



DETECÇÃO DE MINAS TERRESTRES VIA ANÁLISE MULTIVARIADA DE IMAGEM

Leandro Vitral Andraos

Instituto Militar de Engenharia

Praça Gen. Tibúrcio, 80 - Praia Vermelha, Rio de Janeiro - RJ

leandroandraos@hotmail.com

Paulo Henrique Coelho Maranhão

Instituto Militar de Engenharia

Praça Gen. Tibúrcio, 80 - Praia Vermelha, Rio de Janeiro - RJ

maranhao@ime.eb.br

RESUMO

Apesar dos avanços tecnológicos, as ações de minas terrestres ainda afetam a vida de muitas pessoas e a busca de métodos eficientes para a detecção dessas minas torna-se um tema relevante. Dessa forma, este trabalho propõe a técnica de Análise Multivariada de Imagens para a detecção de minas terrestres usando imagens infravermelha (IR). Adicionalmente, é proposto o monitoramento dessas minas por meio do gráfico de controle T^2 de Hotelling. Resultados experimentais mostram que os métodos propostos foram eficientes tanto para a detecção, quanto para o monitoramento de minas terrestres.

PALAVRAS CHAVE. Mina terrestre, detecção, análise multivariada de imagens.

Tópicos: (4. Resultados, 2. Métodos, 5. Conclusão, 3. Metodologia, 1. Introdução, 6. Referências bibliográficas)

ABSTRACT

Despite the technological advances, landmine action still affects the lives of many people and the search for efficient methods to detect these mines becomes a relevant issue. Thus, this work proposes the technique of Multivariate Image Analysis for the detection of landmine using infrared (IR) images. In addition, monitoring of these mines is proposed through the T^2 control chart. Experimental results show that the proposed methods were efficient for both detection and monitoring of landmines.

KEYWORDS. Landmine, detection, multivariate image analysis.

Paper topics:(4. Results, 2. Methods, 5. Conclusion, 3. Methodology, 1. Introduction, 6. References)



1. Introdução

A utilização de imagens térmicas infravermelhas (IR) para a detecção de minas terrestres tornou-se um tema de grande interesse nos últimos tempos. De acordo com os dados do Serviço de Ação de Minas [Nações Unidas 2014], dez pessoas são mortas ou mutiladas por uma mina terrestre a cada dia e existe, ainda hoje, uma mina para cada 17 crianças no mundo, apresentando um sério risco para a população. Segundo [Hong et al. 2001], estima-se que ainda existam pelo menos 100 milhões de minas terrestres espalhadas por mais de 60 países, o que torna a busca de métodos mais eficientes para detecção de minas um tema ainda atual e importante. Além disso, de acordo com o monitoramento global de munição e minas terrestres [Landmine Monitor 2015], 61 países foram classificados como afetados pelas minas no ano de 2015.

O princípio da termografia deixa claro que a assinatura do solo é alterada pela presença de objetos superficialmente enterrados. [Lopez et al. 2003] relaciona a detecção de minas terrestres com suas propriedades térmicas, já que isso resulta em perturbações do padrão térmico esperado, podendo então ser medidas por sensores IR. Tal detecção vale para cada tipo de mina e mesmo se houver pouca quantidade de metal, sua identificação pode ser realizada.

A utilização da termografia IR para a detecção de minas terrestres enterradas é uma aplicação recente, embora a teoria básica tenha sido desenvolvida por [Watson 1975]. Além disso, a utilização de imagens infravermelhas térmicas para detectar minas terrestres baseia-se no pressuposto de que as minas têm propriedades térmicas diferentes do solo onde está inserida, [Janssen et al. 1996].

[DePersia et al. 1995] foram percussores em trabalhos que relataram assinaturas térmicas em áreas com minas terrestres. As diferenças de temperatura entre a superfície do solo e a mina são atribuídas a diferenças em suas capacidades de calor, bem como a perturbação da superfície durante sua instalação. Estudos realizados por [Simunek et al. 2001] avaliaram como a textura do solo e a água afetam as assinaturas térmicas de minas terrestres. Já [Messelink et al. 2002] utilizou classificadores baseados em distância de Mahalanobis e Fisher para fazer uma variação da transformação de Hough e encontrar objetos de forma circular baseadas em imagens infravermelhas.

Com o desenvolvimento da teoria de problemas inversos, [López et al. 2003] realizaram uma análise não destrutiva interna do solo, a fim de detectar a presença de minas enterradas. Já [Sendur e Baertlein 2009] descreveram técnicas baseadas em sensores e em processamento de sinais para melhorar a detecção de minas com o uso de imagens de infravermelhos térmicos.

