

MODELO PREDITIVO PARA GERAÇÃO DE INFORMAÇÕES GERENCIAIS PARA EMPRESAS PATROCINADORAS DE ENTIDADES FECHADAS DE PREVIDÊNCIA COMPLEMENTAR

A PREDICTIVE MODEL FOR THE GENERATION OF MANAGERIAL INFORMATION FOR SPONSORING COMPANIES OF CLOSED COMPLEMENTARY WELFARE ENTITIES

Vera Lúcia Cruz¹ , Rodrigo José Guerra Leone² , Telmo de Menezes e Silva Filho³ , Fátima Regina Ney Matos⁴ 

O objetivo do estudo foi realizar uma análise comparativa na aplicação de dois modelos o Auto-regressivos Integrados de Média Móvel (ARIMA) e o modelo de Auto-regressão Vetorial (ARV) em empresas patrocinadoras das Entidades Fechadas de Previdência Complementar, listadas no Brasil, Bolsa, Balcão (B3). Através de uma ação quase-experimental, foram utilizados dois modelos, o auto-regressivos integrados de média móvel (ARIMA) e o modelo de Auto-regressão Vetorial (ARV). Com base nos resultados preditivos dos modelos, foi possível identificar que os dados rodados pelo método ARIMA não apresentaram um bom ajuste e foi possível concluir que o modelo criado pelo ARV se apresentou mais robusto na previsão das situações futuras das empresas analisadas, e que, as decisões com base nos modelos preditivos, apontaram a necessidade de antecipação de decisões sobre a taxa de desconto, a taxa de inflação, taxa do aumento salarial e sobre os ativos garantidores.

Palavras-chave: CPC 33 (R1). EFPC. Modelo preditivo. Auto Regressão Vetorial. ARIMA.

The objective of this study is to carry out a comparative analysis with the application of two models, the Autoregressive Integrated Moving Average (ARIMA) and the Vectorial Autoregression (VAR), in the sponsoring companies of the *Entidades Fechadas de Previdência Complementar*, listed in *Brasil, Bolsa, Balcão (B3)*. Through a quasi-experimental action, two models were utilized, the Autoregressive Integrated Moving Average (ARIMA) and the Vector Autoregression model (ARV). Based on the predictive results of these models, it was possible to identify that the data run by the ARIMA method did not present a good fit, it was possible to conclude that the model created by ARV was more robust in predicting future situations of the analyzed companies, and that, decisions based on predictive models, pointed to the need to anticipate decisions on the discount rate, the inflation rate, the rate of salary increase and on the guaranteeing assets.

Keywords: CPC 33 (R1). EFPC. Predictive model. Autoregression Vector. ARIMA.

Autor correspondente:

Vera Lúcia Cruz

E-mail:

vera.cruz@ccsa.ufpb.br

Declaração de interesses:

Os autores certificam que não possuem implicação comercial ou associativa que represente conflito de interesses em relação ao manuscrito.

Authors' Contributions:

^{1, 2, 3} Conceptualization

^{1, 2, 3} Data collect

^{1, 2, 3} Analysis

^{1, 2, 3} Writing and Editing

¹ Universidade Federal da Paraíba – Departamento de Finanças e Contabilidade, João Pessoa – PB.

² PPGA da Universidade Potiguar, Ponta Negra, Natal – RN.

³ Universidade Federal da Paraíba – Departamento de Estatística, João Pessoa – PB.

⁴ Instituto Superior Miguel Torga, Coimbra, Portugal.

INTRODUÇÃO

Após o processo de convergência em 2007, vários pronunciamentos foram emitidos pelo Comitê de Pronunciamentos Contábeis (CPC), que tem, dentre seus objetivos, melhorar a informação gerencial das empresas de modo a ajudar o usuário a entender, de forma mais precisa, os relatórios que são gerados pela entidade. Dentre esses pronunciamentos, encontra-se o CPC 33 (R1), que prevê as contabilizações de benefícios a empregados, sejam estes funcionários ativos ou os que se encontram no pós-emprego.

Assim, o CPC traz consigo o intuito de preencher lacunas informacionais que tenham ocasionado a não contabilização de eventos por algum critério ou procedimento ainda não determinado para seu efetivo registro. Com isso, o *International Accounting Standard* (IAS) 19 promove maior transparência quanto à divulgação dos dados e aos atributos qualitativos desses planos. Essa norma fornece, desse modo, melhores articulações na divulgação sobre as informações atuariais dos planos de benefícios (BLOOM, 2013).

A revisão dessa norma trouxe mais detalhamento para o pronunciamento que se alinha à IAS 19. Isso promoveu tratamentos contábeis diferenciados para cada classe de benefícios, tanto para os funcionários ativos como para aqueles em condição de pós-emprego, visando a melhorar a qualidade da informação contábil para seus usuários. Porém, a proposta de contabilização prevista no CPC (R1) Benefícios a Empregados exclui a possibilidade da utilização do “método do corredor”, este contabilizava o maior valor entre 10% do valor justo dos ativos do plano e da obrigação de benefícios definido, e somente a diferença atuarial que ficasse fora do limite do corredor seria reconhecida no resultado durante o período médio restante de trabalho dos empregados (CPC, 2012).

No que se refere à contabilização desses benefícios, o CPC 33 R1 (2012) determina que a entidade reconheça um passivo quando o empregado prestou o serviço em troca de benefícios a serem pagos no futuro; e uma despesa quando a entidade se utiliza do benefício econômico proveniente do serviço recebido do empregado, em troca de benefícios a esse empregado.

Os reflexos informacionais, gerados com as mudanças nos critérios de contabilização, provocaram oscilações nas demonstrações dos resultados abrangentes das empresas patrocinadoras, as quais financiam as Entidades Fechadas de Previdência Complementar (EFPC). Para a PREVIC (2022), Entidades Fechadas de Previdência Complementar (EFPC) são operadoras de plano(s) de benefícios, constituídas na forma de sociedade civil ou a fundação, e sem fins lucrativos, estruturada na forma do artigo 35, da Lei Complementar nº 109, de 29 de maio de 2001, que tenha por objeto operar plano de benefício de caráter previdenciário. As EFPC'S têm por objeto operar plano de benefício de caráter previdenciário, caracterizando-se como instituições criadas para o fim exclusivo de administrar planos de benefícios de natureza previdenciária, patrocinados e/ou instituidores. A Escola de Administração Fazendária (ESAF, 2018) aponta que o patrocinador é o empregador que cria o plano de benefício previdenciário para seus empregados, a ser administrado por uma EFPC.

Ressalta-se que a mudança no pronunciamento relacionado ao critério e ao reflexo das informações, que passaram a ser evidenciados nos DRA's, teve como objetivo estabelecer a contabilização e a divulgação das informações relacionadas aos direitos inerentes aos empregados. As oscilações apresentadas no demonstrativo estão mais relacionadas à mudança no critério da contabilização, já que os confrontos das contas eram contabilizados pelo método corredor, e após a mudança, passou a ser total na demonstração do resultado abrangente.

Diante desse quadro, é possível consentir que a identificação de quais valores serão apresentados em cada fechamento pode ajudar a patrocinadora a prever o que ocorrerá com o resultado da demonstração do resultado abrangente, tendo em vista as variáveis que podem afetar sua oscilação. Assim, um modelo preditivo pode identificar qual será o resultado possível da variação a valor presente da obrigação de benefícios definido em relação ao valor justo dos ativos do plano evidenciado na demonstração do resultado abrangente. Esse modelo preditivo propiciará tanto a identificação antecipada dos valores, como a possibilidade de antecipar a tomada de decisão por parte dos gestores.

