade, Granger & Ramanathan (1984) mostraram que a combinação

$$y_t = \beta_0 + \beta_1 f_t^1 + \beta_2 f_t^2 + \Lambda + \beta_k f_t^k \quad (\text{eq. III-22})$$

em que as ponderações são obtidas por mínimos quadrados ordinários proporciona freqüentemente uma previsão combinada não viesada com erro quadrático médio menor que as previsões individuais f_t^i ($i = 1, \dots, k$). Deve-se destacar que neste procedimento os pesos estimados não necessitam somar a unidade e que as previsões individuais podem ser viesadas. Ainda, a estimação eficiente das ponderações dependerá do cumprimento dos pressupostos do modelo de regressão linear.

Uma outra forma de atribuir pesos diferentes aos modelos que compõem a técnica de combinação é aquela em que consiste na determinação dos pesos a partir da inversão de seu erro percentual absoluto médio.²⁸ Evidentemente que a determinação dos pesos também pode ser obtida a partir da utilização de qualquer outro critério que meça a eficiência de predição.

Resultados empíricos apresentados por Makridakis & Winkler (1983) mostraram que, após a comparação de desempenho de alguns procedimentos para a determinação dos pesos, um dos mais apropriados é decorrente da equação dada a seguir:

$$W_i = \frac{\left(\sum_{s=t-v}^{t-1} e_s^{(i)2} \right)^{-1}}{\sum_{j=1}^p \left(\sum_{s=t-v}^{t-1} e_s^{(j)2} \right)^{-1}} \quad (\text{eq. III-23})$$

²⁸ Uma vasta gama de métodos de determinação dos pesos pode ser encontrada em Castelar & Mynbaev (2001) e em Vélez & Velandia.

em que: p = número de previsões incluídas na combinação;

$i = 1, \dots, p$;

v = número de períodos inclusos no processo de determinação dos pesos.

Finalmente, cabe alertar que ainda existem outras técnicas para o cálculo das ponderações. Uma técnica que vem sendo empregada com bastante frequência consiste em utilizar ponderações diferentes, mas que apresentam variações com o decorrer do tempo. Vários autores têm enfatizado que em muitos casos os procedimentos anteriores de combinação com coeficientes constantes podem resultar em resultados inadequados e apresentam alguns argumentos para se utilizar ponderações variáveis com o tempo. Em primeiro lugar, geralmente os pesquisadores tentam cada vez mais melhorar seus modelos, o que sugere que o comportamento das previsões poderiam estar variando com o tempo e, portanto, as ponderações da combinação provavelmente também variariam com o tempo. Em segundo lugar, alguns modelos que compõem a combinação fornecem melhores resultados que outros em determinados períodos de tempo. Assim, uma forma de aumentar a acurácia de predição do modelo seria incorporar pesos que variassem de acordo com esses períodos críticos. Na determinação dos pesos do modelo de combinação para a previsão do imposto de renda proposto por este trabalho utilizou-se desta última metodologia. Isto é, os pesos do modelo variam para cada mês que se realizará a previsão.

4 RESULTADOS EMPÍRICOS

Nesta seção, como forma de desenvolver o modelo de combinação de previsões e assim obter os valores previstos para o ano de 2002, serão apresentados os principais resultados de previsão mensal do imposto de renda (IR) utilizando-se das três metodologias discutidas anteriormente: alisamento exponencial, modelos ARIMA e modelo de correção de erro. Posteriormente se fará a comparação dos resultados do modelo de combinação com os valores reais observados do imposto de renda a fim de verificar o poder de predição do modelo. Outro tipo de comparação ainda será realizado, mas agora para o ano de 2001. Em outras palavras, confrontam-se os resultados de previsão do modelo de combinação com os resultados do modelo dinâmico de Siqueira (2002) com o objetivo de averiguar qual dos modelos apresenta melhores resultados.

Inicialmente deflacionou-se os dados disponíveis do IR (período: Jan/90 a Dez/02; fonte: Banco Central do Brasil) pelo IGP-DI (base Dez/2002).²⁹ Os resultados dos três métodos de previsão (alisamento exponencial sazonal de Holt-Winters, modelos ARIMA e modelo de correção de erro) foram obtidos por meio da utilização do programa computacional E-Views (versão 3.1). A seguir encontram-se os procedimentos e os resultados de previsão do IR:

Resultados da Previsão Utilizando a Técnica do Alisamento Exponencial

Existem várias maneiras de realizar o alisamento exponencial de uma série. Quando se suspeita que a série a ser alisada apresenta alguma forma de tendência e/ou sazonalidade recorre-se à metodologia em que se incorpora ambos os componentes. Dessa forma, os dois métodos a serem empregados para a obtenção da série alisada do IR serão o do alisamento exponencial sazonal de Holt-Winters aditivo e o do alisamento exponencial sazonal de Holt-Winters multiplicativo. Dentre esses dois métodos, o escolhido para a tarefa de realizar previsões se baseará no valor do critério do erro percentual absoluto médio (EPAM). Ou seja, o método que apresentar menor EPAM para a previsão *ex-post* (2001:01 a 2001:12) será adotado para gerar as previsões *ex-ante* (2002:01 a 2002:12) do imposto de renda.

²⁹ O anexo 4 contém os valores das variáveis IR e PIB.

Primeiramente serão apresentados os resultados da série IR alisada através do modelo de alisamento exponencial sazonal aditivo (esta nova série será denominada IRWHAD), onde se fará algumas considerações a respeito destes resultados. Logo em seguida, os resultados da mesma série, alisada agora pelo método do alisamento exponencial sazonal multiplicativo (série denominada IRHWMU), serão mostrados e discutidos. Deve-se observar, entretanto, que primeiramente reduziu-se o período da amostra em um ano (de 2001 para 2000) para que se pudesse confrontar os resultados de previsão (ano: 2001) dos dois modelos com os dados disponíveis e, assim, evidenciar qual dos métodos apresentaria melhor ajustamento. Segue, então, os resultados do primeiro método de alisamento (aditivo):

Sample: 1990:01 2000:12
 Included observations: 132
 Method: Holt-Winters Additive Seasonal
 Original Series: IR
 Forecast Series: IRHWAD

Parameters:	Alpha	0.2400
	Beta	0.0000
	Gamma	0.0000
	Sum of Squared Residuals	1.78E+08
	Root Mean Squared Error	1162.834

End of Period Levels:	Mean	7056.411
	Trend	9.858163
	Seasonals:	
	2000:01	361.0631
	2000:02	-370.6155
	2000:03	771.3836
	2000:04	816.3250
	2000:05	712.9604
	2000:06	-487.1675
	2000:07	-143.6753
	2000:08	-656.5639
	2000:09	-650.1819
	2000:10	-690.8689
	2000:11	-914.3433
	2000:12	1251.684

Tabela 01: Resultado de estimação da série IR pelo método do alisamento exponencial Holt-Winters aditivo (período: 1990:01 a 2000:12)

Verifica-se que a série alisada apresenta somente um dos seus três coeficientes (ou constantes) de alisamento diferente de zero (deve-se destacar que os mesmos foram livremente estimados). O significado destes coeficientes serem zero é que os componentes tendência e sazonalidade estimados são fixos e não mudam ao longo do tempo. Por outro lado, tem-se um valor relativamente baixo para o parâmetro α o que implica que as previsões finais serão mais estáveis, pois pesos maiores serão dados às

observações passadas. O gráfico abaixo destaca a série alisada (pelo método sazonal aditivo) e a série original do imposto de renda para o período de 2000:12 a 2001:12:

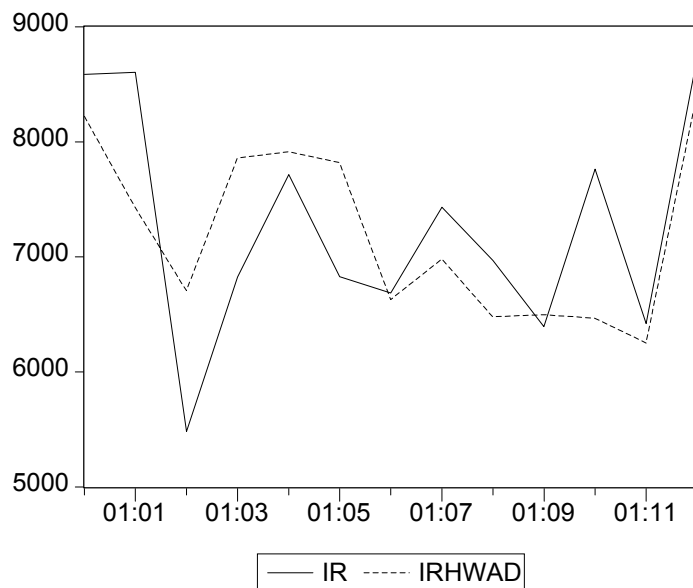


Gráfico 01: Séries IR e IRHWAD (período: 2000:12 a 2001:12)

Com relação aos resultados do segundo modelo (o sazonal multiplicativo) os mesmos se apresentaram da seguinte forma:

Sample: 1990:01 2000:12
 Included observations: 132
 Method: Holt-Winters Multiplicative Seasonal
 Original Series: IR
 Forecast Series: IRHWMU

Parameters:	Alpha	0.2200
	Beta	0.0000
	Gamma	0.0000
	Sum of Squared Residuals	1.78E+08
	Root Mean Squared Error	1159.926
End of Period Levels:	Mean	7093.346
	Trend	9.858163
	Seasonals:	
	2000:01	1.044697
	2000:02	0.917544
	2000:03	1.103586
	2000:04	1.165362
	2000:05	1.171366
	2000:06	0.931844
	2000:07	0.976414
	2000:08	0.885250
	2000:09	0.875210
	2000:10	0.874194
	2000:11	0.840086
	2000:12	1.214448

Tabela 02: Resultado de estimação da série IR pelo método do alisamento exponencial Holt-Winters multiplicativo (período: 1990:01 a 2000:12)

Semelhantemente aos resultados da técnica de alisamento anterior a estimativa do coeficiente de alisamento α é baixa evidenciando que as previsões finais da série do imposto de renda serão estáveis. A figura a seguir ilustra três séries: a série original do imposto de renda, a série do IR alisada pelo método sazonal aditivo e a série do IR alisada pelo método sazonal multiplicativo para o período de 2000:12 a 2001:12:




Gráfico 02: Séries IR, IRHWAD e IRHWMU (período: 2000:12 a 2001:12)

Como se pode observar pelo gráfico anterior as séries IRHWAD e IRHWMU são bastantes parecidas. Isto decorre dos resultados de estimação serem próximos um do outro.

Para a decisão da técnica utilizada para gerar previsões da série do IR recorreu-se à comparação do erro percentual absoluto médio de cada modelo. O cálculo deste critério é baseado na seguinte fórmula:³⁰

$$EPAM = \frac{\sum_{t=1}^n \frac{|y_t - \hat{y}_t|}{y_t}}{n} \quad (\text{eq. IV-01})$$

³⁰ Outros critérios de medida e controle de predição podem ser encontrados em FERREIRA (1996) e em Hanke & Reitsch (1992).

Os resultados do cálculo deste indicador estão resumidos na tabela abaixo, a partir dos quais chega-se a conclusão de que, dentre os dois métodos disponíveis de alisamento exponencial para se obter a previsão da série do imposto de renda, o modelo de alisamento exponencial sazonal aditivo de Holt-Winters mostra-se mais indicado pelo fato de apresentar menor EPAM.

