

# Data Mining-Based Analysis of Alert Messages of Executive Aircraft

P. B. Soares, O. M. Silva Junior, R. A. S. Fernandes, *Member, IEEE*, and J. H. Bidinotto

**Abstract**—Once the years, a large number of alert messages have been stored by aircraft manufacturers, which characterize the aircraft behavior and performance. This way, some aspects such as component failures and aircraft health can be obtained by means of these messages in order to make decisions and better manage the aircraft. However, these messages are stored faster than can be processed by the reliability engineering team. Motivated by this fact, this paper proposes the use of Data Mining to determine sequential patterns of messages. In this context, it can be observed that the use of Data Mining may contribute to prevent aircraft accidents and reduce the time of maintenance. Therefore, this paper presents a methodology based on the Apriori algorithm to extract association rules from a database of messages sent by executive aircraft operating in Latin America. It is important to highlight that the proposed method was validated using a database provided by a real aircraft manufacturer. Finally, the results obtained by the Apriori algorithm were analyzed in contrast with specialist's knowledge, for known messages, where the method robustness could be validated since the associated messages always had a systemic cause for such emergence.

**Index Terms**— Data Mining, Apriori Algorithm, Aircraft Reliability, Alert Messages, Executive Aircraft.

## I. INTRODUCTION

AVIÕES executivos são feitos pela integração de vários, isolados e complexos sistemas que compõem um produto único no final de seu processo de fabricação. Entre esses sistemas, pode-se citar: fuselagem, ar condicionado, sistema hidráulico, elétrico, pneumático, motor, entre outros. Devido a essa grande quantidade e diversidade de componentes e sistemas, nota-se um grande número de fabricantes envolvidos.

De acordo com este contexto, a *Air Transport Association of America* (A.T.A.) padronizou as especificações desses sistemas, conhecido como padrão A.T.A. *Specification* 100 [1], que divide seus respectivos subsistemas em 100 capítulos.

Este trabalho foi financiado pela FAPESP (Fundação de Apoio à Pesquisa do Estado de São Paulo) – processo no. 2014/15770-9.

P. B. Soares e O. M. Silva Junior estão com o Departamento de Engenharia Mecânica da Universidade Federal de São Carlos, São Carlos, SP, Brasil (e-mail: prisoares14@gmail.com, osmar\_mendes\_silva@yahoo.com.br).

R. A. S. Fernandes está com o Departamento de Engenharia Elétrica, Universidade Federal de São Carlos, São Carlos, SP, Brasil (e-mail: ricardo.asf@ufscar.br).

J. H. Bidinotto está com o Departamento de Engenharia Aeronáutica,

Universidade de São Paulo, São Carlos, SP, Brasil (e-mail: jhbidi@sc.usp.br). Além disso, é importante enfatizar que essa especificação visa ajudar engenheiros a obter informações e, conseqüentemente, melhorar a manutenção e/ou reparo de aeronaves executivas. No entanto, é difícil controlar todos estes sistemas e subsistemas da aeronave, uma vez que cada um tem um comportamento diferente e único, que pode ser alterado ao longo de anos de atividade.

Neste cenário complexo, a indústria aeroespacial desenvolveu métodos e ferramentas para monitorar a vida útil dos componentes da aeronave, a fim de aumentar sua segurança e robustez.

É importante mencionar ainda que alguns métodos propostos foram idealizados com base em ferramentas computacionais [2]-[11]. Entre esses métodos, pode-se destacar [5], onde os autores propõem um sistema de monitoramento que recebe os dados da aeronave em tempo real. Esses dados são analisados e o sistema gera uma mensagem de alerta quando um componente precisa ser substituído. Dessa forma, Redes Bayesianas foram usadas para determinar falhas em motores de 16 aeronaves.

Dois anos depois, os autores de [6] propuseram o uso de um classificador *Neuro-Fuzzy* para fornecer um prognóstico sobre a aeronave em análise. Tal método é capaz de determinar o desgaste de válvulas, utilizando regras de decisão extraídas da base de conhecimento do sistema *Neuro-Fuzzy*. Em [7], foi proposto o uso de um classificador baseado em Árvore de Decisão e também em distribuição probabilística para indicar possíveis falhas em sistemas aviônicos. A base de dados utilizada foi composta por medidas de vibração, temperatura, carga e pressão atmosférica.

