



Análise Operacional e Engenharia Logística: Otimização e Estatística

Método de avaliação aplicado à configuração dinâmica dos setores de controle do espaço aéreo

Evaluation method applied to the dynamic configuration of airspace control sectors

Fábio S. Nascimento¹, Denise Beatriz T. P. A. Ferrari¹, Paulo Cesar G. Costa², Alexandre B. Barreto³.¹ Instituto Tecnológico de Aeronáutica – São José dos Campos – SP – Brasil² George Mason University – Fairfax – VA – EUA³ Instituto de Controle do Espaço Aéreo – São José dos Campos – SP – Brasil

Article Info

Article History:

Received	23 April	2021
Revised	09 June	2021
Accepted	12 August	2021
Available online	30 September	2021

Palavras Chave:

Simulação
Gerenciamento do Espaço Aéreo
Configuração Dinâmica do Espaço Aéreo
Markov-switching vector autoregression

Keywords:

Simulation
Airspace management
Dynamic airspace configuration
Markov-switching vector autoregression

E-mail addresses:

94fabiosouza@gmail.com (F. S. Nascimento),
denise@ita.br (D. B. T. P. A. Ferrari),
pcosta@gmu.edu (P. C. G. Costa),
barretoabb@icca.gov.br (A. B. Barreto).

Resumo

Dentre as iniciativas de modernização do controle do espaço aéreo, a configuração dinâmica do espaço aéreo (*Dynamic Airspace Configuration* – DAC) constitui um novo paradigma para a aviação, em que a geometria dos setores de controle busca adaptar-se às constantes alterações na demanda. Este estudo apresenta o método AirCEM (*Airspace Configuration Evaluation Method*), o qual propõe uma métrica de avaliação, baseada em um modelo markoviano de estados, o qual proporciona a visualização dinâmica dos efeitos da nova configuração nos períodos críticos de carga de trabalho, dentro de um horizonte de tempo definido. Dado o seu caráter analítico, a metodologia apresenta uma métrica a qual auxilia na decisão de separar/combinar os setores de controle, em função dos fatores de complexidade e carga de trabalho do controlador.

Abstract

Among the initiatives for the modernization of airspace control, Dynamic Airspace Configuration – DAC is a new paradigm for aviation, in which control sectors geometry are managed to adapt to the changing demand. This paper presents the AirCEM method (Airspace Complexity Evaluation), which proposes a metric of assessing, based on a Markov state model, which provides a dynamic visualization of the new configuration effects at the critical periods of workload within a given period. The methodology provides a metric that helps on the decision of separating/combining control sectors, considering airspace complexity factors and controller workload.

I. INTRODUÇÃO

O crescimento do tráfego aéreo é um fenômeno mundial, somente no Brasil, a demanda doméstica do transporte aéreo apresentou uma média de crescimento de 14,35% ao ano entre 2003 e 2012, representando uma quantidade de passageiros transportados da ordem de 88,7 milhões em voos domésticos e 18,5 milhões em voos internacionais [1]. Estas projeções de crescimento apontam para a necessidade de replanejamento do gerenciamento do espaço aéreo, de modo a comportar a aumento da demanda, mantendo os níveis de segurança, além de atender às exigências de redução de emissões de poluentes.

Dentre as iniciativas de modernização do controle do espaço aéreo, a configuração dinâmica do espaço aéreo (DAC – Dynamic Airspace Configuration) constitui um novo paradigma operacional, proposto com o objetivo de migrar do atual conceito estático de alocação do espaço aéreo, para um espaço aéreo dinâmico, capaz de adaptar-se às demandas dos

usuários, enquanto atende às restrições impostas pela meteorologia, segurança de voo, complexidade e diversidade de aeronaves que compõem o tráfego aéreo [2]. Pesquisas em DAC tem sido realizadas em três campos principais:

- A organização do espaço aéreo como um todo;
- Alterações dinâmicas do espaço aéreo, de modo a atender a demanda;
- Caracterização genérica do espaço aéreo.

