
Estimação de Eventos de Segurança Operacional em Aeroportos por meio de Filtro Adaptativo

Marcell Bruno Sousa e Silva ¹

1 Agência Nacional de Aviação Civil - ANAC

RESUMO: O presente artigo tem por objetivo modelar as ocorrências aeronáuticas, utilizando dados provenientes de um grande aeroporto brasileiro, para quantificar a correlação entre tais episódios e viabilizar a estimação de eventos de segurança operacional, de forma a analisar a utilização de técnicas preditivas para o Sistema de Gerenciamento de Segurança Operacional (SGSO). Os métodos testados foram os filtros adaptativos Recursive Least Squares (RLS) e Least Mean Squares (LMS) amplamente utilizados na área de processamento digital de sinais (Sayed, 2008), baseados no autoaprendizado ao longo do tempo para aumentar a precisão das estimações. A partir da aplicação dos filtros adaptativos LMS e RLS para a estimação de ocorrências aeronáuticas do aeroporto em questão chegou-se a previsões com erros de estimação decrescentes, demonstrando-se assim que os filtros LMS e RLS são ferramentas importantes para a estimação de eventos de segurança operacional em aeroportos.

Palavras chave: Sistema de Gerenciamento de Segurança Operacional. SGSO. Técnica Preditiva.

Estimation of Operational Safety Events in Airports through Adaptive Filters

ABSTRACT: This article aims to model occurrences at airports in order to quantify the correlation between them, infer how they affect each other and estimate future operational safety events through the airports occurrences one month earlier, in order to suggest two new predictive techniques for safety management systems (SMS) of airports. The methods used are the adaptive filters Recursive Least Squares - RLS and Least Mean Squares - LMS (Sayed, 2008) which are methods well known by the scientific community and widely used in solving problems such as suppression of acoustic echoes, systems recognition, forecasts. These adaptive filters are based on self-learning over time aiming to improve the accuracy and precision of the estimates. In this paper, the data used are from a big Brazilian airport. LMS and RLS filters provided predictions with decreasing estimation errors, demonstrating that LMS and RLS filters are important tools for estimation of operational safety events in airports.

Key words: Safety Management System. SMS. Predictive Technique.

Citação: Sousa e Silva, MB. (2016) Estimação de Eventos de Segurança Operacional em Aeroportos por meio de Filtro Adaptativo. *Revista Conexão Sipaer*, Vol. 7, No. 1, pp. 182-190.

1 INTRODUÇÃO

Segundo a *International Civil Aviation Organization*, o gerenciamento de segurança operacional deve utilizar metodologias reativas, preventivas e preditivas. Metodologias reativas advêm do resultado de investigação de acidentes aeronáuticos, esses resultados são utilizados para evitar que as causas aconteçam de novo, gerando outros acidentes similares, as metodologias preventivas visam a identificação de fatores humanos que possam ocasionar novos acidentes, enquanto que metodologias preditivas são focadas em fatores organizacionais, como políticas de segurança das empresas, e visam monitorar continuamente indicadores de níveis de segurança, de forma a identificar ameaças e gerenciar riscos. O presente artigo tem por objetivo apresentar duas técnicas preditivas de gerenciamento de riscos em aeroportos, a partir de registro de ocorrências aeronáuticas em um aeroporto brasileiro (ICAO, 2009).

De acordo com Gil-Alana & Barros (2012), foi verificada memória longa na série temporal mensal de acidentes de aviões no Brasil no período de 1999 a 2009, de forma que existem correlações significativas entre acidentes

ocorridos em 2009, com acidentes ocorridos em 1999, o que pode indicar que partes do sistema de aviação nacional não tenha apresentado mudanças significativas quanto à segurança operacional.

Ainda de acordo com Gil-Alana & Barros (2012), acidentes envolvendo helicópteros apresentaram memória curta, o que indica maiores mudanças operacionais na operação de helicópteros no Brasil.

Como os maiores usuários de aeroportos no Brasil de 2009 a 2012 eram aviões; e como estes utilizam mais a infraestrutura aeroportuária, como as pistas de pouso e decolagem, do que os helicópteros; pode-se considerar que os acidentes com aviões nos aeroportos também possuam memória longa, como foi considerado em 2009 na estimação de acidentes/incidentes futuros por meio de modelo estatístico de regressão logística (Wong, 2009, pp. 903-912).

Ainda em 2009, foi proposto outro modelo estatístico de regressão que inferia a ocorrência, os riscos e as probabilidades de acidente nos aeroportos New York LaGuardia e Boca Raton na Flórida (Wong, 2012, p. 913-924) aplicando também o conceito de memória longa, dado que no período amostral não houveram mudanças nas dimensões das

pistas e visto que na inferência dos acidentes não eram considerados os momentos de ocorrência.