<i>PERÍODO</i>	<i>IR</i>	<i>IRHWAD</i>	<i>IRHWMU</i>	<i>EPAM-AD</i>	<i>EPAM-MU</i>
Jan/01	8601.817	7427.332	7420.699	0.136539	0.137310
Fev/01	5482.212	6705.512	6526.545	0.223140	0.190495
Mar/01	6823.903	7857.369	7860.755	0.151448	0.151944
Abr/01	7714.506	7912.169	8312.267	0.025622	0.077485
Mai/01	6826.406	7818.662	8366.641	0.145356	0.225629
Jun/01	6685.793	6628.393	6665.011	0.008585	0.003108
Jul/01	7430.427	6981.743	6993.420	0.060385	0.058813
Ago/01	6967.576	6478.712	6349.201	0.070163	0.088750
Set/01	6393.484	6494.953	6285.819	0.015871	0.016840
Out/01	7762.130	6464.124	6287.141	0.167223	0.190024
Nov/01	6419.178	6250.508	6050.118	0.026276	0.057493
Dez/01	8740.033	8426.393	8758.167	0.035885	0.002075
				0.088874	0.099997

Tabela 03: Comparação para a escolha do modelo de alisamento exponencial

Determinado o modelo mais adequado pode-se gerar uma nova série alisada considerando-se, desta vez, todo o período amostral disponível (no caso o novo período é de 1990:01 à 2001:12) para obter as previsões para o ano de 2002. Procedendo-se então dessa forma os resultados obtidos, utilizando-se o método de alisamento exponencial sazonal aditivo de Holt-Winters (a nova série é denominada de IRHWAD2), foram os seguintes:

Sample: 1990:01 2001:12
 Included observations: 144
 Method: Holt-Winters Additive Seasonal
 Original Series: IR
 Forecast Series: IRHWAD2

Parameters:	Alpha	0.2300
	Beta	0.0000
	Gamma	0.0000
	Sum of Squared Residuals	1.86E+08
	Root Mean Squared Error	1136.203
End of Period Levels:	Mean	7429.885
	Trend	11.13068
	Seasonals:	
	2001:01	463.1468
	2001:02	-469.6197
	2001:03	686.9263
	2001:04	800.2456
	2001:05	629.3923
	2001:06	-484.5368
	2001:07	-109.7101
	2001:08	-620.5229
	2001:09	-664.6078
	2001:10	-589.9444
	2001:11	-908.8026
	2001:12	1268.033

Tabela 04: Resultado de estimação da série IR pelo método do alisamento exponencial Holt-Winters aditivo (período: 1990:01 a 2001:12)

Portanto, de posse dos novos coeficientes estimados pode-se partir definitivamente para a obtenção dos valores de previsão da série do imposto de renda para o ano de 2002. Os resultados, utilizando-se o método do alisamento exponencial sazonal aditivo de Holt-Winters, estão resumidos logo abaixo em forma de tabela e gráfico:

PERÍODO	ALIS. EXP.
Jan/02	7904.162
Fev/02	6982.526
Mar/02	8150.203
Abr/02	8274.653
Mai/02	8114.93
Jun/02	7012.132
Jul/02	7398.089
Ago/02	6898.407
Set/02	6865.453
Out/02	6951.247
Nov/02	6643.519
Dez/02	8831.486

Tabela 05: Resultados de previsão para o ano de 2002 (Método: Alisamento Exponencial – Holt-Winters Aditivo)

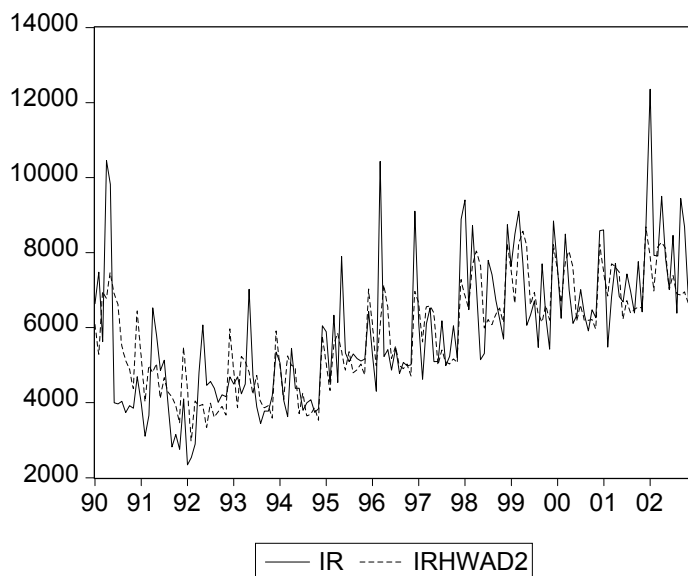


Gráfico 03: Séries IR e IRHWAD2 (período: 1990:01 a 2002:12)

Resultados da Previsão Utilizando a Metodologia de Box-Jenkins

A segunda forma de realizar a previsão da série IR foi baseada na metodologia de Box-Jenkins, também conhecida como modelos ARIMA. Para alcançar este objetivo o procedimento utilizado consistiu na adoção de três etapas metodológicas: i) identificação; ii) estimação; iii) e a checagem de diagnóstico.

Na primeira etapa, com base nas funções amostrais de autocorrelação e autocorrelação parcial, foram selecionados alguns modelos suspeitos de terem gerado a série de estudo. Os resultados das duas funções, bem como a estatística Q de Ljung-Box para a série original, estão expostos no anexo 1 (tabela 21). Observa-se que a função de autocorrelação amostral da série do imposto de renda não converge rapidamente para zero quando o valor de k aumenta. Em outras palavras, esta função nos informa que a série IR não é estacionária indicando que se deve diferenciá-la a fim de verificar se a mesma se torna estacionária. De forma similar, a análise gráfica desta série está de acordo com a função AC, pois se pode observar a existência de uma leve tendência positiva (não estacionaridade). O gráfico da série do imposto de renda é mostrado a seguir:




Gráfico 04: Série IR (período: 1990:01 a 2001:12)

A tabela 22 do anexo 1 fornece os resultados das funções AC e PAC para a primeira diferença da série do imposto de renda (o seu gráfico, denominado $D(IR)$, pode ser visto abaixo). Analisando-se estas funções observa-se que a nova série é estacionária apresentando, porém, um forte padrão de sazonalidade.




Gráfico 05: Primeira diferença da série IR (período: 1990:01 a 2001:12)

Recomenda-se, para séries temporais que apresentam forte padrão de sazonalidade, tomar primeiro a diferença sazonal (no caso específico da série do imposto de renda $s = 12$) e depois verificar a função AC da série resultante. Caso a série desazonalizada ainda não for estacionária toma-se então a primeira diferença.

Adotando-se este procedimento o gráfico a seguir mostra a série do IR quando se realiza a diferença sazonal ($y_t - y_{t-12}$). A função de autocorrelação amostral para esta série encontra-se na tabela 23 do anexo 1. Como se pode observar, a série ainda pode ser considerada não estacionária, necessitando-se realizar a primeira diferença da mesma para iniciar a identificação dos modelos. Os resultados da função de autocorrelação para a primeira diferença da série desazonalizada são dados na tabela 24 do anexo 1 e de acordo com tais resultados nota-se que esta nova série é estacionária podendo-se, desta forma, utilizá-la para identificar os modelos. A seguir são ilustrados os gráficos destas duas séries:




Gráfico 06: Diferença sazonal da série IR (período: 1990:01 a 2001:12)




Gráfico 07: Primeira diferença da série IR desazonalizada (período: 1990:01 a 2001:12)

Portanto, com base no correlograma da tabela 4 do anexo 1, partiu-se para a identificação dos outros dois componentes (p e q) do modelo. Dessa forma, analisando-se atentamente a tabela 4, pôde-se selecionar alguns modelos sazonais ARIMA a fim de descobrir qual seria o melhor para a tarefa de previsão. A tabela a seguir fornece um resumo dos dois modelos selecionados:

<i>Modelos SARIMA Selecionados</i>	<i>Especificação</i>
Modelo 01 (IR01): SARIMA(0,1,1)(0,1,2) ₁₂	$(1 - L^{12})(1 - L)y_t = (1 + \theta_1 L)(1 + \Theta_1 L^{12})(1 + \Theta_2 L^{24})\varepsilon_t$
Modelo 02 (IR02): SARIMA(1,1,0)(0,1,2) ₁₂	$(1 - L^{12})(1 - L)(1 - \phi_1 L)y_t = (1 + \Theta_1 L^{12})(1 + \Theta_2 L^{24})\varepsilon_t$

Tabela 06: Modelos SARIMA selecionados

A escolha do modelo ARIMA mais apropriado será, a princípio, similar ao realizado pelo método de alisamento exponencial no sentido de que se reduzirá o tamanho da amostra em um ano a fim de verificar qual modelo apresenta menor EPAM (erro percentual absoluto médio). Após a adoção deste critério recorre-se à checagem de diagnóstico para eleger o modelo que será o responsável pela previsão da série do imposto de renda. Os resultados dos respectivos cálculos do EPAM, juntamente com o respectivo gráfico, encontram-se logo abaixo:

<i>PERÍODO</i>	<i>IR</i>	<i>IR01</i>	<i>IR02</i>	<i>EPAM-IR01</i>	<i>EPAM-IR02</i>
Jan/01	8601.817	7525.419	7887.599	0.1251361	0.0830311
Fev/01	5482.212	6473.052	6622.539	0.1807373	0.2080049
Mar/01	6823.903	8090.586	8585.904	0.1856244	0.2582101
Abr/01	7714.506	7543.153	7430.294	0.0222118	0.0368412
Mai/01	6826.406	7151.578	6705.858	0.0476344	0.0176591
Jun/01	6685.793	6452.258	6499.447	0.03493	0.0278719
Jul/01	7430.427	7002.091	7256.838	0.0576462	0.0233619
Ago/01	6967.576	6460.566	6610.886	0.0727671	0.0511928
Set/01	6393.484	6301.524	6673.469	0.0143834	0.0437922
Out/01	7762.130	6481.594	6749.354	0.1649722	0.1304766
Nov/01	6419.178	6269.724	6445.568	0.0232824	0.0041111
Dez/01	8740.033	8558.822	9086.078	0.0207334	0.0395931
				0.0791716	0.0770122

Tabela 07: Comparação para a escolha do modelo SARIMA




Gráfico 08: Séries IR, IR01 e IR02 (período: 2000:12 a 2001:12)

Como se pôde observar acima, os modelos selecionados apresentaram-se próximos um do outro necessitando de uma outra ferramenta para realizar a escolha do melhor modelo. Desta forma, fez-se a estimação destes dois modelos levando-se em consideração todo o período amostral (1990:01 à 2001:12) a fim de observar o comportamento dos resíduos. Com base nos gráficos e nos correlogramas notou-se que aparentemente todos os modelos constituíram-se em um processo de ruído branco. No entanto, a estatística $Q^*(K)$ do modelo 01 apresentou-se mais consistente, pois seus valores p indicaram que conjuntamente os coeficientes de correlação dos resíduos para este modelo são estatisticamente iguais a zero (no anexo 1 a tabela 25 ilustra o correlograma dos resíduos do modelo IR01, enquanto a tabela 26 demonstra o correlograma dos resíduos do modelo IR02). Como a análise do correlograma apontou o modelo 01 como sendo o mais conveniente para gerar previsões, elaborou-se a previsão da série do imposto de renda com base no modelo SARIMA(0,1,1)(0,1,2)₁₂.³¹ Logo abaixo segue a tabela de valores da previsão do IR para o ano de 2002:

³¹ O anexo 2 fornece os resultados de estimação do modelo 01.