Em [Macdonald e Lockwood 2003] é discutida a questão do detector de metais ainda ser o dispositivo popular mais utilizado na detecção de minas terrestres metálicas, no entanto é pouco útil no caso mais comum, mina não metálica (PVC e polietileno). Estudos realizados por [Mende et al. 2004] investigaram como a absorção de temperatura cria um gradiente de concentração térmico na superfície do solo.

Atualmente novas investigações em detecção de minas estão sendo avaliadas. Estudos baseados em radares holográficos (métodos que discriminam alvos de objetos enterrados) são conduzidas por [Zea e Cadernas 2013]; [Szymanik 2014] introduziu um método novo envolvendo termografia infravermelha ativa com microondas; [Song et al 2016] intercalou radares holográficos com simulação numérica e [Hameed 2016] desenvolveu algoritmos capazes de escanear sistematicamente um campo de minas através de robôs.

A desminagem de terrenos é, ainda, uma tarefa árdua e perigosa com um custo de remoção excessivamente alto e de acordo com [Smith 2014] os métodos tradicionais de detecção de minas são pouco eficazes e perigosos, assim estudos vêm sendo realizados para aperfeiçoar as técnicas existentes ou implementar novas metodologias para melhorar sua qualidade em termos de sua percepção.

Dessa forma, o objetivo deste artigo é avaliar a eficácia de uma técnica de análise estatística multivariada para detecção de minas terrestres. A partir da obtenção de uma série de imagens e da aplicação dessa técnica espera-se classificar e detectar os objetos na imagem. Em



seguida, serão desenvolvidos gráficos de controle baseados na estatística T^2 de Hotelling para identificar eventuais divergências nas imagens baseado em um grupo de imagens controle.

O restante do artigo inclui mais cinco Seções. A segunda apresenta os métodos abordados no trabalho, com algumas definições de processamento e análise multivariada de imagens incluindo as principais características da técnica de componentes principais utilizada. A terceira Seção explica a metodologia abordada e os resultados e discussões levantados no trabalho aparecem na Seção quatro. Por fim, as conclusões são apresentadas na Seção cinco.

2. Métodos

2.1. Análise Multivariada de imagem

Ao longo dos anos o uso da inspeção visual tem sido comum em processos de controle e monitoramento em diversas áreas, e apesar de serem realizadas por pessoas qualificadas para a função, tornou-se um sistema limitado e sujeito a falhas humanas. De acordo com [Crósta 1993] o objetivo principal do processamento de imagens é o de remover essas barreiras, inerentes ao sistema visual humano, facilitando a extração de informações a partir de imagens.

Em [Gonzalez 2000] a definição de imagem é feita como uma função bidimensional $f(x,y)$ em que x e y são coordenadas espaciais e a amplitude f em qualquer par de coordenadas (x,y) é denominado de intensidade da imagem nesse ponto. Dessa forma, uma imagem digital é composta por um número finito de elementos, com localização e valores específicos, sendo chamado de pixel cada representação do elemento da imagem.

Na análise de imagens cada pixel poderá conter mais de uma medida, ou seja, diferentes canais da banda de cor representam distintas medições para um determinado pixel. Assim a utilização do primeiro e/ou segundo tipo de representação de imagem depende se a informação procurada é encontrada no nível do pixel (segmentação da imagem em diferentes classes de acordo com a semelhança de pixel) ou a um nível global (imagens completas utilizadas para fins de tomada de decisão no controle de processo).

Uma técnica muito difundida de análise de imagens em monitoramento de processos é a Análise Multivariada de Imagens (MIA) [Geladi e Grahn, 1996], [Prats-Montalbán et al. 2011]. A sua aplicabilidade pode ser feita em diversas áreas e em inúmeras imagens produzidas por processos complexos de monitoramento. A partir dessa técnica pode-se reduzir a dimensão das informações e tornar o tempo de processamento menor. Uma revisão sobre a aplicação do MIA pode ser encontrada em [Duchesne e MacGregor 2012].

Utilizando a MIA, [Wise e Geladi 2000] discutem a reorganização de uma matriz original de três ou mais dimensões e através de um processo de "desdobramento" cada pixel se transforma numa linha da matriz. Em outras palavras, uma imagem originalmente formada com I por J pixels com K bandas espectrais é convertida para duas dimensões $I \times J$ por K . A partir desta nova matriz utiliza-se a técnica de Análise de Componentes Principais (PCA) para reduzir a dimensão da imagem através das componentes e em seguida gráficos de controle com a estatística T^2 para o monitoramento e detecção de possíveis distúrbios nas imagens podem ser construídos. O processo será detalhado no item a seguir.