Apesar desse modelo ter apresentado bons resultados no contexto de segurança operacional de aeroportos (Wong, 2012, pp. 913-924), o mesmo requer grande quantidade de dados, visto que é uma metodologia frequentista, e não possui sensibilidade às mudanças no sistema que gera as amostras (Harvey, 1990). Mesmo tendo sido consideradas memórias longas nas modelagens aeroportuárias citadas, o presente trabalho não leva em conta memória longa nem estacionariedade nos acidentes, nem nas ocorrências aeronáuticas. Porém melhores resultados são verificados com dados estacionários (Sayed, 2008).

De acordo com Teorema Central do Limite (TCL) quando muitas variáveis aleatórias com diversas distribuições de probabilidade são somadas, muito provavelmente a variável aleatória resultante obedece a uma distribuição de probabilidade gaussiana (Papoulis, 1991).

Na inferência estatística bayesiana as variáveis de estado de um modelo também são consideradas variáveis aleatórias, com distribuição de probabilidade associada (Resende, 2000), como as variáveis de estado de um modelo geralmente não são observáveis, geralmente assume-se uma distribuição de probabilidade gaussiana por conta do TCL.

Nas inferências estatísticas frequentistas ou clássicas utiliza-se as amostras para a determinação dos modelos, enquanto que na inferência bayesiana seleciona-se hipóteses para o modelo a partir de uma interpretação do mundo real e verifica-se não só se são aplicáveis, mas também qual das hipóteses é mais verossímil, utilizando a função de verossimilhança ou similaridade (Hainline, 2013; Harvey, 1990).

Um exemplo de inferência bayesiana ocorre na técnica Hidden Markov Models (HMM) vastamente utilizada na modelagem de séries temporais e reconhecimento de voz. Nessa técnica utiliza-se a hipótese de que a variável de estado no tempo discretizado n só depende da variável de estado no tempo $n-1$, que os valores das variáveis de estado são discretos, que as variáveis de estado não são observáveis e que a distribuição de probabilidade condicional da variável observável no tempo n em relação à variável de estado no tempo n é gaussiana. Nenhuma das hipóteses de funcionamento da técnica HMM podem ser auferidas diretamente, nem mesmo testes de normalidade podem ser feitos, no entanto é medido o quão verossímil esse modelo é para conjuntos específicos de amostras (Ghahramani, 2001).

Quando as variáveis de estado dos filtros adaptativos apresentam distribuição de probabilidade gaussiana ou conjuntamente gaussiana, esses filtros se comportam como os mais adequados estimadores (Harvey, 1990; Sayed, 2008), sendo aplicável a hipótese de que as variáveis de estado dos filtros adaptativos têm distribuições de probabilidade gaussianas, a quantidade de dados necessários para boas estimações pode ser menor do que usando a regressão estatística (Sayed, 2008).

Outra condição importante, resultante de problemas com variáveis aleatórias gaussianas, é o fato de que, se todas as variáveis aleatórias envolvidas forem gaussianas de média zero, os estimadores ótimos são lineares (Sayed, 2008), com isto, caso a hipótese de gaussianidade seja aplicável, os estimadores com melhores resultados apresentarão maior simplicidade do que estimadores não-lineares uma vez que são lineares.

Baseando-se na teoria da causa única de Herbert William Heinrich (Heinrich, 1931), e na teoria das causas múltiplas (Reason, 1997), a ICAO (2009) assumiu a existência de correlação entre acidentes, incidentes e condições latentes em um aeroporto, ilustrando-a com a figura de um iceberg, onde os incidentes e as condições latentes são as partes invisíveis do iceberg que somadas geram os acidentes que são as partes visíveis.

Dessa forma o presente trabalho considera existência de correlação existente entre os acidentes, os incidentes e as condições latentes existentes no aeroporto para estimá-los no mês seguinte (ICAO, 2009). Por conta da condição de correlação entre vários dados de segurança operacional adotados, os filtros adaptativos implementados são multivariados.

É importante destacar que o presente trabalho não tem por finalidade inferir causas de incidentes/acidentes aeronáuticos, mas apenas a correlação entre incidentes/acidentes e eventos de segurança operacional, visto que parcela significativa de acidentes/incidentes e eventos de segurança operacional são influenciados pelas mesmas causas, e essas causas podem ser mais facilmente identificadas através dos indicadores dos eventos de segurança operacional (ICAO, 2009).

2 FILTROS ADAPTATIVOS

Os filtros adaptativos são caracterizados pela adaptabilidade do seu funcionamento de acordo com as características estatísticas do problema (Sayed, 2008).

No presente trabalho as iterações de funcionamento dos filtros adaptativos são os meses, desta forma, com o passar dos meses, o algoritmo realiza auto aprendizado e tende a ficar cada vez mais preciso e acurado (Sayed, 2008).