Entende-se que a modelagem preditiva se aplica a todas as áreas de conhecimento, nessa perspectiva Guazzelli (2012) anui que um modelo preditivo é simplesmente uma função matemática capaz de aprender o mapeamento entre um conjunto de variáveis de dados geralmente agrupadas, um registro e uma variável de resposta destino. Em complemento a esse pensamento, Taurion (2014) aponta que um modelo preditivo é uma função matemática que, aplicada a uma massa de dados, consegue identificar padrões ocultos e prever o que poderá ocorrer.

Consoante ao raciocínio empregado por esses autores, a identificação do melhor modelo preditivo fundamenta-se nesses pressupostos, admitindo como objetivo prever a ocorrência dessas modificações a partir do conhecimento prévio das variáveis informacionais. A partir do tema deste estudo e da contextualização, delineou-se esta pesquisa, cujo objetivo geral do estudo foi realizar uma análise comparativa na aplicação de dois modelos o Auto-regressivos Integrados de Média Móvel (ARIMA) e o modelo de Auto-regressão Vetorial (ARV) em empresas patrocinadoras das Entidades Fechadas de Previdência Complementar, listadas na Brasil, Bolsa, Balcão (B3).

Assim, a pesquisa pretende colaborar com a geração antecipada de informações para o gerenciamento das empresas patrocinadoras, dessa forma, buscou apresentar dados mais precisos para a sociedade. Essa perspectiva se justifica, especialmente, pelo fato de que 3,8% dos brasileiros estão vinculados a alguma EFPC e depositam sua confiança e sua economia em busca de um retorno tranquilo no futuro, segundo afirma Santos (2018).

Ademais, a pesquisa busca contribuir gerencialmente apresentando um modelo que visa antecipar a informação para ajudar os gestores na tomada de decisão. Assim como, tenta contribuir para o avanço da ciência, através da geração da possibilidade de antecipação da informação com a utilização do modelo adequado para previsão de situações futuras. Além disso, busca servir também de fonte para futuras pesquisas na

academia através da geração de informações para os alunos, professores, pesquisadores e outras pessoas interessadas no assunto tratado neste estudo.

REVISÃO DA LITERATURA

Demonstração do Resultado Abrangente

O conceito do resultado abrangente (*comprehensive income*) foi introduzido pela primeira vez na literatura contábil em 1980, pela publicação dos textos jurídicos americanos do Financial Accounting Standards Board (FASB) o *Statement of Financial Accounting Concepts* (SFAC) nº 3 – *Elements of Financial Statements of Business Enterprises* (YEN; HIRST; HOPKINS, 2007; DUMITRANA; JIANU; JINGA, 2010; LUNELLI, 2010; JIANU; JIANU; GUSATU, 2012). Segundo o FASB, o resultado abrangente “é a mudança na equidade de uma empresa durante um período de transações e outros eventos e circunstâncias de fontes não-proprietárias” (SFAC nº 3, pág. 28). O relatório aponta a necessidade de incluir todas as alterações no capital próprio durante um período, exceto as resultantes de investimentos dos proprietários.

Para Gazzola e Amelio (2014), a Demonstração do Resultado Abrangente reflete todas as receitas, as despesas, os ganhos e as perdas que devem ser reconhecidas de acordo com os padrões contábeis durante um período. Ele inclui quaisquer ganhos ou perdas registradas durante o exercício, realizados ou não. A adoção do resultado abrangente representa uma mudança conceitual com importantes consequências para mensurar o desempenho nas demonstrações financeiras (FIRESCU, 2015).

No Brasil, esse conceito passou a ser discutido em setembro de 2009, quando o Comitê de Pronunciamento Contábil (CPC) aprovou o Pronunciamento Técnico nº 26, que regulamenta, dentre outras demonstrações, a Demonstração do Resultado Abrangente. Segundo a Resolução do CFC nº 1.185/09 e do CPC 26, a demonstração do resultado abrangente, mesmo não sendo prevista na Lei nº 6.404/76, passou a ser obrigatória.

Em junho de 2011, o FASB lançou o *Comprehensive Income Topic* nº 220 com os objetivos de atualizar e melhorar a comparabilidade, a consistência, a transparência dos relatórios financeiros e aumentar a proeminência dos itens reportados em outros resultados abrangentes. Buscando facilitar a convergência dos princípios contábeis geralmente aceitos *Generally Accepted Accounting Principles* (GAAP) e o *International Financial Reporting Standards* (IFRS), o FASB decidiu eliminar a opção de apresentar componentes de outros resultados abrangentes como parte da demonstração das mudanças no patrimônio líquido, entre outras alterações.

Assim, as entidades podem apresentar a demonstração do resultado abrangente em dois formatos, quais sejam: (a) uma única declaração contínua do resultado abrangente que inclui tanto o lucro líquido como outros resultados abrangentes; (b) dois resultados separados, mas declarações de (i) uma demonstração de resultados tradicional, (ii) uma demonstração do resultado abrangente (KIM, 2016; GAZZOLA; AMELIO, 2014).

Diante do contexto, outros resultados abrangentes são elementos que compõem o patrimônio líquido e suas movimentações podem afetar o desempenho em períodos futuros. No entanto, afetam as informações do balanço patrimonial, aumentando ou diminuindo seu valor, possuem demonstração própria (DRA), e, no momento da distribuição, não afetam os resultados apresentados na DRE (COLARES et al., 2022).

Evidencia-se que a demonstração do resultado abrangente é uma demonstração financeira que resume o lucro líquido padrão e outros resultados abrangentes (DRA). O lucro líquido é extraído do resultado obtido com a elaboração da demonstração do resultado. Assim, os outros resultados abrangentes consistem em todos os ganhos e perdas não realizados em ativos que não estão refletidos na demonstração do resultado. Sendo considerado um documento mais robusto que tende a ser usado por grandes corporações que costumam investir em vários países, segundo a Corporate Finance Institute (CFI, 2022).

Corroborando, Bookstime (2022) aponta que a Demonstração de Resultado Abrangente (DRA) é um documento financeiro robusto assumindo dois tipos de receita, o lucro líquido padrão, que abrange receitas auferidas e despesas incorridas, incluindo impostos e juros, assim como outros resultados abrangentes, nesse ponto na DRA são descritos os ganhos e perdas não realizados que são resultantes da flutuação no valor de certos ativos. Esses itens são excluídos do Lucro e Perda e, em vez disso, são registrados como patrimônio líquido.

O *International Accounting Standards Board* (IASB), através da IAS nº 1 (2007), evidencia que a demonstração do resultado e de outros resultados abrangentes (demonstração do resultado abrangente) deverá apresentar, além dos lucros ou das perdas e outras seções do rendimento integral, os seguintes itens: (a) lucro ou perda; (b) total de outros resultados abrangentes; (c) rendimento integral do período, sendo o total do lucro ou da perda e outros resultados abrangentes.

Entretanto, considerando que no Brasil a demonstração das mutações do patrimônio líquido é obrigatória para as companhias abertas, existe a possibilidade da apresentação da demonstração do resultado abrangente aparecer como parte integrante da Demonstração da Mutações do Patrimônio Líquido (DMPL), tendo em vista que a própria regulamentação emitida pelo CPC autoriza tal publicação quando diz que pode constar na DMPL, o resultado abrangente do período, apresentando separadamente o montante total atribuível aos proprietários da entidade controladora do montante correspondente à participação de não controladores.

Estudo de Cenários

A capacidade de prever, de se voltar para o futuro e direcioná-lo, faz parte dos atributos da ciência (MARCIAL; GRUMBACH, 2008). Assim, a prospecção de cenários é um esforço da ciência em sondar o tempo, através de seus atores e de suas variáveis, no sentido de nos revelar as tendências que estão por serem observadas e identificadas no esforço constante do homem em busca de entender e compreender cada vez mais o seu futuro e o seu destino neste universo de complexidade que nos envolve (MORITZ et al., 2010).