2.2. Processamento Digital de imagem

As imagens utilizadas no artigo estão no modelo RGB (*Red, Green, Blue*), onde cada cor aparece em seus componentes espectrais primários em tons de vermelho, verde e azul, sendo baseado no sistema de coordenadas cartesianas. Assim, cada imagem apresenta três bandas, uma para cada cor primária e a combinação dessas cores primárias formam as imagens em cores compostas.



Como descrito anteriormente, um passo importante para a construção do modelo PCA é a transformação dos dados originais da imagem numa matriz bidimensional. O desenvolvimento do processo pode ser visto em [Prats-Montalbán et al.2011], [Prats-Montalbán e Ferrer 2014]. A estrutura dos dados originais das imagens utilizadas são dispostas em tensores tridimensionais (generalização do conceito de matriz), pois apresentam uma camada para cada uma das três bandas de cor. Após a transformação passa-se a trabalhar com uma matriz bidimensional, condição necessária para aplicação das componentes principais, ou seja, os pixels da imagem ficam dispostos em um vetor de apenas uma banda.

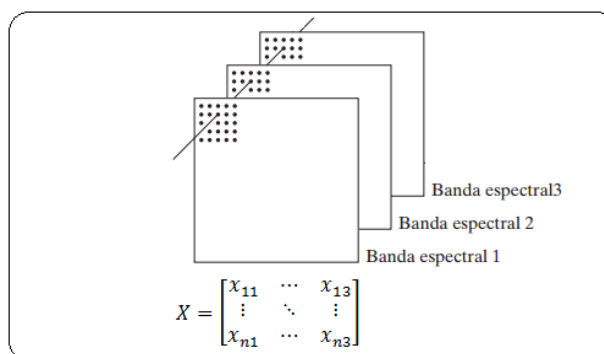


Figura 1: Imagem RGB (3 bandas de cor) com a matriz transformada, n pixels e 3 colunas.

O processo consiste, então, em transformar o cubo numa matriz de duas dimensões, ou seja, os eixos relativos à localização são agregados formando um vetor para cada pixel nas linhas e este é cruzado com o número de bandas nas colunas. Assim, a reorganização da imagem leva a formação de um vetor de três elementos para cada conjunto de pixels correspondentes nas imagens, como pode ser visto na Figura 1 desenvolvida em [Gonzalez e Woods 1992].

2.3. Análise de Componentes Principais

Devido à grande combinação de pixels numa imagem, independentemente das escalas de cores, uma técnica muito utilizada na MIA é a Análise de Componentes Principais (PCA). O objetivo deste método é comprimir dados altamente correlacionados e projetá-los num subespaço de dimensões reduzidas através de combinações lineares dos dados originais [Bharati e MacGregor 1998]. Dessa forma, a estrutura de variância e covariância de um vetor aleatório, composto de p-variáveis aleatórias, serão explicadas a partir das combinações lineares das variáveis originais. Tais combinações são chamadas de componentes principais, também chamadas de variáveis latentes, visto que não podem ser medidas diretamente. Além disso, essas componentes são não correlacionadas entre si.

Ao gerar o modelo PCA, o número de componentes principais será igual ao número de variáveis originais, e tais componentes serão arranjadas por ordem decrescente do seu poder de explicação em relação à variância ou covariância total. A qualidade da aproximação pode ser medida através da avaliação da proporção da variância total explicada por essas combinações. Além disso, a variabilidade do vetor aleatório com a p variáveis originais é aproximado com a variabilidade do vetor aleatório que contém as k componentes principais. Maiores informações e variedades de exemplos podem ser encontrados em [Vines 2000] e [Jackson 2003].

A vantagem deste método é selecionar as primeiras componentes e dado seu alto grau de explicação, reduzir a dimensão da matriz dos dados fazendo com que poucas componentes expliquem grande parte da variabilidade dos dados originais [Mingoti 2005]. Assim, pode-se utilizar, por exemplo, somente 2 ou 3 componentes, ao invés das 25 variáveis originais obtidas de uma imagem. A técnica PCA será aplicada a todas as imagens envolvidas no estudo.