Dentro do segundo campo de estudo, o replanejamento dinâmico da divisão do espaço aéreo em setores, para acomodar mudanças no tráfego aéreo, ainda é uma proposta inovadora no gerenciamento do tráfego aéreo. Alguns métodos e algoritmos têm sido estudados dentro desta temática.

No entanto, apesar de todos apresentarem resultados promissores, ocorrem algumas restrições, as quais ainda demandam pesquisas e esforços futuros. Referência [3] destaca que métricas para reconfiguração ainda não foram totalmente exploradas e definidas. Outros trabalhos também apontam para essa necessidade [4]-[6]. Em especial, métricas que permitam analisar os custos e benefícios em mudar de uma configuração para outra. Uma vez que o objetivo principal do DAC é a flexibilização do espaço aéreo onde e quando for possível, é necessário avaliar os custos de uma nova configuração, em comparação com a anterior.

O presente trabalho aborda esta lacuna, propondo um método para avaliar diferentes soluções de configuração. O método AirCEM (*Airspace Configuration Evaluation Method*) combina métricas físicas do espaço aéreo (por exemplo, fluxo de aeronaves) com fatores humanos, como aqueles associados à carga de trabalho dos controladores de tráfego aéreo. O modelo pressupõe a existência de dois estados não observados de capacidade do espaço aéreo. As entidades do espaço aéreo (por exemplo, setores de controle de tráfego aéreo) são considerados capazes de alternar entre esses estados ao longo do tempo, e o processo de mudança é assumido como sendo markoviano. Seu principal objetivo é fornecer aos gestores do espaço aéreo um método de seleção entre várias configurações possíveis dos setores de controle de tráfego aéreo.

II. MÉTODO

O modelo MSwM (*Markov-switching model*) [7], também conhecido como o modelo de mudança de regime, é um dos modelos de séries temporais não lineares mais populares da literatura. Este modelo envolve várias estruturas (equações) que podem caracterizar os comportamentos de séries temporais em diferentes regimes. Ao permitir a alternância entre essas estruturas, este modelo é capaz de capturar padrões dinâmicos mais complexos. Uma característica do modelo MSwM é que o mecanismo de comutação é controlado por uma variável de estado não observável que segue uma cadeia de Markov de primeira ordem. Em particular, as propriedades markovianas que regulam o valor atual da variável de estado dependem do seu valor imediatamente anterior. Como tal, uma estrutura pode prevalecer durante um período de tempo aleatório, e que irá ser substituído por uma outra estrutura quando uma mudança ocorre. O modelo MSwM é, portanto, adequado para descrever dados correlacionados que exibem padrões dinâmicos distintos durante períodos de tempo diferentes.

Seja s_t uma variável de estado não observável a qual assume os valores 0 e 1. Um modelo MSwM simples (1) para a variável z_t envolve duas especificações AR (auto regressivas):

$$z_t = \begin{cases} \alpha_0 + \beta_{z_{t-1}} + \varepsilon_t, & s_t = 0 \\ \alpha_0 + \alpha_1 + \beta_{z_{t-1}} + \varepsilon_t, & s_t = 1 \end{cases} \quad (1)$$

Onde $|\beta| < 1$ e ε_t é uma variável aleatória iid (independente e identicamente distribuída) com média zero e variância σ_ε^2 . Este é um processo estacionário AR(1) com média $\alpha_0/(1 - \beta)$ quando $s_t = 0$, e muda para outro processo estacionário AR(1) com média $(\alpha_0 + \alpha_1)/(1 - \beta)$, quando s_t muda de 0 para 1. Dado que $\alpha_1 \neq 0$, este modelo admite duas estruturas dinâmicas em níveis diferentes, dependendo do valor da variável de estado s_t . Assim, z_t é governada por duas distribuições com médias diferentes, e s_t determina a comutação entre estas duas distribuições, ou regimes.