O termo “cenário” tem muitos significados, variando desde montagens de ambientes para filmagens ou apresentações teatrais até combinações estatísticas de incertezas (MARCIAL; GRUMBACH, 2008). Para definir cenário, utilizava-se, quando necessário, o termo francês “*la prospective*” para designar esta disciplina, que se esforça por antecipar para esclarecer a ação presente à luz dos futuros possíveis e desejáveis (GODET; DURANCE, 2011). Godet (1987) define que o cenário é “o conjunto formado pela descrição coerente de uma situação futura e pelo encaminhamento dos acontecimentos que permitem passar da situação de origem à situação futura”. Para Schoemaker, Cornelius e Heijden (1992), os cenários são ferramentas que têm por objetivo melhorar o processo decisório, com base no estudo de possíveis ambientes futuros.

Assim, um cenário é uma descrição (geralmente de um possível futuro) que pressupõe a intervenção de vários eventos ou condições fundamentais que terão entre a hora da situação original e a hora em que o cenário é o conjunto (GODET; DURANCE; GERBER, 2008). Sendo um poderoso instrumento para ajudar a engajar a todos na construção de uma visão compartilhada de um futuro desejável (WRIGHT; SPERS, 2006), propiciando um ambiente que enriquece o debate sobre questões críticas relacionadas com o futuro da organização e permitem que os dirigentes da empresa tomem decisões de risco com mais transparência (MARCIAL; GRUMBACH, 2008).

Dentro dessa perspectiva, para se prognosticar futuros, é preciso considerar o alto grau de incertezas que nos cerca, e, atualmente, a percepção de cenários é uma das ferramentas mais poderosas para realizar esses prognósticos (CAMPOS, 2011). Ainda segundo o autor, os cenários abrem a percepção para novas possibilidades e, num mundo onde o risco e a incerteza podem interromper determinadas tendências e movimentos, torna-se necessário o investimento nesse tipo de pesquisa antecipatória.

Na prática, não há apenas um método de construção de cenário, mas vários métodos. Porém, o termo “método de cenário” só se aplicaria a uma abordagem que incluísse alguns passos específicos, como análise de sistemas; retrospectiva; identificação das variáveis, seu comportamento e relações; estratégia dos atores e elaboração de cenários múltiplos (GODET; ROUBELAT, 1996). Assim, elaborar cenários não é um exercício de predição, mas sim um esforço de fazer descrições plausíveis e consistentes de situações futuras possíveis, apresentando as condicionantes do caminho entre a situação atual e cada cenário futuro, destacando os fatores relevantes às decisões que precisam ser tomadas (WRIGHT; SPERS, 2006). Dentro dessa perspectiva, Wack (1985) aponta que os cenários lidam com dois mundos: o mundo dos fatos e o mundo das percepções. Eles exploram os fatos, mas visam percepções dos tomadores de decisão.

Dessa forma, os cenários servem a dois propósitos principais, sendo o primeiro protetor: antecipar e compreender o risco; e o segundo é empreendedor: descobrir opções estratégicas que você desconhecia anteriormente, este último propósito é, a longo prazo, mais importante (WACK, 1985). No entanto, o fundamental de um cenário futuro é que ele visa tratar a incerteza. A condição essencial para que os cenários sejam realmente úteis é que eles devem ser plausíveis, internamente consistentes, isto é, logicamente montados e relevantes para os tomadores de decisão de hoje (RIALLAND; WOLD, 2009).

Palermo (2018) aponta que as práticas subjacentes aos cenários e suas respectivas análises podem variar de modelagem quantitativa para inteligência de negócios e julgamento profissional. Ainda segundo o autor, o uso de cenários pode também variar de decisões centralizadas em nível de estratégia a decisões descentralizadas ou específicas de funções processos. Assim, as análises de cenários geralmente envolvem a geração de cenários como sua redução. A geração de cenários busca extrair cenários de um determinado conjunto de dados de variáveis aleatórias. Enquanto a redução do cenário, costuma ser usada para reduzir a escala do cenário definido para reservar o necessário características de variáveis aleatórias (LI et al., 2022).

Com base no contexto, a utilização de cenários em estudos acadêmicos vem se diversificando, tendo em vista que, a análise de cenários fornece uma ferramenta útil para prever as condições futuras dos serviços ecossistêmicos urbanos (LUMENG; JIANGUO, 2022), e, sua utilização pode proporcionar a avaliação de competências, assim como tem potencial de aplicação na gestão de projetos, e pode ser um modelo utilizado por organizações (MARGALHO, 2022).

METODOLOGIA

A pesquisa foi classificada como documental e quase-experimento, para Bardin (1977), a análise documental tem por objetivo dar forma conveniente e representar de outro modo essa informação por intermédio de procedimentos de transformação. Os documentos são os mais variados possíveis, conservados no interior de órgãos públicos e privados, tais como: registros, anais, regulamentos, circulares, ofícios, balancetes, entre outros (SILVA, 2006; MARTINS; THEÓPHILO, 2009).

Quanto aos delineamentos quase-experimentais, estes “tentam atingir um grau de controle próximo ao dos delineamentos, para inferir que dado tratamento teve o êxito pretendido” (COZBY, 2014, p. 238) e surgiram a partir da necessidade de realizar pesquisas onde não era possível conseguir o grau de controle dos experimentos.

Após a definição do problema realizou a escolha do modelo, depois a coleta dos dados que foram usados durante o processo de aprendizagem. Na sequência, houve o desenvolvimento de uma solução para realizar o teste do modelo. Foi necessária a análise exploratória para realizar a análise dos dados e a necessidade de eliminação das empresas que não possuíam dados suficientes para ajudar no desenvolvimento do estudo.

O universo da pesquisa consistiu nas empresas patrocinadoras listadas na B3 que em abril de 2019 totalizaram 103 empresas, deste total, 15 empresas continham dados suficientes para gerar o modelo, após uma série de testes, foi verificado que 6 empresas precisaram ser descartadas por não gerarem um modelo com informações suficientes para atender aos critérios definidos na investigação, dessa forma, a amostra foi de 9 (nove) empresas, representando 8,74% do universo da pesquisa.

Após a coleta, os dados foram transferidos para planilhas do Sistema Excel®, tendo em vista a quantidade de dados utilizados entre os períodos (2009 a 2018) que precisaram ser analisados. O recorte temporal buscou levantar os dados antes da revisão

da CPC 33 (R1) e o que aconteceu após sua implantação. Na realização do tratamento estatístico, foi utilizada a linguagem de acesso livre denominada *Python* na versão 3.7 disponível no site (<https://www.python.org/>). Inicialmente, foi realizado um teste de normalidade dos dados e verificou-se que os mesmos não são normais, sendo necessária a utilização de testes estatísticos para dados não paramétricos.

Para o desenvolvimento dos modelos foram utilizadas as séries temporais levantadas pela pesquisa. Ressalta-se que os protótipos não foram implementados do zero, já que, para seu desenvolvimento, o estudo utilizou as informações disponíveis na biblioteca StatsModels da linguagem *Python*, esta biblioteca encontra-se disponível no site (<https://www.Statsmodels.org>).

Assim, foi realizado o desenvolvimento do modelo tanto pelo método ARIMA como a criação de um modelo através da Auto-regressão vetorial, que são duas abordagens econômicas das quatro previstas por Gujarati (2000) que são: (1) modelo de regressão de equação única; (2) modelos de regressão de equações simultâneas; (3) modelos auto-regressivos integrados de média móvel (ARIMA); (4) modelos de Auto-regressão Vetorial (ARV). Foram descartados o modelo de equação única e o modelo de regressão de equações simultâneas, este por ser uma versão mais complexa, e a limitação de dados levantados pela pesquisa, iriam exigir muitos ajustes no modelo.