PERÍODO	SARIMA
Jan/02	8183.493
Fev/02	6539.158
Mar/02	7772.114
Abr/02	8025.862
Mai/02	7520.017
Jun/02	6779.156
Jul/02	7312.919
Ago/02	6785.302
Set/02	6658.100
Out/02	7088.050
Nov/02	6383.443
Dez/02	8708.236

Tabela 08: Resultados de previsão para o ano de 2002 (Método: Box-Jenkins)

Resultados da Previsão Utilizando o Modelo Vetorial de Correção de Erro (VEC)

A terceira metodologia utilizada para a previsão da série mensal do imposto de renda foi a aplicação de um modelo vetorial de correção de erro (VEC). Este tipo de modelo econométrico consiste em um caso particular de modelos vetoriais autoregressivos (VAR) em que as variáveis endógenas não são estacionárias. No caso específico, as variáveis endógenas empregadas para a previsão do imposto de renda foram imposto de renda desazonalizado (IRSA)³² e produto interno bruto desazonalizado (PIBSA) para o período de 1994:08 a 2001:12. Assim, utilizou-se a variável PIB como uma *proxy* da variável renda.

Inicialmente o procedimento empregado consistiu no uso do teste de estacionaridade destas duas séries. Em outras palavras, o teste de Dickey-Fuller (DF) para raízes unitárias foi utilizado para averiguar a ordem de integração das mesmas. Após a aplicação do teste de DF, a etapa seguinte constituiu na adoção do teste de Johansen com o intuito de verificar se as séries eram cointegradas. De posse do resultado deste último teste seguiu-se para a construção do modelo vetorial de correção de erro.

³² O método utilizado para desazonalizar as séries foi a diferença da média móvel encontrada no programa E-Views (versão 3.1).

Os resultados dos testes para as duas séries encontram-se logo abaixo. Verificou-se que as séries não são estacionárias tendo em vista que a hipótese nula da existência de raiz unitária não foi rejeitada.

ADF Test Statistic	0.365201	1% Critical Value*	-2.5902
		5% Critical Value	-1.9440
		10% Critical Value	-1.6177

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

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(IRSA)

Method: Least Squares

Sample(adjusted): 1994:12 2001:12

Included observations: 85 after adjusting endpoints

Variable	Coefficient	Std. Error	t-Statistic	Prob.
IRSA(-1)	0.006033	0.016520	0.365201	0.7159
D(IRSA(-1))	-0.652008	0.109906	-5.932401	0.0000
D(IRSA(-2))	-0.489305	0.120149	-4.072488	0.0001
D(IRSA(-3))	-0.240583	0.109829	-2.190531	0.0314
R-squared	0.314046	Mean dependent var		22.68194
Adjusted R-squared	0.288640	S.D. dependent var		1158.797
S.E. of regression	977.3541	Akaike info criterion		16.65349
Sum squared resid	77372911	Schwarz criterion		16.76844
Log likelihood	-703.7734	Durbin-Watson stat		2.069092

Tabela 09: Resultado do teste DF para a série IRSA

ADF Test Statistic	0.228458	1% Critical Value*	-2.5899
		5% Critical Value	-1.9439
		10% Critical Value	-1.6177

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

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(PIBSA)

Method: Least Squares

Sample(adjusted): 1994:11 2001:12

Included observations: 86 after adjusting endpoints

Variable	Coefficient	Std. Error	t-Statistic	Prob.
PIBSA(-1)	0.000703	0.003078	0.228458	0.8199
D(PIBSA(-1))	0.227664	0.106187	2.143988	0.0350
D(PIBSA(-2))	-0.164746	0.105826	-1.556767	0.1233
R-squared	0.066433	Mean dependent var		166.6905
Adjusted R-squared	0.043938	S.D. dependent var		3893.742
S.E. of regression	3807.240	Akaike info criterion		19.36146
Sum squared resid	1.20E+09	Schwarz criterion		19.44707
Log likelihood	-829.5427	Durbin-Watson stat		2.162288

Tabela 10: Resultado do teste DF para a série PIBSA

Dado que os resultados do teste indicaram a existência de uma raiz unitária partiu-se para determinar a ordem de integração das séries. Assim, utilizando-se novamente do teste de DF, dessa vez para a primeira diferença, obteve-se os seguintes resultados:

ADF Test Statistic	-8.833768	1% Critical Value*	-2.5902
		5% Critical Value	-1.9440
		10% Critical Value	-1.6177

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

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(IRSA,2)

Method: Least Squares

Sample(adjusted): 1994:12 2001:12

Included observations: 85 after adjusting endpoints

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(IRSA(-1))	-2.364272	0.267640	-8.833768	0.0000
D(IRSA(-1),2)	0.719402	0.197340	3.645494	0.0005
D(IRSA(-2),2)	0.236577	0.108700	2.176411	0.0324
R-squared	0.757346	Mean dependent var		-13.59370
Adjusted R-squared	0.751428	S.D. dependent var		1949.927
S.E. of regression	972.1758	Akaike info criterion		16.63161
Sum squared resid	77500310	Schwarz criterion		16.71782
Log likelihood	-703.8433	Durbin-Watson stat		2.066468

Tabela 11: Resultado do teste DF para a primeira diferença da série IRSA

ADF Test Statistic	-6.150070	1% Critical Value*	-2.5909
		5% Critical Value	-1.9441
		10% Critical Value	-1.6178

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

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(PIBSA,2)

Method: Least Squares

Sample(adjusted): 1995:02 2001:12

Included observations: 83 after adjusting endpoints

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(PIBSA(-1))	-1.666463	0.270967	-6.150070	0.0000
D(PIBSA(-1),2)	0.709413	0.215034	3.299068	0.0015
D(PIBSA(-2),2)	0.613943	0.169235	3.627742	0.0005
D(PIBSA(-3),2)	0.304194	0.142892	2.128838	0.0364
D(PIBSA(-4),2)	0.044570	0.105552	0.422252	0.6740
R-squared	0.548545	Mean dependent var		-148.6135
Adjusted R-squared	0.525393	S.D. dependent var		4796.741
S.E. of regression	3304.558	Akaike info criterion		19.10234
Sum squared resid	8.52E+08	Schwarz criterion		19.24806
Log likelihood	-787.7472	Durbin-Watson stat		2.053351

Tabela 12: Resultado do teste DF para a primeira diferença da série PIBSA

Deste modo, como se rejeitou a hipótese nula da existência de duas raízes unitárias, indicando que as séries possuíam a mesma ordem de integração ($I=1$), pôde-se realizar o teste de Johansen. A seguir apresenta-se o resultado do teste de cointegração de Johansen juntamente com o gráfico das séries IRSA e PIBSA:

Sample: 1994:08 2001:12

Included observations: 84

Test assumption: No deterministic trend in the data

Series: IRSA PIBSA

Lags interval: 1 to 4

Eigenvalue	Likelihood Ratio	5 Percent Critical Value	1 Percent Critical Value	Hypothesized No. of CE(s)
0.248211	28.18600	19.96	24.60	None **
0.049006	4.220797	9.24	12.97	At most 1

*(**) denotes rejection of the hypothesis at 5%(1%) significance level

L.R. test indicates 1 cointegrating equation(s) at 5% significance level

Unnormalized Cointegrating Coefficients:

IRSA	PIBSA	C
-0.000116	-3.99E-06	1.314453
-0.000126	1.88E-05	-1.695953

Normalized Cointegrating Coefficients: 1 Cointegrating Equation(s)

IRSA	PIBSA	C
1.000000	0.034306 (0.03823)	-11306.94 (5178.97)

Log likelihood -1477.415

Tabela 13: Resultado do teste de Johansen para as séries IRSA e PIBSA

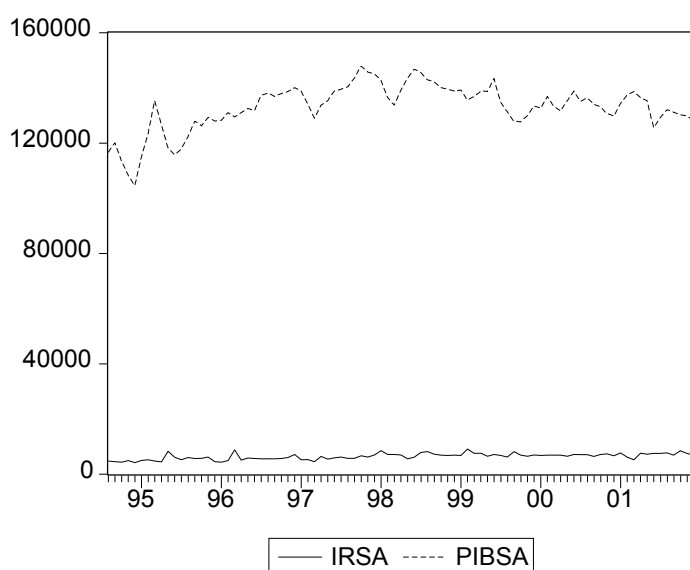


Gráfico 09: Séries IRSA e PIBSA (período: 1994:08 a 2001:12)

Realizado o teste de cointegração de Johansen e verificado que as séries são de fato cointegradas, o próximo passo foi construir um modelo vetorial de correção de erro para gerar a previsão da série do imposto de renda. Foram selecionados e estimados cinco modelos de correção de erro em que os “lags” foram escolhidos de acordo com o comportamento dos resíduos. Para realizar a escolha do modelo mais apropriado procedeu-se de forma similar as duas metodologias anteriormente empregadas, isto é, fez-se inicialmente uma previsão *ex-post* da série do imposto de renda e calculou-se para cada modelo o erro percentual absoluto médio (EPAM). Como se pode observar na tabela dada a seguir, o EPAM do modelo VEC02 apresentou menor valor:

