



UNIVERSIDADE FEDERAL DE SERGIPE
CENTRO DE CIENCIAS EXATAS E TECNOLOGIA
DEPARTAMENTO DE ESTATISTICA E CIENCIAS ATUARIAIS



Sandra Santos Santa Rosa

**ARRECAÇÃO DA PREVIDÊNCIA COMPLEMENTAR ABERTA: UMA
ANÁLISE DE DESEMPENHO E CASUALIDADE**

São Cristóvão – SE

2014

Sandra Santos Santa Rosa

**ARRECADAÇÃO DA PREVIDÊNCIA COMPLEMENTAR ABERTA: UMA
ANÁLISE DE DESEMPENHO E CASUALIDADE**

**Trabalho de Conclusão de Curso apresentada
ao Departamento de Estatística e Ciências
Atuariais da Universidade Federal de Sergipe,
como parte dos requisitos para obtenção do
grau de Bacharel em Ciências Atuariais.**

Orientador (a): Prof. Bel. Íkaro Daniel de Carvalho Barreto

São Cristóvão – SE

2014

Sandra Santos Santa Rosa

ARRECAÇÃO DA PREVIDÊNCIA COMPLEMENTAR ABERTA: UMA
ANÁLISE DE DESEMPENHO E CASUALIDADE

Trabalho de Conclusão de Curso
apresentado ao Departamento de
Estatística e Ciências Atuariais
da Universidade Federal de
Sergipe, como um dos pré-
requisitos para obtenção do grau
de Bacharel em Ciências
Atuariais.

17/09/2014

Banca Examinadora:

Ikaro Daniel de Carvalho Barreto

Prof.º Bel. Ikaro Daniel de Carvalho Barreto (UFS)
Orientador

Rosilda Benício de Souza

Prof.º Msc.ª Rosilda Benício de Souza (UFS)
1º Examinador

José Augusto Andrade Filho

Prof. Dr. José Augusto Andrade Filho (UFS)
2º Examinador

Juliana Kátia da Silva

Prof.ª Msc.ª Juliana Kátia da Silva (UFS)
3º Examinador

AGRADECIMENTOS

Primeiramente agradeço a Deus, por me conceder saúde, fé e determinação para jamais desistir diante dos desafios que a vida impõe.

Aos meus pais e meus irmãos pelo esforço, dedicação e cuidados que sempre tiveram e por serem um exemplo de vida para mim.

A todos os professores do DECAT e todos os funcionários do campus por todo apoio concedido durante a graduação.

Aos professores Augusto e Íkaro, que me deram força e orientação transmitindo toda sua sabedoria e dedicação.

A todos os colegas que passaram pelo curso e de alguma forma contribuíram para a realização deste trabalho.

"Depois de muito meditar, cheguei à conclusão de que um ser humano que estabelece um propósito deve cumpri-lo, e que nada pode resistir a um desejo, a uma vontade, mesmo quando para sua realização seja necessária uma existência inteira."

Benjamin Disraeli

RESUMO

A capacidade em termos de previsão para calcular o acúmulo de contribuições mensais obtidos pelos planos de previdência complementar aberta é algo que, no atual mercado competitivo e globalizado, pode ser um fator fundamental para que as seguradoras e demais instituições financeiras mantenham ou obtenham seu equilíbrio financeiro e atuarial. Neste sentido o presente estudo visa comparar modelos de séries temporais e modelos de inteligência computacional, através da casualidade dos erros encontrados na previsão. Ao final, o modelo de Box & Jenkins se mostrou mais acurado que os modelos de Redes Neurais Artificiais em termos de parcimônia entre desempenho e dificuldade técnica.

Palavras-chave: Previsão, Redes Neurais Artificiais, Previdência Complementar, Modelos Box & Jenkins

ABSTRACT

The capacity in terms of prediction to calculate the accumulation of monthly contributions made by open supplementary pension plans is something that, in the current competitive and globalized market, can be a key factor for insurers and other financial institutions to maintain or obtain their financial and actuarial balance. In this sense, the present study aims to compare time series and computational intelligence models through the randomness of the errors found in the forecast. Finally, the model of Box & Jenkins proved to be more accurate than the models of Artificial Neural Networks in terms of parsimony between performance and technical difficulty.

Keywords: Prediction, Artificial Neural Networks, Supplementary Pension Plans, Box & Jenkins Models.

LISTA DE FIGURAS

Figura 1: Contribuições e provisões obtidas pelas EAPCs (valores em R\$ mil) de 2001 à 2012.....	20
Figura 2: Evolução das Taxas básicas de Inflação (% a.a).....	23
Figura 3. Impostos e Contribuições Pagos ao Governo pelas EAPCs em 2008.	24
Figura 4. Estágios do ciclo de Box e Jenkins.....	33
Figura 5. Funções de ativação mais usuais para limitar a saída de um neurônio.....	39
Figura 6. Rede Perceptron de Múltiplas Camadas (MLP)	40
Figura 7. Algoritmo do processo da MLP no Matlab	41
Figura 8. Série Original de Arrecadações pelas EAPCs no período de janeiro de 2003 a maio de 2013	43
Figura 9. Decomposição da Série Original contribuições pagas as EAPCs.....	44
Figura 10. FAC e FACP da Série Original contribuições pagas as EAPCs.....	45
Figura 11. Análise da estatística de Box–Pierce (e Ljung–Box).....	47
Figura 12. Previsões fornecidas pelas modelagens Box & Jenkins e, RNA para o período entre junho/2013 e maio/2014.....	50

LISTA DE TABELAS

Tabela 1. Modelos ajustados e valores da estatística AIC e BIC	46
Tabela 2. Teste de autocorrelação	47
Tabela 3. Parâmetros de configurações das MLPs utilizadas	49
Tabela 4. Resultados dos Modelos de Box & Jenkins e, RNA	50

LISTA DE ABREVIATURAS E SIGLAS

AIC- Critério de Informação de Akaike

AR- Auto-Regressivo

ARIMA- Modelos Auto-Regressivos Integrados de Médias Móveis

ARMA- Auto-Regressivo e de Médias Móveis

BIC- Critério de Informação de Bayesiano

CNSP- Conselho Nacional de Seguros Privados

COFINS - Contribuição para Financiamento da Seguridade Social

COPOM- Comitê de Política Monetária

EAPC - Entidade Aberta de Previdência Complementar

EFPC - Entidade Fechada de Previdência Complementar

ERISA - Employee Retirement Income Security Act

FAC- Função de Autocorrelação

FACP- Função de Autocorrelação Parcial

FIE - Fundos de Investimento Especialmente Constituídos

IBGE - Instituto Brasileiro de Geografia e Estatística

IGP-M- Índice Geral de Preços do Mercado

INSS - Instituto Nacional de Seguridade Social

LB - Estatística de Ljung e Box

MA- Média Móvel

MAPE- Erro Percentual Absoluto Médio

MLP- Multilayer Perceptron

MPAS - Ministério da Previdência e Assistência Social

PIB - Produto Interno Bruto

PCA-Previdência Complementar Aberta

PGBL - Plano Gerador de Benefício Livre

PIS - Programa de Integração Social

PREVIC - Superintendência Nacional de Previdência Complementar

RNA- Rede Neural Artificial

RNAs- Redes Neurais Artificiais

SARIMA- Sazonal Auto-Regressivos Integrados de Médias Móveis

SELIC - Sistema Especial de Liquidação e Custódia

SPC - Secretaria de Previdência Complementar

SUSEP - Superintendência de Seguros Privados

SUMÁRIO

1. INTRODUÇÃO.....	13
1.1. OBJETIVOS.....	15
1.2. JUSTIFICATIVA	16
2. REVISÃO TEÓRICA	17
2.1. Contextualização	17
2.2. Viabilidade de crescimento das Entidades Abertas de Previdência Complementar	18
2.3 A economia e o mercado de Previdência Complementar no Brasil	19
2.4 Fatores que afetam o desempenho de arrecadações no sistema de Previdência Complementar Aberta.....	21
2.5 Pesquisas científicas sobre a previsibilidade na Indústria de Seguros com ênfase em previdência.....	24
3. METODOLOGIA.....	26
3.1 Series Temporais	26
3.2 Metodologias de Box & Jenkins.....	33
3.3 Redes Neurais Artificiais.....	37
3.4 Previsões para modelos ARIMA e MLP	42
4. RESULTADOS E DISCUSSÕES	43
4.1 Análise Preliminar dos Dados	43
4.2 Box & Jenkins	45
4.3 Redes Neurais Artificiais	48
4.4 Box & Jenkins x Redes Neurais Artificiais: previsão e análise de desempenho	49
5. CONCLUSÕES	51
REFERÊNCIAS	53

1. INTRODUÇÃO

O fluxo na adesão de planos de previdência privada tem relação com o desenvolvimento econômico, em face de créditos de investimentos além das perspectivas para a previdência social, que mediante seus planos não conseguem fornecer uma aposentadoria digna. Nesse contexto o desenvolvimento e complementação da renda poderiam ser proporcionais a um benefício próximo a realidade que um assistido venha a ter. Portanto o setor de previdência complementar aberta é de fundamental importância nesse processo.

Alguns dados demonstram essa importância, de acordo com o Relatório de Acompanhamento dos Mercados Supervisionados de 2013, a participação percentual dos mercados supervisionados em relação ao PIB salta de 2,45% em 2003 para 3,83% em 10 anos (SUSEP, 2013). Esse crescimento está distribuído em diversos ramos do seguro sendo, a margem para nossa pesquisa apenas o volume de contribuições arrecadadas pelas Entidades Abertas de Previdência Complementar - EAPC oferecida pelas instituições financeiras.

As EAPC fornecem informações pertinentes aos mercados supervisionados e ao público em geral, possibilitando maior entendimento acerca das operações, e variações de contribuições, tendo como base os dados de janeiro 2003 a maio de 2014, encaminhados a SUSEP pelas companhias supervisionadas.

Para compreender o funcionamento da Previdência complementar aberta é necessário identificar diversos que afetam o mercado de previdência complementar no país inteiro. São fatores externos como inflação e, resquícios da crise econômica de 2008. Além de fatores internos como as reformas na previdência social, taxa de juros, carregamento administrativo e imposto de renda (AMARAL, 2013).

Em face destes e demais fatores que afetam direta ou indiretamente o volume nas arrecadações da previdência complementar aberta, a relevância desse estudo se dá por meio da simplificação dessa variável. Nesse caso, simplificar o modelo significa desconsiderar variáveis do modelo tornando apenas fatores que explicam flutuações do banco de dados. Esse fato não é verificado com frequência na literatura científica, pois,

normalmente, a simplificação é usada para modelos teóricos e o estudo aqui proposto será de caráter prático.

A ausência de um modelo de previsão frente à demanda de contribuições para o cenário nacional é o que motiva o desenvolvimento deste trabalho, uma vez que a contribuição é um indicador que afeta o desempenho e liquidez na indústria de seguros.

Em primeiro momento a solução para tais problemas consiste na utilização de técnicas de previsão através de ajuste de modelos ao comparar a abordagem de Box & Jenkins com os métodos de Redes Neurais Artificiais (RNAs). De modo que os níveis de erro de cada modelagem servirão como critério de validação.

É possível analisar a dependência do efeito contributivo das EAPCs do Brasil como reflexo do comportamento da economia com resultados satisfatórios de previsão para os próximos doze meses?

Para atender aos objetivos deste estudo o trabalho de conclusão aqui proposto, subdividiu-se nos seguintes capítulos: no Capítulo 1, é apresentada a introdução com uma breve discussão sobre o tema proposto, a hipótese lançada para o estudo, os objetivos propostos e a justificativa; no Capítulo 2, são apresentados os conceitos e demais informações relativas à previsão do volume de arrecadações por parte das EAPCs; no Capítulo 3, é apresentada a modelagem de series temporal e redes neurais artificiais definidas para o trabalho, utilizando os modelos ARIMA e MLP supracitados; no Capítulo 4, são apresentados os resultados da modelagem da série; e por fim, o Capítulo 5 que apresenta a conclusão do trabalho e faz sugestões para pesquisas futuras.

1.1 OBJETIVOS:

1.1.1 Geral

O presente estudo tem por objetivo fornecer informações pertinentes aos mercados supervisionados e ao público em geral, possibilitando maior entendimento acerca das operações e, variações de contribuições no setor de previdência complementar aberta, tendo como base o segundo relatório de mercado da SUSEP-Superintendência de Seguros Privados.

1.1.2 Específicos

- a) Avaliar e contextualizar as flutuações do mercado contributivo de previdência complementar aberta em nível nacional;
- b) Verificar se há semelhança ou casualidade entre a arrecadação mensal do Brasil e os valores previstos em diferentes modelagens;
- c) Estimar e descrever contribuições pagas ao setor de Previdência Complementar Aberta-EAPC 12 meses adiante com resultados satisfatórios.