As principais aplicações dos filtros adaptativos são: predição de dados, identificação de sistemas, cancelamento de interferências, obtenção de modelos inversos (Haykin, 1995). Na Figura 1 está disposto o esquema de predição de dados.

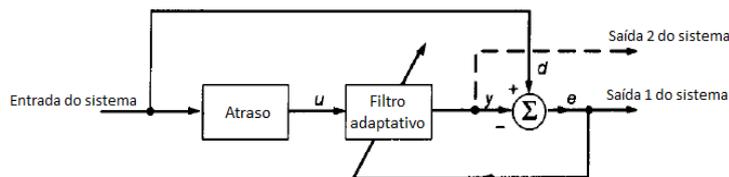


FIGURA 1: Sistema de predição utilizando filtro adaptativo
Fonte: (Haykin, 1995)

Dois dos principais filtros adaptativos utilizados em estimação de dados são o algoritmo Recursive Least Squares (RLS) e o Least Mean Squares (LMS).

2.1 Recursive Least Squares - RLS

O algoritmo RLS tem por finalidade encontrar o vetor pesos w que minimiza a seguinte função custo:

$$\min_w [w^* \Pi w + \|y_{N-1} - H_{N-1} w\|^2]$$

Sendo Π uma matriz identidade multiplicada por uma constante α e:

$$y = \begin{bmatrix} d(0) \\ d(1) \\ d(2) \\ \vdots \\ d(N-1) \end{bmatrix}, \quad H = \begin{bmatrix} u_0 \\ u_1 \\ u_2 \\ \vdots \\ u_{N-1} \end{bmatrix}$$

As variáveis $d(n)$ e u_n são vetores de dimensão $1 \times K$ e $1 \times N$ respectivamente, Π possui dimensão $N \times N$, e w tem dimensão $N \times K$.

Quanto ao significado físico; u_n representa a entrada de dados para cada mês, $d(n)$ representa o valor medido no mês n , e a estimação no mês $n+1$ é fruto do produto $u_n \times w(n)$, com $0 \leq n \leq N-1$.

Como o RLS e o LMS são projetados para tratar dados u_n com média zero, cada iteração foi estimada a média dos dados de entrada até então, subtraída do dado antes do processamento e somada à estimativa gerada após o processamento (Sayed, 2008; Haykin, 1995).

A variável Π representa uma estimação inicial para o sistema, de forma que no período de transiente onde o sistema é alimentado por poucos dados a estimação inicial do sistema tem maior influência nas previsões. Quando o número de dados é inferior ao número de dimensões dos dados o processo de estimação se tornaria sem efeito na ausência da variável Π .

Por meio de manipulações algébricas pode-se mostrar que o valor estimado de w é (Sayed, 2008):

$$w_{\text{estimado}} = (\Pi + H^* N - 1 H N - 1) - 1 H N - 1 y$$

RLS resolve a equação acima por meio do lema de inversão de matrizes, obtendo assim w estimado de forma iterativa (Sayed, 2008), que é o principal objetivo do presente trabalho: o auto aprendizado dos filtros adaptativos de forma a melhorarem suas precisões e acurácias.

Uma vez de posse de w_{estimado} , pode-se obter a estimação para cada mês da seguinte maneira:

$$\text{estimação} = u \times w_{\text{estimado}}$$

No caso do RLS, por ser um caso especial do filtro de Kalman, que é um filtro ótimo para o caso de variáveis de estado com distribuição de probabilidade gaussiana ou conjuntamente gaussiana, pode-se esperar resultados próximos aos melhores possíveis, após a convergência, se essas condições forem atendidas (Sayed, 2008).

2.2 Least Mean Squares - LMS

O algoritmo LMS tem por finalidade encontrar o vetor pesos w que minimiza a seguinte função custo (Sayed, 2008):

$$\min_w E |d - uw|^2$$

Considerando-se que w_0 é o vetor de pesos que resolve esta equação, a partir de algumas manipulações algébricas pode-se demonstrar que:

$$w^0 = R_u^{-1} R_{du}$$

Onde R_u é a matriz de correlação dos dados de entrada, e R_{du} é a matriz de correlação entre os dados de referência e os dados de entrada.

A forma de resolver essa equação de forma iterativa, é conhecida como Steepest-Descent Technique, através da seguinte equação, também obtida por manipulações algébricas:

$$w_n = w_{n-1} + \mu [R_{du} - R_u w_{n-1}], \quad n \geq 0$$

Sendo o tempo expressado pela variável n , e sendo μ o passo de convergência, o qual é responsável por estabelecer uma velocidade de convergência do algoritmo ao longo do tempo, na prática μ obedece a seguinte relação, com λ_{\max} sendo o maior autovalor de R_u (Sayed, 2008):

$$0 < \mu < \frac{2}{\lambda_{\max}}$$

Como a obtenção de R_u e de R_{du} demanda o conhecimento dos dados no tempo de $-\infty$ à $+\infty$ é impossível a obtenção exata dos mesmos por não se ter dados desde o tempo $-\infty$. No entanto, a principal funcionalidade do LMS é a estimação de R_u e R_{du} .