PERÍODO	IR	VEC01	VEC02	VEC03	VEC04	VEC05
Jan/01	8601.817	7369.743	7580.288	7637.073	7695.717	7502.957
Fev/01	5482.212	5914.275	6134.958	6090.341	6172.800	6174.043
Mar/01	6823.903	8031.445	8282.597	8276.417	7984.534	8033.998
Abr/01	7714.506	6632.161	6719.514	6865.570	6933.975	7004.507
Mai/01	6826.406	6411.532	6631.480	6742.432	6880.899	6948.987
Jun/01	6685.793	5772.396	5740.327	5938.514	5795.065	5903.031
Jul/01	7430.427	6970.079	6992.659	7003.268	7241.442	7324.861
Ago/01	6967.576	5589.640	5988.012	5738.671	5821.796	5752.905
Set/01	6393.484	6101.619	6338.517	6443.712	5744.297	5709.419
Out/01	7762.130	5995.242	6622.864	6489.707	6491.241	6125.214
Nov/01	6419.178	5838.016	6401.639	6637.193	6728.080	6870.550
Dez/01	8740.033	8517.316	9066.964	9245.499	9016.431	8697.465
		EPAM-VEC01	EPAM-VEC02	EPAM-VEC03	EPAM-VEC04	EPAM-VEC05
		0.14323411	0.118757304	0.112155792	0.105338163	0.127747382
		0.078811783	0.119066154	0.110927651	0.125968843	0.126195576
		0.176957674	0.213762417	0.212856777	0.170083162	0.1773318
		0.140300001	0.128976787	0.110044143	0.101177081	0.092034305
		0.06077485	0.028554674	0.012301319	0.007982707	0.017956916
		0.136617676	0.141414265	0.111771259	0.133227053	0.117078483
		0.061954414	0.058915558	0.05748778	0.025433902	0.014207225
		0.197764	0.140588879	0.176374782	0.164444521	0.174331891
		0.045650447	0.008597409	0.007856061	0.101538911	0.106994152
		0.22762922	0.146772291	0.163926989	0.163729363	0.210884847
		0.090535268	0.002732281	0.033963071	0.048121738	0.070316168
		0.025482398	0.037406152	0.05783342	0.031624366	0.004870462
		0.115475987	0.095462014	0.097291587	0.098222484	0.103329101

Tabela 14: Comparação para a escolha do modelo de correção de erro

Feita a escolha do modelo de correção de erro reestimou-se o modelo VEC02 levando-se em consideração todo o período amostral (1994:08 a 2001:12) a fim de obter a previsão mensal *ex-ante* para o ano de 2002 (essa estimativa encontra-se no anexo 3, tabela 28). Os resultados obtidos estão resumidos na tabela abaixo:

PERÍODO	VEC
Jan/02	7389.733
Fev/02	8141.013
Mar/02	7889.312
Abr/02	8256.701
Mai/02	8490.893
Jun/02	7723.063
Jul/02	7934.850
Ago/02	8124.166
Set/02	7677.810
Out/02	8320.435
Nov/02	8258.538
Dez/02	8359.643

Tabela 15: Resultados de previsão para o ano de 2002 (Método: Modelo de correção de erro)

Resultados da Previsão Utilizando a Técnica de Combinação de Previsões

Elaborada as três previsões da série do imposto de renda para o período de 2002, partiu-se para a obtenção da previsão desta série por meio da técnica da combinação de previsões. Em outras palavras, tendo em mãos as previsões oriundas dos três métodos buscou-se combinar esses três resultados por meio de uma média ponderada variável a fim de alcançar melhores resultados de predição.

Inicialmente, devido aos melhores resultados conseguidos, se utilizou ponderação diferente para cada mês. A técnica escolhida para a determinação dos pesos foi definida pelo critério da ponderação inversa ao erro quadrático médio (EQM) em que, para cada mês, os resultados de previsão mais acurados obtiveram maiores pesos. Desta forma, para cada mês utilizou-se a seguinte fórmula para se determinar os pesos:

$$W_{(j)} = \frac{(e_{(j)}^2)^{-1}}{\sum_{j=1}^p (e_{(j)}^2)^{-1}} \quad (\text{eq. IV-02})$$

em que: $e_{(j)}^2$ é o erro quadrático médio de previsão da j-ésima técnica.

Os resultados dos pesos que comporam o modelo de combinação encontram-se abaixo sendo que W1, W2 e W3 são os pesos para a técnica de alisamento exponencial, modelos ARIMA e modelo de correção de erros, respectivamente:

PERÍODO	W1	W2	W3
Jan/01	0,284702381	0,338953626	0,376343993
Fev/01	0,165660375	0,252509389	0,581830236
Mar/01	0,461335414	0,30709539	0,231569196
Abr/01	0,421918556	0,561430454	0,016650989
Mai/01	0,027606005	0,257054221	0,715339774
Jun/01	0,939763661	0,05677256	0,003463779
Jul/01	0,31768619	0,348586327	0,333727483
Ago/01	0,458975744	0,426709977	0,114314279
Set/01	0,177772705	0,216438201	0,605789094
Out/01	0,300701464	0,308962206	0,39033633
Nov/01	0,010553248	0,013441469	0,976005283
Dez/01	0,203416845	0,609369467	0,187213688

Tabela 16: Resultado do cálculo dos pesos do modelo de combinação de previsões

Os resultados da previsão *ex-post* da combinação de previsão são ilustrados a seguir onde se verifica que de fato esta técnica fornece um erro percentual absoluto médio (EPAM) menor comparada com os EPAM dos outros modelos analisados anteriormente:

PERÍODO	IR	IRHWAD	SARIMA	VEC	C.P.	EPAM
Jan/01	8601,817	7427,332	7525,419	7580,288	7518,143167	0,125981968
Fev/01	5482,212	6705,512	6473,052	6134,958	6314,848041	0,151879577
Mar/01	6823,903	7857,369	8090,586	8282,597	8027,458572	0,176373488
Abr/01	7714,506	7912,169	7543,153	6719,514	7685,133291	0,003807465
Mai/01	6826,406	7818,662	7151,578	6631,480	6797,946881	0,004168975
Jun/01	6685,793	6628,393	6452,258	5740,327	6615,317299	0,010541113
Jul/01	7430,427	6981,743	7002,091	6992,659	6992,479087	0,058939804
Ago/01	6967,576	6478,712	6460,566	5988,012	6414,874938	0,079324727
Set/01	6393,484	6494,953	6301,524	6338,517	6358,32011	0,005499957
Out/01	7762,130	6464,124	6481,594	6622,864	6531,483715	0,158544921
Nov/01	6419,178	6250,508	6269,724	6401,639	6398,270946	0,003256968
Dez/01	8740,033	8426,393	8558,822	9066,964	8627,014848	0,01293109
						0,065937504

Tabela 17: Resultados de previsão para o ano de 2001 com respectivo cálculo do EPAM

Desta forma, elaborado o modelo de combinação de previsões pôde-se dispor dos resultados da série do imposto de renda para o ano de 2002. Abaixo se encontram os valores previstos por essa metodologia:

PERÍODO	C. P.
Jan/02	7805,23999
Fev/02	7544,61418
Mar/02	7973,67929
Abr/02	8134,67524
Mai/02	8230,94639
Jun/02	7001,36786
Jul/02	7547,53180
Ago/02	6990,26572
Set/02	7312,69090
Out/02	7527,95778
Nov/02	8216,29027
Dez/02	8668,04575

Tabela 18: Resultados de previsão para o ano de 2002 (Método: modelo de combinação de previsões)

Comparação dos Resultados de Previsão

Esta etapa possui dois objetivos fundamentais. O primeiro consiste em realizar uma comparação dos resultados de previsão da série do imposto de renda, para o ano de 2001, do presente trabalho com os resultados apresentados pelo modelo dinâmico de Siqueira (2002), no intuito de verificar qual das duas técnicas apresenta melhor performance. O segundo ponto essencial, por outro lado, consiste em elaborar uma comparação entre os resultados de previsão fornecidos pelo modelo de combinação de previsões com os valores reais observados do imposto de renda para os meses do ano de 2002. Esta última comparação tem por finalidade determinar o poder de predição do modelo para o período considerado.

Como dito anteriormente, objetivou-se, no tocante a primeira comparação, evidenciar o modelo que forneceu resultados mais satisfatórios. A tabela a seguir ilustra os resultados do cálculo do erro percentual absoluto médio (EPAM) de previsão para os dois modelos: i) EPAM 1, referente ao modelo de combinação; ii) e EPAM 2, referente ao modelo dinâmico de Siqueira:

PERÍODO	IR	C.P.	EPAM 1	EPAM 2
Jan/01	8601,817	7518,14316	0,12598196	0,090617
Fev/01	5482,212	6314,84804	0,15187957	0,0869021
Mar/01	6823,903	8027,45857	0,17637348	0,0823599
Abr/01	7714,506	7685,13329	0,00380746	0,0554795
Mai/01	6826,406	6797,94688	0,00416897	0,0932285
Jun/01	6685,793	6615,31729	0,01054111	0,1027397
Jul/01	7430,427	6992,47908	0,05893980	0,1386171
Ago/01	6967,576	6414,87493	0,07932472	0,074505
Set/01	6393,484	6358,32011	0,00549995	0,0901578
Out/01	7762,130	6531,48371	0,15854492	0,0984666
Nov/01	6419,178	6398,27094	0,00325696	0,1760072
Dez/01	8740,033	8627,01484	0,01293109	0,1134696
			0,0659375	0,1002125

Tabela 19: Resultados de previsão do modelo de combinação para o ano de 2001

Ao analisar a tabela acima, pode-se julgar os seus resultados de duas formas distintas. Inicialmente, através da análise da média global de todos os meses, em que se observa somente o desempenho médio dos modelos. O segundo julgamento, diferentemente do primeiro, pode ser realizado considerando-se as previsões individuais dos meses de 2001, destacando-se, para cada modelo, os meses em que os resultados se mostraram mais eficientes, isto é, apresentaram menores erros de predição.

De uma forma geral, como se pode constatar pela tabela, considerando a média de todos os meses previstos, a técnica de combinação de previsão apresentou erro percentual absoluto inferior ao do modelo elaborado por Siqueira (2002). Especificamente, o modelo de combinação forneceu um EPAM no valor de 6,59%, enquanto o modelo dinâmico gerou erro médio de previsão de 10,02%. Portanto, na média, a técnica de combinação apresentou resultado bastante superior quando confrontado com o modelo concorrente.

Por outro lado, ao realizar uma comparação individual dos resultados apresentados pelos dois modelos, verificou-se que para alguns meses o modelo dinâmico de Siqueira se mostrou mais competente. Observa-se que para os meses de janeiro, fevereiro, março, agosto e outubro, os resultados demonstrados por Siqueira (2002) foram mais consistentes (já que indicaram menores erros percentuais absolutos), muito embora, para o mês de agosto, admita-se a ocorrência de um empate técnico. Em contrapartida, para o restante do período (abril, maio, junho, julho, setembro, novembro

e dezembro) o modelo de combinação forneceu resultados mais eficientes que os do modelo de Siqueira (2002).

Portanto, após realizar esta primeira comparação, constatou-se que o modelo de combinação, tanto sob a ótica da média global como da média individual, forneceu melhores resultados de previsão para o imposto de renda.

Para analisar os resultados de predição do modelo de combinação, para o ano de 2002, confrontaram-se tais valores com os de fato realizados para esse período. Em outras palavras, fez-se o cálculo do erro percentual absoluto médio (EPAM) para todo ano de 2002. Abaixo se encontram os referidos cálculos:

PERÍODO	IR	C. P.	EPAM
Jan/02	12352,64	7805,23999	0,3681318
Fev/02	7923,264	7544,61418	0,0477896
Mar/02	7911,8	7973,67929	0,0078211
Abr/02	9497,264	8134,67524	0,1434717
Mai/02	7859,916	8230,94639	0,0472054
Jun/02	7022,601	7001,36786	0,0030235
Jul/02	8456,112	7547,53180	0,1074466
Ago/02	6383,094	6990,26572	0,0951219
Set/02	9443,574	7312,69090	0,2256437
Out/02	8684,596	7527,95778	0,1331827
Nov/02	6759,598	8216,29027	0,2154998
Dez/02	8186	8668,04575	0,0588866
			0,121102

Tabela 20: Comparação dos valores observados e previstos para o ano de 2002

Seguindo a análise anterior, para elaborar a comparação dos resultados, realizou-se os julgamentos pela média global do erro percentual absoluto e pelo erro percentual absoluto individual. Dessa forma, orientando-se pela tabela acima, observa-se que, em termos médios, o EPAM do modelo de combinação para o ano de 2002 foi de 12,11%. Obtém-se assim um pior resultado quando comparado ao EPAM para o ano de 2001, pois, para este último ano, o modelo apresentou um erro percentual absoluto médio de 6,59%.