1.2 JUSTIFICATIVA

Este estudo se justifica pela relação direta com fatores relevantes na previdência social e flutuações advindas do cenário econômico nos últimos 10 anos (SUSEP, 2013). Esses fatores podem contribuir no desenvolvimento da modelagem como ferramenta descritiva rumo a explicações dos resultados atribuídos a uma margem de erro satisfatória. Portanto, esse trabalho de conclusão pode ser classificado como uma abordagem quantitativa por meio de procedimentos técnicos de modelagem.

Assim, o serviço analisado nessa pesquisa é à entrada de capital nas Entidades abertas de previdência complementar (EAPCs) por meio de contribuições num panorama econométrico em nível nacional, em consonância do importante papel do volume de arrecadações no sistema de previdência complementar aberta. Com base nesses dados de contribuições e possíveis contribuições pode-se estimar o equilíbrio financeiro necessário para manter a liquidez e o consumo de serviços de investimento futuros.

Estimar a variabilidade do consumo na indústria de seguros pode ajudar seguradoras e bancos a antever e adequar as necessidades do setor de previdência complementar analisando os reflexos de um reconhecimento de padrão de contribuições aplicadas ao serviço.

Uma alternativa para a resolução deste tipo de problema relacionado ao campo da ciência atuarial é a aplicação de técnicas estatísticas e computacionais como diagnóstico e a verificação de modelos estimados, que se dá pelos níveis de erros.

2. REVISÃO TEÓRICA

2.1 Contextualização

Os primeiros projetos de previdência privada surgiram no início do século XIX, devido os reflexos das receitas geradas durante a Revolução Industrial. Nos Estados Unidos, por exemplo, foi criado um plano de pensão pelo empregador com o objetivo de fornecer segurança aos idosos no período pós Revolução. Mas conforme Pòvoas (1985), só em 02 de setembro de 1974 a previdência complementar Americana se oficializou, através da lei conhecida como ERISA- Employee Retirement Income Security Act.

A lei ERISA foi motivada pela determinação de uma disciplina de confiança do beneficiário em relação à empresa responsável pelo plano de aposentadoria, ou seja, essa lei obrigou as empresas a arcar com os benefícios oferecidos ao final do período contributivo, e foi utilizada como modelo para inúmeros países.

A previdência complementar no Brasil teve início tempos depois com a publicação da lei 6435 de julho 1977, inspirada no modelo americano seu objetivo é fiscalizar e normatizar o regime (SILVA, 2011). Essa lei foi regulamentada por dois decretos:

- Primeiro pelo decreto nº 81240 de 1978, este por sua vez, refere-se às entidades fechadas de previdência complementar (EFPC), conhecidas como fundos de pensão e controlados pela Secretaria de Previdência Complementar (SPC) do Ministério de Previdência e Assistência Social (MPAS);
- Segundo pelo decreto nº 81402 de 1978 trata-se das Entidades Abertas de Previdência Complementar (EAPCs), controlada pela Superintendência de Seguros Privados (SUSEP) do Ministério da Fazenda. As EAPCs tem como órgão normativo o Conselho Nacional de Seguros Privados (CNSP).

Em 2001 os decretos da lei 6435/77 foram regulamentados, valendo-se de uma nova lei, a lei complementar nº109. Essa nova lei estabelece que todos os planos de previdência complementar aberta necessitam sumariamente de aprovação da SUSEP antes do início de comercialização (SUSEP,2013).

Cada plano submetido pelas EAPCs tem a opção de ser contratado de forma individual ou coletiva por intermédio das sociedades seguradoras autorizadas a operar tão somente no ramo de seguros de pessoas. O sistema é de caráter contributivo, possui

diversos tipos de planos e todos se diferenciam segundo alguns aspectos, como: benefícios, carência, taxa de administração, taxa de carregamento e resgate.

2.2 Viabilidade de crescimento das Entidades Abertas de Previdência Complementar

Para Moura (2007) a previdência social não consegue cumprir seu papel de integradora junto aos poderes públicos e a sociedade tendo em vista seu objetivo de assegurar os direitos relativos à saúde, à previdência e à assistência social, apresentados no artigo 194 capítulo II da constituição de 1988, esse fato trouxe desconfiança e prejuízos acumulados durante anos.

É nesse cenário que à previdência privada ou complementar ganhou força, como uma perspectiva de solução para a realocação da renda, permitindo a manutenção da qualidade de vida do beneficiário. Deste modo para cada plano existe um objetivo de restabelecer o nível de renda na ocasião de morte, invalidez ou sobrevivência.

De acordo com Montesinos (2007), as EAPCs têm desempenhado papel importante no processo de complementação de renda. Este seguimento se tornou atrativo, pois, é acessível a qualquer pessoa física, assim como detém a maior variedade de planos (individuais ou coletivos). Outro aspecto relevante é que seus planos permitem total flexibilidade na escolha da idade para adesão do benefício e periodicidades das contribuições que vão custear o plano.

Segundo Amaral (2013), outro aspecto relevante quanto à procura por planos oferecidos pelas EAPCs se deve ao fato da garantia de remuneração destes planos não ser apenas calculada com base na inflação medida pelo Índice Geral de Preços do Mercado (IGP-M) mais 6% ao ano. Os planos atuais são garantidos com base no FIE (Fundos de Investimento Especialmente Constituídos) e estruturados em conformidade com a CMN, onde os únicos quotistas são as seguradoras e EAPCs.

Este fato se deve também em função da escolha do produto que as EAPCs disponibilizam no mercado brasileiro. Atualmente são os Planos Tradicionais, o Plano Gerador de Benefício Livre (PGBL) e o Vida Gerador de Benefício Livre (VGBL). Os três planos são bastante semelhantes, diferindo em função do benefício fiscal e da cobrança de imposto de renda incidente no momento do resgate.

Os planos tradicionais ainda têm como base no cálculo da garantia de remuneração (IGP-M) mais 6% ao ano, já o PGBL e o VGBL adotam a FIE, onde não há remuneração fixa e rentabilidade mínima durante a fase de acumulação dos recursos, porém, os fundos para aplicação dos recursos variam entre os mais arriscados que investem até 49% do patrimônio em renda variável ou os mais conservadores, que aplicam apenas em títulos públicos ou privados (SUSEP, 2014).

Ouro fato que se deve ter atenção na escolha de um plano de previdência complementar são nas praticas distintas das taxas de administração e carregamento, pois estas taxas incidem sobre as contribuições provocando, um descolamento da poupança formada ao final do período de acumulação. Segundo Souza *et al.* (2012), estas taxas impactam no resgate de benefícios futuros, onerando o capital acumulado disponível, ao qual poderá alterar os rendimentos da remuneração esperada.

Mas o principal atrativo dos produtos das EAPCs se refere ao aspecto do benefício fiscal, no produto PGBL as contribuições no ano podem ser deduzidas da base de cálculo do imposto de renda, em até 12% para os participantes que fazem a declaração completa. No caso do VGBL a dedução ocorre apenas da rentabilidade auferida.

Diante disto a previdência complementar aberta se popularizou, sendo seu desempenho acumulado na carteira de investimentos (conjunto de ativos oferecidos em garantia das obrigações com os clientes) em dezembro de 2011 apresentou um volume de 20,54% a mais do que os valores registrados no mesmo mês do ano anterior (SOUZA, 2012). Assim as EAPCs tem papel importante na economia nacional, sem elas, o desenvolvimento e a geração de renda não seriam possíveis na escala que temos atualmente.

2.3 A economia e o mercado de previdência complementar no Brasil

Nos últimos 10 anos o crescimento no mercado de seguros foi realmente expressivo, conforme o Relatório de Acompanhamento dos Mercados Supervisionados da SUSEP, de 2013, a participação percentual do conjunto seguros +capitalização +previdência em relação ao PIB acumularam 3,83% de 2003 até o primeiro semestre de 2013. No entanto, o mercado de Previdência Complementar Aberta, por sua vez, não apresentou o mesmo desempenho e, registrou redução em sua participação, caindo de 0,58% em 2001 para 0,25% em 2012 (Figura 1).

Figura 1: Contribuições e provisões obtidas pelas EAPCs (valores em R\$ mil) de 2001 à 2012.

MERCADO BRASILEIRO DE PREV. COMPLEMENTAR ABERTA			
ANO	CONTRIBUIÇÕES	PROVISÕES	PART. PIB (%)
2001	7,524,592	20,782,833	0.58%
2002	7,147,172	26,754,328	0.48%
2003	7,784,518	34,665,477	0.46%
2004	8,128,739	42,588,834	0.42%
2005	7,483,137	48,228,840	0.35%
2006	7,323,839	54,766,362	0.31%
2007	7,933,329	63,001,342	0.30%
2008	8,230,983	70,543,989	0.27%
2009	8,235,163	79,949,792	0.25%
2010	9,083,370	90,490,115	0.24%
2011	10,190,087	102,254,114	0.25%
2012	11,022,884	115,853,625	0.25%

Fonte: SUSEP, 2013.

Pela análise da Figura 1 a participação do mercado de Previdência Complementar Aberta (PCA) no PIB, decresceu nos últimos 10 anos. Mas mesmo assim as receitas tendem a aumentar, pois, o número de contribuições arrecadadas ainda é um índice importante para avaliar o desempenho das EAPCs. Nesse caso o fato das arrecadações não acompanharem o PIB, não quer dizer que o acúmulo de contribuições das EAPCs tenha diminuído, apenas ela não cresceu na mesma proporção.

Segundo Contador (2007), existe uma medida capaz de mensurar a evolução do mercado de seguros em uma região, essa medida nada mais é do que, a razão entre arrecadações no mercado de seguros supervisionado sobre o PIB. Esse processo ficou conhecido como coeficiente de penetração de seguros, é uma informação importante, mas subestima a contribuição total da indústria de seguros (seguros, capitalização e previdência complementar).

Além disso, existem outros indicadores que são relevantes para economia. A função da provisão matemática, por exemplo, permite calcular um valor a partir da parcela (cota de contribuição) incidente sobre cada mensalidade e que irá formar o valor do benefício ou resgate (SUSEP, 2013).

As contribuições arrecadadas pelas EAPCs variam ao longo do tempo e de região para região, esse acúmulo de capital não apenas é revertido em benefício para os clientes do plano, mas, também se transforma em lucro para seguradoras e demais instituições financeiras.

Enfim, apesar do exposto anteriormente a gestão de contribuições em EAPCs, acompanham a maioria das atividades econômicas principalmente como investimentos de renda fixa assumindo riscos de caráter previdenciário. As provisões demonstram a estabilidade e solvência dos rendimentos obtidos pelas EAPCs. Esses rendimentos apresentam fortes flutuações influenciadas por variáveis macroeconômicas, com destaque para as taxas de Juros (HOLSBOER, 2000).

2.4 Fatores que afetam o desempenho de arrecadações no sistema de Previdência Complementar Aberta

A ciência atuarial fornece elementos essenciais para a definição do valor de contribuições em planos de previdência, porém ainda persiste a dificuldade para o cálculo de sua demanda (ARAÚJO, 2008).

Assim o mercado de previdência complementar aberta tem passado por variações marcantes na última década. Um processo de previsão pode ser útil na administração de recursos e, tomada de decisão quanto ao custeio dos planos de previdência privada. Esse processo pressupõe resultados quantitativos ao nosso estudo, porém, serão usadas variáveis empíricas que expliquem o comportamento do volume de contribuições pagas as EAPCs. A revisão de literatura apontou fatores supostamente relevantes para essa abordagem. Para Barros (2007), a incerteza gerada pelo processo eleitoral em 2006, quanto à capacidade de controle da inflação, fez com que o COPOM introduzisse um viés de baixa consequentemente, houve piora na percepção de risco e alguns movimentos especulativos, agentes se desfazendo de posições em contrato futuro, contribuíram para que no dia 21 de junho de 2006, a curva de juros atingisse o maior grau de inclinação durante o período impactando seriamente nas arrecadações pelas EAPCs.

Segundo Meyerson *et al.* (2001), a taxa de juros pode ser um fator preponderante no ganho cumulativo de ativos do sistema de previdência complementar americano.

Fato semelhante ocorre no sistema de previdência complementar brasileiro, uma vez que este se baseia no sistema dos Estados Unidos.

Além do seu papel na economia, as taxas de juros são importante instrumento de dedução no valor da entrada do benefício oferecido pelas EAPCs, ou seja, durante o período contributivo. Porém, em face de uma crise financeira estas taxas podem influenciar negativamente o mercado de previdência.