No contexto da prevenção de falhas, em [8], os autores caracterizam falhas em atuadores elétricos localizados no sistema de combustível da aeronave (bombas e válvulas). Os dados foram adquiridos via testes de bancada, onde as condições de voo da aeronave foram simuladas. A metodologia proposta também emprega Redes Bayesianas e provou ser viável para se estabelecer padrões de degradação em atuadores elétricos.

Além disso, em [9], o modelo FMEA (*Failure Mode and Effect Analysis*) foi usado como pré-processamento responsável pela seleção de falhas e uma Árvore de Decisão foi empregada para verificar a ocorrência ou não de uma falha específica. Vale mencionar que esta metodologia foi aplicada ao sistema de ventilação da aeronave.

Recentemente, os autores de [10] propuseram o uso de regras de associação para extrair padrões sequenciais

relacionados a falhas de aeronaves da Força Aérea Coreana. Foram utilizados dados históricos de quatro modelos de aeronaves. Tais dados foram divididos de acordo com seus sistemas (instrumentação, equipamento de ataque, ar condicionado, etc.). Neste estudo, 24 cenários foram considerados em termos do tipo de missão e temporada. É importante mencionar que as regras foram limitadas a uma sequência máxima de três falhas. Após a fase de processamento, foi escolhida uma regra de associação com maior suporte e confiança para cada cenário. Os resultados obtidos mostraram que as regras extraídas são relevantes para a manutenção das aeronaves.

Por outro lado, os autores de [11] usaram o algoritmo *A priori* para analisar dados históricos de manutenção e de ASRL (*Aircraft Shot and Recovery Log*), buscando padrões de falhas sequenciais. A análise de tendências dos dados do ASRL foi levada em consideração. Os resultados obtidos a partir da análise de ambas as bases de dados foram comparados. Desta forma, demonstrou-se que componentes de aeronaves que fazem voos noturnos apresentavam vida útil mais curta. Portanto, faz-se necessário um número maior de tarefas de manutenção para que essas aeronaves continuem a funcionar corretamente.

Seguindo o contexto supramencionado, este trabalho tem como objetivo definir uma metodologia com base na mineração de dados para permitir a análise de mensagens enviadas por aeronaves executivas em operação. Por meio do método proposto, buscou-se estabelecer regras que associem essas mensagens. Portanto, pretende-se identificar o padrão de ocorrência de alguns alertas de forma a auxiliar o fabricante na tomada de decisão em relação à manutenção da aeronave.

Vale ressaltar ainda que esta pesquisa se justifica pelo fato de que, na literatura, não há padrões sequenciais obtidos para as mensagens de alerta enviadas por aeronaves executivas e, dessa forma, a mineração de dados torna-se atraente para a análise automatizada de uma grande quantidade de dados, muitas vezes descartados por falta de capacidade de análise.

Este artigo está organizado de forma que a Seção II apresenta os aspectos do diagnóstico e manutenção de aeronaves. A Seção III apresenta os fundamentos da mineração de dados com base em regras de associação. Na Seção IV são mostrados os detalhes da metodologia proposta e, finalmente, as Seções V e VI são destinadas respectivamente às análises de resultados e conclusões.

## II. ASPECTOS FUNDAMENTAIS DE DIAGNÓSTICO E MANUTENÇÃO DE AERONAVES

O diagnóstico em aeronaves pode ser dividido em dois grandes grupos: *on-line* e *off-line*. As ferramentas destinadas ao diagnóstico *on-line* recebem parâmetros históricos da aeronave e, assim, os dados são adquiridos e processados. A seguir, se aplicável, o piloto recebe mensagens de alerta. Neste processo, são empregadas tecnologias sofisticadas, que permitem o diagnóstico em tempo real e identificação de possíveis falhas. O diagnóstico *on-line* pode ser integrado com a MMEL (*Master Minimum Equipment List*), que é um documento criado pelo fabricante e afirma que a aeronave,

mesmo com uma falha de componente, pode permanecer em operação. Assim, antes do pouso, tanto o piloto como a equipe de manutenção já conhecem os procedimentos para manter a aeronave disponível para uso e operação [12].

Por outro lado, as ferramentas que possuem diagnóstico *off-line* são baseadas na análise das informações registradas pela aeronave (em voo e em solo). Com base em dados históricos, o operador da aeronave e a equipe de manutenção podem identificar as principais atividades que ocorrem no sistema e nos componentes. Consequentemente, torna-se possível determinar a origem da falha para garantir uma vida útil mais longa dos componentes [13], [14]. Após o diagnóstico da aeronave, é necessário realizar a manutenção para devolvê-la às suas condições normais de operação.