Quando se analisa individualmente o resultado de previsão nota-se que se tem bons resultados para os meses de fevereiro março, maio, junho e dezembro. De outro modo, para estes meses o modelo apresentou pequenos erros de predição. Para os meses

de abril, julho, agosto e outubro, por outro lado, o erro absoluto de previsão possui média de aproximadamente 11,97%. Assim, para esses quatro meses o modelo de combinação revelou, na média, erros considerados razoáveis. No que se refere aos erros percentuais absolutos para os restantes dos meses do ano, no entanto, os mesmos não se mostraram satisfatórios, pois apresentaram valores significativamente altos sendo, conseqüentemente, inapropriado para realizar previsões para esses meses.

5 CONCLUSÕES

O principal objetivo do presente trabalho foi realizar previsões mensais da série do imposto de renda (IR) para o ano de 2002. Na busca desse objetivo, utilizou-se a técnica de combinação de previsões, que, de uma forma bastante simples, consiste em se combinar adequadamente vários resultados de previsões oriundos de diferentes metodologias. Ainda como parte integrante do trabalho, realizou-se, a fim de analisar o desempenho e a acurácia do modelo de combinação, dois tipos de comparações. A primeira consistiu em confrontar os resultados de predição, para o ano de 2001, do presente trabalho com os resultados apresentados por Siqueira (2002). Com base no critério do erro percentual absoluto médio (EPAM), buscou-se verificar qual modelo forneceria melhores resultados futuros (menores erros de predição) para a série imposto de renda. A segunda foi realizada comparando-se os resultados de previsão advindos da técnica de combinação com os reais valores observados da série imposto de renda para os meses do ano de 2002.

Com respeito aos meios usados para a obtenção de previsões, na utilização da técnica de alisamento exponencial, adotou-se o modelo de Alisamento Exponencial Sazonal de Holt-Winters Aditivo, pois, como visto no decorrer do trabalho, além da série do imposto de renda apresentar forte padrão sazonal, a análise dos resultados da previsão *ex-post*, através da verificação do erro percentual absoluto médio, mostraram-se superiores ao modelo de Alisamento Exponencial de Holt-Winters Multiplicativo. Quanto à aplicação dos modelos ARIMA, na tentativa de se chegar aos resultados de previsão, seguiu-se cada etapa proposta pela metodologia de Box-Jenkins. Primeiramente, identificou-se, por meio da análise das funções amostrais de autocorrelação e autocorrelação parcial, dois modelos capazes de gerar previsões da série IR. Em seguida, reduzindo-se o tamanho da amostra em um ano, os modelos foram estimados com o intuito de verificar o que apresentou menor erro percentual absoluto médio para a previsão *ex-post*. A última etapa, anterior a elaboração da previsão, constituiu-se na análise dos resíduos (etapa da checagem de diagnóstico) onde se elegeu definitivamente o melhor modelo SARIMA capaz de realizar a previsão mensal da série em discussão para o ano de 2002. No tocante ao modelo de correção de erro, após a constatação de todos os requisitos necessários para a construção do mesmo (testes de

Dickey-Fuller e Johansen), selecionou-se e estimou-se cinco modelos com diferentes defasagens. Através do critério do EPAM, escolheu-se somente um modelo e novamente o estimou-se para que se obtivesse as previsões para o ano de 2002. Por último, de posse dos três resultados de previsão, elaborou-se um modelo de combinação de previsão com ponderação variável no decorrer dos meses.

A principal conclusão que se verificou nesta primeira etapa do trabalho foi a de que, conforme explica a teoria econométrica sobre combinação de previsões e como demonstra trabalhos empíricos nessa área, o resultado de previsão oriundo dessa técnica foi a que apresentou melhor desempenho, tendo em vista que o critério adotado para a mensuração do erro de predição *ex-post* (EPAM) do modelo de combinação, quando comparado aos demais modelos individuais, foi o menor (6,59%).

Acerca da segunda etapa do trabalho, as conclusões que se chegaram foram as seguintes. No que se refere à análise dos resultados da primeira comparação, de uma forma geral, considerando a média global dos meses previstos, a técnica de combinação de previsão apresentou erro percentual absoluto médio menor que o do modelo demonstrado por Siqueira (2002). Ou seja, isto indica que o modelo de combinação prevê em média melhor que o modelo dinâmico de Siqueira. Na análise realizada sob a ótica individual dos meses, deve-se ressaltar, entretanto, que a previsão de alguns meses do modelo dinâmico de Siqueira (2002) apresentou melhores resultados (janeiro, fevereiro, março, agosto e outubro), mas que para os restantes dos meses do ano de 2001 o modelo de combinação forneceu resultados superiores.

Quando se confrontam os resultados de previsão gerados pela técnica de combinação com os reais valores observados para o ano de 2002 e se analisam os resultados pela média global, embora na média, quando comparado ao erro de predição para o ano de 2001, o erro percentual absoluto tenha aumentado (de 6,59% para 12,11%), observa-se que este modelo ainda pode ser utilizado satisfatoriamente para realizar previsões. Deve-se atentar para o fato de que individualmente os erros de previsão para os meses de janeiro, setembro e novembro foram consideravelmente altos. Para a maior parte dos meses, no entanto, o modelo forneceu resultados razoáveis.

Portanto, quando comparado ao modelo dinâmico de Siqueira o modelo de combinação de previsões proposto por este trabalho fornece em média melhores previsões para o imposto de renda. Ainda, como se observou na comparação com valores reais do imposto de renda para o ano de 2002, o mesmo pode fornecer bons resultados para previsões *ex-ante* desta variável.

REFERÊNCIA BIBLIOGRÁFICA

- BARTLETT, M. S. **On the Theoretical Specification and Sampling Properties of Autocorrelated Time Serie**. Journal of the Royal Statistical Society. B2: 27-41, 1946.
- BATES, J. M. & GRANGER, C. W. J. **The Combination of Forecasts**. Operational Research Quaterly, Vol. 20, 451 – 468, 1969.
- BOX, G. E. P.; JENKINS, G. M. & REINSEL, G. C. **Time Series Analysis: Forecasting and Control**. New Jersey, Prentice Hall, 1994.
- CASTELAR, I. & MYNBAEV, K. T. **Two Essays on Econometrics**. Fortaleza: CAEN, 2001.
- CHARENZA, W. W. & DEADMAN, D. F. **New Directions in Econometric Practice**. Edward Elgar Publishing, 1997.
- CHIMENTE, R. C. **Direito Tributário**. Editora Saraiva, 2001 – Coleção Sinopses Jurídicas, vol. 16.
- CONSTITUIÇÃO FEDERAL – CÓDIGO COMERCIAL**. Organizadora: Vera Helena de Mello Franco – **CÓDIGO TRIBUTÁRIO NACIONAL**. Organizador: Roque Antonio Carrazza. 5ª ed. Ver. Atual. E ampl. São Paulo: RT, 2003.
- ENDERS, W. **Applied Econometric Time Series**. John Wiley & Sons, inc, 1995.
- FERREIRA, R. T. **Modelos de Análise de Séries Temporais para Previsão do ICMS Mensal do Estado do Ceará**. 1996, 93p. Dissertação (Mestrado em Economia). Universidade Federal do Ceará.
- FULLER, W. A. **Introduction to Statistical Time Series**. New York. Jonh Wiley and Sons, 1996.
- GIAMBIAGI, F. & Além, A. C. **Finanças Públicas: Teoria e Prática no Brasil**. Editora Campus, 1999.
- GRANGER, C. W. J. & NEWBOLD, P. **Forecasting Economic Time Series**. Academic Press – second edition, 1986.
- GRANGER, C. W. J. & RAMANATHAN, R. , **Improved Methods for Combinig Forecasts**. Journal of Forecasting, Vol. 3, 197 – 204, 1984.
- GREENE, W. H. **Econometrics Analysis**. New York: Macmillian Publishing Company, 1993.

- GUJARATI, D. N. **Econometria Básica**. São Paulo: Makron Books, 2000.
- HAMILTON, J. D. **Times Series Analysis**. New Jersey: Princeton University Press, 1994.
- HANKE, J. E. & REITSCH, A. G. **Business Forecasting**. Allyn and Bacon, 1992.
- JOHSTON, J. & DINARDO, J. **Métodos Econométricos**. Portugal: MacGraw-Hill, 2001.
- JONHSTON, J. **Econometric Methods**. Singapore: McGraw-Hill, 1987.
- KMENTA, J. **Elementos de Econometria**. São Paulo: Atlas, 1994.
- MACHADO, H. de B. **Curso de Direito Tributário**. Malheiros Editores, 2002.
- MADDALA, G. S. **Introduction to Econometrics**. New York: Macmillian Publishing Company, 1992.
- MAKRIDAKIS, S. & WINKLER, R. L. **The Combination of Forecasts**. Journal of the Royal Statistical Society A., Part 2 146. 1983.
- MORETTIN, P. A. e Toloi, C. M. de C. **Previsão de Séries Temporais**. Atual Editora, 1987.
- MORETTIN, P. A. **Ondas e Ondaletas: Da Análise de Fourier à Análise de Ondaletas**. Edusp, 1999.
- MUSGRAVE, R. A. & MUSGRAVE, P. B. **Finanças Públicas: Teoria e Prática**. Editora Campus, 1980.
- PINDYCK, R. & RUBINFELD, D. L. **Econometrics Models and Economic Forecasts**. New York: McGraw-Hill, 1998.
- RIANI, F. **Economia do Setor Público: Uma Abordagem Introdutória**. Editora Atlas, 2002.
- SIQUEIRA, M. L. **Melhorando a Previsão da Arrecadação Tributária Federal através da Atualização de Modelos de Séries Temporais**. ESAF, 2002 (Monografia – VII Prêmio do Tesouro Nacional).
- VASCONCELLOS, M. A. S. & ALVES, D. **Manual de Econometria**. São Paulo: Atlas, 2000.
- VÉLEZ, E. C. & VELANDIA, L. F. M. **Métodos de Combinación de Prognósticos: Una aplicación a la inflación colombiana**. Banco De La Republica (Subgerencia de estudios Económicos).