Foi o que aconteceu durante a crise imobiliária que atingiu os Estados Unidos em 2007, chegando ao Brasil em 2008. Essa crise difundiu uma nova política no governo do presidente Lula. A finalidade da nova liderança era desaceleração na economia do país. Portanto, a meta era controlar a taxa de inflação diminuindo as taxas de juros.

O impacto da redução nas taxas de juros foi aceitável no setor de produção e consumo, no entanto, esse ajuste não foi interessante para a rentabilidade das seguradoras, houve um desestímulo à formação de poupança e inibição dos investidores.

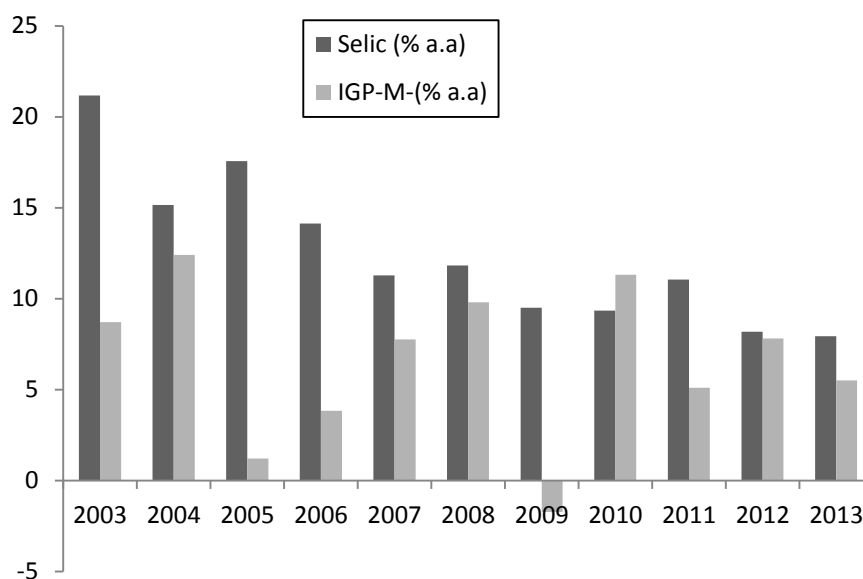
A taxa de juros de inflação à longo prazo realmente fator chave na indústria de seguros principalmente em relação aos planos oferecidos pela previdência complementar. Por ter o maior período cumulativo as EAPCs sofrem para manter suas reservas sem aumentar demasiadamente os índices de reajuste dos seus planos.

Este fato acontece porque os custos dos benefícios são inversamente proporcionais as possíveis mudanças na taxa de inflação, ou seja, quanto maior a perda com a inflação menor será o poder de compra dos benefícios (RODRIGUES, 2008).

As taxas escolhidas foram o IGP-M (Índice Geral de Preços do Mercado) e a SELIC (Sistema Especial de Liquidação e Custódia), pois, conforme afirmado anteriormente o IGP-M mais 6% ao ano é a base no cálculo da garantia de remuneração dos planos tradicionais, já a Selic foi selecionada como indicador da inflação porque é considerada a taxa básica de juros da economia e pode vir a influenciar o volume de prêmios (contribuições) na indústria de seguros.

As flutuações nas taxas IGP-M e Selic foram causadas pela crise vivenciada ao final de 2008 repercutindo principalmente no ano seguinte (Figura 2).

Figura 2 – Evolução das taxas básicas de inflação (% a.a).



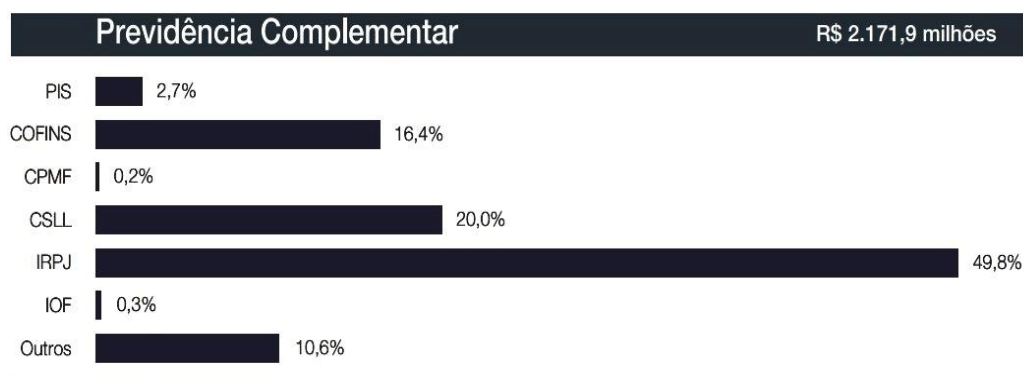
Fonte: Elaborado pelo autor com os dados do IPEADATA.

A queda da taxa de juros IGP-M e Selic em 2009 afetou o mercado de previdência complementar de tal modo que as arrecadações foram subestimadas ocasionando uma redução na rentabilidade de previdência, principalmente nos planos com reservas em títulos públicos.

A taxa de juros teria, portanto, efeitos na arrecadação e nos benefícios previdenciários. Deste modo segundo Faria (2006), a redução na taxa Selic provoca aumento nas obrigações, ou seja, aumento de despesas técnicas reservas para manter a solvência das seguradoras.

Além disso, várias taxas em forma de impostos incidem sobre o valor das contribuições das EAPCs, só em 2008 o governo recolheu aos cofres públicos um montante global de 2,17 bilhões (CNseg, 2008). A previdência complementar confirmou a relevância da sua participação na geração e recolhimento de impostos e contribuições conforme a Figura 3:

Figura 3: Impostos e Contribuições Pagos ao Governo pela Previdência Complementar em 2008.



Fonte: CNseg, 2008.

Outro fator negativo que afeta diretamente o desempenho das arrecadações auferidas pelas EAPCs são os desequilíbrios atuariais. Segundo Vaz (2011), essa instabilidade foi causada pela comercialização de planos de previdência com base em tábuas de mortalidade que não refletem a experiência de mortalidade do banco de dados de empresas brasileiras.

Nesse contexto, pelo grau de dificuldade e frente às restrições da Susep, só em 2010 as EAPCs passaram a ter uma tábua de mortalidade construída a partir dos seus próprios dados, pois, até então todo o mercado de previdência complementar era aludido por tábuas de mortalidade estrangeiras, principalmente norte-americanas.

Essa mudança a primeiro momento instaurou a desconfiança e uma desaceleração em todo o mercado de previdência ainda no ano 2010. Conseqüentemente as EAPCs apresentaram a menor participação no PIB, que durante 2009 representava 0,25% e no ano seguinte caiu para 0,24% (SUSEP, 2013).

2.5 Pesquisas científicas sobre a previsibilidade na Indústria de Seguros com ênfase em previdência

Diante da reduzida literatura destinada a estudar o comportamento temporal por meio da comparação de modelos preditivos aplicados à série volume de contribuições em planos oferecidos pelas companhias abertas atuantes no Brasil. Este fato se deve principalmente à falta de experiência para lidar com as metodologias empregadas e as séries são sensíveis a fatores macroeconômicos. Assim, torna-se imprescindível um

aprofundamento do tema na literatura nacional generalizando o estudo para toda a indústria de seguros e previdência.

Dentre as técnicas mais abordadas no sistema de previdência, a abordagem quantitativa foi a segunda mais relevante. Segundo Silva et al. (2013), em seu artigo *Análise da Produção Científica em Administração sobre a Previdência Brasileira: Meta-avaliação da Produção nos Eventos da ANPAD*, foram catalogados 33 artigos de 1997 até o ano de 2011, dentre estes 16 usavam a abordagem quantitativa associada à qualitativa por meio de procedimentos econométricos como regressão, séries temporais (com modelos de previsão) dentre outros. Essa abordagem segundo a autora só foi possível pelo auxílio de softwares como: SPSS, MATLAB e STATA. Por fim, verificou-se que apesar de ser pequena a diferença, a abordagem quantitativa tem predominado nas pesquisas sobre a Previdência, já que esta faz parte, dentre outras áreas, dos estudos econômicos, onde mais se utiliza os modelos estatísticos e econométricos.

Dantas (2010), publicou um artigo intitulado: *Uma aplicação de Inteligência Computacional e Estatística Clássica na Previsão do Mercado de Seguros de Automóveis Brasileiro* cujo objetivo era comparar as técnicas de estatística clássica e os métodos de redes neurais mais adequados para a previsão do acúmulo de prêmios diretos mensais. Nesse estudo também foram analisados os fatores empíricos que podem vir a influenciar a série no tempo, o autor considerou fatores macroeconômicos. Na comparação de metodologias conforme a métrica do erro MAPE, o melhor desempenho foi o dos modelos de previsão em Redes Neurais Artificiais.

Assim, outros autores buscam afirmar a relação de causalidade entre mercado de previdência complementar aberta e economia, demonstrando, portanto se o mercado de PCA gera de fato crescimento econômico. Barros (2007), analisa eventos que possam ter alterado o ritmo de crescimento deste mercado. Neste estudo foram considerados eventos preponderantes para a série de dados históricos de arrecadação mensal de janeiro de 1995 a dezembro de 2005. A metodologia empregada foi dedicada ao uso da modelagem econométrica, para a qual se utilizou preliminarmente um Vetor Auto-Regressivo (VAR), cujo objetivo é explicar os pontos de inflexão da série por meio de três modelos distintos no tempo que mais sofrem influência de variáveis exógenas: fatores como a desregulamentação do sistema financeiro, o aumento da concorrência, as crises financeiras e políticas em algumas regiões do planeta. Após a especificação do

VAR, e da análise dos Vetores Auto Regressivos para os eventos em citados pelo autor, foi definido o modelo mais parcimonioso, representado por um modelo Auto Regressivo - AR - de ordem 1 com tendência constante, suficiente para realizar previsões para o ano de 2006 validar o modelo proposto para arrecadação em previdência complementar aberta.

3. METODOLOGIA

3.1 Séries Temporais

O conceito ingênuo de série temporal pode ser entendido como uma função de interesse limitada a um intervalo de tempo, dentro de um universo de possibilidades que poderiam ter sido escolhidas. Consequentemente o processo no domínio temporal também é estocástico, ou seja, é um conjunto de variáveis aleatórias ordenadas em um espaço de tempo (GUJARATI, 2006).

Os principais objetivos da análise de séries temporais é investigar o princípio originário para a construção de um modelo, descrever o comportamento dos dados, identificar a presença de sazonalidade e realizar previsões futuras da série. Em todos os casos, a modelagem proposta poderá ser de caráter paramétrico ou não paramétrico e que seja parcimoniosa (modelos com o menor número de parâmetros possível).

A criação de um gráfico dos dados históricos da série é um fator fundamental para detectar seu comportamento podendo revelar padrões interessantes para o nosso estudo tais como: tendência, sazonalidade, ciclos e aleatoriedade. A tendência indicara o comportamento da série em longo prazo, ou seja, se estes valores crescem (ou decrescem) quase que invariavelmente conforme o tempo, já a sazonalidade representa a série mensal com um mesmo comportamento no mês em anos distintos, acima de um ano os padrões serão cíclicos (SCHRÖDER & DIAS, 2012).

Outro aspecto relevante está na escolha do método que produza os menores erros de previsão e o melhor ajuste para os valores da serie. Na economia, por exemplo, um dos métodos mais populares é o procedimento de Box & Jenkins. Este método consiste na escolha de um modelo baseado nos próprios dados constituindo uma análise univariada através da correlação temporal mediante apenas da presença dos valores presentes e passados, na intenção de prever os valores futuros da série com precisão.

O método de extrapolação sofisticado caracteriza a estrutura de uma serie no tempo, mas, não basta somente conhecer a estrutura da variável de interesse é imprescindível focar em informações a respeito da natureza das suas propriedades, como a forma como os modelos podem ser descritos (estacionárias ou não estacionárias).

3.1.1 Processos Estacionários

Series que se desenvolvem no tempo podem ser positiva ou negativa ao acaso (aleatória), envolta a uma média constante constituem a classe de modelos estacionários (SARTORIS NETO, 2009). Neste caso supõe-se que a serie temporal seja gerada por um filtro linear.