Como os resultados das empresas mantidas na análise têm escalas muito diferentes, os resultados de cada empresa foram normalizados, ficando com média 0 e variância 1. Os resultados normalizados, obtidos entre 2013-1 e 2017-3, foram usados para estimar o modelo ARV, enquanto que os dados de 2017-4 até 2018-4 foram usados para testar o modelo. Como os resultados das empresas mantidas na análise têm escalas muito diferentes, os resultados de cada empresa foram normalizados, passando a ter média 0 e variância 1, usando a fórmula 1:

$$y_i = \frac{x_i - \bar{x}}{s}, \quad (1)$$

Onde:

y_i é o i -ésimo valor observado para a empresa

e \bar{x} e s são a média e o desvio-padrão amostrais dos valores observados para a empresa entre 2013-1 e 2017-3 (conjunto de treinamento).

Como os valores normalizados foram usados para treinar o modelo, as predições do modelo também não estarão nas escalas originais dos dados. Para obter os valores estimados nas escalas originais, pode-se usar a fórmula 2:

$$\hat{x}_i = \hat{y}_i s + \bar{x}, \quad (2)$$

Onde:

\hat{y}_i é o i -ésimo valor estimado pelo modelo

\hat{x}_i é o i -ésimo valor estimado na escala original dos valores da empresa.

Apesar da pequena quantidade de dados disponíveis para a análise, o modelo encontrou um bom ajuste, o que era esperado, pois o teste de co-integração indicou a existência de comportamento conjunto das empresas. As diferenças entre os valores observados normalizados e os estimados para cada empresa foram avaliadas usando o erro quadrático médio (EQM), cuja fórmula é a 3:

$$EQM = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}, \quad (3)$$

Onde:

y_i é o i -ésimo valor observado normalizado;

\hat{y}_i é o i -ésimo valor estimado;

n é o tamanho da série de teste.

Os valores de EQM indicam erros baixos, considerando que a variância dos dados normalizados é igual a 1.

Além do modelo ARV, os resultados das empresas também foram modelados individualmente usando o modelo ARIMA. O objetivo foi verificar se os comportamentos das empresas poderiam ser explicados, com mais acurácia, separados ou em conjunto. O modelo ARIMA possui 3 hiperparâmetros (p , q e d) que podem ter valores ideais diferentes para cada empresa. Portanto, os melhores valores dos hiperparâmetros foram selecionados no intervalo $[0, 3]$, tal que o critério de informação e Akaike (CIA) fosse minimizado no conjunto de treinamento, esse critério trata do princípio da parcimônia, onde se escolhe a explicação mais simples que se alinhe com as evidências (BURNHAM; ANDERSON, 2004).

Entende-se como hiperparâmetro a configuração que resulta no desempenho esperado do modelo. Assim, o “ p ” vai apresentar de quantas observações é composta a média; o “ d ” identifica o número de diferenças sazonais para o modelo ser estacionário; e o “ q ” número de unidades de erro na predição do modelo.

Para efeito de análise da evolução ou involução das previsões apresentadas pelos modelos que foram gerados, o estudo considerou a “taxa de desconto”, a “taxa de inflação” e a “taxa de crescimento salarial” que integram a premissa financeira. Já que, a própria CPC 33 relata que uma premissa atuarial que tem efeito significativo é a taxa de desconto, porque essa taxa de desconto deve refletir o valor do dinheiro no tempo. O quadro 1, apresenta mais detalhes das taxas escolhidas para analisar os resultados.

Quadro 1- Descrição das taxas utilizadas no estudo

Descrição	Definição
Taxa de Desconto	A magnitude do valor presente de uma série futura de pagamento de benefícios depende da taxa de juros escolhida para desconto deste fluxo, que é função da expectativa da taxa de rentabilidade dos investimentos. Assim, uma alta taxa de juros como hipótese ter-se-á um valor presente menor e vice-versa, logo, o valor atual dos benefícios futuros de um plano de benefício de uma entidade fechada de previdência complementar é inversamente proporcional à taxa de juros.
Inflação	O custo das aposentadorias e pensões nos planos de benefícios das entidades fechadas de previdência complementar e inversamente proporcional a mudanças na taxa de inflação de longo prazo, ou seja, quanto maior a perda inflacionária futura, menor poder aquisitivo terão as remunerações e os benefícios, e menor será, conseqüentemente, em termos reais, o valor atual dos benefícios futuros do plano de benefícios.
Aumento Salarial	Se o plano de benefícios é função dos salários, estimativas dos salários futuros dos participantes são necessárias e envolvem aumentos salariais por mérito pessoal a carreira ou antiguidade e aumento devido a ganhos de produtividade do trabalho. Dessa forma, quanto maior o crescimento real do salário esperado, em função da escala de mérito e dos ganhos de produtividade, maior o custo previdenciário estimado, uma vez que o benefício tem relação direta com o valor da remuneração do participante.

Fonte: Adaptado de Pinheiro (2005)

A premissa financeira foi escolhida, tendo em vista que os dados coletados para análise foram mais harmônicos entre as empresas utilizadas pela pesquisa, além disso, ajuda a explicar melhor os valores apresentados nas Demonstrações dos Resultados Abrangentes, em razão de que a premissa demográfica trata mais das características futuras dos atuais e ex-empregados. Para efeito de detalhamento sobre a utilização das respectivas taxas, em alguns casos, foram consideradas as médias das mesmas, dado que algumas empresas colocavam uma estimativa “de” “a”.

RESULTADOS

Nesta seção, são apresentados os modelos preditivos gerados individualmente pelo método ARIMA e o modelo de que foi rodado através da auto-regressão vetorial (ARV) das empresas que apresentaram informações para que pudessem ser gerados os modelos preditivos previstos no objetivo do estudo, tendo em vista que, após a aplicação dos testes realizados inicialmente em 103 empresas, elas foram as que mostraram comportamentos que podiam ser explicados de forma conjunta (o resultado do teste indicou a existência de pelo menos 3 vetores de co-integração), foram elas: AMBEV S/A, BNDESPAR, COPASA, ELETROBRAS, GER PARANAP, ITAÚ UNIBANCO, LITEL, USIMINAS e a VALE.

Nesta etapa são apresentados os resultados dos hiperparâmetros “p,d,q” do modelo ARIMA de cada empresa, tendo em vista que a ideia era descobrir qual modelo era mais adequado para explicar a dinâmica dos dados levantados pela pesquisa.

Quadro 2 - Hiperparâmetros dos modelos ARIMA.

Empresa	<i>P</i>	<i>D</i>	<i>Q</i>
AMBEV S/A	1	1	0
BNDESPAR	2	2	0
COPASA	2	1	0
ELETROBRAS	0	0	0
GER PARANAP	0	0	0
ITAÚ UNIBANCO	0	0	0
LITEL	0	1	1
USIMINAS	0	1	0
VALE	0	0	0

Fonte: Dados da Pesquisa (2019)

De acordo com os dados obtidos no quadro 2, resultantes dos modelos gerados das empresas, faz-se necessária, uma explanação sobre a função do “p, d e q”, já que eles representam as características das séries temporais estudadas. No que se refere ao entendimento dos resultados, a coluna “p” indica quantas amostras da série temporal se fazem necessárias, para o modelo, quando o resultado é zero, quer dizer que, para gerar um modelo preditivo, a informação necessária é a amostra do momento atual, se deu um, é a do momento anterior e o atual, e se for 2 dois, irá precisar da amostra de dois momentos anteriores e o momento atual, e assim sucessivamente.

Já o “d”, apresenta a ordem do componente na série, mais especificamente sua sazonalidade, e o “q”, está relacionada à média, mais especificamente à média dos valores observados em um certo momento e para cada momento seguinte.