ANEXO 1

Tabela 21: Correlograma de IR

Sample: 1990:01 2001:12

Included observations: 144

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
. ****	. ****	1	0.546	0.546	43.843	0.000
. ***	. *	2	0.418	0.171	69.720	0.000
. ****	. **	3	0.470	0.276	102.70	0.000
. ***	. .	4	0.363	0.004	122.47	0.000
. **	. .	5	0.315	0.048	137.50	0.000
. ***	. *	6	0.330	0.068	154.05	0.000
. ***	. *	7	0.337	0.103	171.43	0.000
. **	. .	8	0.309	0.042	186.17	0.000
. ***	. *	9	0.378	0.167	208.41	0.000
. **	. .	10	0.310	-0.045	223.52	0.000
. ***	. *	11	0.365	0.169	244.63	0.000
. ****	. ***	12	0.575	0.374	297.30	0.000
. ***	. *	13	0.415	-0.067	324.88	0.000
. **	. *	14	0.316	-0.087	341.07	0.000
. ***	. .	15	0.349	-0.046	360.94	0.000
. **	. *	16	0.255	-0.100	371.61	0.000
. *	. .	17	0.184	-0.057	377.20	0.000
. *	. *	18	0.190	-0.064	383.24	0.000
. **	. *	19	0.242	0.069	393.08	0.000
. **	. .	20	0.202	-0.023	399.98	0.000
. **	. .	21	0.251	0.035	410.77	0.000
. **	. .	22	0.211	-0.031	418.43	0.000
. **	. .	23	0.235	0.039	428.04	0.000
. ***	. *	24	0.382	0.099	453.65	0.000
. **	. *	25	0.231	-0.148	463.07	0.000
. *	. *	26	0.164	-0.069	467.87	0.000
. **	. .	27	0.218	0.011	476.41	0.000
. *	. .	28	0.172	0.032	481.77	0.000
. *	. *	29	0.144	0.121	485.58	0.000
. *	. .	30	0.128	-0.032	488.59	0.000
. *	. .	31	0.153	-0.018	492.96	0.000
. *	. *	32	0.167	0.069	498.16	0.000
. **	. *	33	0.216	0.067	507.01	0.000
. *	. .	34	0.185	0.022	513.58	0.000
. *	. *	35	0.137	-0.136	517.19	0.000
. **	. *	36	0.282	0.067	532.71	0.000

Tabela 22: Correlograma de D(IR)

Sample: 1990:01 2001:12

Included observations: 143

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
*** .	*** .	1	-0.352	-0.352	18.079	0.000
** .	*** .	2	-0.210	-0.382	24.593	0.000
. *	* .	3	0.180	-0.076	29.380	0.000
* .	* .	4	-0.071	-0.125	30.126	0.000
* .	* .	5	-0.059	-0.116	30.652	0.000
. .	* .	6	0.015	-0.134	30.684	0.000
. .	* .	7	0.038	-0.058	30.903	0.000
* .	** .	8	-0.116	-0.193	32.987	0.000
. *	. .	9	0.161	0.040	37.021	0.000
* .	* .	10	-0.128	-0.168	39.559	0.000
** .	*** .	11	-0.203	-0.382	46.037	0.000
. ***	. *	12	0.421	0.076	74.056	0.000
. .	. *	13	-0.049	0.097	74.440	0.000
* .	. *	14	-0.152	0.067	78.140	0.000
. *	. *	15	0.141	0.128	81.371	0.000
. .	. *	16	-0.028	0.073	81.497	0.000
* .	. .	17	-0.091	0.057	82.870	0.000
. .	* .	18	-0.046	-0.084	83.221	0.000
. *	. .	19	0.109	0.017	85.193	0.000
* .	. .	20	-0.106	-0.036	87.088	0.000
. *	. .	21	0.088	-0.001	88.408	0.000
. .	* .	22	-0.054	-0.069	88.903	0.000
* .	* .	23	-0.154	-0.110	93.026	0.000
. ***	. *	24	0.333	0.149	112.31	0.000
* .	. *	25	-0.068	0.074	113.14	0.000
* .	. .	26	-0.144	-0.012	116.83	0.000
. *	* .	27	0.096	-0.061	118.49	0.000
. .	* .	28	-0.006	-0.142	118.50	0.000
. .	. .	29	-0.019	-0.003	118.57	0.000
. .	. .	30	-0.045	0.014	118.93	0.000
. .	* .	31	0.016	-0.074	118.98	0.000
. .	* .	32	-0.054	-0.083	119.52	0.000
. *	. .	33	0.079	-0.052	120.69	0.000
. .	. *	34	0.025	0.086	120.81	0.000
** .	* .	35	-0.214	-0.080	129.63	0.000
. **	. *	36	0.324	0.116	150.01	0.000

Tabela 23: Correlograma de IR(-12)

Sample: 1990:01 2001:12
 Included observations: 132

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
.**	.**	1	0.312	0.312	13.145	0.000
.*	.*	2	0.189	0.101	17.987	0.000
.*	.*	3	0.187	0.115	22.807	0.000
.*	.	4	0.144	0.050	25.667	0.000
.*	.	5	0.080	-0.006	26.559	0.000
.*	.*	6	0.136	0.089	29.169	0.000
.*	.	7	0.113	0.032	30.974	0.000
.	.	8	0.058	-0.015	31.447	0.000
.*	.*	9	0.116	0.075	33.388	0.000
.	.	10	0.044	-0.043	33.665	0.000
.	*	11	-0.028	-0.070	33.778	0.000
**	**	12	-0.196	-0.234	39.437	0.000
.*	.**	13	0.136	0.276	42.197	0.000
.	.	14	0.057	0.000	42.692	0.000
.	.	15	-0.003	-0.024	42.693	0.000
*	*	16	-0.094	-0.158	44.027	0.000
*	*	17	-0.176	-0.176	48.778	0.000
*	.	18	-0.146	0.006	52.090	0.000
.	.*	19	-0.039	0.088	52.331	0.000
*	*	20	-0.110	-0.078	54.231	0.000
*	.	21	-0.154	-0.056	58.015	0.000
*	*	22	-0.132	-0.126	60.799	0.000
.	.*	23	-0.009	0.143	60.813	0.000
*	*	24	-0.114	-0.135	62.952	0.000
*	.*	25	-0.134	0.120	65.915	0.000
.	.*	26	0.031	0.118	66.077	0.000
.	.*	27	0.055	0.077	66.580	0.000
.*	.*	28	0.174	0.145	71.725	0.000
.**	.*	29	0.216	0.096	79.748	0.000
.*	.	30	0.103	0.047	81.584	0.000
.	.	31	0.009	0.016	81.599	0.000
.*	*	32	0.093	-0.069	83.124	0.000
.*	.	33	0.086	0.022	84.439	0.000
.*	.	34	0.149	0.054	88.436	0.000
.	.	35	0.024	-0.044	88.537	0.000
.*	.	36	0.144	0.001	92.344	0.000

Tabela 24: Correlograma de D(IR(-12))

Sample: 1990:01 2001:12

Included observations: 131

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
*** .	*** .	1	-0.434	-0.434	25.261	0.000
* .	*** .	2	-0.071	-0.320	25.949	0.000
. .	** .	3	0.015	-0.226	25.981	0.000
. .	* .	4	0.014	-0.154	26.007	0.000
. .	* .	5	-0.049	-0.181	26.341	0.000
. .	* .	6	0.062	-0.087	26.872	0.000
. .	. .	7	0.013	-0.024	26.897	0.000
* .	* .	8	-0.091	-0.118	28.082	0.000
. *	. .	9	0.099	0.000	29.479	0.001
. .	. .	10	-0.004	0.035	29.481	0.001
. *	. *	11	0.076	0.195	30.314	0.001
*** .	*** .	12	-0.381	-0.340	51.527	0.000
. **	* .	13	0.314	-0.070	66.112	0.000
. .	. .	14	-0.016	-0.027	66.148	0.000
. .	. *	15	0.015	0.080	66.184	0.000
. .	. *	16	0.010	0.120	66.198	0.000
* .	. .	17	-0.089	-0.032	67.402	0.000
* .	* .	18	-0.059	-0.119	67.937	0.000
. *	. .	19	0.140	0.044	70.991	0.000
. .	. .	20	-0.013	0.001	71.018	0.000
. .	. *	21	-0.051	0.071	71.426	0.000
* .	* .	22	-0.071	-0.164	72.232	0.000
. *	. *	23	0.162	0.120	76.472	0.000
. .	* .	24	-0.051	-0.117	76.889	0.000
* .	* .	25	-0.137	-0.125	79.981	0.000
. *	* .	26	0.099	-0.072	81.596	0.000
* .	* .	27	-0.085	-0.149	82.803	0.000
. *	* .	28	0.068	-0.070	83.585	0.000
. *	. .	29	0.110	0.001	85.648	0.000
. .	. .	30	-0.022	0.028	85.734	0.000
* .	. *	31	-0.134	0.106	88.881	0.000
. *	. .	32	0.073	0.017	89.825	0.000
. .	. .	33	-0.054	-0.038	90.340	0.000
. *	. .	34	0.143	0.060	94.037	0.000
* .	. .	35	-0.177	-0.013	99.716	0.000
. *	. .	36	0.102	0.011	101.62	0.000

Tabela 25: Correlograma dos resíduos do modelo IR01

Sample: 1990:01 2001:12

Included observations: 131

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
. .	. .	1	0.044	0.044	0.2541	0.614
* .	* .	2	-0.106	-0.108	1.7770	0.411
. .	. .	3	-0.017	-0.007	1.8165	0.611
* .	* .	4	-0.089	-0.101	2.9017	0.574
* .	* .	5	-0.104	-0.100	4.4054	0.493
. *	. *	6	0.084	0.074	5.3942	0.494
. .	* .	7	-0.034	-0.069	5.5576	0.592
* .	* .	8	-0.141	-0.136	8.3856	0.397
. *	. .	9	0.077	0.066	9.2306	0.416
. .	* .	10	-0.025	-0.065	9.3187	0.502
* .	* .	11	-0.073	-0.058	10.088	0.523
. .	. .	12	0.044	0.006	10.373	0.583
. *	. *	13	0.195	0.178	16.009	0.249
. .	. .	14	-0.045	-0.042	16.311	0.295
. .	. .	15	-0.003	-0.003	16.312	0.362
* .	* .	16	-0.067	-0.083	16.998	0.386
** .	* .	17	-0.224	-0.175	24.644	0.103
. .	. .	18	-0.046	-0.047	24.972	0.126
. .	. .	19	0.038	-0.050	25.196	0.154
* .	* .	20	-0.120	-0.141	27.471	0.123
. .	. .	21	-0.018	-0.029	27.523	0.154
. .	* .	22	-0.040	-0.165	27.782	0.183
. .	. .	23	0.037	0.059	28.001	0.216
. *	. .	24	0.088	0.022	29.257	0.211
. .	* .	25	-0.036	-0.148	29.474	0.245
* .	* .	26	-0.062	-0.089	30.112	0.263
. .	* .	27	-0.021	-0.077	30.189	0.306
. *	. *	28	0.127	0.083	32.914	0.239
. *	. *	29	0.074	0.078	33.837	0.245
. .	. *	30	0.047	0.068	34.214	0.272
* .	* .	31	-0.076	-0.066	35.210	0.276
. .	. .	32	-0.055	-0.053	35.738	0.297
. .	. .	33	0.040	0.057	36.020	0.329
. *	. *	34	0.110	0.073	38.188	0.285
. .	. .	35	-0.050	-0.057	38.649	0.308
. *	. *	36	0.163	0.168	43.496	0.182