Um modelo de filtro linear pode ser escrito pela equação:

$$Z_t = \mu + a_t + \psi_1 a_{t-1} + \psi_2 a_{t-2} + \dots = \mu + \psi(B)a_t, \quad (3.1)$$

Chamando $Y_t = Z_t - \mu$, temos que

$$Y_t = \psi(B)a_t,$$

sendo $\psi(B) = 1 + \psi_1 B + \psi_2 B^2 + \dots$,

em que

$\psi(B)$ = Função de transferência do filtro linear

a_t = Resíduo ou ruído branco

μ = Termo constante

Z_t será denotado pelos valores futuros da variável em estudo. Esta variável pode ser descrita por um processo linear (discreto), nesse caso devemos levar em conta os princípios:

$$E(a_t) = 0, \forall t,$$

$$Var(a_t) = \sigma_a^2, \forall t,$$

$$E(a_t a_s) = 0, s \neq t.$$

Em correspondência ao processo estocástico existe a possibilidade de uma serie temporal apresentar um comportamento estritamente estacionário, ou seja, sua distribuição conjunta $Y(t_1), \dots, Y(t_n)$ é a mesma distribuição conjunta de

$Y(t_1 + k), \dots, Y(t_n + k)$ para todos os n e k , portanto a condição será válida se depender apenas da diferença ou defasagem de $t_1 - t_2$ (MADDALA, 2003). Como a função de autocovariância $\gamma(t_1, t_2)$ também depende da defasagem neste caso dada por $\gamma(k)$, logo, o coeficiente de autocovariância pode ser descrito pela equação:

$$\gamma(k) = E[Y(t) - \mu][Y(t+k) - \mu] = \text{cov}[Y(t), Y(t+k)], \quad (3.2)$$

Deste modo ao normalizar as autocovariâncias considerando que a média e a variância são constantes, por conseguinte $Y(t) = \text{var}(t+k) = \sigma^2 = \gamma(0)$ dão origem a Função de Autocorrelação Teórica - FAC, descrita pelo produto dos respectivos desvios padrão (3.3):

$$\rho(k) = \frac{\gamma(k)}{\gamma(0)} \quad (3.3)$$

O gráfico da função de autocorrelação contra $\rho(k)$ é o conhecido como correlograma ao qual é suficiente para comprovar a presença de estacionariedade.

Ao fazer uso do correlograma confirmamos primeiramente se a série é ou não aleatória. Nesse caso se a série confirma a completa aleatoriedade, os valores defasados serão não correlacionados e a Função de Autocorrelação será amostral e, determinada por $\rho(0) = 1$, $\rho(k) = 0$, para $k > 0$, este processo também é conhecido como ruído branco.

3.1.2 A Função de Autocorrelação - FAC

Um processo estocástico é fundamentalmente teórico e na prática em termos de amostra é conveniente fazer uso de um método mais empírico, conhecido como Função de Autocorrelação Amostral-FAC, descrita de modo análogo a anterior. Ambas possuem as mesmas propriedades e, estas por sua vez, são facilmente verificáveis (EHLERS, 2007):

- a) A correlação entre $Y(t)$ e $Y(t+k)$ é a mesma entre $Y(t)$ e $Y(t-k)$, ou seja, $\rho(k) = \rho(-k)$;
- b) $-1 < \rho(k) < 1$;

- c) É possível descobrir vários processos não normais para uma mesma FAC, fato esse que dificulta qualquer interpretação do gráfico da função de autocorrelação.

3.1.3 O modelo auto-regressivo

Os modelos de ordem “p”[AR(p)]: em que “p” é o numero de termos auto-regressivos dado um valor histórico Z_t em um determinado tempo t, este período depende de seu antecessor (t-1), de termos aleatórios ou ruído branco a_t (que possui media zero e variância constante) e, um parâmetro ϕ_i (que é descrito como a combinação de Z_t e seus valores passados, isto é, $Z_{(t-i)}$) descrevendo assim a equação generalizada do modelo pela soma ponderada dos seus p valores passados (MORETTIN; TOLOI, 2006) :

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t \quad (3.4)$$

Tratando-se de um modelo estacionário para AR (1) se as raízes do parâmetro combinado ao operador de defasagem forem nulas $\phi(B) = 0$, dizemos que estas raízes caem fora do círculo unitário, isto é, $|\phi| < 1$ (MORETTIN; TOLOI, 2006). Para o caso de termos apenas um operador linear escrevemos:

$$\phi(B) = 1 - \phi_1 B_{t-1} - \dots - \phi_p B_p, \text{ Ou } \phi(B)Z_t = a_t \quad (3.5)$$

3.1.4 O modelo de médias móveis

Modelos de ordem “q” [MA(q)]: em que “q” é o número de termos encontrados através da media móvel tal que esse resultado é obtido da combinação linear de ruídos aleatórios a_t ocorridos no tempo t e no tempo (t-1). Quando o processo acontece pela combinação de apenas choques passados, retirado o termo constante teremos (SATORIS NETO, 2009):

$$Z_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (3.6)$$

Em que a defasagem é o operador de médias móveis de ordem q:

$$\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$$

Esse processo se faz necessário em séries temporais principalmente para eliminar tendências e apresentar ciclos. Além disso por ser um processo estacionário a sua função de autocorrelação se torna menor à medida que k aumenta.

3.1.5 O modelo auto-regressivo e de médias móveis- ARMA

Os modelos de ordem “p,q”, contêm ambos os operadores, tanto o auto-regressivo como o de media móvel, identificados como ARMA(p,q) (MORETTIN; TOLOI, 2006). Assim teremos a soma ponderada dos operadores, AR = p e MA = q definidos pela seguinte equação:

$$Z_t = \phi_1 Z_{t-1} + \dots + \phi_p Z_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (3.7)$$

Muitos processos aleatórios estacionários serão eficientes se conjugados os modelos AR e MA convertidos a um modelo misto auto-regressivo e de médias móveis.

3.1.6 Função de Autocorrelação Parcial – FACP

O excesso de correlação na defasagem p em um processo auto-regressivo AR(p) passou a ser medido pelo ultimo coeficiente α_p da ordem facilitando por vezes a identificação e estimação de modelos AR, MA e, ARMA. Nesse caso para k= 1,2,..., origina-se a Função de Autocorrelação Parcial. No entanto, em um processo AR(p) não há correlação direta entre $Z(t)$ e $Z_{t-p-1}, Z_{t-p-2}, \dots$ por isso seus k valores passam a ser k+1, k+2..., substituindo na equação de Yule-Walker, ao qual se obtêm todos os coeficientes de correlação parcial nulos para k > p (EHLERS, 2005). Como por exemplo, se substituirmos k por k+1 na equação de Walker teremos (3.8):

$$\rho(p+1) = \alpha_1 \rho(p) + \dots + \alpha_p \rho(1) + \alpha_{p+1} \quad (3.8)$$

3.1.7 O Processo de Raiz Unitária

Um processo de raiz unitária em termos estocásticos pode ser tratado como sinônimo de não-estacionariedade e passeio aleatório, como por exemplo no caso de um polinômio auto-regressivo de ordem 1= AR(1), conseqüentemente Z_t é não-estacionário e, sua raiz unitária será $\rho = 1$. Assim o modelo pode ser descrito pela equação (3.9):

$$Z_t = \rho Z_{t-1} + a_t \quad (3.9)$$

Ao diferenciar esse AR (1) Dickey-Fuller criaram um novo parâmetro $\delta = \rho - 1$ determinado pela estatística do teste conhecida como tau (τ), onde eles testaram (τ) sob a hipótese $H_0: \delta = 0$, que é equivalente a testar $H_0: \rho = 1$, contra $H_1: \rho < 1$. Nesse teste se a estatística calculada for maior que o valor tabelado, rejeitamos H_0 , ou seja, a série é estacionária e o modelo do teste de Dickey-Fuller passa a ser administrado da seguinte forma (SCHRÖDER & DIAS, 2012):

$$Z_t = \delta Z_{t-1} + a_t. \quad (3.10)$$

Existem ainda outros modelos para o teste com valores críticos próprios e suas determinadas hipóteses.

Sabe-se que os modelos do teste Dickey-Fuller funcionam apenas para processos AR(1), logo surgiu a necessidade de testar processos AR(p) através de um novo método de avaliação que ficou conhecido como teste de ampliado de Dickey-Fuller, ao qual, consiste em acrescentar termos de tendências e defasagens no modelo tradicional mantendo os mesmos valores críticos para ambos os modelos.

3.1.8 Modelos Não-Estacionários

A não estacionariedade ocorre normalmente em séries econômicas nas quais há uma tendência linear com inclinação positiva ou negativa. Este fato descreve satisfatoriamente séries que não apresentem comportamento explosivo, ou seja, séries ditas homogêneas.

Quando a variável não é estacionária, se faz necessário definir uma nova variável Y_t para tomar diferenças sucessivas de Z_t . Para uma diferenciação teremos:

$$Y_t = Z_t - Z_{t-1} = \Delta Z_t \quad t = 1, 2, \dots, d. \quad (3.11)$$

A segunda diferenciação:

$$\Delta^2 Z_t = Z_t - 2Z_{t-1} + Z_{t-2} \quad t = 1, 2, \dots, d \quad (3.12)$$

3.1.9 Modelos auto-regressivos integrados de médias móveis-ARIMA

O modelo ARIMA (p, d, q) é normalmente usado quando se trata de uma série de dados não estacionária. Para iniciar o processo é necessário neutralizar as propriedades da serie para que ela não seja afetada ao longo do tempo através de possíveis diferenciações conhecidas por d e, representadas na equação sendo Z_t não estacionária, no entanto, ΔZ_t será estacionaria tal processo se confirma pela equação na d-ésima diferenciação:

$$\Delta^d Z_t = W_t \quad t = 1, 2, \dots, d. \quad (3.13)$$

E, essa variável W_t segue um processo ARMA (p, q), isto é:

$$W_t = \phi_1 W_{t-1} + \dots + \phi_p W_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}$$

Sendo a integração de ordem d, e sua d-ésima diferença combinada ao modelo ARMA (p,q), obteremos um processo ARIMA (p, d, q) descrito pela equação:

$$\Delta^d Z_t = \phi_1 \Delta^d Z_{t-1} + \dots + \phi_p \Delta^d Z_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (3.14)$$

3.1.10 Modelos ARIMA sazonal – SARIMA

Ao considerar dados observados num período máximo de 12 meses, se faz necessário a presença de um componente sazonal dado que essa sazonalidade pode ser: estocástica, ou seja, ajustar a série original a um modelo ARIMA sazonal- SARIMA ou ainda determinística, quando se torna estacionária após D diferenças (MORETTIN; TOLOI, 2006). Em diversos casos a série temporal pode apresentar ambas as características.

Box *et al.* (1994) propõem a generalização do modelo ARIMA, para poder lidar com a sazonalidade, ao qual define por de modelo ARIMA sazonal multiplicativo denotado por SARIMA (p, d, q)(P, D, Q)_s. Nesse caso o operador sazonal $\Delta^d \Delta_s^D$ será a combinação da d-ésima diferença Δ^d com D-ésima diferença sazonal Δ_s^D . Aplicando o operador $\Delta^d \Delta_s^D = (1 - B)^d (1 - B^s)^D$ teremos a equação (3.15):

$$\phi(B)\Phi(B^s)\Delta^d \Delta_s^D Z_t = \theta(B)\Theta(B^s) a_t \quad (3.15)$$

Onde: $W_t = \Delta^d \Delta_s^D Z_t$;

$\phi(B) = (1 - \phi_1 B^1 - \dots - \phi_p B^p)$ é o polinômio autorregressivo de ordem P;

$\phi(B)^s = (1 - \phi_1 B^s - \dots - \phi_p B^{ps})$ é o polinômio autorregressivo sazonal;

$\theta(B) = (1 - \theta_1 B^1 - \dots - \theta_q B^q)$ é o polinômio de médias móveis de ordem q;

$\Phi(B)^s = (1 - \Phi_1 B^s - \dots - \Phi_Q B^{Qs})$ é o polinômio sazonal de ordem Q;

Sendo o SARIMA (p, d, q)(P, D, Q)_s descrito pela equação (3.16):

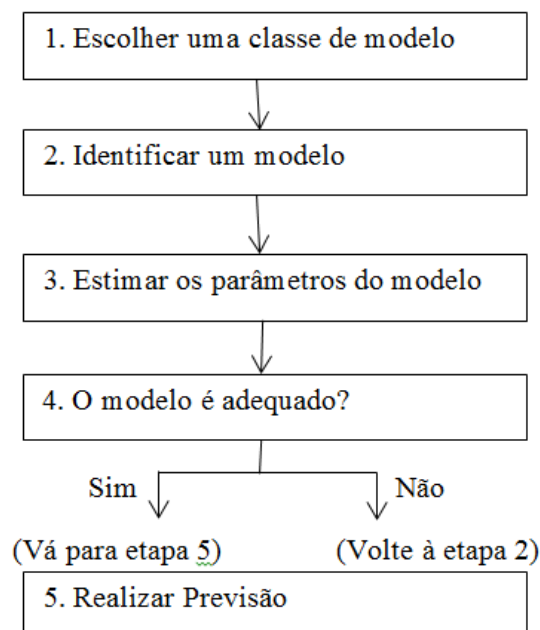
$$\phi(B)\Phi(B^s)W_t = \theta(B)\Phi(B)^s a_t \quad (3.16)$$

3.2 Metodologia de Box & Jenkins

A abordagem conhecida popularmente como Box & Jenkins é comumente utilizada na análise de modelos paramétricos. Essa metodologia consiste em ajustar modelos auto-regressivos integrados de médias móveis, ARIMA a um conjunto de dados (MORETTIN; TOLOI, 2006). Existe ainda a possibilidade de generalizar o modelo anterior considerando a sazonalidade estocástica e assim ajustar a serie a um ARIMA sazonal (SARIMA).