De acordo com os dados obtidos pelos hiperparâmetros, observa-se que os melhores valores dos hiperparâmetros “p, q e d” para cada empresa. Todas as empresas selecionaram o valor 0 para pelo menos um dos parâmetros, e, 4 (quatro) empresas selecionaram 0 para p, q e d (0,0,0) ELETROBRÁS, GER PARANAP, ITAÚ UNIBANCO e a VALE, esse resultado para estatística é chamado de ruído branco, que é um ruído constante que pode não ser aleatório, mas indica que não tem relação com outras variáveis, é considerado um ruído independente.

Esses resultados indicam que o modelo ARIMA não apresenta um bom ajuste para esses dados. Um importante motivo para o baixo ajuste dos modelos pode estar relacionado à quantidade limitada de dados disponíveis para cada empresa. Vale salientar que, mesmo com uma quantidade de dados, pode-se explicar o que foi previsto pelo modelo em relação ao que aconteceu na empresa, provando que, aumentando a quantidade da série temporal nesse modelo, provavelmente pode-se obter melhores resultados preditivos.

Nesse sentido, o modelo ARV tem a vantagem de modelar os dados das empresas de forma conjunta, fazendo com que o problema da pouca quantidade de dados seja amenizado. A figura 14 mostra o resultado da integração entre as empresas no modelo ARV.




Figura 1 - Resultado normalizado (média 0 e variância 1) das empresas no período compreendido entre 2013-1 e 2017-3.

Fonte: Dados da Pesquisa (2019).

A figura 1 ilustra os dados usados para estimar o modelo pelo método de auto regressão vetorial, no período de 2013.1 a 2017.4. Apesar da quantidade limitada de dados disponíveis para a análise, o modelo encontrou um bom ajuste, o que era esperado, pois o teste de co-integração indicou a existência de comportamento conjunto das empresas, já que o resultado do teste indicou a existência de pelo menos 3 vetores de co-integração.

Com base nos resultados apresentados na figura 1, as considerações foram analisadas por ano para alinhar aos índices levantados pelo estudo, no caso, a taxa de desconto, a taxa de inflação e a do aumento salarial. Essas taxas serviram de base para análises das possíveis explicações para as empresas que não corroboraram para

harmonia do modelo. De acordo com a figura 1, evidencia-se que algumas empresas analisadas tiveram variações consideráveis em determinados anos, assim, utilizou-se dos índices levantados pela pesquisa e pela análise individual, para gerar informações que pudessem ajudar a entender o porquê das variações. Entre as empresas que oscilaram estão USIMINAS, no período de 2015 a 2017, o ITAÚ UNIBANCO, de 2013 a 2015, a BNDESPAR, nos anos de 2013 e 2015, a GER PARANAP, em 2014 e 2016, a COPASA em 2013, e a AMBEV em 2017. Sendo 2013 e 2015 os anos que mais apresentaram empresas que se distanciaram de forma mais consistente das demais.

No caso da USIMINAS, foi verificado que as variações apresentadas no gráfico refletem nas suas taxas, onde a taxa de desconto reduziu 51,22%, de 2015 para 2016, e continuou a reduzir em 2017. A mesma coisa aconteceu com sua taxa de aumento do salário que reduziu 35%, de 2015 para 2016, e 58,54%, de 2016 para 2017. Seguindo essa linha, a taxa de inflação reduziu 14%, de 2015 para 2016, e permaneceu estável de 2016 para 2017. Com base nesses resultados, a tendência negativa apresentada no modelo pode estar relacionada à taxa de desconto e à taxa de inflação, por terem apresentado redução de seus índices e, como a taxa do aumento salarial também baixou, pode ter ajudado nos períodos em que se apresentam oscilações positivas.

O ITAÚ UNIBANCO apresentou variação apenas na taxa de desconto com aumentos sucessivos, sendo de 2013 para 2014 um aumento de 5,08% e de 2014 para 2015, aumentou em 9,22%. As taxas de inflação e de aumento salarial permaneceram constantes nos três anos. Com base nesses resultados, as taxas desses períodos não dão suporte suficiente para explicar a tendência negativa do gráfico, já que a taxa de desconto estava aumentando ao longo dos anos, e a da inflação e do aumento salarial ficaram constantes.

A empresa BNDESPAR, nos anos analisados, teve suas taxas variando para mais, apresentando um aumento de 19,11% na sua taxa de desconto entre os anos de 2013 e 2015, um aumento 30,76% na sua taxa de inflação, e na taxa do aumento salarial a variação foi de 1,27%, também para mais. Com base no aumento de suas taxas, pode-se inferir que os resultados positivos podem estar sustentados no aumento de suas taxas de desconto e de inflação.

A companhia GER PARANAP apresenta flutuações positivas e negativas, e, especificamente, em 2014 e 2016, anos que apresentaram variações no modelo, todas as suas taxas apresentaram redução, em relação ao período anterior. A oscilação negativa de 2014 se explica pela redução da taxa de desconto e da taxa de inflação, já a positiva, pela diminuição da taxa referente ao aumento salarial. Já em 2016, a positiva se explica pela permanência do índice de aumento salarial e a negativa, pela redução da taxa de desconto e da inflação.

No caso da COPASA, sua oscilação foi evidenciada em 2013, quando as taxas apresentadas podem representar que a oscilação positiva está relacionada à alta taxa de desconto, e a variação positiva à taxa do aumento salarial. A AMBEV apresenta oscilações positivas e negativas, e a explicação para a oscilação negativa pode estar relacionada às suas taxas, tendo em vista que, ao contrário das outras empresas, que reduziram a taxa do aumento salarial ao longo dos anos, a AMBEV aumentou esse índice

em 3,60%, o que pode gerar uma oscilação negativa, além disso, a taxa de inflação baixou em 2% e a taxa de desconto em 1%, que também podem corroborar para situação negativa. Assim, apesar da figura apresentar oscilações positivas e negativas, o comportamento das taxas ajuda a explicar apenas as situações negativas.

Após ter realizado o teste do modelo nos períodos de 2017-4 até 2018-4, com o intuito de confirmar a eficácia do modelo, foi gerado o modelo preditivo pelo método ARV para os períodos de 2019.1 a 2021.4, com a expectativa de prever o que pode acontecer com as empresas de forma conjunta, nesses próximos três anos. A figura 2 apresenta o resultado.




Figura 2 - Previsões conjuntas das empresas para o período de 2019.1 a 2021.
 Fonte: Dados da Pesquisa (2019).

De acordo com o modelo preditivo, as empresas em 2019 apresentam situações positivas, com exceção do ITAÚ UNIBANCO, que exibe uma situação negativa considerável em 2019.2. Em 2019.3, a tendência de prejuízo aparece para USIMINAS, BNDESPAR, GER PARANAP, ELETROBRÁS E AMBEV, recuperando-se em 2019.4, neste mesmo período, a LITEL, ITAÚ UNIBANCO e a VALE são as que apresentam situações negativas. A partir de 2020, o gráfico apresenta situações positivas para

COPASA, AMBEV, VALE, ITAÚ UNIBANCO e USIMINAS, o que pode acontecer, já que, de acordo com a projeção das taxas, essas empresas mostraram, nos períodos analisados, redução de sua taxa de aumento salarial, o que pode impactar no seu resultado positivo, tendo em vista sua relação direta com a diminuição das obrigações.

Já a BNDESPAR, GER PARANAP, LITEL e ELETROBRÁS apresentam projeções de situações negativas, neste mesmo período, em relação às suas taxas. Foi verificado que as empresas, com exceção da LITEL, apresentam redução em suas taxas de desconto e de inflação, o que pode fazer com que os resultados previstos aconteçam.