Com o propósito de aplicar a modelagem apresentada em um problema de setorização do espaço aéreo, considere N setores do espaço aéreo (ou, mais genericamente, entidades do espaço aéreo ou áreas geográficas), em que são observados períodos sucessivos $t = 1, 2, \dots, T$. O modelo MSwM assume a existência de uma variável de estado não observada (latente) $S_{t,n}$, a qual determina o estado da capacidade do setor para o n -ésimo setor do espaço aéreo (ou entidade, ou área geográfica) durante o período de tempo t . Assume-se que a variável de estado $S_{t,n}$ pode assumir somente dois valores: $S_{t,n} = 0$ corresponde ao primeiro estado e $S_{t,n} = 1$ corresponde ao segundo estado, sendo que a escolha dos rótulos "0" e "1" para os dois estados é apenas uma questão de conveniência. Assume-se ainda que, para cada n segmento do espaço aéreo, a variável de estado $S_{t,n}$ segue uma cadeia de Markov de dois estados estacionária no tempo.

O passo seguinte consiste em reunir as séries temporais de interesse, como fluxo de tráfego e carga de trabalho do controlador, entre outros fatores de complexidade, em um único modelo, constituindo um vetor autoregressivo (VAR). Em sua forma básica, o VAR consiste de um conjunto de K variáveis endógenas $y_t = (y_{1t}, \dots, y_{kt}, \dots, y_{Kt})$ para $k = 1, \dots, K$. Um processo VAR(p) é então assim definido:

$$y_t = A_1 y_{t-1} + \dots + A_p y_{t-p} + u_t \quad (2)$$

Em que A_i são os coeficientes de uma matriz ($K \times K$) para $i = 1, \dots, p$ e u_t é um processo K -dimensional com $E(u_t) = 0$ e matriz de covariância positiva $E(u_t u_t^T) = \Sigma_u$ (ruído branco).

Uma característica importante de um processo VAR(p) é a sua estabilidade. Isso significa que ele gera séries estacionárias com médias invariantes no tempo, estrutura de variância e covariância, considerando valores iniciais suficientes. Outro aspecto importante é que se trata de um modelo multivariado, em que um vetor autoregressivo de ordem p apresenta as relações entre n variáveis endógenas, conectadas entre si através de uma matriz A , a qual define as restrições contemporâneas entre as variáveis que constituem o vetor [8]. Tal propriedade permite a análise conjunta de várias séries temporais, o que é bastante útil ao método proposto.

Após a construção do modelo VAR(p) que contém as informações referentes às séries temporais de interesse, a última etapa do método AirCEM consiste em aplicar o modelo markoviano de estados ao próprio vetor autoregressivo. Essa modelagem é conhecida como *Markov-switching vector autoregression* (MSVAR) [9].

O MSVAR pode ser considerado uma generalização do modelo VAR(p). Considere a p -ésima autoregressão para um vetor K -dimensional $y_t = (y_{1t}, \dots, y_{Kt})'$, $t = 1, \dots, T$:

$$y_t = v + A_1 y_{t-1} + \dots + A_p y_{t-p} + u_t \quad (3)$$

Se a série temporal está sujeita a mudanças em seu regime, um modelo VAR, com seus parâmetros invariantes no tempo, pode ser inadequado. Logo, o MSVAR pode ser considerado como um modelo estrutural com mudança de regime.

A ideia geral por trás dessa classe de modelos é que os parâmetros do processo de geração dos dados de uma série temporal y_t dependem de um regime não observável s_t , o que representa a probabilidade de estar em um regime diferente. Assim, uma importante característica deste modelo é a hipótese de que o regime não observado $s_t \in \{1, \dots, M\}$ é governado por um processo estocástico markoviano discreto no tempo, o qual é definido pela seguinte probabilidade de transição:

$$p_{ij} = \Pr(s_{t+1} = j | s_t = i), \sum_{j=1}^M p_{ij} = 1 \quad \forall i, j \in \{1, \dots, M\} \quad (4)$$

Mais precisamente, assume-se que s_t segue um processo markoviano ergódico e irredutível, com a seguinte matriz de transição:

$$P = \begin{bmatrix} p_{11} & p_{12} & \dots & p_{1M} \\ p_{21} & p_{22} & \dots & p_{2M} \\ \vdots & \vdots & \ddots & \vdots \\ p_{i1} & p_{i2} & \dots & p_{iM} \end{bmatrix} \quad (5)$$

Em que $p_{iM} = 1 - p_{i1} - \dots - p_{i,M-1}$ para $i = 1, \dots, M$.