A construção dos modelos será feita baseando-se nos próprios dados por meio de um ciclo iterativo: identificação, estimação e verificação. Cujos estágios deste ciclo constituem a abordagem de adequação do modelo com o intuito de realizar previsões (Figura 4).

Figura 4- Estágios do ciclo de Box e Jenkins



Fonte: Elaborado pela própria autora.

Uma vez determinada a classe (estacionária ou não-estacionária) do modelo escolhido, em seguida, são abordados os critérios para identificação do modelo ARIMA e SARIMA. Se os critérios forem satisfatórios o próximo passo é estimar os parâmetros do modelo tentativo e por fim, verificar se os resíduos estimados desse processo apresentam comportamento de ruído branco, em caso afirmativo é possível realizar previsões, do contrário é necessário recomeçar testando outros modelos.

3.2.1 Identificação

A identificação consiste em um conjunto de procedimentos que tem por objetivo informar os valores p , d e q do modelo ARIMA e também P , D e Q , quando a série tiver componente sazonal (SARIMA). Considerada a fase crítica do ciclo iterativo de Box & Jenkins, essa identificação é baseada na análise das autocorrelações e autocorrelações parciais estimadas. A dificuldade na escolha de um parâmetro se deve a possibilidade de uma mesma série apresentar inúmeros modelos.

A classe da série deve ser devidamente especificada garantindo a sua estacionariedade por meio da diferenciação, utilizando para o reconhecimento deste comportamento o correlograma. Neste caso a estacionariedade também é alcançada quando a função de autocorrelação amostral de $\Delta^d Z_t = W_t$ do modelo ARMA decresce subitamente para zero. Assim é possível identificar os valores p e q e, além dos valores P e Q se a série demonstrar sazonalidade estocástica. (MORETTIN; TOLOI, 2006).

A parametrização de modelos ARIMA ou SARIMA pode ser feita por meio de formas alternativas ou complementares de identificação, das quais não depende de quem está analisando a série de tempo e sim de critérios de seleção de modelos, construídos com base na variância estimada e dos valores p e q (SILVA, 2011).

Segundo Fava (1999), os critérios predominantes de seleção de parâmetros são o Critério de Informação Akaike (AIC) e o Critério de Informação Bayesiano (BIC), descrito pelas equações (3.16) e (3.17) respectivamente.

$$AIC = \ln \sigma_a^2 + \frac{2(p+q)}{N} \quad (3.16)$$

$$BIC = \ln \sigma_a^2 + \frac{(p+q)}{N} \ln(N) \quad (3.17)$$

Assim são estimados os modelos parcimoniosos (a melhor representação de um modelo se dá pelo reduzido número de parâmetros), escolhido dentre os modelos que apresentar menor AIC e BIC.

3.2.2 Estimação

Uma vez identificado um modelo tentativo, o próximo passo será estimar seus parâmetros ϕ na presença de um componente auto-regressivo AR, Θ na presença de um filtro de médias móvel MA e a variância do ruído branco σ_a^2 do modelo (WEI, 2006). Neste caso foram escolhidos os valores dos parâmetros que minimizam a soma dos quadrados das diferenças entre $W_t = \Delta^d Z_t$ e o modelo ajustado resultando na equação (3.18):

$$W_t = \phi_1 W_{t-1} + \dots + \phi_p W_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (3.18)$$

A estimação pode ser feita mediante equação genérica do método de mínimos quadrados levando em conta os resíduos associados aos parâmetros do modelo, de tal modo que $\hat{a}_t = \theta^{-1}(B)\hat{\phi}(B)W_t$. Assim a equação resultante será denotada por:

$$S(\hat{\phi}_1, \dots, \hat{\phi}_p, \hat{\theta}_1, \dots, \hat{\theta}_q) = \sum_t \hat{a}_t^2 \quad (3.19)$$

Além do método de mínimos quadrados existe a possibilidade de estimar parâmetros através da máxima verossimilhança, convém admitir que o ruído branco do modelo tenha distribuição normal. Segundo Box *et al.* (1994), o procedimento usual em séries não-estacionárias é a função de verossimilhança com procedimento não-condicional, denotada por:

$$S(\eta) = S(\phi, \theta) = \sum_{t=-\infty}^n [a_t(\eta, W)]^2 \quad (3.20)$$

é a soma não-condicional, com

$$[a_t(\eta, W)] = E(a_t | \eta, W).$$

Segue-se que os estimadores de mínimos quadrados obtidos minimizando-se (3.20), serão aproximações eficientes para os estimadores de máxima verossimilhança (MORETTIN; TOLOI, 2006). No entanto, esse não é um processo simples, portanto

convém usar pacotes estatísticos para dinamizar o estudo e obter mais facilmente os modelos estimados.

3.2.3 Verificação

Após estimar o modelo, a próxima etapa é verificar se o modelo que sofreu o ajuste é adequado. Esse processo diferentemente da identificação usará uma função de autocorrelação amostral apenas para os resíduos que sejam próximos de zero para um deslocamento $k \geq 1$ (PINDYCK; RUBINFELD, 2004).

Assim podemos pressupor que os termos dos erros aleatórios $\hat{a}_t = \theta^{-1} \hat{\phi}(B) W_t$ tem distribuição normal e são independentes. Isso significa que provavelmente os resíduos não terão correlação entre si, logo devem apresentar um comportamento de ruído branco. Para, tanto a função de autocorrelação dos resíduos será descrita por (3.21):

$$\hat{\rho}_k = \frac{\sum_t \hat{a}_t \hat{a}_{t-k}}{\sum_t \hat{a}_t^2} \quad (3.21)$$

A função de autocorrelação amostral dos resíduos pode ser diagnosticada conforme uma estatística que segue uma distribuição aproximadamente qui-quadrado com m graus de liberdade. Essa análise pode ser feita por meio de um teste de hipótese, ao qual podemos testar a hipótese conjunta de que todos os $\hat{\rho}_k$ até determinada defasagem são ao mesmo tempo iguais à zero, usa-se a estatística de Box e Pierce (GUJARATI, 2006):

$$Q = n \sum_{k=1}^m \hat{\rho}_k^2 \quad (3.22)$$

Uma variação da estatística de Q de Box e Pierce é a estatística de Ljung e Box LB, ambas são semelhantes seguem uma distribuição qui-quadrado com m graus de liberdade, no entanto, a LB apresenta estatísticas mais eficientes para amostras pequenas e é denotada por (3.23):

$$LB = n(n+2) \sum_{k=1}^m \frac{\hat{\rho}_k^2}{(n-k)} \quad (3.23)$$

Então será aplicado o teste de hipótese considerando a hipótese criada na estatística Q funcionando de forma semelhante ao teste LB, cada uma dessas hipóteses sugerem a precisão do modelo, ao comparar o valor observado de Q com os pontos adequados de uma tabela qui-quadrado (GUJARATI, 2006).

Recordando que neste trabalho pressupõe-se que os erros aleatórios no processo de verificação devem ter distribuição normal. Isso significa que os coeficientes de autocorrelação dos erros apresentam alguma normalidade, para provar esta normalidade convém analisar se os momentos da série estimada são iguais aos da Normal através do teste de Jarque-Bera (MATOS, 2000).

Se o modelo verificado passar por todos os testes propostos anteriormente, o mesmo é adequado e suficiente para realizar previsões, caso contrário, outro modelo deve ser indicado para modelar a série temporal.

Uma forma simples de avaliar modelos de previsão é através de alguma medida quantitativa dos erros de previsão, como a média ou a soma dos erros quadráticos. Além disso, outras características dos erros podem ser analisadas como, por exemplo, a normalidade e a aleatoriedade.

3.3 Redes Neurais Artificiais

Redes Neurais Artificiais (RNA) são modelos computacionais inspirados em um sistema nervoso biológico, como o próprio cérebro humano. Deste modo, quando as unidades do RNA são processadas elas simplificam o neurônio biológico em uma classe denominada neurônios artificiais. Esse interesse foi motivado pela facilidade que o cérebro tem em interpretar observações, reconhecer padrões e armazenar o conhecimento por experiência diante de tarefas simples ou complexas. Porém, o funcionamento de redes neurais naturais em um comportamento individual ainda não foi totalmente desvendado pelo homem. Assim as RNAs tentam apenas reproduzir as funções das redes biológicas (BRAGA, CARVALHO, LUDERMIR, 2000).

As RNAs são não-lineares e têm a capacidade de: generalizar, tolerar falhas e adaptar-se funcionam modelando como uma rede de neurônios interconectados que

calculam valores a partir de entradas fornecidas à rede. Além disso, existem outras características dos neurônios artificiais que fomentam diversas aplicações e resultados importantes em diversas áreas, tais como: sistemas de segurança e previsão de séries temporais, etc.

A rede neural possui exclusivamente duas fases de processamento a de aprendizado e a de utilização. O aprendizado (ou treinamento) consiste no ajuste de pesos das conexões em resposta a um estímulo apresentado a rede neural, já a utilização consiste na forma como a rede responde a um estímulo de entrada sem modificar sua estrutura (OLIVEIRA *et al.*, 2007).

O neurônio artificial manipula informações através da interação entre diversos números de unidades básicas de processamento. Essas unidades ou RNAs enviam sinais entre si, podendo apresentar múltiplas camadas (camada de entrada), conectados por meio de pesos (dendritos). E, para gerar a saída normalmente é usada a função de ativação onde o comportamento do neurônio será representado por um mecanismo simples, que faz a soma ponderada de suas entradas (BRAGA, CARVALHO, LUDERMIR, 2000).

Portanto a rede de uma só camada terá porta de limiar linear capaz de restringir-se a solução de problemas que são linearmente superáveis, ou seja, a função de ativação fica responsável por gerar saídas com base em pesos sinápticos. Como por exemplo, a equação 3.24, do tipo degrau deslocada do limiar de ativação θ em relação a origem neste caso a saída será 1, caso contrario o limiar de ativação θ será negativo e a saída será 0.

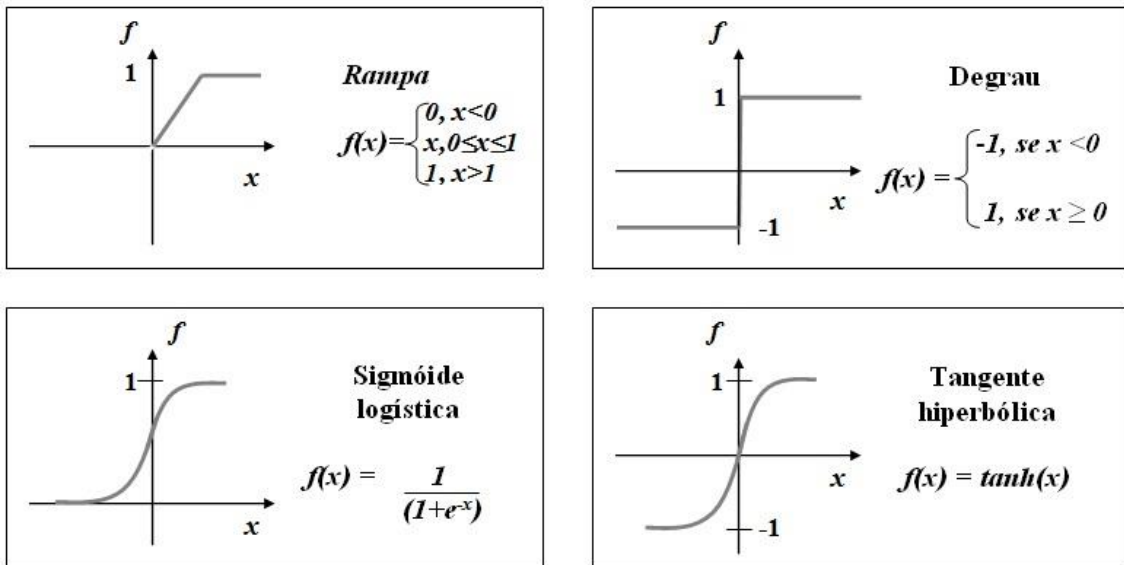
$$\sum_{i=1}^n x_i w_i \geq \theta \quad (3.24)$$

Na RNA, o limiar é ativado pela função de transferência, os modelos variam e as funções de ativação também, no entanto, as mais usuais são apresentadas na Figura 5.