Comparando os gráficos gerados individualmente para cada empresa e o gráfico gerado com todas as companhias pelo método de Auto-regressão Vetorial, pode-se verificar que as empresas LITEL, VALE, AMBEV, ELETROBRÁS e BNDESPAR apresentaram as mesmas tendências preditivas, nos dois modelos, referente ao período utilizado para predição que compreendia 2019.1 a 2021.4, inclusive, já que a abordagem do VAR, para fins de previsão, considera diversas séries temporais de uma única vez (GUJARATI, 2000).

Já a USIMINAS, GER PARANAP, COPASA e ITAÚ UNIBANCO apresentaram discordância em alguns anos em relação aos resultados individuais apresentados. Verifica-se que o método dá subsídios para que sejam feitos estudos com dados das entidades, para tentar verificar o comportamento futuro de seus valores, dando suporte à tomada de decisão por parte dos gestores, ao analisarem as tendências futuras das obrigações com os participantes dos planos de aposentadoria, ajudando, assim, a gerir ações mais assertivas, ao se deparar com o que pode acontecer com os resultados futuros, tendo como base a série temporal da empresa.

De acordo com o que foi levantado pelo estudo, não foram apontados pelas empresas em suas notas explicativas, fatores externos que pudessem ter interferido nas oscilações dos resultados apresentados pelo estudo, já que fatores externos não previstos nas premissas, é o risco que se corre, e o plano está exposto a essas situações. Tendo em vista que existem circunstâncias que não podem ser previstas, como é o caso, por exemplo, do atrito na relação comercial entre os Estados Unidos e a China que provocou a queda das bolsas no início do segundo semestre de 2019, este é um caso atípico que não tem como se antever.

No que se refere à taxa real de inflação ser maior ou menor do que a taxa projetada, aquela pode gerar um desequilíbrio atuarial em virtude de ter feito uma reserva matemática diferente da que se concretizou. Além disso, pode afetar a mudança futura no índice projetado da inflação, desde que seja verificado se foi um acontecimento aleatório ou existe uma tendência para essa taxa de inflação que se materializou diferente da que foi projetada.

Outro evento que pode ter influenciado as oscilações, em alguns casos, está relacionado com a mudança da tábua de Vida (mortalidade ou atuarial), que é um instrumento utilizado para medir probabilidades de vida e de morte de uma população (WILBERT; DE LIMA; GOMES, 2013), onde, geralmente a empresa muda de tábua de mortalidade para realizar o cálculo levando em consideração que a taxa de mortalidade caiu ao longo dos anos, logo, a longevidade aumentou, em outras palavras, as pessoas

estão vivendo mais. Assim, a implicação dessa mudança no cálculo do valor presente das obrigações atuariais é que a aposentadoria passa a ser paga por mais tempo, em virtude da possibilidade de mais tempo de sobrevivência do segurado. Significa dizer que elas vão sobreviver por mais tempo e irão receber benefícios por todo esse período de longevidade previsto pelo plano, logo, isso implica em maiores obrigações para os institutos de previdência acarretando situações mais negativas do que positivas. Porém, não foi objeto do estudo verificar quais as tábuas foram utilizadas para realizar o cálculo atuarial.

Vale salientar que a vantagem é que, como se projeta em média de 30 a 40 anos, representa em longuíssimo prazo, efeitos ou variações bruscas, em espaço pequeno de tempo, que costuma não ter muito impacto. No entanto, mudanças de regras previdenciárias, de elegibilidade ou mudanças de leis farão com que sejam feitas as mudanças necessárias para se adequar à nova exigência legal. Assim, as oscilações são fruto do confronto entre o valor presente da obrigação de benefícios definido com o valor justo dos ativos do plano, dessa forma, a variação crescente ou decrescente, apresentada na pesquisa, pode estar atrelada às modificações que ocorrem nas premissas financeiras e demográficas, já que o estudo tomou por base as premissas financeiras, e esta apresentou modificações ao longo dos anos.

Evidencia-se que o modelo ARV apresentou resultados mais precisos com as séries temporais utilizadas, que estudos de outras áreas, mas que utilizaram o mesmo modelo, agregam suas pesquisas para dar suporte aos resultados encontrados pelo estudo, já que as regressões automáticas de vetor (ARV) são ferramentas padrão em macroeconomia e são amplamente utilizadas em análises estruturais e previsão (BAÑBURA; GIANNONE; REICHLIN, 2010).

Além disso, mesmo com pouca quantidade de dados, até um ARV baseado em 20 variáveis, produz resultados que permanecem robustos quando o modelo é ampliado (BAÑBURA; GIANNONE; REICHLIN, 2010). Outro ponto é que as aplicações ARV são geralmente baseadas apenas em um pequeno número de variáveis (BAÑBURA; GIANNONE; REICHLIN, 2008), assim, os resultados mostram que o ARV pode servir como uma alternativa promissora aos modelos de previsão existentes (RAMEDANI et al., 2014).

Estudos como o de Yang et al. (2017) propuseram um algoritmo de regressão vetorial de suporte (ARV) e forneceram uma estratégia de otimização dos parâmetros para ARV usando pesquisa de grade e validação cruzada. Assim, analisou o desempenho do algoritmo da ARV em três casos diferentes: ajuste de função, regressão multivariada e predição de corrosão em tubulações de usinas nucleares. Os resultados mostram que o desempenho do algoritmo ARV proposto é melhor do que a rede neutra BP tradicional, comparando a previsão do erro quadrático médio e coeficiente de correlação ao quadrado de dois métodos. A vantagem do algoritmo ARV na aprendizagem de pequenas amostras também é demonstrado, e verifica-se que o algoritmo ARV é uma abordagem eficaz para modelar a degradação de componentes com dados raros de inspeção.

O estudo de Raphael e Gabriel (2015) utilizou a análise do modelo pelo ARV para testar se ou não variáveis setoriais estimulam o crescimento da produção no setor manufatureiro da economia nigeriana e se existem interações com algumas variáveis

macroeconômicas importantes na economia nigeriana, utilizando dados anuais de 2012. O estudo também aplicou testes de cointegração de raiz unitária e *Johansen* para examinar o comportamento dos dados. O resultado sugere que diminuir as restrições de desenvolvimento financeiro e aprofundar o setor financeiro é crucial para impulsionar o crescimento da produção industrial na Nigéria.

A conclusão do teste é que os dados são consistentes com os dois modelos (SOWELL, 1992). No entanto, o ARV conseguiu apresentar previsões mais consistentes nas empresas que disponibilizaram dados suficientes para que fosse possível treinar os modelos, no período de 2013.1 a 2017.3, testá-los, nos períodos de 2017.4 e 2018.4 para poder gerar os modelos preditivos representados na figura 2.

CONCLUSÕES

A Pesquisa procurou identificar um modelo que, utilizando as séries históricas das empresas patrocinadoras das EFPC, resultante da variação entre o valor presente da obrigação de benefícios definido em relação ao valor justo dos ativos do plano, pudesse gerar os resultados futuros para tomada de decisão. Para isso, o estudo foi alicerçado de informações extraídas dos relatórios das empresas patrocinadoras das Entidades Fechadas de Previdência Complementar, listadas no endereço eletrônico da B3 em funcionamento no país.

Os dados levantados das nove empresas foram lançados na linguagem *Python*, que é uma linguagem de máquina que trabalha com uma grande porcentagem de conjuntos de dados, e podem ser transformados em uma forma estruturada mais adequada para análise e modelagem (MCKINNEY, 2013), para poder, assim, gerar os modelos pelo método ARIMA e pela Auto Regressão Vetorial.