O modelo PCA é descrito por [Mingoti 2005] como:

$$Y_j = a_j'X \quad \text{Equação 1}$$

Onde X é a matriz de dados originais, j é o número de componentes principais do modelo PCA, a_j' é o vetor corresponde aos coeficientes das combinações lineares e Y o vetor correspondente às combinações lineares das variáveis aleatórias do vetor X .

Cada autovalor λ_j (cada componente tem um valor diferente) obtido a partir da matriz de covariância representa a variância de uma componente principal de Y_j . Como há uma ordenação dos autovalores em ordem decrescente, a primeira componente é responsável pela maior variabilidade e a j -ésima a de menor. Assim, a proporção de variância total que é explicada pela j -ésima componente pode ser dada por

$$\frac{\text{Var}(Y_j)}{\text{Var total de } X} = \frac{\lambda_j}{\sum_{i=1}^j \lambda_i} \quad \text{Equação 2}$$

Com isso, espera-se que a quantidade de informação contida nas j componentes seja tão alta quanto às contidas nas p variáveis originais, reduzindo assim a dimensão das imagens analisadas.

2.4. Controle Estatístico de Processo

Para estabelecer o modelo de controle estatístico de qualidade, primeiramente é necessário identificar as imagens consideradas ideais, sem imperfeições ou anomalias. A partir dessas imagens consideradas perfeitas são determinados os limites de controle, que serão adicionadas aos gráficos de controle das imagens com algum tipo de perturbação (mina e/ou outros objetos).

Em relação às estatísticas de controle, as aplicações mais comumente utilizadas convergem ao uso da estatística de T^2 de Hotelling (conhecida como estatística de Hotelling). Ferramenta muito utilizada junto do modelo PCA, pois consegue medir o quão distante as observações estão em relação ao centro do espaço de variáveis latentes. A T^2 é obtida da seguinte forma [Montgomery 2004]:

$$T^2 = (X_i - \bar{X}) S^{-1} (X_i - \bar{X}) \quad \text{Equação 3}$$

onde os pixels de cada banda são representados por X_i , \bar{X} é a média dos pixels de cada banda e S^{-1} é a matriz de covariância amostral. Os limites superiores de controle são dados por:

$$\text{LSC} = \frac{(m-1)^2}{m} B \left(1 - \frac{\alpha}{2}, \frac{p}{2}, \frac{(m-p-1)}{2} \right) \quad \text{Equação 4}$$

em que p representa o número de bandas, m o número total de pixels, α o nível de significância e B indicam os quantis correspondentes à distribuição Beta. O nível $(1 - \alpha)$ de confiança adotado foi de 95%. A partir desta estatística gráficos de controles serão construídos com seus respectivos limites para o caso das imagens em controle. Em seguida, tal limite será adicionado às imagens com a inserção de alguns objetos e espera-se que haja uma quantidade maior de pixel acima do LSC, o que significa dizer que as componentes estão captando bem esses objetos. Já o limite inferior de controle (LIC) é definido como zero. Para [Mason et. al 1992] isto ocorre porque qualquer mudança na média leva a um aumento na estatística T^2 e assim o LIC pode ser ignorado.

Alguns exemplos da aplicação destes gráficos podem ser vistos em [Prats-Montalbán et al. 2011], [Kruse et al. 2014] e [Prats-Montalbán e Ferrer 2014].



3. Metodologia

O experimento consistiu em captar imagens IR (infravermelho) de uma caixa preenchida com areia para diferentes temperaturas. Para medição do contraste térmico no experimento foi utilizada uma câmera de imagem térmica da série T da FLIR. A experimentação foi toda realizada em laboratório com o objetivo de haver um melhor controle dos parâmetros e ter agilidade nos resultados.

As temperaturas foram controladas através de aquecimento por lâmpada ultravioleta. A mesma foi posicionada a 30 cm da caixa na vertical. A lâmpada aquecia a areia até que alcançasse temperatura de 40° C e depois era desligada (Figura 2), o experimento terminava assim que a temperatura decaísse para 28°C. Para acompanhar a temperatura foram usados dois medidores. O primeiro foi um termômetro simples de mercúrio colocado dentro da caixa e o segundo através da medida do sensor térmico da câmera. Ambas as medições de temperatura foram muito semelhantes. Conforme ocorria o esfriamento, as imagens eram captadas. As imagens foram captadas conforme a temperatura decrescia 4°C.