No LMS a estimativa de R_u é $uN^T \cdot uN$ e a estimativa de R_{du} é $uN^T \cdot d(N)$, desta forma, a equação que denota a obtenção de w_n por parte do LMS é:

$$w_n = w_{n-1} + \mu u_n^T [d(n) - u_n w_{n-1}], \quad w_{-1} = \text{valor inicial}$$

No caso do LMS, se as aproximações das matrizes de correlações utilizadas forem boas, o resultado também se aproximará do resultado ótimo obtido da teoria de estimação (Sayed, 2008).

3 METODOLOGIA

O experimento realizado se deu por meio da utilização de dados de um aeroporto brasileiro que não será identificado. Esses dados públicos, disponibilizadas pelo próprio aeroporto, foram coletados no período de janeiro de 2010 a abril de 2012 e estão apresentados no Anexo I. Dos 28 dados mensais coletados do aeroporto em questão, cada um era composto por 9 dimensões, e cada dimensão representava um indicador medido.

Os indicadores divulgados pelo operador aeroportuário estavam em ocorrências por 1000 movimentos, e eram: colisões em solo (CLS), quase colisões em solo (QLS), avistamento (VST), objetos estranhos na pista (foreign object - F.O.), dano ocasionado por objeto estranho na pista (foreign object damage - F.O.D.), acidentes aeronáuticos no aeroporto (CDT), incidentes aeronáuticos no aeroporto (NCD), ocorrências de solo (CRR), incursões em pista (NCR). O autor do artigo não teve acesso a informações de como esses dados foram obtidos, e/ou classificados nessas categorias, principalmente ocorrências similares como F.O.D. e NCD.

Os dados de janeiro de 2010 a março de 2012 foram utilizados para obter uma estimativa para abril de 2012 e em seguinte comparar com o dado de abril de 2012.

Os valores iniciais usados para os parâmetros dos filtros com condição inicial zero foram:

$u_0 = [0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0]$, $\mu = 0,2$ e $w-1$ igual à uma matriz zero com dimensão 9×9 .

Com condição inicial diferente de zero $w-1$ igual às matrizes estimadas pelas duas diferentes técnicas no final da metodologia com condição inicial nula, w_n para o LMS e $w_{estimado}$ para o RLS.

O software utilizado nas simulações foi o software livre Octave versão 3.6.1.

4 RESULTADOS

As condições iniciais de um problema de estimação são de extrema importância quando a quantidade de dados disponível é baixa (Harvey, 1990). Desta forma, são apresentados os comportamentos das metodologias propostas com condição inicial nula, ou seja, matrizes de peso nulas, e com as matrizes de peso iniciais iguais às matrizes de peso resultantes do processo com matrizes de peso nulas.

4.1 Resultados com condição inicial zero

A Tabela 1 mostra os valores estimados pelos filtros RLS e LMS, com as matrizes de peso nulas.

TABELA 1 – Valores estimados pelo RLS e LMS, e valores reais coletados em abril de 2012, com matriz de pesos nula.

	Colisão (CLS)	Quase colisão (QLS)	Avistamento (VST)	F.O. (foreign object)	F.O.D. (foreign object damage)	Acidentes aeronáuticos (CDT)	Incidentes aeronáuticos (NCD)	Ocorrências de solo (CRR)	Incursões em pista (NCR)
Estimado - RLS	0,1294	0	0	0,0505	0	0	0,7697	1,0042	0,0114
Estimado - LMS	0,1517	0	0	0,0339	0	0	0,7256	1,1365	0,0081
Obtido	0,1760	0	0	0,0440	0	0,0440	0,7039	1,0119	0

Das estimativas resultantes do filtro RLS, se destacam ocorrências de solo e incidentes aeronáuticos, com erros de 0,76% e 9,35% respectivamente. Sendo a definição de erro utilizada:

$$erro = \frac{|estimativa - medição|}{medição}$$

Quanto às estimativas resultantes do filtro LMS se destacaram incidentes aeronáuticos e ocorrências de solo, com erros de 3,08% e 12,31% respectivamente.

As estimativas de quase colisão, avistamento e acidentes aeronáuticos foram zero porque todos os dados coletados passados foram zero (ver Anexo I), e porque não havia informação suficiente do sistema na matriz de pesos inicial.