O aprendizado da RNA obedece a duas regras de classificação: o aprendizado supervisionado onde um supervisor fica responsável em estimular as entradas da rede por meio de padrões e observar a saída calculada. Já o aprendizado não-supervisionado não há necessidade de um supervisor externo para acompanhar o processo de aprendizado apesar de não existir saída padrão.

Quando a rede é eficiente na etapa de aprendizado seus parâmetros internos e pesos são ajustados de tal modo que produzem saídas com erros toleráveis (OLIVEIRA *et al.*, 2007). Os erros serão satisfatórios de acordo com as premissas do processo de treinamento onde serão explorados os conjuntos de teste e validação.

Figura. 5 - Funções de ativação mais usuais para limitar a saída de um neurônio



Fonte: Adaptado pela autora (2014) com base em OLIVEIRA, (2007).

Quanto à arquitetura das RNAs elas podem ser divididas em: redes *feedforward* de camadas simples, redes *feedforward* de camadas múltiplas e etc. No entanto, a mais usada atualmente é a *feedforward* com o Perceptron multicamadas (MLP).

3.3.1 Redes Neurais Perceptron de Múltiplas Camadas (MLP)

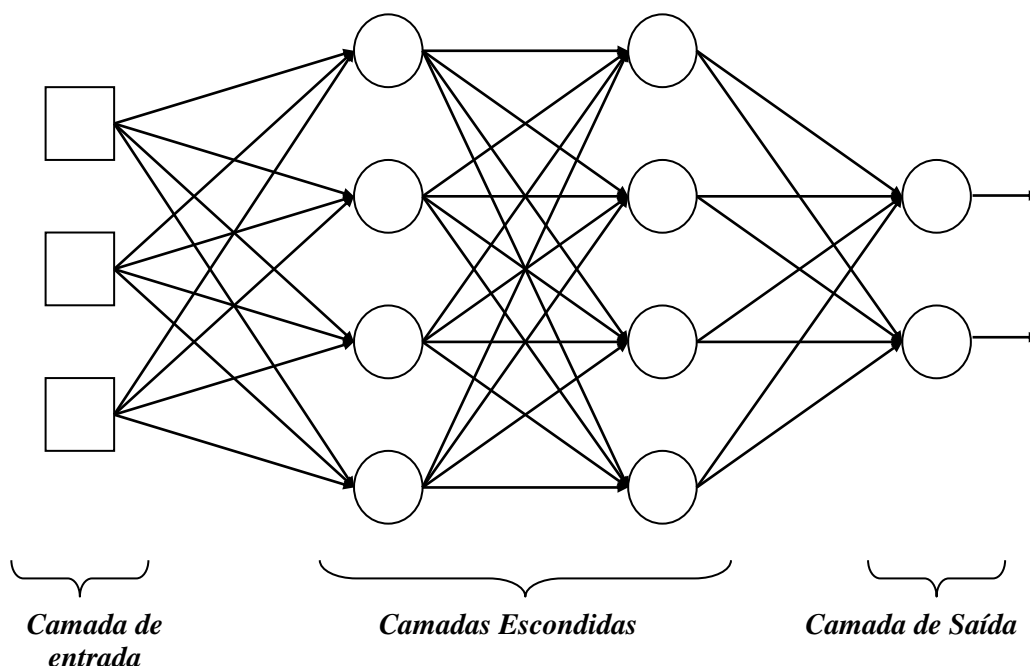
Uma MLP é composta por diversas camadas de neurônios, onde uma camada está completamente ligada à camada seguinte, isto é, um neurônio de uma camada está ligado a todos os neurônios da camada seguinte. Cada uma dessas ligações tem um peso associado. O processo de aprendizagem ocorre ao alterar o valor do peso dessas conexões, após a análise de um exemplo, tomando como base a comparação do erro na camada de saída e o resultado esperado (HAYKIN, 2001).

As MLPs são caracterizadas pela presença de camadas de entrada (*Input Layer*) e pelo menos uma camada escondida de neurônios (*Hidden Layer*) e a respectiva

camada de saída (Output Layer). Além disso, as MLPs são tipicamente usadas em diversos tipos de problemas com destaque nesse estudo a área de concentração aplicada a series de tempo na prática de previsões e análise de padrões.

A MLP é treinada de forma supervisionada onde o fluxo de informações se inicia na camada de entrada, percorre em seguida as camadas ocultas, sendo então finalizado na camada de saída (SILVA; SPATTI; FLAUZINO, 2010). Esse processo é ilustrado na Figura 6.

Figura. 6- Rede Perceptron de Múltiplas Camadas (MLP)



Fonte: Adaptado pela autora (2014) com base no HAYKIN, (2001).

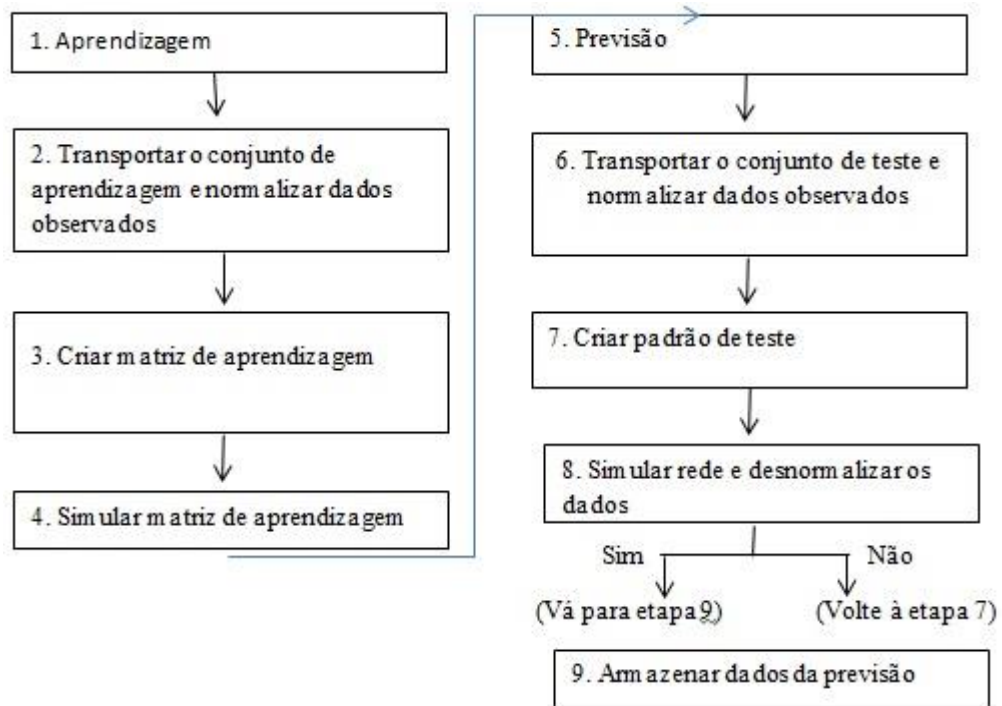
O algoritmo backpropagation utiliza pares (entrada, saída desejada) ao qual, por meio de um mecanismo de conexão de erros possa ajustar os pesos da rede. Essa rede é administrada em duas fases bem definidas: a fase *forward* – define a saída de rede para um dado padrão de entrada; fase *backward* – utiliza a saída desejada e a saída fornecida pela rede para atualizar os pesos de suas conexões.

O algoritmo backpropagation é o mais usado no treinamento de uma MLP, ao qual a função de transferência é geralmente uma log-sigmoidal com saídas no intervalo [0,1]. Como dito anteriormente a regra de aprendizado consiste em ajustar pesos e bias da rede, visando minimizar a soma do erro quadrático médio. Deste modo derivadas do

erro são calculadas para a camada de saída, ou seja, são retropropagadas até que os vetores delta estejam disponíveis para cada camada escondida (OLIVEIRA *et al.*, 2007).

Assim o aprendizado continua até um número máximo de iterações ou a um erro satisfatório de previsão, estruturado no algoritmo proposto (Figura 7).

Figura. 7- Algoritmo do processo da MLP no Matlab.



Fonte: Elaborado pela própria autora.

3.4 Previsões para modelos ARIMA e MLP

As previsões feitas para cada um dos modelos ARIMA e MLP apresentam uma relação de desempenho e casualidade, pois, ambas as metodologias minimizam o erro quadrático médio de previsão.

O desempenho da previsão tanto para modelos ARIMA quanto para o modelo MLP podem ser avaliados e comparados com base no Erro Percentual Médio Absoluto (MAPE), que é calculado sobre o conjunto de teste conforme cada uma das modelagens.

$$MAPE = \frac{1}{N} \sum_{j=1}^N \left| \frac{\text{valores reais} - \text{previstos}}{\text{valores reais}} \right| \times 100 \quad (3.25)$$


Em que os valores previstos representam a previsão pela rede neural MLP ou pela modelagem de Box e Jenkins. Portanto a escolha do modelo consiste em administrar MAPEs inferiores a 10% (aceitáveis).

4. RESULTADOS E DISCUSSÃO

4.1. Análise Preliminar dos Dados

A análise preliminar dos dados é de fundamental importância para entender o comportamento da série temporal, no entanto, existem variáveis externas que não fazem parte da série original de dados, mas, influenciam os valores reais e futuros da série. As variáveis externas que mais influenciam o comportamento dos dados em longo prazo é a inflação medida pelas taxas SELIC e pelo IGP-M, pois exerce impacto no valor acumulado de contribuições mensais arrecadadas pelas companhias seguradoras. Só para exemplificar, com a inflação veio à redução nas taxas de juros, fato esse que não foi interessante para a rentabilidade das seguradoras, houve um desestímulo à formação de poupança e inibição dos investidores principalmente em 2006, por causa da política especulativa no governo Lula e em 2008 devido à crise financeira mundial. Além disso, o gráfico (Figura 8) permite inferir que a série não é estacionária na média, uma vez que a mesma apresenta uma trajetória de decrescimento e crescimento ao longo do período.

Figura 8: Série Original de Arrecadações pelas EAPCs no período de janeiro de 2003 a maio de 2013.




Fonte: Software R 3.0.3

Após a crise o mercado se recuperou porém, em 2010 o mercado de previdência voltou a cair, o que mudou é que o fator de impacto naquele ano foi à mudança na tábua de mortalidade e não apenas a taxa de juros. Essa mudança a primeiro momento instaurou a desconfiança e uma desaceleração em todo o mercado de previdência ainda no ano 2010.

A análise da série temporal predispõe que a série possa ser representada sequencialmente ao longo do tempo, logo em uma visualização simples que revela padrões de sazonalidade (*seasonal*) homogênea e estável em todos os anos, fato já esperado considerando a sazonalidade dos valores expressos pelas contribuições mensais pagas as EAPCs (Figura 9). Também existe uma tendência (*trend*) crescente pós-modificações em 2010 associadas a tábua de mortalidade, fato que comprova o retorno da confiança dos segurados em planos de previdência complementar aberta.