As hipóteses de ergodicidade e irredutibilidade são essenciais para as propriedades teóricas do modelo MSVAR. Uma discussão aprofundada sobre a aplicação da teoria de cadeias de Markov em modelos de mudança de regime pode ser encontrada em [9].

Generalizando o modelo VAR(p) em (2), tem-se o modelo MSVAR de ordem p e M regimes:

$$y_t - \mu(s_t) = A_1(s_t)(y_{t-1} - \mu(s_{t-1})) + \dots + A_p(s_t)(y_{t-p} - \mu(s_{t-p})) + u_t \quad (6)$$

Em que $u_t \sim NID(0, \Sigma(s_t))$ e $\mu(s_t), A_1(s_t), \dots, A_p(s_t), \Sigma(s_t)$ são os parâmetros de mudança (*regime-shifting functions*) [9].

III. SIMULAÇÃO E APLICAÇÃO DO MÉTODO

Para aplicar o método AirCEM no problema em estudo, foram consideradas as séries temporais do fluxo do tráfego aéreo em setor de controle.

O fluxo do tráfego aéreo é considerado um importante fator de complexidade do setor [10] porém, outros fatores devem ser considerados na análise da complexidade do setor, pois alterações no nível de complexidade de um setor podem ocorrer sem que seja alterada a quantidade de aeronaves existentes no setor em um dado intervalo de tempo, como evidencia a Fig. 1.




Fig. 1. Diferentes níveis de complexidade para o mesmo nível de densidade de tráfego.

a) baixa complexidade, b) alta complexidade [11].

Na literatura, pode ser encontrado um vasto material sobre os fatores de complexidade que afetam o tráfego aéreo [12]-[17], sendo que, em sua maioria, estes estão diretamente relacionados com a quantidade de aeronaves existentes no setor, como alterações de rota, quantidade de tráfegos ascendentes/descendentes, número de cruzamentos de tráfegos, diferenças de desempenho entre aeronaves. Todos estes fatores irão contribuir para a variação na carga de trabalho do controlador de tráfego aéreo, que, juntamente com o piloto, constituem o elemento humano no sistema de controle do espaço aéreo [18].

Para ilustrar a aplicabilidade do método em um problema de avaliação da configuração do espaço aéreo, foi utilizado como estudo de caso o redimensionamento dos setores de controle do espaço aéreo brasileiro, realizado pelo Departamento de Controle do Espaço Aéreo (DECEA) em 2013.

O projeto de definição de setores em uma FIR/TMA é parte de um projeto maior de estruturação do espaço aéreo, onde a primeira parte está no redimensionamento da FIR/TMA, tendo como base os auxílios de telecomunicações existentes, bem como o relevo e características de tráfego existentes na região. Somente após esse redimensionamento é que se torna possível a tarefa de organizar internamente cada um dos setores.

O projeto de redimensionamento de setores tinha como objetivo atender a demanda crescente de movimento de tráfego aéreo até 2016, considerando uma tendência de crescimento no movimento do tráfego aéreo e contemplando as necessidades de novos setores, por ocasião dos eventos esportivos da Copa do Mundo (2014) e das Olimpíadas (2016) no Brasil.

Em virtude do aumento do movimento do tráfego aéreo a cada ano, especialmente naqueles fluxos de maior demanda, percebeu-se uma saturação e congestionamento de setores nas Regiões de Informação de Voo, principalmente em Curitiba (FIRCW) e Brasília (FIRBS).

Visando solucionar os problemas nas regiões citadas, as demais regiões (Recife e Manaus) tiveram as suas configurações alteradas, ocasionando a expansão de 08 para 13 setores na FIRRF, onde foi dividido os setores ao norte para atender a demanda de tráfegos internacionais, adequados os limites próximos a Salvador, Maceió e Recife, com o intuito de diminuir as coordenações entre setores e, finalmente, dividido os setores limítrofes com a FIR-BS para garantir flexibilidade de agrupamento e desagrupamento e, dessa forma, garantir maior fluidez dos tráfegos de/para a Europa.