Com base nos dados obtidos pela pesquisa, o estudo pôde concluir que o modelo ARIMA não conseguiu prever, com muita eficiência, os resultados futuros das empresas, apresentando várias oscilações, não conseguindo, assim, responder à pergunta da pesquisa, no entanto, pode ser que seja eficaz se utilizado por alguma empresa, já que sua base de dados é maior do que as informações disponibilizadas na B3, tendo em vista que a empresa tem informações mensais, já na Bolsa de valores, sua obrigação de divulgação é trimestral.

Com relação ao modelo de auto regressão vetorial, este apresentou-se estatisticamente mais robusto para explicar o conjunto dos dados das empresas objeto da pesquisa, conseguindo responder à pergunta da pesquisa. Além disso, as projeções futuras obtidas pelo modelo podem ser utilizadas gerencialmente para tomada de decisão, já que, com base no estudo, ficou evidenciada a necessidade de as empresas realizarem estudos sobre as taxas de desconto, de inflação e do aumento salarial, assim como, realizar o acompanhamento dos ativos garantidores.

Com base nos resultados obtidos, a pesquisa do estudo foi confirmada ao ser demonstrado o modelo que utiliza os dados das séries temporais das empresas objeto do estudo, para projetar o futuro e mostrar o que pode acontecer, ajudando as mesmas a inferir no futuro, para tomarem melhores decisões no presente. Apesar da quantidade de

dados disponibilizados ter sido limitada, o estudo pôde comprovar sua pesquisa ao demonstrar que, para essas empresas, o modelo gerado pela Auto Regressão Vetorial pode gerar cenários futuros para ajudar na tomada de decisões.

De toda forma, e com base no que foi levantado, testado e estudado, o resultado atende as empresas que foram objeto do estudo e que não se pode excluir a aplicabilidade do modelo ARIMA por parte dessas empresas, tendo em vista a quantidade de dados internos que as mesmas possuem para poder testar o modelo. Porém, o modelo Auto Regressão Vetorial conseguiu trabalhar melhor as séries históricas e criou modelos mais assertivos.

Houve limitação na amostra, já que a maioria das empresas não apresentaram informações suficientes no período delimitado pelo estudo, para poder testar os modelos, fazendo com que os achados se limitassem às empresas que atenderam a todos os critérios determinados pelo estudo.

Para novas pesquisas sugere-se ampliar a amostra e confrontar os resultados com os modelos preditivos propostos neste estudo. Além disso, existe um leque de contas que as EFPC's possuem e são passíveis de serem testadas, para demonstrarem suas projeções futuras e ajudar no desempenho da entidade.

REFERÊNCIAS

BAÑBURA, M.; GIANNONE, D.; REICHLIN, L. Large Bayesian VARs. **European Central Bank – Working Paper** Séries, n. 966, p. 1-44, 2008.

BAÑBURA, M.; GIANNONE, D.; REICHLIN, L. Large Bayesian vector auto regressions. **Journal of applied Econometrics**, v. 25, n. 1, p. 71-92, 2010.

BARDIN, L. **Análise de conteúdo**. Lisboa: Edições 70, 1977.

BLOOM, R. A Note on the New International Accounting Standards Board (IASB) Pronouncement IAS No. 19 (R). **Compensation & Benefits Review**, 2013, v. 45 (1), p. 54-57, 2013.

B3 BRASIL, BOLSA, BALCÃO. **Demonstração dos Resultados Abrangentes**. Disponível em:

http://www.b3.com.br/pt_br/produtos-e-servicos/negociacao/renda-variavel/empresas-lista-das.htm. Acesso em: 20 abr. 2019.

BOOKSTIME. Statement of Comprehensive Income. Disponível em:

<https://www.bookstime.com/articles/statement-of-comprehensive-income>. Acesso em: 18 fev.2023

BRASIL. Lei nº 6.404/76. **Sociedade por ações**. Disponível em:

http://www.planalto.gov.br/ccivil_03/leis/L6404compilada.htm. Acesso em: 20 mar. 2018.

BRASIL. Lei Complementar nº 109/2001. Regime de Previdência Complementar. Disponível em: <https://legislacao.presidencia.gov.br/atos/?tipo=LCP&numero=109&ano=2001&ato=a3ccXWq5kMNpWT77a>. Acesso em: 20 mar. 2019.

BURNHAM, K. P.; ANDERSON, D. R. Multimodel inference: understanding AIC and BIC in model selection. **Sociological methods & research**, v. 33, n. 2, p. 261-304, 2004.

CAMPOS, M.A.M.S. **A prospecção de Cenários Futuros integradas ao processo de design:** a geração de conhecimento para inovação no design de joias. 2018. Pesquisa (Doutorado em Design) Programa de Pós-graduação em Design do Departamento de Artes & Design da PUC, Rio de Janeiro, 2011. Disponível em: http://www2.dbd.puc-rio.br/pergamum/pesquisasabertas/0710765_2011_cap_6. Acesso em: 10 out. 2018.

COLARES, A. C. V.; TAVARES, A. I. L.; ALVES, D. A.; DE OLIVEIRA, G. C.; PAULINO, G. O. efeitos da pandemia da covid-19 na variação dos resultados abrangentes em companhias listadas na b3. **RAGC**, v. 10, n. 45, 2022.

COMITÊ DE PRONUNCIAMENTOS CONTÁBEIS. **CPC 33 (R1):** Benefícios a Empregados. Disponível em: <http://www.cpc.org.br/CPC/Documentos-Emitidos/Pronunciamentos/Pronunciamento?Id=6>. Acesso em: 18 abr. 2018.

COMITÊ DE PRONUNCIAMENTOS CONTÁBEIS. **CPC 26 (R1):** Apresentação das Demonstrações Contábeis. Disponível em: <http://www.cpc.org.br/CPC/Documentos-Emitidos/Pronunciamentos/Pronunciamento?Id=57>. Acesso em: 20 mar. 2018.

CORPORATE FINANCE INSTITUTE. **Statement of Comprehensive Income.** Disponível em: <https://corporatefinanceinstitute.com/resources/accounting/statement-of-comprehensive-income/>. Acesso em: 18 fev.2023.

COZBY, P.C. **Métodos de Pesquisa em Ciências do Comportamento.** São Paulo: Atlas, 2014.

DUMITRANA, M.; JIANU, I.; JINGA, G. Comprehensive income—past, present and future. **Analele Stiintifice ale Universitatii “Alexandru Ioan Cuza”**, din Iasi, p. 25-40, special number 2010.

ESCOLA DE ADMINISTRAÇÃO FAZENDÁRIA – ESAF. **Curso à distância sobre Noções Básicas em Previdência Complementar:** Escola de Administração Fazendária. Disponível em: <https://escolavirtual.esaf.fazenda.gov.br/mod/book/view.php?id=18679&chapterid=33623>. Acesso em: 17 mai. 2018.

FINANCIAL ACCOUNTING STANDARDS BOARD (FASB). **Comprehensive Income (Topic 220):** Presentation of Comprehensive Income. Disponível em: <http://www.fasb.org/resources/ccurl/792/293/CON6.pdf>. Acesso em: 21 mar. 2018.