Devido à degradação dos componentes da aeronave, as ações de manutenção são necessárias para restaurar o funcionamento normal do sistema. Entre essas ações, pode ser destacado: reparo, remoção, substituição, inspeção e calibração. No entanto, existem várias maneiras de usar essas ações para diminuir o tempo de manutenção, onde o uso da mineração de dados pode ser uma alternativa para identificar padrões de falhas.

Assim, as ações de manutenção desempenham um papel vital na indústria aeroespacial devido ao risco de acidentes. Por esse motivo, padrões foram criados e aprimorados para garantir a segurança das aeronaves.

## III. MINERAÇÃO DE DADOS BASEADA EM ALGORITMOS DE REGRAS DE ASSOCIAÇÃO

A Mineração de Dados é um conceito que usa algoritmos automáticos ou semi-automáticos, capazes de extrair informações úteis de bases de dados. Devido à sua ampla possibilidade de aplicações e sua interdisciplinaridade, como as fornecidas por [3] e [4], existem várias definições para o termo.

Neste trabalho, a Mineração de Dados segue as definições dadas por [15], onde representa um passo no processo de descoberta de conhecimento, que consiste na análise de dados e implementação de algoritmos que determinam um conjunto de padrões para os dados. De forma significativa, [15], divide a mineração de dados em duas classes de ferramentas:

1. Baseada em algoritmos supervisionados, onde os dados são usados para construir um modelo que descreva o comportamento de uma variável de interesse. Ou seja, a variável de saída deve ser conhecida para treinar uma ferramenta de aprendizado de máquina;
2. Baseada em algoritmos não supervisionados, onde o comportamento do resultado não é conhecido e um estudo é necessário para encontrar possíveis relações entre entrada e saída.

Entre os algoritmos não supervisionados, algumas técnicas para agrupar dados e gerar regras de associação são destacadas. Vale ressaltar que, neste artigo, serão usadas regras de associação para determinar as relações entre as mensagens enviadas por aeronaves executivas durante o voo.

De acordo com [16], uma regra de associação representa a análise probabilística sobre a ocorrência simultânea de

determinados eventos em uma base de dados. Esta categoria de algoritmos gera regras do tipo “Se...então”. Geralmente, os algoritmos que obtêm regras de associação, para gerar um resultado, têm dois parâmetros: suporte (representa a proporção de instâncias de uma base de dados contendo um determinado conjunto de dados) e confiança (representa a probabilidade de encontrar um “consequente” quando não há ocorrência de um “antecedente” na base de dados). Portanto, o objetivo de um algoritmo baseado em regras de associação é encontrar todas as regras que satisfaçam uma confiança  $p$  maior do que um limiar  $p_t$  e um suporte  $s$  maior do que um limiar  $s_t$ .

Entre os algoritmos baseados em regras de associação, pode-se destacar o *Apriori* que tem a capacidade de extrair conjuntos de itens que frequentemente ocorrem em uma base de dados. Por exemplo, no caso dessa pesquisa, busca-se resposta para as seguintes questões: (1) “Quais falhas ocorrem comumente de forma sequencial na aeronave?”; e (2) “Há falhas que desencadeiam outras em distintos sistemas da aeronave?”.

Ao obter respostas para a questão (1), torna-se possível inferir em melhorias nas atividades de manutenção da aeronave, seja na compra de equipamentos ou até mesmo em aprimoramentos das atividades de manutenção para que a sequência de falhas seja eliminada ou, ao menos, mitigada. Por outro lado, ao obter respostas para questão (2), a equipe de manutenção passa a ter acesso a cadeias de falhas que são dificilmente notadas, pois as equipes de manutenção normalmente esperam pela ocorrência de falhas dentro de um mesmo sistema da aeronave.

Por este motivo, o algoritmo *Apriori* faz uma busca baseada na antimonotonicidade, ou seja, um conjunto de itens (conjunto de mensagens de falhas) apenas pode ser comum na base de dados se todos os itens individuais (cada mensagem de falha) aparecer nessa base com grande frequência, assegurando o grau de confiança desejado pelo usuário (em aeronáutica, essa confiança deve ser elevada – próxima de 1 – para ser considerada). Por convenção, esse algoritmo assume que os itens pertencentes a um grupo são ordenados de forma lexicográfica, assim como é feito em dicionários.

Para este trabalho, as mensagens enviadas por aeronaves executivas (dados) foram organizadas para que o algoritmo seja capaz de fornecer uma análise sobre a relação entre mensagens que ocorrem com maior frequência na base de dados.