Para gerar as séries temporais necessárias à construção do modelo MSVAR, foram criados dois cenários (antes e após o redimensionamento) correspondentes à Região de Informação de Voo (FIR – *Flight Information Region*) de Recife – FIR Recife, utilizando o simulador de tráfego aéreo RAMS Plus [19]. Os dados empregados na elaboração dos cenários foram fornecidos pelo Terceiro Centro Integrado de Defesa Aérea e Controle de Tráfego Aéreo (CINDACTA III) e pelo Instituto de Controle do Espaço Aéreo (ICEA). Com o material fornecido por estes dois órgãos, foi reproduzido no simulador, a FIR Recife, com seus respectivos setores de controle de tráfego, além dos seguintes dados (Fig. 2-3):

- 54 aeródromos;
- 5.368 NAV AIDS (auxílios à navegação);
- 89 rotas, extraídas das cartas de rota referentes ao espaço aéreo superior (Fig. 4);
- 789 voos repetitivos, correspondentes a uma amostra com todos os voos comerciais e regulares que atravessam a FIR Recife em um período de 24 horas.

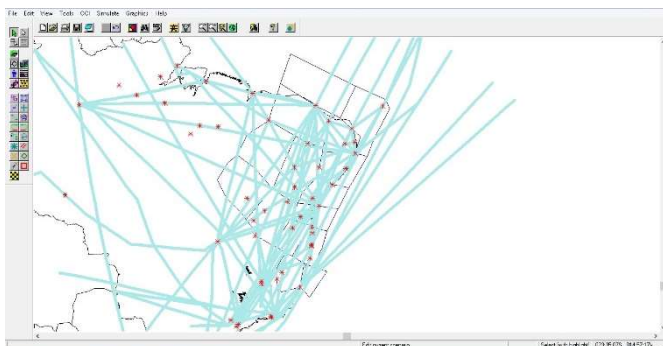


Fig. 2. FIR Recife representada no RAMS Plus contendo: aeródromos (em vermelho) e rotas (em azul).

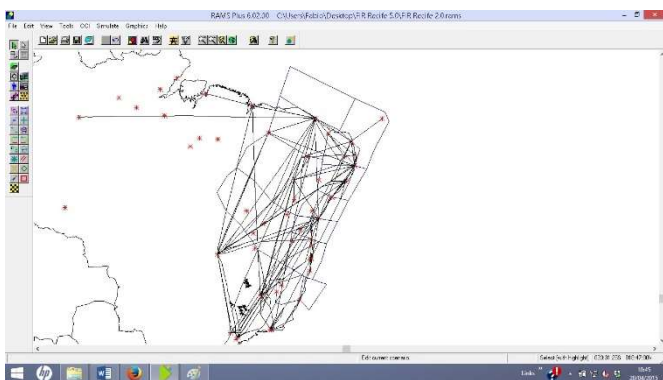


Fig. 3. FIR Recife no RAMS Plus: planos de voo (em preto).




Fig. 4. Carta de rota [20].

O conjunto de dados foi aplicado em dois cenários, representando a setorização da FIR Recife antes e após o seu redimensionamento (Fig. 5-6). A partir das simulações, foram obtidas as séries temporais que alimentam o AirCEM. Esse procedimento permite verificar a aplicabilidade do método em cenários simulados, uma vez que alterações reais na configuração do espaço aéreo são muito complexas e não podem ser realizadas somente a título de teste, podendo acarretar em aumento de atrasos e custos para os operadores. Uma das utilidades do AirCEM consiste em proporcionar a possibilidade de comparar diferentes setorizações em cenários simulados de baixo custo.