Similarmente, a estimativa da ocorrência de acidente aeronáutico também foi zero por que não haviam informações passadas dos acidentes ocorridos. Para a medição da correlação entre o acidente aeronáutico, as demais variáveis, e

posteriores previsões, seria necessário que ao menos um acidente houvesse ocorrido nesse período de tempo.

A matriz de pesos $w_{estimado}$ obtida pelo RLS ao final do processo, considerando também os eventos constatados do mês de abril de 2012 foi:

TABELA 2 – Westimado ao final do processamento por meio do RLS.

w_N	CLS	QLS	VST	F.O.	F.O.D.	CDT	NCD	CRR	NCR
CLS	-0.0266	0	0	0.0194	0	0.0050	0.1916	-0.0127	0.0157
QLS	0	0	0	0	0	0	0	0	0
VST	0	0	0	0	0	0	0	0	0
F.O.	0.0128	0	0	-0.0121	0	0.0006	-0.0729	-0.1466	0.0094
F.O.D.	0	0	0	0	0	0	0	0	0
CDT	0	0	0	0	0	0	0	0	0
NCD	0.0638	0	0	-0.0035	0	0.0018	-0.0488	0.2340	0.0031
CRR	0.0673	0	0	0.0384	0	-0.0011	0.5865	0.5770	0.0028
NCR	0.0112	0	0	-0.0044	0	-0.0006	-0.0328	-0.0711	0.0020

A matriz de pesos w_n obtida pelo LMS ao final do processo, considerando também os eventos constatados do mês de abril de 2012 foi:

TABELA 3 – w_n ao final do processamento por meio do LMS.

w_N	CLS	QLS	VST	F.O.	F.O.D.	CDT	NCD	CRR	NCR
CLS	-0.0098	0	0	0.0007	0	0.0015	0.0302	-0.0028	0.0013
QLS	0	0	0	0	0	0	0	0	0
VST	0	0	0	0	0	0	0	0	0
F.O.	0.0155	0	0	-0.0059	0	0.0004	0.0137	0.0346	0.0031
F.O.D.	0	0	0	0	0	0	0	0	0
CDT	0	0	0	0	0	0	0	0	0
NCD	0.0909	0	0	-0.0211	0	0.0049	-0.0447	0.4258	0.0034
CRR	0.0842	0	0	0.0281	0	0.0023	0.5024	0.5957	-0.0009
NCR	0.0012	0	0	-0.0025	0	-0.0001	-0.0191	-0.0156	-0.0004

De acordo com (Sayed, 2008) as matrizes westimado e w_n podem ser utilizadas para inferir a influência de uma ocorrência sobre a outra.

Por exemplo, para o número de incidentes (representado pela coluna 7), os maiores pesos foram 0,5865 e 0,5024 (correspondentes à linha 8, nas Tabelas 2 e 3), que representam as ocorrências de solo, desta forma quem mais tem influenciado para os incidentes no aeroporto do estudo é o número de ocorrências de solo, de acordo com os dois estimadores utilizados.

Quanto à linha 7 da coluna 7, temos que os estimadores aqui apresentados estimam que a probabilidade de ocorrerem incidentes em um período de 2 meses é relevante, por conta do alto valor absoluto dessa célula. Como o valor dessa célula é negativo, ocorre que caso o valor do número de incidentes esteja acima da média, a tendência desse indicador é que no mês seguinte o número de incidentes passe a ficar abaixo da média, e vice-versa.

Isso se dá porque os filtros adaptativos utilizados só funcionam com dados de média zero, e para fins de processamento eliminamos a média dos dados a cada iteração, de forma que quando um dado fica abaixo da média, seu valor para o filtro fica negativo, e quando multiplicado por um índice negativo, gera um valor positivo, assim se em um mês o valor do número de incidentes fica abaixo da média, os filtros irão estimar que no mês seguinte o número de incidentes ficará acima da média. Após o processamento o valor estimado é novamente somado à média dos dados.

O indicador “incidentes” foi escolhido para se analisar a diferença entre o valor da estimativa e o valor obtido para cada

mês. Nas figuras 2 e 3 estão apresentados os valores obtidos em cada mês e os valores estimados, para o indicador nº de incidentes.

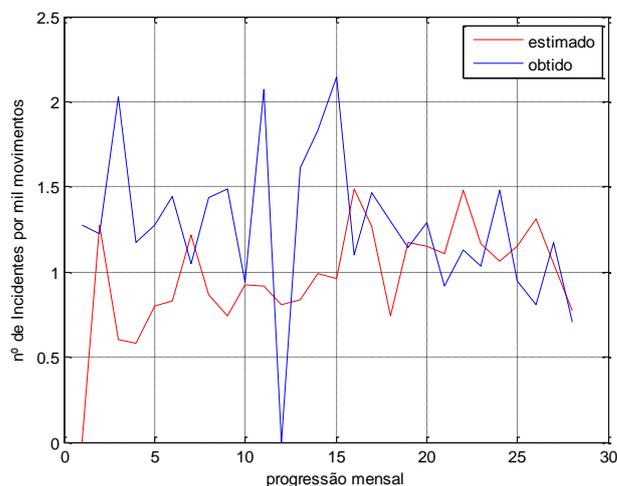


FIGURA 2 – Comparativo mensal entre os valores estimados e os valores obtidos para o nº de incidentes por meio do RLS.