A mina utilizada é o modelo M 409 -*Training & Practice* (material plástico) usada pelas forças armadas brasileiras com finalidade antipessoal, conforme pode ser vista na Figura 3. É uma das minas terrestres mais produzidas e deve ser enterrada a no máximo três centímetros do solo para que possa ser ativada. Sua explosão inicia-se quando alguém pisa no prato de pressão e aciona involuntariamente o detonador. No experimento, a mina foi enterrada na caixa a 2 cm de profundidade.




Figura 2: Foto real da mina utilizada.



Figura 3: Realização do experimento.

Alguns objetos, além da mina, foram incorporados ao experimento para simular as assinaturas de objetos termais semelhantes. Os objetos foram: Pedra, clipe e moeda (ver Figura 5).



Figura 4: Apenas mina na caixa.



Figura 5: Objetos inseridos junto da mina.

As etapas do experimento foram divididas em três partes, todos com o objetivo de simular a ausência ou presença de objetos enterrados. As etapas são descritas da seguinte forma:



- Etapa 1: Ausência de objetos e somente areia (imagem perfeita, sem perturbação, usada como controle);
- Etapa 2: Presença da mina somente na caixa (Figura 4);
- Etapa 3: Inserção de objetos (pedra, clipe e moeda) junto à mina na caixa (Figura 5).

Após a obtenção de todas essas imagens foram utilizados conjuntamente os *softwares* Matlab e R para a construção das componentes principais e o cálculo da estatística T^2 de Hotelling. Então, primeiramente o modelo de componentes principais foi elaborado para a Etapa 1 a fim de verificar se o processo estava realmente em controle. Dado que o processo estava em controle, construiu-se os modelos para a Etapa 2 e Etapa 3 e em seguida, com as componentes foi possível analisar a assinatura térmica da mina individualmente e posteriormente em conjunto com outros objetos.

4. Resultados

Após a realização de todas as etapas do experimento as imagens nas faixas de temperatura estudadas (28°C, 32°C, 36°C, 40°C) puderam ser obtidas, como pode ser visto na Figura 6. As diferenças de coloração são devido às diferenças de temperatura entre os pixels e a régua de temperatura (vide Figura 7) fornece as faixas alcançadas, com azul para valores menores e tons claros para temperaturas mais altas.




Figura 6: Imagens originais obtidas com a câmera infravermelho.

A Etapa 1 é composta apenas pela areia e apresenta imagens como uma grande massa uniforme, variando pouco conforme o aumento de temperatura. Na temperatura mais baixa o tom avermelhado cobre quase toda a imagem, e conforme o aumento de temperatura começam a surgir alguns pontos com tons mais claros, como pode ser visto nas imagens da primeira linha da Figura 6. Ao adicionar a mina (Etapa 2 - Figura 6) é possível perceber algumas diferenças nas imagens em relação à Etapa 1, mesmo nas temperaturas mais altas. Mas com o decréscimo de temperatura a mina torna-se cada vez mais branca. A 40°C tanto a mina quanto a areia estão quentes logo há menos diferenças visuais em termos de comparação. Ou seja, dada a diferença de condutividade térmica entre a areia seca e a mina (composição de PVC), esta última absorve melhor a temperatura e é capturada na imagem conforme a temperatura diminui.



Na Etapa 3 tem-se outros objetos adicionados a imagem, porém nem todos são captados pela imagem infravermelha. Na verdade, somente a pedra e a mina podem ser identificadas visualmente, já que a moeda e o clipe de metal não foram captados. A mina continua bem distinguível (mancha mais branca na parte superior esquerda) com uma temperatura mais alta e a pedra com uma temperatura mais baixa passa também a ser identificada (parte inferior esquerda).



Figura 7: Régua de Temperatura.

A partir das imagens da Figura 6 o modelo de componentes principais e os limites superiores de controle (nível $\alpha = 5\%$) puderam ser construídos. Assim, para cada temperatura foi desenvolvido um modelo diferente. Apesar de todas as imagens terem sido analisadas apenas a de temperatura de 32°C foi adicionada ao artigo como exemplo. A Figura 8 mostra as imagens das três componentes principais obtidas.




Figura 8: Modelo de Componentes Principais para todos os objetos ($T = 32^{\circ}\text{C}$).