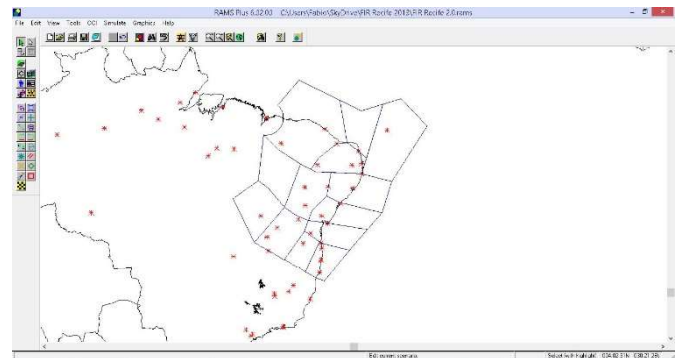


Fig. 5. Configuração antiga da FIR Recife.

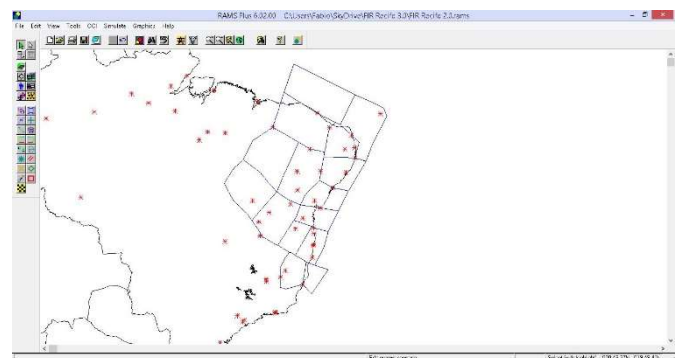


Fig. 6. Configuração atual da FIR Recife.

Os setores selecionados para aplicação do método foram o setor 06, na configuração antiga e 11, o qual corresponde ao mesmo setor na configuração atual.

Estes setores foram escolhidos devido a sua semelhança em termos de geometria e por compreender uma área de tráfego significativo na FIR Recife, situado próximo ao litoral e por onde passam várias rotas que conectam o Sudeste às principais capitais do Nordeste (Fig. 7-8).




Fig. 7. Setor 06 – configuração antiga.




Fig. 8. Setor 11 – configuração atual.

Como resultados da simulação, foram selecionadas as seguintes variáveis:

- *Instantaneous flights in sector* – a qual corresponde a uma contagem de aeronaves existentes no setor por unidade de tempo. No caso em estudo, a contagem foi determinada a cada 15 minutos;
- *Weighted tasks by actor* – corresponde a uma contagem de tempo de execução de tarefa executada pelo controlador de tráfego aéreo, multiplicada por um peso que indica a complexidade da tarefa. O intervalo de tempo da contagem também foi ajustado para 15 minutos.

IV. RESULTADOS E DISCUSSÕES

Obtidas as séries temporais de interesse, resultado das simulações, estas foram reunidas em modelo VAR e, posteriormente, a modelagem MSVAR foi aplicada com o objetivo de identificar os regimes não observáveis do modelo, conforme a estrutura proposta pelo método (Fig. 9). As modelagens foram realizadas em R [21].




Fig. 9. Método AirCEM – forma reduzida.

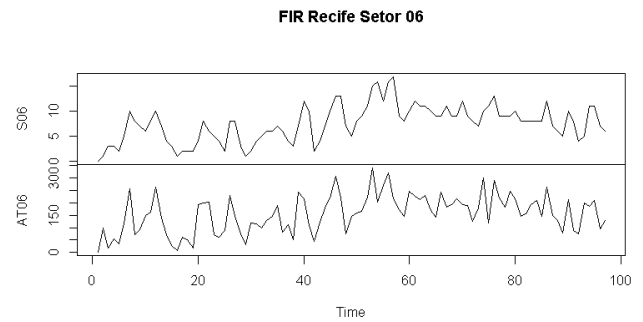


Fig. 10. Séries temporais obtidas do setor 06.




Fig. 11. Séries temporais obtidas do setor 11.

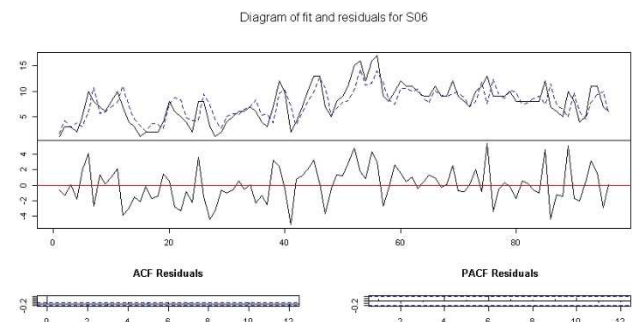


Fig. 12. Modelo VAR aplicado às séries do setor 06.