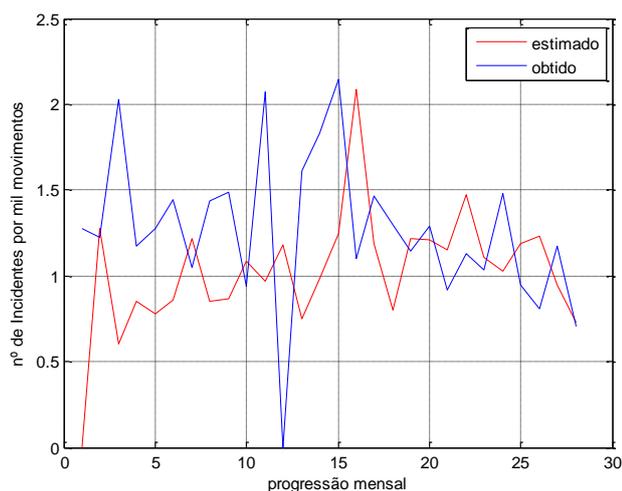


FIGURA 3 – Comparativo mensal entre os valores estimados e os valores obtidos para o nº de incidentes por meio do LMS.

É importante observar a partir dos gráficos apresentados que antes do mês 10 a estimação não foi adequada, visto que nesse período os filtros adaptativos estavam no período transiente. A partir do décimo mês, as estimativas começaram a se aproximarem mais dos dados verificados nos meses subsequentes.

As Figuras 4 e 5 apresentam o módulo do erro de estimação em cada mês para ambos estimadores. A partir deles, pode-se inferir que, apesar de haverem oscilações na progressão mensal dos mesmos, existe uma queda média.

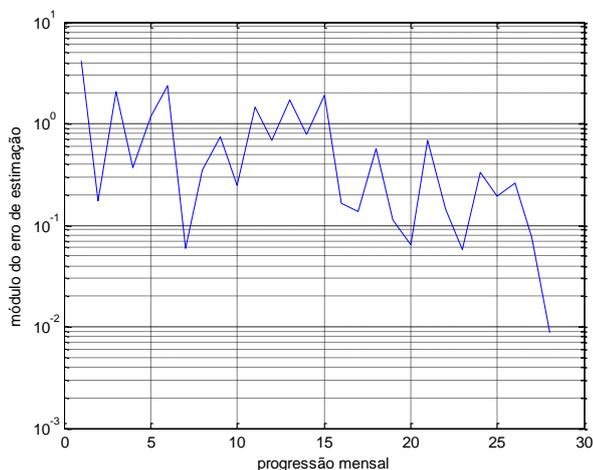


FIGURA 4 – Módulo dos erros de estimação mensais ao longo dos meses para o estimador RLS.

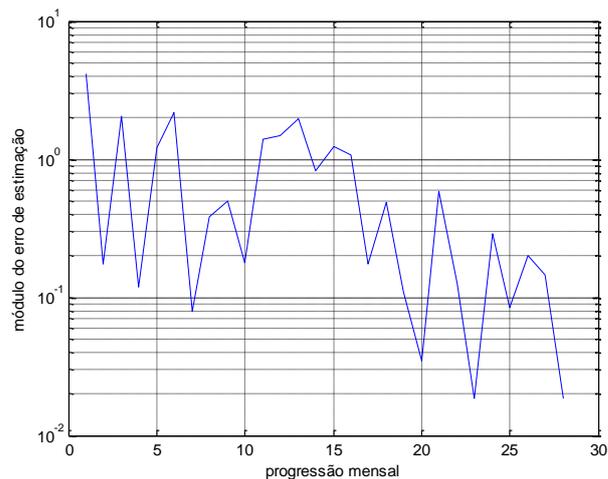


FIGURA 5 – Módulo dos erros de estimação mensais ao longo dos meses para o estimador LMS.

Conforme pode-se observar nas Figuras 4 e 5, foram obtidos erros de estimação decrescentes ao longo dos meses, o que implica que o auto aprendizado dos filtros adaptativos adotados ocorreu com sucesso.