A primeira componente principal (CP1) é a de maior explicação e a partir dela parece ser fácil a identificação de cada etapa. Na areia a CP1 explica grande parte da variabilidade, seguida por valores baixos de CP2 e CP3. Com a inclusão da mina a CP1 aumenta ainda mais seus valores e apresenta baixos valores de CP2 e CP3, mostrando que a mina está sendo explicada grande parte pela primeira componente. Já a Etapa 3 (mina e objetos) tem valores menores para CP1, um valor maior de CP2 e pequeno valor de CP3. Nesse caso a variabilidade é melhor explicada considerando as duas primeiras componentes. Isso ocorreu para todas as opções de temperatura estudadas. O Quadro 1 mostra tais resultados, como efeito de exemplificação, para o caso da temperatura $T = 32^{\circ}\text{C}$. A Figura 8 corrobora os valores das CP's, pois visualmente é perceptível a massa uniforme na areia, a mina na primeira e a pedra na segunda componente.



Itens\ CP's (%)	CP1	CP2	CP3
Areia	83.80	14.50	1.70
Mina	93.00	6.70	0.30
Mina e objetos	84.20	14.80	1.00

Quadro 1: Explicação das Componentes (%) para cada etapa do experimento em T=32°C.

Uma das características mais importantes das componentes principais na análise multivariada de imagem é a redução do armazenamento da imagem, já que uma parcela significativa da variabilidade está contida na CP1 e diminui drasticamente a partir das demais. O motivo é devido aos autovalores, já que indicam as variabilidades em termos de contraste de cada uma das bandas da imagem. Assim, imagens formadas a partir das componentes do vetor correspondente aos maiores autovalores apresentem o maior contraste. Logo, devido a grande explicação da CP1 pode-se manter somente a principal componente da imagem o que reduz significativamente a espaço de armazenamento e/ou transmissão.

Após a construção e análise das componentes o passo seguinte é analisar o T² Hotelling para os pixels e tentar identificar diferenças entre as imagens. O Quadro2 apresenta o resultado da porcentagem dos valores de T² acima do limite superior de controle (LSC) para cada temperatura e etapa de coleta das imagens.

Itens\T (°C)	28	32	36	40
Areia	0.048	0.067	0.058	0.031
Mina	6.094	3.855	6.490	3.675
Mina e objetos	9.3369	10.987	9.563	10.590

Quadro 2: T² Hotelling (%) acima do LSC para os elementos da imagem.

Sabe-se que pela teoria dos gráficos de controle T², espera-se que ocorra em torno de 1 descontrole para cada 90 pontos analisados, ou seja, 1% de pontos fora de controle. Sendo assim, percebe-se pelo Quadro 2, que o valor baixo do T² para areia para cada temperatura se encontra realmente em controle. Ao adicionar a mina o valor da estatística se eleva, já que há um número maior de pixels acima do LSC, o mesmo ocorrendo quando se coloca outros objetos. Para se observar isto, basta verificar o valor do T² no Quadro 2. Gráficos de T² que retratam os valores obtidos no Quadro 2 foram construídos para cada temperatura, como exemplificação apenas T=32°C será mostrado.

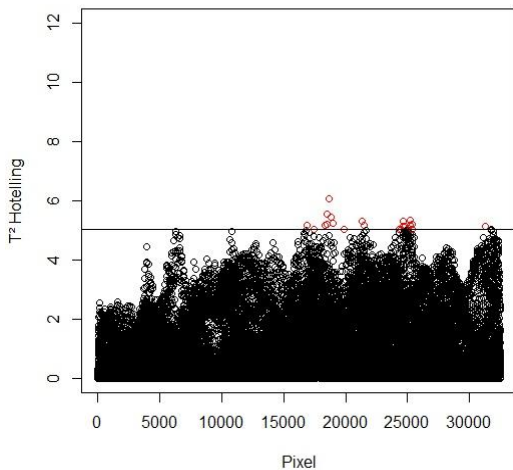


Figura 9: T² Hotelling – Etapa 1 (T=32°C).




Figura 10: T² Hotelling – Etapa 2 (T=32°C).

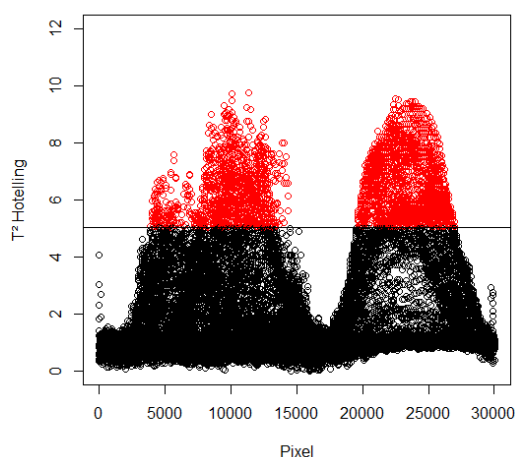


Figura 11: T^2 Hotelling – Etapa 3 ($T=32^\circ\text{C}$).