Vale ressaltar que o algoritmo *Apriori* é iterativo. No entanto, antes de iniciar as iterações, é preciso definir um conjunto de itens frequentes ( $F_k$ ) onde  $k$  é o tamanho definido e as regras dos candidatos são  $C_k$ . Neste caso, definiu-se que um conjunto poderá ter no máximo 3 itens frequentes ( $k = 3$ ) que culminarão em um quarto item. Sendo este quarto item a consequência dos três primeiros (também conhecidos como antecedentes). Assim, o algoritmo *Apriori* realiza uma pesquisa na base de dados para definir conjuntos (com tamanho igual a  $k$ ). Para cada iteração, um contador deve ser incrementado ao encontrar um item que atenda o suporte mínimo parametrizado. Para demonstrar melhor a operação do

algoritmo *Apriori*, a Fig. 1 apresenta seu fluxograma.

O algoritmo foi executado a partir do software de mineração de dados conhecido como WEKA (*Waikato Environment Knowledge Analysis*) desenvolvido na Universidade de Waikato - Nova Zelândia [17]. Finalmente, é importante mencionar que a metodologia proposta, apesar de usar o algoritmo *Apriori*, ainda necessita de etapas de preparação e transformação de dados. Todas estas etapas serão abordadas em detalhes na Seção IV.

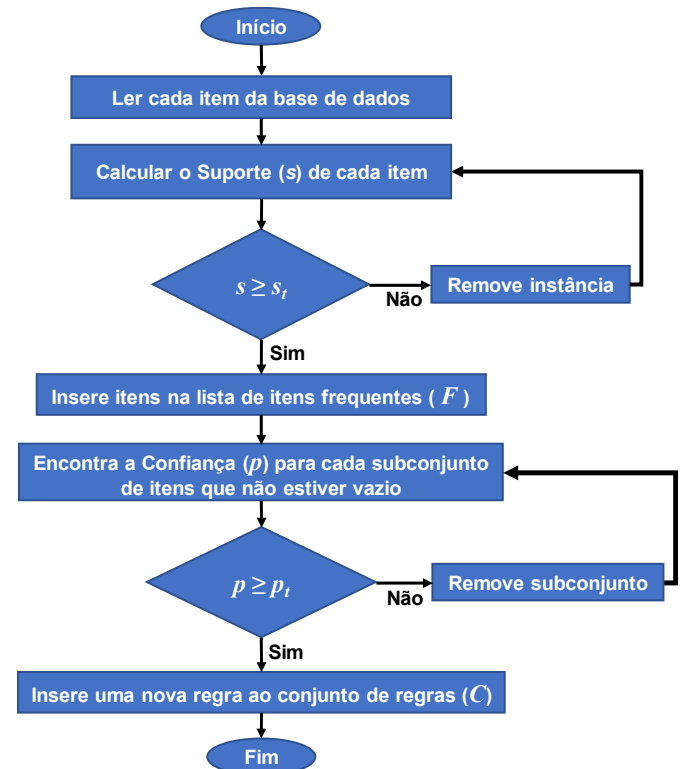


Fig. 1. Fluxograma do algoritmo *Apriori*.

#### IV. METODOLOGIA PROPOSTA

A metodologia proposta para mineração dos dados foi dividida em 6 etapas, que passa pela obtenção, seleção, preparação e transformação dos dados, construção do modelo com base em regras de associação e análise de resultados. Visando uma melhor compreensão, a Fig. 2 apresenta um diagrama de blocos da metodologia proposta. Assim, cada bloco será explanado em detalhes nas subseções que seguem.

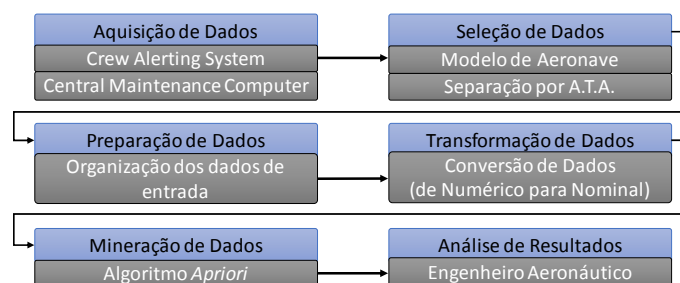


Fig. 2. Visão geral da metodologia proposta.