- FINANCIAL ACCOUNTING STANDARDS BOARD (FASB). **SFAC nº 3:** Elements of Financial Statements of Business Enterprises. Disponível em: http://www.fasb.org/cs/ContentServer?c=Document_C&cid=1176158618212&d=&pagina me=FASB%2FDocument_C%2FDocumentPage. Acesso em: 21 mar. 2018.
- FIRESCU, V. Comprehensive income, a new dimension in performance measurement and reporting. **Procedia Economics and Finance**, v. 20, p. 218-223, 2015.
- GAZZOLA, P.; AMELIO, S. **Is total comprehensive income or net income better for the evaluation of companies' financial performance?**. Disponível em: <https://www.researchgate.net/publication/281240858>. Acesso em: 21 mar. 2018.
- GODET, M.; DURANCE, P. **A prospectiva estratégica: para as empresas e os territórios**. V. 23. Paris: Unesco, 2011.
- GODET, M.; DURANCE, P.; GERBER, A. **Strategic foresight la prospective: use and misure of scenario building**. Paris: Lipsor, 2008.
- GODET, M.; ROUBELAT, F. Creating the future: the use and misuse of scenarios. **Long Range Planning**, v. 29, n. 2, p. 164-171, 1996.
- GODET, M. **Scenarios and stragegic managment**. Londres: Butterworths Scientific, 1987.
- GUAZZELLI, A. **O que é análise preditiva?**. Disponível em: <https://www.ibm.com/developerworks/br/industry/library/ba-predictive-analytics1/index.html> . Acesso em: 06 jun. 2018.
- GUJARATI, D. **Econometria Básica**. 3. ed. São Paulo: Pearson Education do Brasil, 2000.
- INTERNATIONAL ACCOUNTING STANDARDS BOARD – IASB. **IAS 19:** Employee Benefits. Disponível em: <http://www.ifrs.org/issued-standards/list-of-standards/ias-19-employee-benefits/>. Acesso em: 29 mar. 2018.
- INTERNATIONAL ACCOUNTING STANDARDS BOARD – IASB. **IAS 1**. Disponível em: <http://eifrs.ifrs.org/eifrs /bnstandards/ en/IAS1.pdf>. Acesso em: 21 mar. 2018.
- JIANU, I.; JIANU, I.; GUSATU, I. Profit and loss account or comprehensive income statement: which is the best? **International Journal of Business and Management Studies**, v. 1, n. 3, p. 179–188, 2012.
- KIM, J. H. Presentation formats of other comprehensive income after accounting standards update 2011-05. **Research in Accounting Regulation**, v. 28, n. 2, p. 118-122, 2016.

LI, H.; REN, Z.; FAN, M.; LI, W.; XU, Y.; JIANG, Y.; XIA, W. A review of scenario analysis methods in planning and operation of modern power systems: Methodologies, applications, and challenges. **Electric Power Systems Research**, v. 205, p. 107722, 2022.

LUMENG, L. I. U.; JIANGUO, W. U. Scenario analysis in urban ecosystem services research: Progress, prospects, and implications for urban planning and management. **Landscape and Urban Planning**, v. 224, p. 104433, 2022.

LUNELLI, R. L. **Demonstração do Resultado Abrangente**. Disponível em: <http://www.portaldecontabilidade.com.br/tematicas/demonstracaoresultadoabrangente.htm>. Acesso em: 20 mar. 2018.

MARCIAL, E. C.; GRUMBACH, R. J. S. **Cenários prospectivos**: como construir um futuro melhor. 5. ed., Rio de Janeiro: FGV – Edição Kindle, 2008.

MARGALHO, É. M. **Utilização de cenários como meio de avaliação de competências de liderança em gestão de projetos**. Dissertação de Mestrado em Gestão de Projetos em Engenharia da Universidade do Minho, 2022

MARTINS, G. A. THEÓPHILO, C. R. **Metodologia da Investigação Científica para Ciências Sociais Aplicadas**. 2. ed. São Paulo: Atlas, 2009.

MCKINNEY, Wes. Python for Data Analysis. United States, O'Reillymedia, 2013.

MORITZ, G. O.; PEREIRA, M. F.; SOUZA, I.; HERLING, L. H. D.; MORITZ, M. O.; CESCINETTO, S. **A prospecção de cenários nas universidades: variáveis portadoras de futuro e a trajetória estratégica da UFSC para 2022**. Colóquio Internacional sobre Gestión Universitária em América del Sur, Mar del Plata, 2010.

PALERMO, T. Accounts of the future: A multiple-case study of scenarios in planning and management control processes. **Qualitative Research in Accounting & Management**, Vol. 15 Nº 01, pp. 2-23, 2018.

PINHEIRO, R. P. **Riscos demográficos e atuariais nos planos de benefício definido e de contribuição definida num fundo de pensão**. 2005. Pesquisa (Doutorado em Demografia) - Centro de Desenvolvimento e Planejamento Regional da Faculdade de Ciências Econômicas da Universidade Federal de Minas Gerais, Minas Gerais, 2005.

PYTHON.ORG. **Python**. Disponível em: <https://www.python.org/>. Acesso em: 01 jun. 2019.

RAPHAEL, A. I.; GABRIEL, A. A. Effect of Financial Sector Development on Manufacturing Output Growth in Nigeria (1986-2012): A Vector Auto Regression Approach. **Journal of Applied Economics and Business Research**, v. 5, n. 1, p. 38-55, 2015.

RAMEDANI, Z.; OMID, M.; KEYHANI, A.; KHOSHNEVISAN, B.; SABOOHI, H. A comparative study between fuzzy linear regression and support vector regression for global solar radiation prediction in Iran. **Solar Energy**, v. 109, p. 135-143, 2014.

RIALLAND, A.; WOLD, K. E. Future Studies, Foresight and Scenarios as basis for better strategic decisions. **Trondheim, December**, 2009. Working Paper

SANTOS, P.C. **Noções Básicas em Previdência Complementar**: Escola de Administração Fazendária. Disponível em:

<https://escolavirtual.esaf.fazenda.gov.br/mod/book/view.php?id=18679&chapterid=33623>. Acesso em: 17 abr. 2018.

SCHOEMAKER, P. J. H.; CORNELIUS, A. J. M.; HEIDJEN, V. D. Integrating scenarios into strategic planning at Royal Dutch Shell. **Planning Review**, n. 20, p. 41-46, May./ Jun. 1992.

SILVA, C. R. da. **Metodologia da Pesquisa Aplicada à Contabilidade**. 2. Ed. São Paulo: Atlas, 2006.

SOWELL, F. Modeling long-run behavior with the fractional ARIMA model. **Journal of Monetary Economics**, v. 29, n. 2, p. 277-302, 1992.

SUPERINTENDÊNCIA DE PREVIDÊNCIA COMPLEMENTAR – PREVIC. Entidades Fechadas de Previdência Complementar (EFPC). Disponível em:

<https://www.gov.br/previc/pt-br/previdencia-complementar-fechada/entidades-fechadas-de-previdencia-complementar-efpc>. Acesso em: 20 fev. 2023.

TAURION, C. **Você sabe o que é um modelo preditivo?**. Disponível em:

<http://computerworld.com.br/tecnologia/2014/12/16/voce-sabe-o-que-e-um-modelo-preditivo>. Acesso em: 17 abr. 2018.

WACK, P. Scenarios: Shooting the rapids. **Harvard Business Review**. V. 06. P. 139-150. Disponível em: <https://hbr.org/1985/11/scenarios-shooting-the-rapids>. Acesso em: 11 out. 2018.

WILBERT, Marcelo Driemeyer; DE LIMA, Diana Vaz; GOMES, Marília Miranda Forte. O Impacto da Utilização de Diferentes Tábuas de Mortalidade nas Estimativas de Pagamento de Benefícios no RGPS. **R. Bras. Risco e Seg**, p. 19-40, 2013.

WRIGHT, J. T. C.; SPERS, R. G. O país no futuro: aspectos metodológicos e cenários. **Estudos Avançados**, v. 20, n. 56, p. 13-28, 2006.

YANG, C.; LIU, J.; ZENG, Y.; XIE, G. Prediction of components degradation using support vector regression with optimized parameters. **Energy Procedia**, v. 127, p. 284-290, 2017.

YEN, A. C.; HIRST, D. E.; HOPKINS, P. E. A content analysis of the comprehensive income exposure draft comment letters. **Research in Accounting Regulation**, v. 19, p. 53-79, 2007.

Recebido: 24-01-2022

Aprovado: 22-02-2023



This is an Open Access article distributed under the terms of the Creative Commons Attribution License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.