Pelo resultado das Figuras 9-11 percebe-se a diferença no valor do T^2 encontrado. Na Etapa 1 (caso controle) os pixels apresentam quase a totalidade dentro do limite de controle. Já ao adicionar a mina (Etapa 2), a estatística de Hotelling consegue captar sua inserção, pois muitos pontos ultrapassam o LSC. Na Etapa 3, além da mina, o T^2 capta também a inserção da pedra, conforme pode-se verificar na Figura 11. Além disso, outro fato interessante é que o T^2 reflete bem a posição dos elementos dentro da caixa, com a mina do lado esquerdo e a pedra do lado direito.

5. Conclusão

A partir do estudo da técnica de análise multivariada de imagens foi possível construir modelos utilizando análise de componentes principais para a detecção das minas terrestres. A elaboração do experimento foi realizada na comparação do terreno em três etapas, primeiramente somente com areia (controle) e depois adicionando uma mina terrestre e demais objetos (pedra, clipe e moeda). Em seguida, os modelos das componentes baseado nas imagens controle foram construídos. Os resultados apontaram para uma grande explicação da primeira componente, responsável por praticamente toda a variabilidade das imagens. Isso é um bom indicativo de que as imagens podem ser reduzidas para esta nova dimensão, reduzindo tempo e custo de processamento.

Em seguida, limites de controle foram construídos para o gráfico T^2 e os valores dessa estatística foram obtidos para cada uma das etapas, sendo observado que a quantidade de pixels acima do LSC aumenta à medida que novos objetos são inseridos ao sistema. Assim, para o caso do experimento considerando somente a areia o valor do número de pontos fora de controle do gráfico T^2 foi baixo, visto que não há nenhuma perturbação no sistema, e, portanto, diz-se que o processo está em controle. Entretanto, ao adicionar a mina o número de descontroles aumenta significativamente e esse número se eleva ainda mais com a inserção dos demais objetos. Além disso, foi observado que o gráfico T^2 (Fig. 11) consegue captar os diferentes objetos.

Por fim, verifica-se também que os resultados apontam para uma melhor identificação dos objetos à medida que a temperatura diminui, uma consequência direta da diferença de condutividade térmica entre os elementos da imagem.

Adicionalmente, pode-se pensar em trilhar diversos caminhos futuros. Uma possibilidade seria a de criar um sistema de monitoramento online de imagens, pois com a redução dimensional e otimização no processamento dos dados, consegue-se criar processos automatizados que ampliam e agilizam o processo de monitoramento, gerando estatísticas instantaneamente. Outra possibilidade é a de construir outras estatísticas para identificação dos objetos na imagem ou desenvolver uma análise da forma dos objetos, criando uma assinatura para os diversos objetos na imagem.