Os dados utilizados neste trabalho foram extraídos da

ferramenta de suporte de gerenciamento de aeronaves executivas. Esta ferramenta transmite, em tempo real, mensagens do CAS (*Crew Alerting System*) e do CMC (*Central Maintenance Computer*), sendo as CAS exibidas para a tripulação durante o voo, no momento em que o alerta ocorre e as CMC observadas durante as atividades de manutenção. Vale ressaltar que os dados foram coletados entre março de 2009 e agosto de 2013.

As mensagens coletadas foram selecionadas de modo que uma base de dados homogênea pudesse ser gerada para garantir resultados consistentes ao aplicar o algoritmo *Apriori*. Neste sentido, foi selecionado um modelo específico de aeronave, uma vez que diferentes modelos de aeronaves também possuem comportamentos diferentes, o que seria refletido nas mensagens.

Apenas as mensagens transmitidas em voo foram coletadas, pois, durante a decolagem ou pouso da aeronave, muitos dos sistemas estão desligados. Portanto, a maioria das mensagens transmitidas em solo são consideradas inconsistentes e foram descartadas deste estudo.

É importante enfatizar que os dados disponíveis são de 87 aeronaves operando na América Latina, com 37265 mensagens no período analisado.

Essas mensagens foram divididas por A.T.A. A Tabela I apresenta o significado de cada A.T.A. e a quantidade de mensagens referente a cada uma delas.

A fase de preparação de dados consiste em organizar a base de dados, de modo que a mesma possa ser analisada adequadamente. Uma vez que o objetivo é encontrar padrões entre as mensagens que ocorreram no mesmo voo, essas mensagens foram ordenadas em primeiro nível pelo número do voo e em segundo nível por data/hora de ocorrência. Posteriormente, a base de dados foi processada para que os códigos das mensagens de um mesmo voo permanecessem organizadas no mesmo registro. Após esta operação, os arquivos gerados foram submetidos ao software WEKA, onde é iniciado o processo de transformação dos dados.

TABELA I

DESCRIBÇÃO SIMPLIFICADA DAS A.T.A. E SUAS OCORRÊNCIAS.

A.T.A.	Descrição	Ocorrências
21	Ar condicionado e pressurização	2059
22	Sistema de Piloto automático	3710
23	Sistema de Comunicação	266
24	Sistema Elétrico	12295
26	Sistema de proteção contra incêndio	12
27	Comandos de voo	4630
28	Sistema de combustível	689
29	Sistema hidráulico	3
30	Proteção contra gelo e chuva	8742
31	Sistemas de indicação/gravação	516
32	Trem de pouso	330
34	Sistemas de navegação	1570
35	Oxigênio	9
36	Sistema pneumático	699
52	Portas	89
73	Sistema de controle de combustível	702
76	Sistema de controle de motor	20
77	Indicações de motor	260
79	Óleo	664

Na sequência, os dados foram transformados em uma classe

compatível com a que o algoritmo é capaz de processar (numérico, nominal ou binário). O software WEKA, ao receber os arquivos de entrada, interpreta automaticamente os códigos A.T.A. de cada mensagem como variáveis quantitativas (numéricas). No entanto, apesar de serem expressos por números, esses códigos devem ser variáveis nominais, pois identificam apenas a A.T.A. com seus respectivos subitens. Portanto, foi necessário transformar esses dados numéricos em valores nominais.

Finalmente, o algoritmo *Apriori* pode ser aplicado à base de dados. Assim, é importante mencionar que o algoritmo foi parametrizado para que ele atinja um limiar de suporte ( $s_r$ ) de 0,001 ou um limiar de confiança ( $p_r$ ) de 0,95. Tais valores puderam ser definidos por meio de testes.

Os resultados obtidos pelo algoritmo *Apriori* serão relatados em mais detalhes na Seção V. Além disso, vale mencionar que, como esta pesquisa gera como resultados as regras que associam mensagens de alerta da aeronave, foi necessário que um especialista (engenheiro aeronáutico) realizasse uma investigação de coerência das regras de associação geradas.

## V. RESULTADOS

Conforme já mencionado, o algoritmo *Apriori* foi usado para encontrar as melhores regras de associação, ou seja, as mais frequentes na base de dados de mensagens de alerta.

Os resultados forneceram as regras de associação mais confiáveis, que são aquelas em que a frequência de aparição das mensagens de alerta no mesmo voo foi maior. Neste artigo, foram avaliadas aquelas regras cuja taxa de confiança é superior a 95%, pois esta taxa pode ser considerada eficaz perante a indústria aeroespacial. Os casos obtidos serão analisados de acordo com suas causas, justificando o surgimento de mensagens, analisando a possibilidade de uma reação em cadeia devido a um alerta e demonstrando a robustez da metodologia proposta. Assim, a Tabela II apresenta as regras de associação com confiança superiores a 95%.