Figura 9: Decomposição da série Original Contribuições pagas as EAPCs

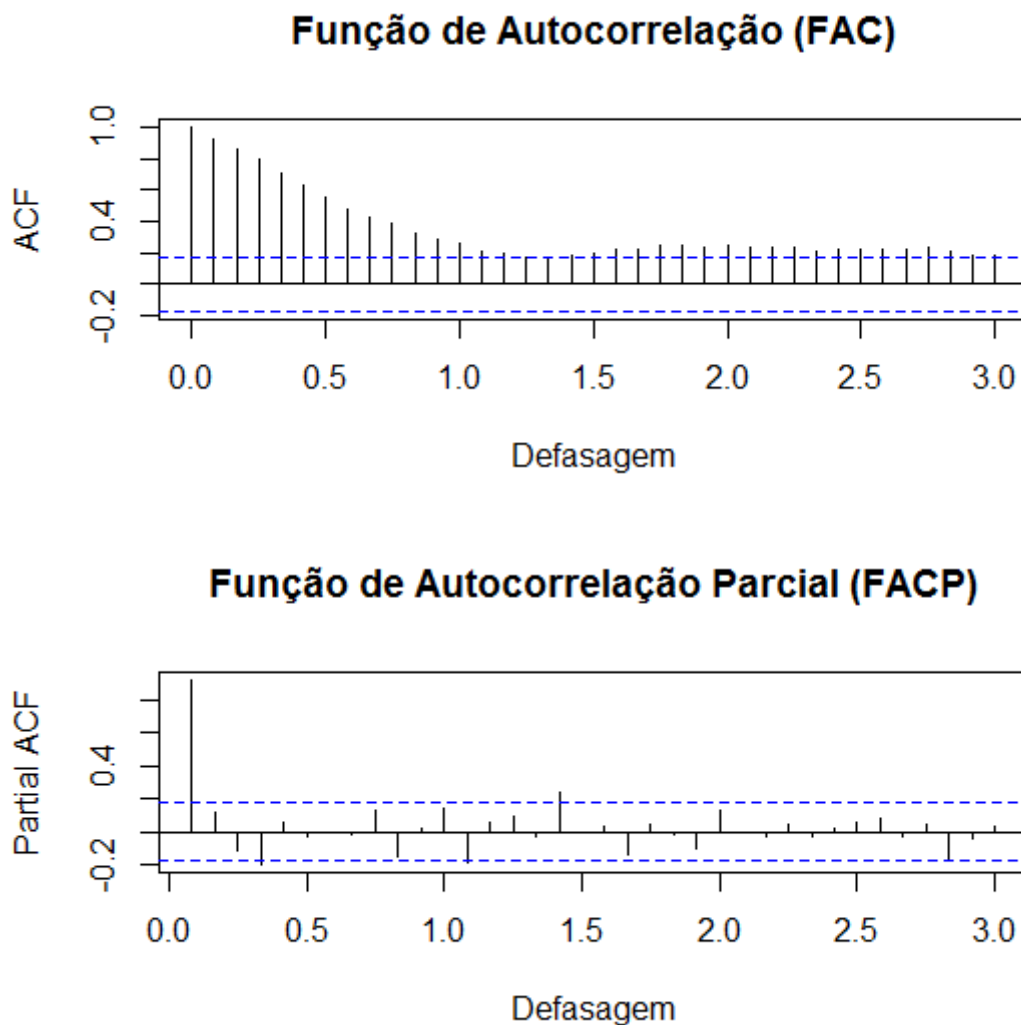


Fonte: Software R 3.0.3

4.2 – Box & Jenkins

Na etapa de identificação a escolha de um modelo ARIMA ou SARIMA de ajuste para a série de dados contribuições em EAPC foi feita com base nos cálculos da Função de autocorrelação (FAC) e da Função de autocorrelação parcial (FACP) obtendo os correlogramas (Figura 10). Há fortes evidências de seu comportamento sazonal, com picos nas defasagens 24 e 32 do correlograma da FAC, diferentemente, do correlograma das FACP onde o pico de defasagem ocorre na defasagem 16. Como os valores dos picos decaem lentamente pode-se pressupor um sinal de não-estacionariedade da série, logo a série deve ser diferenciada para retirar a tendência.

Figura 10: FAC e FACP da Série Original de contribuições pagas as EAPCs



Fonte: Software R 3.0.3

Existem ainda as formas alternativas de identificação para lidar com a não-estacionariedade da média encontrada na série em estudo, basta apenas verificar se está não-estacionariedade decorre de um processo de raiz unitária. A verificação de uma tendência inerente a série é feita com o teste de Dickey-Fuller, utilizando o comando *ur.df* (Augmented Dickey-Fuller Test Unit Root Test) do *R* cujos resultados são: estatística no valor de 1,662 e p-valor de 0,194, apontam para a presença dessa característica. Logo há, em princípio a necessidade de diferenciar a série contribuições pagas as EAPCs.

Para identificar o número ótimo de parâmetros do modelo de Box&Jenkins que melhor se adapta à série, será realizado um processo iterativo, variando-se os parâmetros p , d , q , P , D e Q da Tabela 1 estimado através do comando *arima* no software *R*, obtendo-se dois modelos um ARIMA e um SARIMA correspondente a série temporal. Para cada modelo foram calculados os valores do AIC (*Akaike Information Criteria*) e BIC (*Bayesian Information Criteria*) e escolhidos aqueles que apresentam os menores valores.

Tabela1: Modelos ajustados e valores da estatística AIC e BIC

Modelo	AIC	BIC
ARIMA (0,1,2) ₁₂	3997,7	4006,16
SARIMA (0,1,0)(2,0,1) ₁₂	3988,6	3999,9

Fonte: Software R 3.0.3

Assim o modelo que apresentou respectivamente os menores AIC e BIC foi o modelo SARIMA (0,1,0)(2,0,1)₁₂ ajustado para a série contribuições pagas as EAPCs.

Antes de verificar o modelo estimado anteriormente, deve-se analisar se os coeficientes de autocorrelação dos erros apresentam alguma normalidade, para provar está normalidade basta realizar um teste de normalidade, cujo teste escolhido foi o teste de Jarque-Bera. O resultado foi p-valor <0,05, então rejeita a hipótese de normalidade, porém neste caso p-valor foi arbitrariamente baixo. Logo, a distribuição seria, para fins práticos, igual a uma normal, pois assumir normalidade não prejudicaria sua inferência. Portanto não convém rejeitar a normalidade, já que os erros aleatórios da distribuição normal são independentes.

Por fim, verifica-se o modelo SARIMA (0,1,0)(2,0,1)₁₂ é adequado para fins de diagnóstico e previsão. Nesse processo os resíduos devem apresentar distribuição normal com média zero e variância σ^2 e serem não correlacionados. A análise conjunta dos testes Ljung-Box e Box-Pierce (Tabela 2) indicaram que não há evidência para rejeitar hipótese nula de ruído branco, ao nível de significância de 5%, ou seja, os resíduos são não correlacionados.

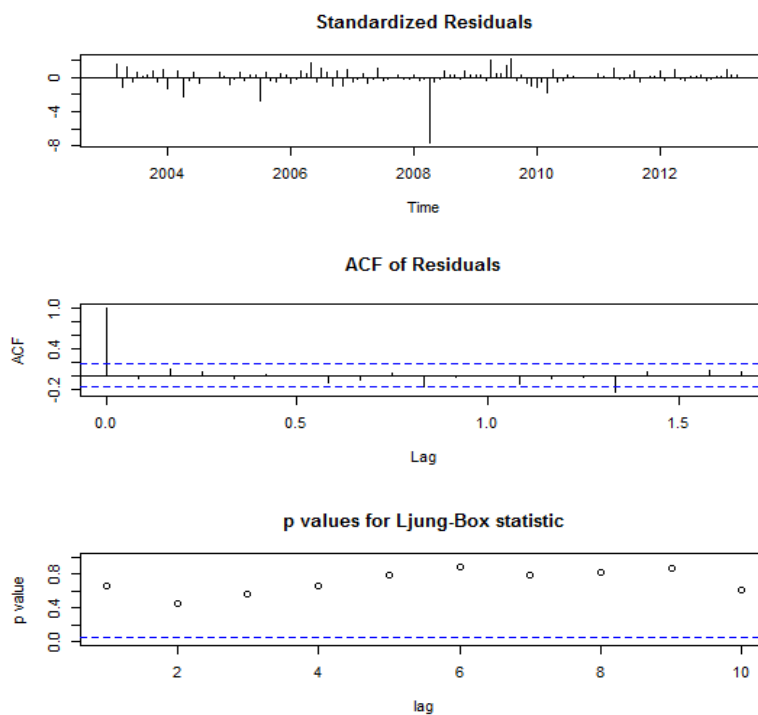
Tabela2: Teste de autocorrelação

Modelo SARIMA (0,1,0)(2,0,1) ₁₂	Box-Pierce	Ljung-Box
Estatística	0,1884	0,1929
p-valor	0,6643	0,6605

Fonte: Dados da pesquisa

Logo a autocorrelação amostral dos resíduos dispõem de resultados positivos satisfazendo assim mais um pressuposto de Box-Jenkins. Deste modo todos os gráficos dos resíduos se mostram favoráveis ao modelo SARIMA (0,1,0)(2,0,1)₁₂ ajustado (Figura 11).

Figura 11: Análise da estatística de Box–Pierce (e Ljung–Box)



Fonte: Dados da pesquisa

4.3 Redes Neurais Artificiais

A criação da RNA foi realizada através do pacote de ferramentas para redes neurais “*nntools*” do Matlab R2013a. Com esse comando é possível definir os padrões de entrada, saída e, modelar a rede com as ferramentas disponíveis na IDE *nntool*.

A série arrecadações em reais pelas EAPCs foi dividida em duas partes: onde a primeira parte são as observações compondo 120 observações para o conjunto de treinamento; a segunda parte contém os conjuntos de validação e teste composto por 12 observações. Com a rede treinada foi feita a previsão utilizando os valores de entrada do conjunto de teste. O passo seguinte consiste em simular a RNA carregando o conjunto de teste e normalizar os dados no intervalo $[-1,1]$. Desse modo, foi gerado um padrão de entrada para a rede com mesmo valor de arrecadações (fechamento EAPC) utilizadas na matriz de treinamento.

Na modelagem das RNAs foi utilizado o algoritmo *backpropagation* que é o mais usado no treinamento supervisionado de uma MLP e, a função de ativação aplicada aos modelos foi a *sigmoid logistic*. Nesse estudo, o número de neurônios da camada de entrada (*Input Layer*) corresponde à escolha das defasagens abordadas para descobrir o padrão existente da série arrecadações em reais pelas EAPCs no período de janeiro de 2003 a maio de 2013, ou seja, representa o número máximo de ciclos ou sazonalidade que um modelo MLP pode apurar.

Quanto à camada oculta (*Hidden Layer*), apenas uma única camada escondida foi o suficiente para obter bons resultados, aplicando a uma quantidade de neurônios pré-determinada. A determinação de neurônios na *Hidden Layer* foi implementada com base no princípio da parcimônia, ou seja, a utilização de poucos neurônios proporciona uma melhor capacidade de generalização, porém, os resultados obtidos podem simplificar demais o modelo restringindo a rede e favorecendo o aparecimento de um problema conhecido como *overtraining*. Para evitar que tal problema ocorra a configuração do número de neurônios na camada intermediária foi validada pelo erro quadrático médio, logo a melhor configuração é aquela que fornece o menor erro de validação e o mínimo erro para o conjunto de teste.

Já a camada de saída (*Output Layer*) determinará o horizonte de previsão um passo a frente, portanto essa camada possui somente um neurônio.

Assim essas três camadas formaram o modelo de abordagem na construção da MLP, a qual variou de acordo com a Tabela 3 em quantidade de neurônios a cada intervalo de tempo.

Tabela 3: Parâmetros de configuração das MLPs utilizadas

Técnica	MLP-6	MLP-12	MLP-18
Neurônios na Input Layer	6	12	18
Neurônios na Hidden Layer	4	10	20
Aprendizagem	0,5	0,5	0,5
Condição de Parada (erro)	0,1	0,1	0,5

Fonte: Dados da pesquisa

Para as varias simulações das MLPs, o coeficiente de treinamento definido foi de 0,5 e representa a velocidade de aprendizado. O número de ciclos para parada do treinamento permaneceu em 1.000 iterações com o objetivo de evitar o super-ajuste da rede de dados de treinamento. Como condição de parada, utilizou-se uma medida de erro quadrático. O erro considerado para a MLP com 18 neurônios na camada de entrada (MLP-18) foi maior do que os outros casos, pois a rede não atingiu a condição de parada de 0,1 em tempo hábil.

4.4 Box & Jenkins x Redes Neurais Artificiais: previsão e análise de desempenho

Conforme descrito na Seção 1.1 o presente estudo visa fornecer informações pertinentes acerca de variações de contribuições no setor de PCA, avaliando seu desempenho por intermédio de previsões, então buscou-se analisar os resultados projetados de acordo com os dados coletados durante o período de observação, a fim de validar o melhor modelo.

Após a parametrização dos modelos de Box & Jenkins e os modelos Redes Neurais Artificiais para a previsão do volume de contribuições mensais (fechamento EAPC) entre os meses de maio de 2013 até maio de 2014. Devem-se testar as técnicas descritas anteriormente, já que, existe uma relação de desempenho e casualidade, pois, ambas as metodologias minimizam o erro quadrático médio de previsão. Conforme a

seção 3.4 esse desempenho é avaliado tipicamente pelo Erro Percentual Médio Absoluto (MAPE).

Ao aplicar as medidas de erro sobre os erros de previsão foram encontrados os resultados do MAPE para cada modelagem (Tabela 4).

