

ESTIMAÇÃO DE EVENTOS DE SEGURANÇA OPERACIONAL EM AEROPORTOS POR MEIO DE FILTRO ADAPTATIVO.

M. B. S. Silva¹

1- Assessoria de Articulação com o Sistema de Investigação e Prevenção de Acidentes Aeronáuticos – Agência Nacional de Aviação Civil
Setor Comercial Sul Quadra 09 Torre A Lote C Ed. Parque Cidade Corporate – CEP: 70308-200 – Brasília- DF – Brasil
Telefone: (61) 3314-4656 – Email: marcell.silva@anac.gov.br

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, 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.

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 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.

KEYWORDS: Safety Management System, SMS, Predictive Technique.

1. INTRODUÇÃO.

Segundo a International Civil Aviation Organization (ICAO), 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[1].

De acordo com Gil-Alana & Barros [2], 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, acidentes envolvendo helicópteros apresentaram memória curta, o que indica maiores mudanças operacionais na operação de helicópteros no Brasil [2].

Como os maiores usuários de aeroportos no Brasil de 2009 à 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 [3].

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 [4] 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 [4], 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 [5]. 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 [6].

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 [7].

Na inferência estatística bayesiana as variáveis de estado de um modelo também são consideradas variáveis aleatórias, com distribuição de probabilidade associada [8], 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 [9][5].

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 $n-1$ 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 [10].

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 [5][6], 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 [6].

Outra condição importante, resultante de problemas com variáveis aleatórias gaussianas, é o fato de que, se todas as variáveis aleatórias envolvidas forem gaussianas, os estimadores ótimos são lineares [6], com isto, caso a hipótese de gaussianidade seja aplicável, os estimadores com melhores resultados apresentarão maior simplicidade do que estimadores não-lineares por serem lineares.

Baseando-se na teoria da causa única de Herbert William Heinrich [11], e na teoria das causas múltiplas [12], a ICAO assumiu a existência de correlação entre acidentes, incidentes e condições latentes em um aeroporto [1], 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 [1]. Por conta da condição de correlação entre vários dados de segurança operacional adotados, os filtros adaptativos implementados são multivariados.

2. FILTROS ADAPTATIVOS

Os filtros adaptativos são caracterizados pela adaptabilidade do seu funcionamento de acordo com as características estatísticas do problema [6][13].

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 [6].

As principais aplicações dos filtros adaptativos são: predição de dados, identificação de sistemas, cancelamento de interferências, obtenção de modelos inversos [13]. Na Figura 1 está disposto o esquema de predição de dados.




Figura 1. Sistema de predição utilizando filtro adaptativo [13].

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

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 à 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 nula com dimensão 9×9 , a notação das variáveis é a mesma usada em [6].

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 [5]. 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:

$$\text{erro} = \frac{|\text{estimativa} - \text{medição}|}{\text{medição}} \quad (1)$$

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 Figuras 2 e 3 apresentam o módulo do erro de estimação em cada mês para ambos estimadores. Cada erro de estimação

quadrático apresentado nas Figuras 2 e 3 é resultado da raiz quadrada da soma dos quadrados dos erros de estimação dos nove parâmetros utilizados no mês correspondente, conforme a fórmula:

$$\text{erro de estimação quadrático} = \sqrt{\sum_{i=1}^9 (\text{estimativa}_i - \text{medição}_i)^2} \quad (2)$$

A partir das Figuras 2 e 3, pode-se inferir que, apesar de haverem oscilações na

progressão mensal dos erros de estimação quadráticos, existe uma queda média.




Figura 2. Erros de estimação quadráticos mensais ao longo dos meses para o estimador RLS




Figura 3. Erros de estimação quadráticos mensais ao longo dos meses para o estimador LMS

Conforme pode-se observar nas Figuras 2 e 3, foram obtidos erros de estimação decrescentes ao longo dos meses, o que implica que o auto-aprendizado dos filtros adaptativos adotados ocorreu com sucesso. Pode-se também 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.

4.1. Resultados com Condição Inicial Estimada

A Tabela 2 mostra os valores estimados pelos filtros RLS e LMS, com as matrizes de peso iniciais estimadas.

Tabela 2. 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. (foreign object) | F.O.D. (foreign object damage) | Acidentes aeronáuticos (CDT) | Incidentes aeronáuticos (NCD) | Ocorrências de solo (CRR) | Incursões em pista (NCR) |
|----------------|---------------|---------------------|-------------------|-----------------------|--------------------------------|------------------------------|-------------------------------|---------------------------|--------------------------|
| Estimado - RLS | 0,1272 | 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 |

A principal diferença entre a Tabela 2 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.

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 tem a capacidade de estimar, com acurácia relevante, ocorrências de acidentes/incidentes aeronáuticos em aeroportos, tendo a metodologia LMS se destacado.

Como na implementação dos filtros adaptativos RLS e LMS é feita a estimação da matriz de correlação entre os diversos parâmetros, é possível medir o quanto uma variável impacta nas demais, e dessa forma diminuir a probabilidade de ocorrências diminuindo a incidência de uma das variáveis por meio de melhoria dos procedimentos de segurança operacional.

5. CITAÇÕES BIBLIOGRÁFICAS

- [1] International Civil Aviation Organization [ICAO]. Safety Management Manual [SMM], Doc 9859-AN474, 2nd Edition, Montreal, Quebec, Canada, 2009.
- [2] GIL-ALANA, L. A.; BARROS, C. P.; ARAÚJO Jr, A. F. Aircraft accidents in Brazil, International Journal of Sustainable Transportation, Vol. 6, Issue 2, pp. 111–126, 2012.
- [3] WONG, D. K. Y.; PITFIELD, D.E.; CAVES, R.E.; APPLEYARD, A.J. 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, 2009.
- [4] WONG, D. K. Y.; PITFIELD, D.E.; CAVES, R.E.; APPLEYARD, A.J. 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, 2009.
- [5] HARVEY, A. C. Forecasting, structural time series models and the Kalman filter, Cambridge university press, 1990.
- [6] SAYED, A. H. Adaptive filters, 1st Edition., New Jersey: John Wiley & Sons, 2008.
- [7] PAPOULIS, A. Probability, random variables, and stochastic processes, Edition, City, McGraw-Hill, 1991.
- [8] RESENDE, M. D. V. 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, 2000.
- [9] HAINLINE, A. E. 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, 2013.
- [10] GHAMRANI, Z. An introduction to hidden Markov models and Bayesian networks, International Journal of Pattern Recognition and Artificial Intelligence, Vol. 15, No. 01, pp. 9-42, 2001.
- [11] HEINRICH, H. W. Industrial Accident Prevention: A Scientific Approach. first ed. New York: McGraw-Hill, 1931.
- [12] REASON J. Managing the Risks of Organizational Accidents. Burlington: Ashgate, 1997.
- [13] HAYKIN, S. Adaptive filter theory, 3rd Edition, Harlow: FT Prentice Hall, 1995.

6. ANEXO

No presente anexo estão dispostos os dados utilizados para as análises quantitativas. Os dados estão em número de eventos para cada mil movimentos.

Tabela 3 – 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 | | | | | | | | |

Tabela 4 – 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 | | | | | | | | |

Tabela 5 – 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 | | | | | | | | |

Tabela 6 – 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 | | | | | | | | |

Tabela 7 – 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 | | | | | | | | |

Tabela 8 – 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 | | | | | | | | |

Tabela 9 – 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 | | | | | | | | |

Tabela 10 – 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 | | | | | | | | |

Tabela 11 – 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 | | | | | | | | |