TABELA II

ANTECEDENTES (ANT), CONSEQUENTES (CONS) E CONFIABILIDADES (CONF) OBTIDOS PELO ALGORITMO *APRIORI*.

Códigos Identificadores				
Ant.1	Ant.2	Ant.3	Cons.	Conf.
<b>30000245</b>	-	-	<b>27301100</b>	<b>1</b>
<b>24320402</b>	<b>24620401</b>	-	<b>24320402</b>	<b>0.99</b>
<b>30200452</b>	-	-	<b>30200351</b>	<b>0.98</b>

Neste caso, excluindo-se as aparições de mensagens repetidas e combinações semelhantes, três combinações com confiança maior que 95% foram encontradas, mostradas nas Tabelas de III a V.

TABELA III

ANÁLISE DOS DADOS OBTIDOS – COMBINAÇÃO 1.

Mensagem	Identificação	Tipo	Confiança
#1	D-I WINGSTB ON	CAS	100%
#2	SWPS ICE SPEED	CAS	100%

TABELA IV

ANÁLISE DOS DADOS OBTIDOS – COMBINAÇÃO 2.

Mensagem	Identificação	Tipo	Confiança
#1	ELEC BUS TIE CONTACTOR 1 FAIL	CMC	99%
#2	ELEC GEN LINE CONTACTOR 2 FAIL	CMC	99%

TABELA V  
ANÁLISE DOS DADOS OBTIDOS – COMBINAÇÃO 3.

Mensagem	Identificação	Tipo	Confiança
#1	A-I E1 ON	CAS	98%
#2	A-I E2 ON	CAS	98%

Na combinação 1, a mensagem #1 representa um alerta de *De-ice Wings and Stabilizers On*, que relata à tripulação que o sistema de proteção contra gelo da asa e estabilizador está ligado (por ação do piloto). Na aeronave em questão, o sistema de degelo utilizado é um pneumático chamado *boot*, que infla periodicamente uma região da superfície aerodinâmica e torna a desinflar. Em cada ciclo (repetido a cada 5 minutos), o gelo acumulado na região é removido. Uma ilustração deste sistema pneumático pode ser visualizada por meio da Fig. 3.




Fig. 3. Representação do sistema pneumático de degelo (desinflado acima e inflado abaixo) [18].

Ainda em relação à combinação 1, a mensagem #2 significa *Stall Warning Protection System with Ice Speed*, que indica que o sistema de proteção de estol (ou seja, a velocidade mínima da aeronave no voo) foi alterada, apresentando o aviso de baixa velocidade ao piloto, com uma margem de segurança maior (cerca de 15%).

Ambas as mensagens estão intimamente ligadas, uma vez que a ativação do sistema de degelo provoca a deformação das superfícies aerodinâmicas (asas e estabilizadores). Por esta razão, eles devem ter uma maior margem em relação à velocidade mínima de voo, a fim de aumentar a segurança. Assim, a ativação do sistema de degelo ativa automaticamente a nova margem de segurança e, apesar de serem diferentes sistemas de alerta, foram corretamente correlacionadas com o método aqui apresentado.

Na combinação 2, surgiram duas mensagens que relacionam alertas de falha nas chaves contadoras do barramento de

energia elétrica. Nesse caso, uma possível falha em uma dessas chaves levaria a outra a falhar, fazendo com que ambas as mensagens apareçam juntas. Em 99% das mensagens, tal falha pode ter ocorrido, enquanto para o outro 1% restante pode ter havido uma falha isolada, normalmente de um componente da chave.

É importante notar que o sistema elétrico da aeronave pode ser alimentado por uma fonte externa enquanto a aeronave está em solo ou pelos geradores (alimentados pelos motores). Quando alimentado por uma fonte externa, a chave do contator do barramento (BTC – *Bus Tie Contactor*) é fechada enquanto o interruptor da linha do gerador, ou GLC (*Generator Line Contactor*) está aberto para que a fonte externa alimente o sistema e os geradores fiquem isolados. Quando a fonte externa é removida (com os motores acionados), os interruptores são invertidos, isto é, o GLC é fechado enquanto o BTC é aberto, isolando a fonte externa. Um esquema elétrico pode ser visto na Fig. 4.