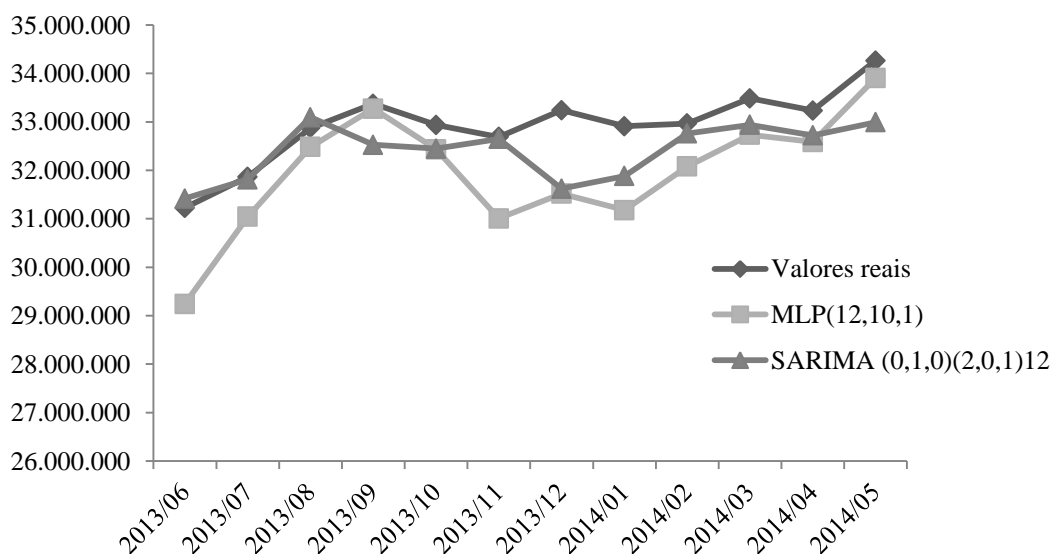
Tabela 4: Resultados dos modelos Box & Jenkins e, RNA.

Modelo	MAPE
MLP (6,4,1)	3,27
MLP (12,10,1)	2,21
MLP(18,20,1)	13,09
ARIMA(0,1,2)	5,21
SARIMA (0,1,0)(2,0,1) ₁₂	1,76

Fonte: Dados da pesquisa

Conforme observado na Tabela 4 os modelos previstos com componente sazonal de 12 meses se adequaram melhor a série de dados, pois, seus valores se aproximam aos valores reais do volume de contribuições mensais (fechamento EAPC) entre o período de maio de 2013 até maio de 2014. Este fato pode ser ilustrado na Figura 11, graficamente a comparação entre as previsões fornecidas pelo modelo SARIMA (0,1,0)(2,0,1)₁₂ e pelo modelo MLP(12,10,1).

Figura 12. Previsões fornecidas pelas modelagens Box & Jenkins e, RNA para o período entre junho/2013 e maio/2014.



Fonte: Dados da pesquisa.

5. CONCLUSÕES

O número de contribuições arrecadadas ainda é um índice importante para avaliar o desempenho das EAPCs, pois em uma análise preliminar de séries temporais esse sistema de mercado se mostrou sensível a mudanças no cenário macroeconômico e a mudanças na base de cálculo principalmente nos últimos 10 anos. Esses fatores explicam o comportamento irregular da série original. Portanto o presente estudo visa fornecer informações pertinentes acerca de operações e variações de contribuições no setor de PCA em relação ao mercado supervisionado de seguros, avaliando seu desempenho por intermédio de critérios de previsões, a fim de validar o melhor modelo.

O modelo estatístico de Box-Jenkins permitiu identificar os padrões de comportamento como tendência e sazonalidade presentes na série estudada. Enquanto que a técnica de Redes Neurais Artificiais não indica com precisão os padrões de comportamento da série contribuição mensal (fechamento EAPC), porém essa técnica pode ser usada como instrumento de apoio e decisão no mercado de PCA, com o propósito de simulação e/ou otimização do volume de arrecadações mensais obtidos pelas EAPCs.

Dentre as metodologias abordadas, e com base nos parâmetros utilizados para comparação, verificou-se que aquela que apresentou modelos com melhor capacidade para prever as Arrecadações pelas EAPCs no período de maio de 2013 a junho de 2014 foi à metodologia de Box & Jenkins, para a série original. Deve-se acrescentar, também, que o método de Redes Neurais Artificiais se revelou interessante para realizar previsões considerando um ano.

Os resultados para ambos os modelos demonstram que estimar a variabilidade do consumo na indústria de seguros pode ajudar as seguradoras e bancos a antever e adequar às necessidades do setor de previdência complementar analisando os reflexos de um reconhecimento de padrão de contribuições aplicadas ao serviço. No entanto, essas previsões devem ser analisadas com atenção, uma vez que os cálculos foram feitos apenas para 12 meses e, diante da complexidade, tempo e experiência para realizar o desenvolvimento de cada modelagem o método de Box & Jenkins mostrou-se mais viável.

Os resultados do Erro Percentual Médio Absoluto (MAPE) foram considerados significativos, porém dada a arbitrariedade dos dados os valores encontrados dão indício

de cautela, pois, a série não converge quando a previsão é maior que 12 meses. Este fato se deve a instabilidade do mercado e das empresas nele inseridas.

Sugere-se em trabalhos futuros uma análise de intervenção aplicada a modelagem ARIMAX no período de 2008, pois, durante esse período a crise mundial atingiu o Brasil proporcionando uma alta volatilidade no mercado supervisionado de seguros reduzindo principalmente a estabilidade nos planos de previdência.

Outra sugestão é a realização de pesquisas futuras que identifique a interação entre modelos de séries temporais e modelos de inteligência computacional através de um modelo híbrido que possa realizar previsões mais acuradas.

Além disso, a análise do resultado de qualquer previsão pode auxiliar no entendimento de como a adoção de diferentes práticas atuariais podem interferir na capacidade informacional dos dados divulgados pela SUSEP, tais como o capital de entrada obtido das contribuições arrecadadas com planos de previdência.

REFERÊNCIAS

AMARAL T. R. S. **Análise de performance de fundos de investimento em previdência.** 2013. Dissertação (Mestrado em Administração) - Faculdade de Economia, Administração e Contabilidade, Universidade de São Paulo, São Paulo, 2013. Disponível em:

<http://www.teses.usp.br/teses/disponiveis/12/12139/tde-10122013-154317/pt-br.php>.

Acesso em: em 03 de agosto de 2014.

ARAÚJO, P. H. S. L. **Elaboração de rankings por meio do uso de técnicas estruturadas:** uma aplicação no setor de seguros privados. 2008. Dissertação (Mestrado em Engenharia de Produção) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2008. Disponível em:

<http://www.teses.usp.br/teses/disponiveis/18/18140/tde-02022009-082321/pt-br.php>.

Acessado em 08 de agosto de 2014.

BARROS M. A. S. **A Evolução da Previdência Complementar Aberta no Brasil: Um Estudo de Eventos.** Dissertação (Mestrado) – Faculdade Ibmec São Paulo, São Paulo: 2007.69 p.

BOX, G. E. P.; JENKINS, C. M.; REISEL, G. C. Time series analysis: Forecasting and Control. 3.ed New Jersey: Prentice Hall, 1994.

BRAGA, A. P., CARVALHO, A. P. L. F. e LUDERMIR, T. B. Redes Neurais Artificiais: Teoria e Aplicações. Rio de Janeiro: LTC, 2000.

CNSEG. Confederação Nacional das Seguradoras. Informe Anual / Balanço Social em 2008. Disponível em: <http://www.cnseg.org.br/cnseg/memoria/informe-anual-balanco-social/>. Acessado em 02 de agosto de 2014.

CONTADOR, C. R.; FERRAZ, C. B. Insurance and Economic Growth: some International evidences. **Revista Brasileira de Risco e Seguro**, Rio de Janeiro, Brasil, v. 1, n. 1, p.41-78, 2007.

DANTAS T. M. **Uma aplicação de Inteligência Computacional e Estatística Clássica na Previsão do Mercado de Seguros de Automóveis Brasileiro.** 19º SINAPE- Simpósio Nacional de Probabilidade e Estatística, São Paulo, 2010. Disponível em: <http://www.ime.unicamp.br/sinape/19sinape/taxonomy/term/35?page=1> Acessado em 02 de junho de 2014.

EHLERS, R.S. **Análise de Séries Temporais.** Departamento de Estatística,

UFPR. 2007. Disponível em <http://leg.est.ufpr.br/~ehlers/notas>. Acesso em: 1 julho de 2014.

FENASEG – Federação Nacional das Empresas de Seguros Privados e de Capitalização. Disponível em: <www.fenaseg.org.br>. Acesso em: 28 de abril de 2014.

FARIA L. V. D. **O Desempenho dos mercados de seguros, previdência complementar aberta e capitalização em 2005**. Rio de Janeiro: FUNENSEG, 2006. 28p.

FAVA, V. L. Metodologia de Box-Jenkins para modelos univariados. Manual de econometria: nível intermediário. São Paulo: ATLAS, 1999, v. 1.

GUJARATI, Damodar. Econometria básica. 4ª edição. Rio de Janeiro: Campus, 2006.

HAYKIN, S. Redes Neurais: princípios e prática. 2ª ed. Porto Alegre: Ed. Bookman, 2001.

HOLSBOER, J.H. The Impact of Low Interest Rates on Insurers. **The Geneva Papers On Risk and Insurance**. Vol. 25 Nº 1, p.38-58. 2000

MADDALA, G. S. **Introdução à Econometria**. 3ª. ed. Rio de Janeiro: LTC, 2003.

MATOS, O. C. Econometria básica: teoria e aplicações. 3ed. São Paulo: Atlas, 2000.

MEYERSON, N. *et al.* **Uncertainty in Social Security's long-term finances: a stochastic analysis**. Congress of the United States - Congressional Budget Office, 2001.

MONTESINOS, D. S.. **Previdência Complementar - Estudo de caso: Plano Fechado de Previdência Complementar**, 2007. 83 folhas. Monografia do Curso de Ciências Contábeis - Universidade Federal de Santa Catarina.

MORETTIN, P. A.; TOLOI, C. M. C. Análise de séries temporais. 2 ed. São Paulo: Edgard Blucher, 2006.

MOURA, R. L.; TAFNER, P.; JESUS FILHO, J. **Testando a propriedade redistributiva do sistema brasileiro: uma abordagem semi-paramétrica**. In: TAFNER, P., GIAMBIAGI, F. (Orgs.). **Previdência no Brasil: debates, dilemas e escolhas**. Rio de Janeiro: IPEA, 2007. p. 349-400.

OLIVEIRA Jr. H. A. *et al.*. **Inteligência computacional: Aplicada à Administração, Economia e Engenharia em Matlab®**. São Paulo: Thomson Learning, 2007.

PINDYCK, R S e RUBINFELD, D L **Econometria: modelos & previsões**. 4ª ed. RJ: Elsevier, 2004.

PÓVOAS, Manoel S. Soares. **Previdência privada filosofia, fundamentos técnicos, conceituação jurídica.** [S.I.]: FUNENSEG, 1985. 426 p.

R Core Team (2013). **R: A language and environment for statistical computing.** R Foundation for Statistical Computing, Vienna, Austria. URL <http://www.R-project.org/>.

RODRIGUES, J. A. **Gestão de Risco Atuarial.** São Paulo: Saraiva. 2008.

SARTORIS NETO, Alexandre. **Estatística e Introdução à Econometria.** 1ª. Ed. São Paulo: Saraiva. 2009.

SCHRÖDERV B. H. V.; DIAS V.P. **Econometria Para Concursos - Série Questões.** Editora: ELSEVIER - CAMPUS: 2012.

SILVA, E. **Previdência Social Oficial e Previdência Privada: Estágio Atual, Perspectivas e Tendências, uma Abordagem Geral.** 2011. 87 p. Orientador: Adilson

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais para engenharia e ciências aplicadas.** São Paulo: Artliber, 2010.

SILVA L. L. *et al.* **A Análise da Produção Científica em Administração sobre a Previdência Brasileira: Meta-avaliação da Produção nos Eventos da ANPAD.** XXXVII Encontro Anpad. Rio de Janeiro: EnAPA, 2013. 14p.

SOUZA A. A. *et al.* **Análise das reservas formadas na previdência complementar aberta e fechada .** V Congresso UFV de Administração e Contabilidade e II Mostra Científica. Minas Gerais: 2012. 17p.

SOUZA B. G. **Governança Corporativa e Normas Contábeis das Entidades Fechadas de Previdência Complementar.** Dissertação (Mestrado)- Pontifícia Universidade Católica PUC, São Paulo: 2012. 283p.

SUSEP- **1º RELATÓRIO DE ANÁLISE E ACOMPANHAMENTO DOS MERCADOS SUPERVISIONADOS,** Rio De Janeiro, 23 de Setembro de 2013. 19 p.

SUSEP. Disponível em: <http://www.susep.gov.br>. Acesso em 10 de agosto de 2014.

SUSEP- **Guia de orientação e defesa do segurado /** Superintendência de Seguros Privados. – 3. Ed. – Rio de Janeiro: Susep, 2014 73 p.

WEI, W. W. S. **Time series analysis: univariate and multivariate methods.** 2ª ed. New York: Pearson, 2006.

VAZ, T. de A. **Estimação das Taxas de Conversão em renda de Planos de Previdência Complementar Aberta no Brasil e seus impactos para as EAPC's.** – São Paulo: Insper, 2011.61 p.