Tabela 26: Correlograma dos resíduos do modelo IR02

Sample: 1990:01 2001:12

Included observations: 130

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
* .	* .	1	-0.133	-0.133	2.3631	0.124
*** .	*** .	2	-0.352	-0.377	19.020	0.000
. .	* .	3	0.046	-0.082	19.301	0.000
. .	** .	4	-0.034	-0.207	19.460	0.001
* .	* .	5	-0.086	-0.181	20.482	0.001
. *	. .	6	0.157	0.019	23.909	0.001
. .	* .	7	-0.021	-0.100	23.972	0.001
* .	* .	8	-0.158	-0.154	27.486	0.001
. *	. .	9	0.134	0.027	30.033	0.000
. .	* .	10	-0.022	-0.122	30.103	0.001
* .	* .	11	-0.153	-0.162	33.466	0.000
. *	* .	12	0.067	-0.115	34.128	0.001
. **	. *	13	0.208	0.093	40.457	0.000
* .	. .	14	-0.094	-0.035	41.763	0.000
. .	. *	15	0.037	0.116	41.970	0.000
. .	. .	16	0.017	0.039	42.012	0.000
** .	* .	17	-0.203	-0.093	48.249	0.000
. .	. .	18	0.044	-0.003	48.546	0.000
. *	. .	19	0.136	-0.009	51.386	0.000
* .	. .	20	-0.093	-0.049	52.744	0.000
. .	. .	21	0.000	0.017	52.744	0.000
. .	* .	22	-0.042	-0.188	53.024	0.000
. .	. *	23	0.043	0.094	53.320	0.000
. *	. *	24	0.119	0.104	55.600	0.000
. .	. .	25	-0.046	-0.018	55.939	0.000
* .	* .	26	-0.136	-0.075	58.986	0.000
. .	* .	27	-0.032	-0.146	59.158	0.000
. *	. .	28	0.124	-0.038	61.742	0.000
. .	. .	29	0.049	0.021	62.157	0.000
. .	. *	30	0.027	0.106	62.280	0.000
* .	. .	31	-0.091	-0.022	63.710	0.000
* .	* .	32	-0.084	-0.064	64.938	0.001
. *	. .	33	0.070	0.032	65.807	0.001
. *	. .	34	0.080	0.028	66.960	0.001
* .	* .	35	-0.139	-0.079	70.458	0.000
. *	. *	36	0.140	0.138	74.012	0.000

ANEXO 2

Tabela 27: Estimação do modelo IR01 (SARIMA(0,1,1)(0,1,2)₁₂)

Dependent Variable: D(IR,1,12)

Method: Least Squares


Sample(adjusted): 1991:02 2001:12

Included observations: 131 after adjusting endpoints

Failure to improve SSR after 23 iterations

Backcast: 1989:01 1991:01

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-3.235411	6.184216	-0.523172	0.6018
MA(1)	-0.799469	0.050073	-15.96597	0.0000
SMA(12)	-0.656989	0.053742	-12.22484	0.0000
SMA(24)	-0.202674	0.006299	-32.17331	0.0000
R-squared	0.577326	Mean dependent var		21.44249
Adjusted R-squared	0.567341	S.D. dependent var		1618.858
S.E. of regression	1064.833	Akaike info criterion		16.80908
Sum squared resid	1.44E+08	Schwarz criterion		16.89687
Log likelihood	-1096.995	F-statistic		57.82259
Durbin-Watson stat	1.854725	Prob(F-statistic)		0.000000
Inverted MA Roots	.99	.86+.49i	.86 -.49i	.85 -.23i
	.85+.23i	.80	.63+.63i	.63+.63i
	.49 -.86i	.49+.86i	.23 -.85i	.23+.85i
	.00 -.99i	-.00+.99i	-.23 -.85i	-.23+.85i
	-.49 -.86i	-.49+.86i	-.63 -.63i	-.63+.63i
	-.85+.23i	-.85 -.23i	-.86+.49i	-.86 -.49i
	-.99			

Gráfico 10: Resíduos do Modelo IR01 (SARIMA(0,1,1)(0,1,2)₁₂)

ANEXO 3

Tabela 28: Estimação do modelo de correção de erro

Sample(adjusted): 1994:12 2001:12

Included observations: 85 after adjusting endpoints

Standard errors & t-statistics in parentheses

Cointegrating Eq:	CointEq1	
IRSA(-1)	1.000000	
PIBSA(-1)	0.042570 (0.05982) (0.71166)	
C	-12445.36 (8104.50) (-1.53561)	
Error Correction:	D(IRSA)	D(PIBSA)
CointEq1	-0.191577 (0.09548) (-2.00642)	-0.950286 (0.34016) (-2.79360)
D(IRSA(-1))	-0.558888 (0.12388) (-4.51156)	0.346416 (0.44133) (0.78493)
D(IRSA(-2))	-0.429707 (0.12107) (-3.54932)	0.081182 (0.43132) (0.18822)
D(IRSA(-3))	-0.181639 (0.10643) (-1.70660)	-0.310468 (0.37918) (-0.81879)
D(PIBSA(-1))	-0.036279 (0.02768) (-1.31051)	0.109338 (0.09862) (1.10864)
D(PIBSA(-2))	0.021384 (0.02752) (0.77715)	-0.093284 (0.09803) (-0.95161)
D(PIBSA(-3))	0.054936 (0.02714) (2.02415)	-0.416258 (0.09669) (-4.30504)
R-squared	0.410845	0.298880
Adj. R-squared	0.365525	0.244948
Sum sq. resids	68911801	8.75E+08
S.E. equation	939.9386	3348.633
F-statistic	9.065504	5.541763
Log likelihood	-698.8515	-806.8433
Akaike AIC	16.60827	19.14926
Schwarz SC	16.80943	19.35041
Mean dependent	23.87201	232.8375
S.D. dependent	1180.028	3853.710
Determinant Residual Covariance		8.26E+12
Log Likelihood		-1505.255
Akaike Information Criteria		35.81777
Schwarz Criteria		36.30630

ANEXO 4

Tabela 29: Série Imposto de Renda

Data	IR (milhões)	IR (R\$)	IGP-DI	IR DEFLACIONADO
jan/90	33723	0.01226291	0.0005	6638.942775
fev/90	60779	0.02210145	0.0008	7478.358667
mar/90	85678	0.03115564	0.0015	5622.387679
abr/90	180495	0.06563455	0.0017	10451.02728
mai/90	179636	0.06532218	0.0018	9823.440023
jun/90	81164	0.02951418	0.002	3994.626452
jul/90	88631	0.03222945	0.0022	3965.570686
ago/90	102504	0.03727418	0.0025	4035.92913
set/90	106304	0.038656	0.0028	3737.096411
out/90	127528	0.04637382	0.0032	3922.819247
nov/90	148672	0.05406255	0.0038	3851.131198
dez/90	209874	0.07631782	0.0044	4695.141554
jan/91	214624	0.07804509	0.0053	3986.072028
fev/91	201711	0.07334945	0.0064	3102.361023
mar/91	253054	0.09201964	0.0068	3663.085207
abr/91	490807	0.17847527	0.0074	6528.625476
mai/91	464111	0.16876764	0.0079	5782.791016
jun/91	429537	0.15619527	0.0087	4859.863306
jul/91	510681	0.18570218	0.0098	5129.397449
ago/91	451542	0.16419709	0.0113	3933.348578
set/91	378195	0.13752545	0.0132	2820.230329
out/91	531944	0.19343418	0.0166	3154.282262
nov/91	582267	0.21173345	0.0208	2755.507321
dez/91	1062317	0.38629709	0.0255	4100.687535
jan/92	767000	0.27890909	0.0323	2337.413611
fev/92	1039000	0.37781818	0.0403	2537.775664
mar/92	1430000	0.52	0.0486	2896.293004
abr/92	2811000	1.02218182	0.0576	4803.757652
mai/92	4353000	1.58290909	0.0706	6069.133536
jun/92	3886000	1.41309091	0.0857	4463.388616
jul/92	4832000	1.75709091	0.1043	4560.215267
ago/92	5822000	2.11709091	0.1309	4377.995205
set/92	6789000	2.46872727	0.1667	4008.78658
out/92	8911000	3.24036364	0.2083	4210.948216
nov/92	10940000	3.97818182	0.2588	4160.981425
dez/92	15252000	5.54618182	0.3201	4690.118865
jan/93	18807000	6.83890909	0.4121	4492.205726
fev/93	24813000	9.02290909	0.5213	4685.266272
mar/93	28659000	10.4214545	0.6663	4233.83517
abr/93	39013000	14.1865455	0.8543	4495.123917
mai/93	80633000	29.3210909	1.13	7023.880301
jun/93	70968000	25.8065455	1.4771	4729.284004
jul/93	76974000	27.9905455	1.9492	3887.141766
ago/93	90934	33.0669091	2.6027	3439.10084
set/93	136752	49.728	3.5655	3775.33916
out/93	184767	67.188	4.8184	3774.542192
nov/93	280570	102.025455	6.5992	4184.973079

dez/93	488851	177.764	8.9895	5352.833048
jan/94	657793	239.197455	12.7822	5065.547196
fev/94	749181	272.429455	18.2031	4051.204131
mar/94	970578	352.937455	26.3635	3623.849089
abr/94	2077455	755.438182	37.5575	5444.74665
mai/94	2356356	856.856727	52.9373	4381.490201
jun/94	3459219	1257.89782	77.5954	4388.183787
jul/94	1358	1358	96.7693	3798.722694
ago/94	1476	1476	100	3995.41392
set/94	1529	1529	101.549	4075.747353
out/94	1439	1439	104.143	3740.29736
nov/94	1514	1514	106.72	3840.214468
dez/94	2397	2397	107.325	6045.643829
jan/95	2369	2369	108.785	5894.832449
fev/95	1846	1846	110.039	4541.093903
mar/95	2621	2621	112.035	6332.697211
abr/95	1922	1922	114.614	4539.323503
mai/95	3358	3358	115.071	7899.329423
jun/95	2323	2323	118.09	5324.900635
jul/95	2270	2270	120.733	5089.501959
ago/95	2394	2394	122.289	5299.222726
set/95	2311	2311	120.967	5171.40387
out/95	2289	2289	121.241	5110.597801
nov/95	2342	2342	122.85	5160.444965
dez/95	2926	2926	123.187	6429.613449
jan/96	2441	2441	125.397	5269.337959
fev/96	2008	2008	126.353	4301.833245
mar/96	4880	4880	126.627	10432.03235
abr/96	2462	2462	127.509	5226.640504
mai/96	2592	2592	129.655	5411.543434
jun/96	2358	2358	131.24	4863.545687
jul/96	2675	2675	132.674	5457.746808
ago/96	2341	2341	132.679	4776.113567
set/96	2488	2488	132.849	5069.52778
out/96	2450	2450	133.141	4981.15081
nov/96	2472	2472	133.517	5011.726027
dez/96	4529	4529	134.689	9102.184054
jan/97	3088	3088	136.814	6109.732162
fev/97	2349	2349	137.39	4628.106179
mar/97	3135	3135	138.99	6105.614936
abr/97	3371	3371	139.807	6526.87442
mai/97	2636	2636	140.229	5088.420455
jun/97	2660	2660	141.207	5099.185734
jul/97	3227	3227	141.33	6180.733631
ago/97	2604	2604	141.268	4989.678965
set/97	2749	2749	142.101	5236.643711
out/97	3188	3188	142.587	6052.207396
nov/97	2760	2760	143.771	5196.527255
dez/97	4756	4756	144.765	8893.110572
jan/98	5074	5074	146.038	9405.026144
fev/98	3498	3498	146.067	6482.508821
mar/98	4715	4715	146.408	8717.507103