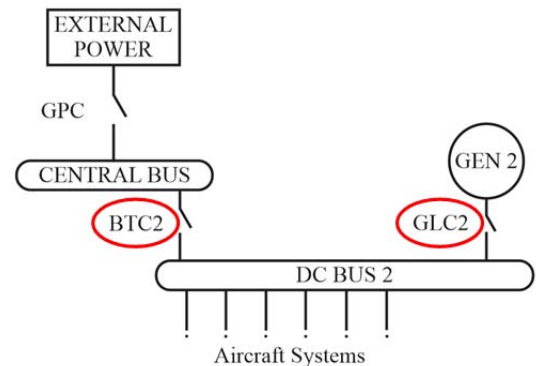


Fig. 4. Esquema elétrico do sistema em corrente contínua da aeronave [19].

Mais uma vez, a mineração de dados baseada em regras de associação mostrou-se consistente em relação à análise do especialista.

Por fim, na combinação 3, as duas mensagens obtidas são informativas e mostram que os sistemas anti-gelo dos motores estão ligados. A mensagem #1 (*Anti-ice Engine 1 On*) refere-se ao motor 1 (lado esquerdo) e a mensagem #2 (*Anti-ice Engine 2 On*) refere-se ao motor 2 (lado direito). Este sistema consiste em um dispositivo pneumático que retira o ar quente do motor e aquece a entrada de ar do mesmo.

Essa correlação é totalmente coerente, uma vez que ambos os sistemas são ativados pelo mesmo interruptor. Portanto, é impossível desencadear um sem desencadear o outro. Os 2% das mensagens (onde apenas um dos sistemas é acionado) são devidos à ativação rápida ou não intencional do sistema pelo piloto, com imediata desativação, uma vez que, quando ativado, os sistemas não ligam ao mesmo tempo, havendo um pequeno atraso de um em relação ao outro.

## VI. CONCLUSÕES

Este artigo apresenta uma metodologia baseada em Mineração de Dados, mais especificamente no algoritmo *Apriori*, estabelecendo relações entre mensagens de alerta transmitidas por aeronaves executivas durante o voo.

A mineração de dados foi eficiente e mostrou que pode, ao utilizar regras de associação para mensagens de alertas, apoiar a tomada de decisão voltada para a manutenção em aeronaves executivas, encontrando relações entre diferentes sistemas. Ou seja, se um tipo de falha presente em um sistema pode desencadear uma outra, em um sistema diferente, as regras de associação aqui descritas podem ser uma valiosa ferramenta na detecção destas características indesejáveis de uma aeronave, atuando fortemente em favor da segurança do voo.

As principais regras encontradas apontam para A.T.A. 30 (proteção contra gelo e chuva), A.T.A. 27 (comandos de voo), A.T.A. 24 (sistema elétrico) e A.T.A. 34 (sistema de navegação). A relação entre diferentes A.T.A. mostra a complexidade e interconexão entre os diferentes sistemas da aeronave e fornece relações não triviais entre esses sistemas. Portanto, as regras de associação são úteis na busca por alertas recorrentes e suas causas em uma determinada frota de aeronaves.

Finalmente, é importante mencionar que os resultados obtidos e analisados pelo especialista mostraram uma coerência do ponto de vista técnico. Além disso, esses resultados são extremamente importantes para determinar as causas de possíveis falhas em diferentes sistemas de uma aeronave executiva. Ainda é válido comentar que essa metodologia pode até mesmo determinar possíveis inconsistências procedimentais entre equipes de manutenção de diferentes regiões.