6. Referências bibliográficas

- Bharati, M. and MacGregor, J. (1998). Multivariate image analysis for real-time process monitoring and control. *Industrial & Engineering Chemistry Research*, 37(12):4715{4724}.
- Crósta, A. P. (1993). *Processamento Digital de Imagens de Sensoriamento Remoto*. Ed. Rev. - Campinas, SP: IG/UNICAMP.
- DePersia, A. T, A, Bowman, P, Lucey, and E, M. Winter(1995). Phenomenology considerations for hyperspectral mine detection, *Proceedings of SPIE*, 2496:159-167.
- Duchesne C, Liu J. J, MacGregor J. F. (2012). Multivariate image analysis in the process industries: a review. *Chemom Intell Lab Syst*;117(1):116–28.
- Geladi P, Grahn H. (1996). *Multivariate image analysis*. Chichester, England: Wiley.
- Gonzalez, R. C.; Woods, R. E. (1992). *Digital image processing*. Reading, MA: Addison-Wesley.
- Hameed, I, A. (2016). Motion planning for autonomous landmine detection and clearance robots. *Engineering and Natural Sciences*, Norwegian University of Science and Technology NTNU in Alesund, Postboks 1517, NO-6025 Ålesund, Norway.
- Hong, S., Miller, T., Tobin, H., Borchers, B., Hendrickx, J. M., Lensen, H.A., Schwering, P. B., Baertlein, B. A. (2001). Impact of soil water content on landmine detection using radar and thermal infrared sensors. *Proc. SPIE*, 4394:409 – 416.
- Jackson JE. (2003). *A user's guide to principal components*. New York: Wiley.
- Janssen, Y. H. L, Jong, A.N, Winkel, H. and Putten, F.J.M.V (1996). Detection of surface laid and buried mines with IR and CCD cameras, an evaluation based on measurements. In A. C. Dubey, R. L. Barnard, and C. J. Lowe, editors, *Proc. SPIE Vol. 2765*. Orlando (FL), USA.
- Kruse, O. M. O., Prats-Montalbn, J. M., Indahl, U. G., Kvaal, K., Ferrer, A., and Futsaether, C. M. (2014). Pixel classification methods for identifying and quantifying leaf surface injury from digital images. *Computers and Electronics in Agriculture*, 108:155{165}.
- Landmine Monitor (2015). *International Campaign to Ban Landmines-Cluster Munition Coalition(ICBL-CMC)*. ISBN:978-2-8399-1707-0. http://www.themonitor.org/media/2152583/Land_mine-Monitor-2015_finalpdf.pdf. Acessado em 09/06/2017.
- Lopez P., H. Sahli, D. L. Vilarino, and D. Cabello (2003). Detection of Perturbations in Thermal IR Signatures: An Inverse Problem for Buried Landmine Detection. Brussels, Belgium. Available at http://www.clearfast.vub.ac.be/publications_files/Lopez_spie_2003.pdf
- Macdonald, J., Lockwood, J. R. (2003). *Alternatives for Landmine Detection*. RAND.
- Mason, R. L.; Tracy, N. D.; Young, J. C. (1992). Multivariate control charts for individual observations. *Journal of Quality Technology*, v. 24, n.2, p. 88-95.
- Mende, H., Dej, B., Khanna, S., Apps, R., Boyle, M., Addison, F. (2004). Microwave enhanced IR detection of landmines using 915 MHz and 2450 MHz. *Defence Research Reports*, no.drdc-ottawa-tm-2004-266. Ottawa (Canada): Defence R&D.



- Messelink, W. A. C. M., Schutte, K., Vossepoel M. A., Cremer F., Schavemaker J. G. M (2002). Feature-based detection of land mines in infrared images. Proc. SPIE 4742, Detection and Remediation Technologies for Mines and Minelike Targets VII, 108.
- Mingoti, S. A. (2005). Análise de dados através de métodos de estatística multivariada: uma abordagem aplicada. Editora UFMG.
- Montgomery, D. C. (2004). Introdução ao Controle Estatístico da Qualidade. 4 ed. Rio de Janeiro: LTC – Livros Técnicos e Científicos Editora S.A.
- Nações Unidas (2014). Web page:<<https://nacoesunidas.org/onu-10-pessoas-morrem-ou-ficam-mutiladas-por-dia-no-mundo-devido-as-minas-terrestres/>>. Acesso: 21 de março de 2017.
- Prats-Montalbán JM, Ferrer A, de Juan A. (2011). Multivariate Image Analysis: a review with applications. Chemom Intell Lab Syst;107:1–23.
- Prats-Montalbán, J. M. and Ferrer, A. (2014). Statistical process control based on multivariate image analysis: A new proposal for monitoring and defect detection. Computers & Chemical Engineering, 71:501{511}.
- Sendur I, K, and Baertlein A, B. (1999). Techniques for improving buried mine detection in thermal IR imagery, Proc. SPIE 3710, Detection and Remediation Technologies for Mines and Minelike Targets IV, 1272; doi:10.1117/12.357009.
- Song, X., Su, J., Huang, M., Lu, S. and Zhu, P. (2016). Landmine detection with holographic radar, Ground Penetrating Radar (GPR) 16th International Conference on, pp. 1-4, 2016.
- Simunek, J., Hendrickx, J. M. H, and Borchere, B.(2001).Modeling transient temperature distributions around landmines in homogeneous bare soils.Proc. ofSPIE, This Volume, Detection and Remediation Technologies for Mines and Minelike Targets IV.
- Szymanik, B. (2014). Inverse Problem Solution in Landmines Detection Based on Active Thermography. Radioengineering.
- Vines, S. K. (2000). Simple principal components. Appl. Stat. 49, 441 – 451.
- Watson, K. (1975). Geological application of thermal infrared images. Proc. IEEE, vol. 63, pp. 128–137.
- Wise, B. M. and Geladi, P. (2000). A brief introduction to multivariate image analysis (MIA).Eigenvector Research.
- Zea, Q., and Cardenas M. (2013). RASCAN Type Radar Image Resolution Enhancement for Non-metallic Landmine Detection, XVIII Symposium of Image Signal Processing and Artificial Vision, pp. 1-4.