Quanto à correlação entre os indicadores e quanto a distribuição de probabilidade gaussiana ou gaussiana conjunta para as variáveis de estado do sistema, pode-se afirmar que se aplicam ao aeroporto estudado de forma relevante porque mesmo com 28 amostras, apenas 19 amostras a mais que 9 amostras que o mínimo para o funcionamento dos filtros (Sayed, 2008), os filtros apresentaram auto aprendizado.

Ainda comparando as Figuras 4 e 5, pode-se observar que a técnica LMS apresentou um melhor decaimento dos erros de estimação ao longo do tempo.

Por fim, o auto aprendizado dos algoritmos apresentados culminou em uma estimativa de precisão relevante ao final dos meses estudados.

4.2 Resultados com condição inicial estimada

A Tabela 4 mostra os valores estimados pelos filtros RLS e LMS, com as matrizes de peso iniciais estimadas.

A principal diferença entre a Tabela 4 e a Tabela 1 é que agora o sistema foi capaz de inferir a ocorrência de acidentes aeronáuticos, isso ocorreu por conta da matriz de pesos inicial que continha informação sobre a correlação entre acidentes aeronáuticos no aeródromo do aeroporto em questão e as demais variáveis.

A acurácia não foi boa para a estimação de acidentes aeronáuticos porque na estimação das matrizes de pesos iniciais foi utilizada apenas uma amostra de acidente aeronáutico.

TABELA 4 – Valores estimados pelo RLS e LMS, e valores reais coletados em abril de 2012, com matrizes de pesos iniciais estimadas.

	Colisão (CLS)	Quase colisão (QLS)	Avistamento (VST)	F.O.	F.O.D.	Acidentes aeronáuticos (CDT)	Incidentes aeronáuticos (NCD)	Ocorrências de solo (CRR)	Incurções em pista (NCR)
Estimado - RLS	0,1272	0	0	0,0515	0	0,0007	0,7744	0,9967	0,0134
Estimado - LMS	0,1377	0	0	0,0483	0	0,0006	0,8057	1,1154	0,0080
Obtido	0,1760	0	0	0,0440	0	0,0440	0,7039	1,0119	0

5 CONCLUSÃO

Pode-se inferir por meio dos resultados, que a premissa de correlação dos dados, e a hipótese de distribuição de probabilidade gaussiana ou gaussiana conjunta das variáveis de estado se aplicaram de forma relevante para o aeródromo do aeroporto em questão.

Apesar da restrição oferecida pela pequena quantidade de dados, a metodologia apresentada demonstrou capacidade de estimar, com acurácia relevante, ocorrências de acidentes/incidentes aeronáuticos em aeroportos, tendo a metodologia LMS se destacado.

O principal ganho para o Sistema de Gerenciamento de Segurança Operacional – SGO do aeródromo em questão é a estimativa da influência que cada parâmetro tem sobre os demais parâmetros e sobre ele próprio, de forma a indicar os parâmetros operacionais mais críticos e a partir disso apontar as prioridades de melhoria operacional guiando assim uma melhor alocação dos recursos nos aeroportos.

REFERÊNCIAS

- GHAHRAMANI, Z. (2001) An introduction to hidden Markov models and Bayesian networks, *International Journal of Pattern Recognition and Artificial Intelligence*, Vol. 15, No. 01, pp. 9-42.
- GIL-ALANA, LA, BARROS, CP; ARAUJO JR, AF. (2012) Aircraft accidents in Brazil, *International Journal of Sustainable Transportation*, Vol. 6, Issue 2, pp. 111–126.
- HAINLINE, AE. (2013) Frequentist and Bayesian modeling in the presence of unmeasured confounding. A Thesis Submitted to the Faculty of Baylor University In Partial Fulfillment of the Requirements for the Honors Program. Waco, Texas May 2013. 56p.
- HARVEY, AC. (1990) *Forecasting, structural time series models and the Kalman filter*, Cambridge university press.
- HAYKIN, S. (1995). *Adaptive filter theory*, 3rd Edition, Harlow: FT Prentice Hall.
- HEINRICH, HW (1931) *Industrial Accident Prevention: A Scientific Approach*. first ed. New York: McGraw-Hill, 1931.
- INTERNATIONAL CIVIL AVIATION ORGANIZATION [ICAO]. (2009) *Safety Management Manual [SMM]*, Doc 9859-AN474, 2nd Edition, Montreal, Quebec, Canada.
- PAPOULIS, A. (1991) *Probability, random variables, and stochastic processes*, Edition, City, McGraw-Hill.
- REASON (1997) *J Managing the Risks of Organizational Accidents*. Burlington: Ashgate.
- RESENDE, MDV de. (2000) *Inferência Bayesiana e simulação estocástica (amostragem de Gibbs) na estimação de componentes de variância e de valores genéticos em plantas perenes*. Colombo: Embrapa Florestas. 68p.
- SAYED, AH. (2008) *Adaptive filters*, 1st Edition., New Jersey: John Wiley & Sons.
- WONG, D. K. Y., PITFIELD, D.E., CAVES, R.E., Appleyard, A.J. (2009a) ‘The development of a more risk-sensitive & flexible airport safety area strategy: part I: the development of an improved accident frequency model’, *Journal of Safety Science* Vol. 47, No. 7, pp. 903-912.
- (2009b) ‘The development of a more risk-sensitive & flexible airport safety area strategy: part II: the development of an improved accident frequency model’, *Journal of Safety Science*, Vol. 47, No. 7, pp. 913-924.