#### REFERÊNCIAS

- [1] ATA, "ATA Spec. 100: Specification for Manufacturers Technical Data", ATA, 1998.
- [2] R. Clements, J. Morse, D. Darr, B. Laskowski, "Meta-data mining for optimized aircraft repair and overhaul", *2<sup>nd</sup> International Symposium on NDT in Aerospace*, pp. 1-8, 2010.
- [3] L. A. E. Silva, "A Data Mining Approach for Standardization of Collectors Names in Herbarium Database", *IEEE Latin America Transactions*, vol. 14, no. 2, pp. 805-810, 2016.
- [4] F. E. Correa, J. Gama, P. L. P. Corrêa, L. R. A. Alves, "Data Mining Frequent Temporal Events in Agrieconomic Time Series", *IEEE Latin America Transactions*, vol. 13, no. 7, pp. 2329-2334, 2015.
- [5] S. Letourneau, F. Famili, S. Matwin, "Data mining to predict aircraft component replacement", *IEEE Intelligence Systems and Their Applications*, vol. 14, no. 6, pp. 59-66, 1999.
- [6] M. J. Roemer, G. J. Kacprzyński, E. O. Nwadiogbu, G. Bloor, "Development of diagnostic and prognostic technologies for aerospace health management applications", *IEEE Aerospace Conference*, pp. 3139-3147, 2001.
- [7] V. Skormin, V. Gorodetski, L. Popyack, "Data mining technology for failure prognostic of avionics", *Aerospace and Electronic Systems*, vol. 38, no. 2, pp. 388-403, 2002.
- [8] K. Keller, K. Swearingen, J. Sheahan, M. Bailey, J. Dunsdon, K. Przytula, "Aircraft electrical power systems prognostics and health management", *IEEE Aerospace Conference*, pp. 1-12, 2006.
- [9] A. Ahmadi, P. Soderholm, "Assessment of operational consequences of aircraft failures: Using event tree analysis", *IEEE Aerospace Conference*, pp. 1-14, 2008.
- [10] H. K. Han, H. S. Kim, S. Y. Sohn, "Sequential association rules for forecasting failure patterns of aircrafts in korean airforce", *Expert Systems with Applications*, vol. 36, no. 2, pp. 1129-1133, 2009.
- [11] T. Young, M. Fehskens, P. Pujara, M. Burger, G. Edwards, "Utilizing data mining to influence maintenance actions", *IEEE Autotest Conference*, pp. 1-5, 2010.
- [12] P. Zhang, S.-W. Zhao, B. Tan, L.-M. Yu, K.-Q. Hua, Applications of decision support system in aviation maintenance, *Efficient Decision*

Support Systems - Practice and Challenges in Multidisciplinary Domains – InTech, 397-412, 2011.

- [13] E. E. Hurdle, L. M. Bartlett, J. D. Andrews, "Fault diagnostics of dynamic system operation using a fault tree based method", *Reliability Engineering and System Safety*, vol. 94, no. 9, pp. 1371-1380, 2009.
- [14] J. A. De Castro, L. Tang, B. Zhang, G. Vachtsevanos, "A safety verification approach to fault-tolerant aircraft supervisory control", *Proceedings of AIAA Guidance, Navigation, and Control Conference*, pp. 1-17, 2011.
- [15] U. Fayyad, G. Piatetsky-Shapiro, P. Smyth, "From data mining to knowledge discovery in databases", *AI Magazine*, vol. 17, no. 3, pp. 37-54, 1996.
- [16] D. Hand, H. Mannila, P. Smyth, "Principles of Data Mining", MIT Press, 2001.
- [17] M. Hall, E. Frank, G. Holmes, B. Pfahringer, P. Reutemann, I. H. Witten, "The weka data mining software: An update", *SIGKDD Explorations*, vol. 11, no. 1, pp. 10-18, 2009.
- [18] FAA, Aviation Maintenance Technician Handbook - Airframe, vol. 2, FAA, 2012.
- [19] I. Moir, A. Seabridge, M. Jukes, Civil Avionics Systems, John Wiley & Sons, 2013.



**Priscila Barros Soares** possui graduação em Engenharia Mecânica (2013) pela Universidade Federal de São Carlos. Atualmente, é engenheira de desenvolvimento de produtos na EMBRAER S.A.



**Osmar Mendes Silva Junior** está concluindo o curso de graduação em Engenharia Mecânica na Universidade Federal de São Carlos. Atualmente, realiza pesquisa direcionada à aplicação de sistemas inteligentes na área aeroespacial.



**Ricardo Augusto Souza Fernandes** possui graduação em Engenharia Elétrica pela Fundação Educacional de Barretos. Obteve os títulos de mestre e doutor em Engenharia Elétrica pela Escola de Engenharia de São Carlos (EESC/USP), respectivamente em 2009 e 2011. Atualmente é Professor Adjunto do Departamento de Engenharia Elétrica da Universidade Federal de São Carlos. Suas atividades de pesquisa incluem a aplicação de sistemas inteligentes em estudos relacionados a sistemas dinâmicos.



**Jorge Henrique Bidinotto** possui graduação em Engenharia Mecânica com ênfase em Aeronaves pela EESC/USP, com mestrado e doutorado na mesma área, pela mesma instituição. Atualmente, é Professor Doutor do Departamento de Engenharia Aeronáutica da EESC/USP, atuando nas áreas de Sistemas de Controle, Aviónica, Navegação, Ensaios em Voo e Fatores Humanos em Aviação. Atuou durante 10 anos como Engenheiro de Ensaios em Voo pela Embraer S.A., totalizando aproximadamente 500 horas de voo de ensaios.