Fig. 13. Modelo VAR aplicado às séries do setor 11.




Fig. 14. Modelo MSVAR aplicado ao setor 06.




Fig. 15. Modelo MSVAR aplicado ao setor 11.

O método permite a visualização dos estados (ou regimes) em que o setor opera durante o período de 24 horas. O eixo vertical indica a probabilidade de o vetor transitar entre os dois regimes identificados pelo modelo MSVAR. No exemplo apresentado, o método indica que, para o setor 06 (Fig. 14), ocorreram três grandes mudanças de regime, mais precisamente às 09:15, 18:00 e 22:45. Já no setor 11 (Fig. 15) – que corresponde ao setor 06 após o redimensionamento da FIR – ocorre uma grande alteração de estado às 12:30. O comportamento do sistema, porém, não se sustenta por muito tempo no regime “1” e logo retorna ao regime “0”, às 15:30. Com exceção deste período, pode-se observar que o setor permanece a maior parte do tempo em um estado, o que pode indicar, em tese, que o redimensionamento gerou um setor mais estável.

V. TRABALHOS FUTUROS

Muito embora existam diversos estudos em andamento no sentido de cada vez mais automatizar o sistema de controle do espaço aéreo [22], o elemento humano ainda é um fator limitador. Ainda, [23] ressalta que a complexidade implica em aumento da carga de trabalho do controlador, logo, bons modelos precisam considerar as interações entre esses fatores. O AirCEM permite essa interação entre variáveis representativas de fatores físicos e humanos do gerenciamento do tráfego aéreo.

Por se tratar de um estudo exploratório, ainda necessita de maiores investigações acerca da sua aplicabilidade em outros cenários e considerando outras variáveis de interesse, como os fatores de complexidade do tráfego aéreo encontrados na literatura.

A flexibilidade do método em permitir a inserção de outras variáveis em sua estrutura o torna aplicável a uma ampla gama de cenários, não somente de tráfego aéreo, mas nas demais aplicações em que a decisão tenha que se tomada com base em níveis de complexidade do cenário, em função de fatores variados, sejam econômicos, físicos ou humanos.