ANEXO I

No presente anexo estão dispostos os dados utilizados para as análises quantitativas.

Na Tabela 5 estão apresentados os eventos de F.O. para cada mil movimentos de voo.

TABELA 5 – Dados de F.O. de janeiro de 2010 a abril de 2012.

	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
2010	0,2453	0,2221	0,0494	0,0000	0,0981	0,0498	0,1823	0,0462	0,1861	0,0449	0,1381	0,0000
2011	0,1308	0,2477	0,1314	0,0918	0,1331	0,0927	0,0424	0,0000	0,1313	0,0839	0,0430	0,0000
2012	0,0410	0,0447	0,0840	0,0440								

Na Tabela 6 estão apresentados os eventos de Colisão para cada mil movimentos de voo.

TABELA 6 – Dados de Colisão de janeiro de 2010 a abril de 2012.

	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
2010	0,0491	0,2221	0,0494	0,2543	0,0000	0,1991	0,1823	0,0925	0,0465	0,0898	0,0460	0,0000
2011	0,0872	0,1981	0,3503	0,3212	0,0887	0,2318	0,0424	0,1718	0,1751	0,2516	0,0861	0,0823
2012	0,2463	0,1788	0,2521	0,1760								

Na Tabela 7 estão apresentados os eventos de Quase Colisão para cada mil movimentos de voo.

TABELA 7 – Dados de Quase Colisão de janeiro de 2010 a abril de 2012.

	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
2010	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
2011	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
2012	0,0000	0,0000	0,0000	0,0000								

Na Tabela 8 estão apresentados os eventos de Avistamento para cada mil movimentos de voo.

TABELA 8 – Dados de Avistamento de janeiro de 2010 a abril de 2012.

	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
2010	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
2011	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
2012	0,0000	0,0000	0,0000	0,0000								

Na Tabela 9 estão apresentados os eventos de F.O.D. para cada mil movimentos de voo.

TABELA 9 – Dados de F.O.D. de janeiro de 2010 a abril de 2012.

	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
2010	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
2011	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
2012	0,0000	0,0000	0,0000	0,0000								

Na Tabela 10 estão apresentados os eventos de Acidentes Aeronáuticos para cada mil movimentos de voo.

TABELA 10 – Dados de Acidentes Aeronáuticos de janeiro de 2010 a abril de 2012.

	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
2010	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
2011	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000

2012	0,0000	0,0000	0,0000	0,0440								
-------------	--------	--------	--------	--------	--	--	--	--	--	--	--	--

Na Tabela 11 estão apresentados os eventos de Incidentes Aeronáuticos para cada mil movimentos de voo.

TABELA 11 – Dados de Incidentes Aeronáuticos de janeiro de 2010 a abril de 2012.

	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
2010	1,2756	1,2216	2,0258	1,1696	1,2754	1,4435	1,0481	1,4339	1,4890	0,9427	2,0722	0,0000
2011	1,6131	1,8327	2,1458	1,1011	1,4640	1,2980	1,1456	1,2883	0,9192	1,1323	1,0328	1,4812
2012	0,9441	0,8044	1,1765	0,7039								

Na Tabela 12 estão apresentados os eventos de Ocorrências de Solo para cada mil movimentos de voo.

TABELA 12 – Dados de Ocorrências de Solo de janeiro de 2010 a abril de 2012.

	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
2010	1,5700	1,9435	1,1858	0,9154	1,6188	2,2897	1,6405	1,0639	1,3494	1,6160	0,8289	0,9701
2011	1,6567	1,4860	1,8831	1,5598	0,9316	1,4370	1,4850	1,3742	1,9697	1,5517	1,4631	1,6047
2012	1,8062	1,4747	1,0084	1,0119								

Na Tabela 13 estão apresentados os eventos de Incursão em Pista para cada mil movimentos de voo.

TABELA 13 – Dados de Incursão em Pista de janeiro de 2010 a abril de 2012.

	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
2010	0,0000	0,0000	0,0494	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
2011	0,0000	0,0000	0,0876	0,0459	0,0000	0,0000	0,0000	0,0000	0,0438	0,0419	0,0000	0,0000
2012	0,0000	0,0000	0,0000	0,0000								