abr/98	3836	3836	146.211	7101.890501
mai/98	2785	2785	146.544	5144.374522
jun/98	2883	2883	146.951	5310.648012
jul/98	4214	4214	146.398	7791.74639
ago/98	4001	4001	146.144	7410.763986
set/98	3631	3631	146.111	6726.958627
out/98	3358	3358	146.063	6223.230633
nov/98	3067	3067	145.797	5694.303477
dez/98	4758	4758	147.231	8747.835279
jan/99	4199	4199	148.921	7632.474319
fev/99	4881	4881	155.528	8495.239777
mar/99	5333	5333	158.6	9102.146507
abr/99	4517	4517	158.647	7707.147088
mai/99	3542	3542	158.1	6064.459608
jun/99	3741	3741	159.711	6340.56998
jul/99	4025	4025	162.253	6715.039475
ago/99	3327	3327	164.612	5471.000194
set/99	4752	4752	167.028	7701.273942
out/99	3932	3932	170.182	6254.251002
nov/99	3499	3499	174.496	5427.925614
dez/99	5769	5769	176.647	8840.354764
jan/00	5050	5050	178.454	7660.207112
fev/00	4127	4127	178.8	6248.019485
mar/00	5620	5620	179.128	8492.748426
abr/00	4638	4638	179.357	6999.835501
mai/00	4074	4074	180.563	6107.559179
jun/00	4261	4261	182.236	6329.257732
jul/00	4829	4829	186.353	7014.492216
ago/00	4436	4436	189.746	6328.405932
set/00	4173	4173	191.049	5912.607321
out/00	4585	4585	191.763	6472.17044
nov/00	4454	4454	192.506	6262.984884
dez/00	6151	6151	193.97	8583.938197
jan/01	6194	6194	194.92	8601.817402
fev/01	3961	3961	195.58	5482.211944
mar/01	4970	4970	197.151	6823.902694
abr/01	5682	5682	199.374	7714.506124
mai/01	5050	5050	200.251	6826.405861
jun/01	5018	5018	203.167	6685.792752
jul/01	5667	5667	206.45	7430.426563
ago/01	5362	5362	208.315	6967.575566
set/01	4939	4939	209.111	6393.483786
out/01	6083	6083	212.135	7762.129946
nov/01	5069	5069	213.756	6419.177698
dez/01	6914	6914	214.137	8740.033194
jan/02	9790	9790	214.535	12352.64493
fev/02	6291	6291	214.927	7923.264048
mar/02	6289	6289	215.17	7911.799916
abr/02	7602	7602	216.673	9497.263545
mai/02	6361	6361	219.07	7859.916063
jun/02	5782	5782	222.872	7022.601062
jul/02	7105	7105	227.441	8456.112398

ago/02	5490	5490	232.818	6383.093575
set/02	8337	8337	238.973	9443.573977
out/02	7990	7990	249.042	8684.595691
nov/02	6582	6582	263.58	6759.597633
dez/02	8186	8186	270.692	8186
Fonte:	BCB-DEPEC			

Tabela 30: Série PIB

Data	PIB (R\$ milhões)	IGP-DI	PIB ATUAL
jan/90	0.2	0.0005	108276.8
fev/90	0.4	0.0008	135346
mar/90	0.8	0.0015	144369.0667
abr/90	0.7	0.0017	111461.4118
mai/90	0.8	0.0018	120307.5556
jun/90	0.8	0.002	108276.8
jul/90	0.9	0.0022	110737.6364
ago/90	1	0.0025	108276.8
set/90	1.1	0.0028	106343.2857
out/90	1.4	0.0032	118427.75
nov/90	1.7	0.0038	121099.0526
dez/90	1.8	0.0044	110737.6364
jan/91	2.1	0.0053	107255.3208
fev/91	2.4	0.0064	101509.5
mar/91	2.5	0.0068	99519.11765
abr/91	3.1	0.0074	113398
mai/91	3.5	0.0079	119926.8354
jun/91	4.1	0.0087	127567.4943
jul/91	4.6	0.0098	127059.5102
ago/91	5.3	0.0113	126961.7345
set/91	5.6	0.0132	114839.0303
out/91	7.4	0.0166	120669.9277
nov/91	9.2	0.0208	119729.1538
dez/91	10.5	0.0255	111461.4118
jan/92	13.1	0.0323	109785.3003
fev/92	16.3	0.0403	109485.8462
mar/92	19.6	0.0486	109167.9671
abr/92	23.6	0.0576	110908.5278
mai/92	30.1	0.0706	115408.3456
jun/92	37.6	0.0857	118763.3512
jul/92	46.1	0.1043	119644.3068
ago/92	56.7	0.1309	117251.615
set/92	70.8	0.1667	114966.9682
out/92	89	0.2083	115658.1277
nov/92	110.4	0.2588	115472.9397
dez/92	127.8	0.3201	108073.8444
jan/93	164.2	0.4121	107856.4096
fev/93	207.4	0.5213	107695.225
mar/93	295.3	0.6663	119969.0044
abr/93	368.9	0.8543	116889.0071
mai/93	482.2	1.13	115511.2234
jun/93	614	1.4771	112521.0805
jul/93	841.7	1.9492	116889.7273
ago/93	1148.9	2.6027	119490.544
set/93	1578	3.5655	119801.4236
out/93	2070	4.8184	116290.1461
nov/93	2792	6.5992	114524.8006
dez/93	3534.5	8.9895	106430.9332
jan/94	4560.8	12.7822	96585.25712
fev/94	5795	18.2031	86175.43935
mar/94	8525.8	26.3635	87540.19207

abr/94	12828.9	37.5575	92463.03931
mai/94	20504.7	52.9373	104849.6665
jun/94	33125.2	77.5954	115557.4511
jul/94	40794.3	96.7693	114113.5738
ago/94	43862.7	100	118732.8199
set/94	43838.4	101.549	116856.9279
out/94	45243.6	104.143	117598.6919
nov/94	45943.3	106.72	116533.7684
dez/94	44181.9	107.325	111434.3058
jan/95	44959.4	108.785	111873.4192
fev/95	45657.1	110.039	112314.8312
mar/95	52447.2	112.035	126719.6632
abr/95	51452.4	114.614	121518.7766
mai/95	51122	115.071	120258.9395
jun/95	52438.6	118.09	120202.4686
jul/95	54237.2	120.733	121603.6721
ago/95	56121.7	122.289	124227.8146
set/95	55699.6	120.967	124640.9031
out/95	58338	121.241	130249.9146
nov/95	62378.6	122.85	137447.1957
dez/95	61339.7	123.187	134788.2981
jan/96	57987.6	125.397	125176.6742
fev/96	56016.7	126.353	120007.2223
mar/96	56499.6	126.627	120779.8473
abr/96	59220.8	127.509	125721.2965
mai/96	64395.4	129.655	134443.8673
jun/96	66004.8	131.24	136139.6779
jul/96	69103.3	132.674	140990.0243
ago/96	68676.3	132.679	140113.5447
set/96	65615.9	132.849	133698.4035
out/96	69854.4	133.141	142022.5719
nov/96	72405	133.517	146793.6986
dez/96	73107	134.689	146927.2178
jan/97	68594.7	136.814	135717.372
fev/97	62562.8	137.39	123264.0619
mar/97	61754.9	138.99	120271.6554
abr/97	66297.6	139.807	128364.3161
mai/97	71141.7	140.229	137328.8625
jun/97	74754.7	141.207	143303.7969
jul/97	74775.9	141.33	143219.6839
ago/97	74299.6	141.268	142369.8737
set/97	73628.1	142.101	140256.1393
out/97	79980.6	142.587	151837.8855
nov/97	81734.3	143.771	153889.318
dez/97	81218.1	144.765	151867.4398
jan/98	75287.2	146.038	139550.2728
fev/98	67691.2	146.067	125445.6264
mar/98	67627.4	146.408	125035.491
abr/98	72261.1	146.211	133782.6954
mai/98	78750.5	146.544	145465.7328
jun/98	82092.2	146.951	151218.4456
jul/98	80748.3	146.398	149304.7639
ago/98	78282.4	146.144	144996.8485
set/98	74943.4	146.111	138843.6109
out/98	77765.6	146.063	144119.495
nov/98	79548	145.797	147691.703
dez/98	79190.6	147.231	145596.117

jan/99	74892.4	148.921	136131.0597
fev/99	71606.5	155.528	124629.0488
mar/99	75129.9	158.6	128228.6437
abr/99	78244.5	158.647	133504.9525
mai/99	82141.4	158.1	140638.9617
jun/99	87195.7	159.711	147786.8051
jul/99	83101.5	162.253	138640.9573
ago/99	81152.4	164.612	133448.9919
set/99	76928.3	167.028	124672.9613
out/99	82821.1	170.182	131735.4902
nov/99	89089.7	174.496	138202.9907
dez/99	91542.4	176.647	140278.6084
jan/00	85348.8	178.454	129463.2643
fev/00	83125	178.8	125846.0431
mar/00	82392.6	179.128	124508.8299
abr/00	83625.1	179.357	126209.9922
mai/00	91537.6	180.563	137229.0891
jun/00	96456.8	182.236	143276.2138
jul/00	95595.2	186.353	138859.3469
ago/00	97004.2	189.746	138386.3739
set/00	92296.9	191.049	130772.9036
out/00	97259.2	191.763	137290.7566
nov/00	98738.8	192.506	138841.4036
dez/00	97875	193.97	136588.0265
jan/01	94536.3	194.92	131285.7589
fev/01	91251.8	195.58	126296.821
mar/01	94685.7	197.151	130005.2321
abr/01	96461.7	199.374	130966.9791
mai/01	101507.7	200.251	137214.4076
jun/01	97519.1	203.167	129930.7477
jul/01	101422.3	206.45	132982.3455
ago/01	103142	208.315	134026.4228
set/01	98782.4	209.111	127872.7825
out/01	105237.3	212.135	134286.6345
nov/01	108959.1	213.756	137981.4213
dez/01	106555.1	214.137	134697.0077
jan/02	101954.5	214.535	128642.2612
fev/02	96393.4	214.927	121403.6498
mar/02	97500.4	215.17	122659.1917
abr/02	102524.9	216.673	128085.5032
mai/02	109105.2	219.07	134814.9213
jun/02	112485.7	222.872	136620.9264
jul/02	113560	227.441	135154.9787
ago/02	113448	232.818	131903.3151
set/02	110212.2	238.973	124840.7177
out/02	118146.4	249.042	128417.2361
nov/02	123957.7	263.58	127302.3664
dez/02	122202	270.692	122202
Fonte:	BCB-DEPEC		

Santos, Alan Vasconcelos Santos

Análise de modelos de séries temporais para a previsão mensal do imposto de renda/Alan Vasconcelos Santos. Fortaleza, 2003.

98 f.

Dissertação (Mestrado) – Universidade Federal do Ceará – CAEN.
Curso de Mestrado em Economia.

1. Previsão econômica 2. Econometria 3. Séries temporais 4. Modelos econométricos 5. Imposto de renda

CDD – 338.5442