REFERÊNCIAS

- [1] BRASIL, “Anuário do Transporte Aéreo - Dados Estatísticos e Econômicos de 2012,” Agência Nacional de Aviação Civil, Brasília, DF, 2013.
- [2] P. Kopardekar, K. Bilimoria, and B. Sridhar, “Initial Concepts for Dynamic Airspace Configuration,” in *7th AIAA ATIO Conf, 2nd CELAT Int'l Conf on Innov & Integr in Aero Sciences, 17th LTA Systems Tech Conf; followed by 2nd TEOS Forum*, 0 vols., American Institute of Aeronautics and Astronautics, 2007.
- [3] A. Yousefi, R. Hoffman, M. Lowther, B. Khorrami, and H. Hackney, “Trigger Metrics for Dynamic Airspace Configuration,” in *9th AIAA Aviation Technology, Integration, and Operations Conference (ATIO)*, 0 vols., American Institute of Aeronautics and Astronautics, 2009.
- [4] D. Gianazza and K. Guittet, “Selection and Evaluation of Air Traffic Complexity Metrics,” presented at the 25th Digital Avionics Systems Conference, 2006 IEEE/AIAA, 2006, pp. 1–12.
- [5] P. Kopardekar, A. Schwartz, S. Magyarits, and J. Rhodes, “Airspace Complexity Measurement: An Air Traffic Control Simulation Analysis,” *Int. J. Ind. Eng. Theory Appl. Pract.*, Jun. 2009.
- [6] S. Zhuoxi, C. Yangzhou, L. Zhenlong, Z. Defu, and B. Hong, “A review for workload measurement of air traffic controller based on air traffic complexity,” presented at the Control and Decision Conference (CCDC), 2013 25th Chinese, 2013, pp. 2107–2112.
- [7] J. D. Hamilton, “A new approach to the economic analysis of nonstationary time series and the business cycle,” *Econometrica*, no. 57, p. 27, 1989.
- [8] R. L. S. Bueno, *Econometria de séries temporais*, 2a ed. Cengage Learning, 2012.
- [9] H.-M. Krolzig, *Markov-Switching Vector Autoregressions. Modelling, Statistical Inference, and Application to Business Cycle Analysis*. Berlin: SPRINGER-VERLAG, 1997.
- [10] A. Yousefi and G. Donohue, “Temporal and Spatial Distribution of Airspace Complexity for Air Traffic Controller Workload-Based Sectorization,” in *AIAA 4th Aviation Technology, Integration and Operations (ATIO) Forum*, 0 vols., American Institute of Aeronautics and Astronautics, 2004.
- [11] M. Farsad and S. M.-B. Malaek, “Part IV: Clustering and Optimization: Application of Dependency Structure Matrix to Airspace Sectorization and Improving the Distribution of the Workload Among Controllers,” in *Risk and Change Management in Complex Systems*, F. Marle, M. Jankovic, M. Maurer, D. M. Schmidt, and U. Lindemann, Eds. Oxford: Hanser, 2014, pp. 147–156.
- [12] R. H. Mogford, J. A. Guttman, S. L. Morrow, and P. Kopardekar, “The Complexity Construct in Air Traffic Control: A Review and Synthesis of the Literature,” Jul. 1995.
- [13] A. Majumdar, W. Ochieng, J. Bentham, and M. Richards, “En-route sector capacity estimation methodologies: An international survey,” *J. Air Transp. Manag.*, vol. 11, no. 6, pp. 375–387, 2005.
- [14] A. Majumdar, W. Y. Ochieng, G. McAuley, J. M. Lenzi, and C. Lepadatu, “The Factors Affecting Airspace Capacity in Europe: A Cross-Sectional Time-Series Analysis Using Simulated Controller Workload Data,” *J. Navig.*, 2004.
- [15] M. Bloem and P. Kopardekar, “Combining Airspace Sectors for the Efficient Use of Air Traffic Control Resources,” in *AIAA Guidance, Navigation and Control Conference and Exhibit*, 0 vols., American Institute of Aeronautics and Astronautics, 2008.
- [16] R. Kicingner and A. Yousefi, “Heuristic Method for 3D Airspace Partitioning: Genetic Algorithm and Agent-Based Approach,” in *9th AIAA Aviation Technology, Integration, and Operations Conference (ATIO)*, 0 vols., American Institute of Aeronautics and Astronautics, 2009.
- [17] J. Mitchell, G. Sabhni, R. Hoffman, J. Krozel, and A. Yousefi, “Dynamic Airspace Configuration Management Based on Computational Geometry Techniques,” in *AIAA Guidance, Navigation*

and Control Conference and Exhibit, 0 vols., American Institute of Aeronautics and Astronautics, 2008.

- [18] BRASIL, “PCA 351-3 Plano de Implementação ATM nacional,” Departamento de Controle do Espaço Aéreo, Brasília, 2012.
- [19] ISASoftware, *Reorganized ATC Mathematical Simulator - RAMS Plus*. 2013.
- [20] BRASIL, “DEPARTAMENTO DE CONTROLE DO ESPAÇO AÉREO,” *Serviço de Informações Aeronáuticas - AIS Brasil*, 2015. [Online]. Available: <http://www.aisweb.aer.mil.br/?i=cartas>.
- [21] R CORETEAM, *R: A language and environment for statistical computing*. Vienna, Austria: R Foundation for Statistical Computing, 2012.
- [22] CANADÁ, “Global Air Traffic Management Operational Concept,” Montreal, 2005.
- [23] A. Majumdar, “A framework for modelling the capacity of Europe’s airspace using a model of air traffic controller workload,” University of London, London, UK, 2003. (Máximo 6 páginas)