



Ministério da Ciência, Tecnologia e Inovação
Instituto Nacional de Pesquisas Espaciais
São José dos Campos
Mestrado em Sensoriamento Remoto

Classificações Multifontes de Imagens de Sensoriamento Remoto baseada em Mapas de Incertezas

Bolsista: Bruna Cristina Braga

Orientador: *Dr.* Sidnei J. S. Sant'Anna

Monografia apresentada na disciplina de introdução
à Geoprocessamento ministrada pelo *Dr.* Antônio
Miguel Vieira Monteiro

São José dos Campos

Junho de 2014

Resumo

Este trabalho tem como objetivo modelar incertezas associadas a cenários oriundos de classificações individuais de fontes distintas. Os dados selecionados para o trabalho proposto contemplam imagens óticas e de micro-ondas que foram classificadas a partir de um classificador por regiões com base em distâncias estocásticas e seus testes de hipótese associados. O classificador além de originar a imagem classificada gera um mapa de incerteza que indica os segmentos para os quais a hipótese nula do teste não foi rejeitada ao nível de significância de 5%. Ao final do processo de classificação utilizam-se os resultados para criação de cinco cenários que servirão como base para a modelagem proposta. A estrutura deste relatório consta de um capítulo para introdução onde apresenta-se a caracterização do problema e principais objetivos. O segundo capítulo descreve a fundamentação teórica necessária para compreensão do trabalho em questão. O capítulo três apresenta uma visão geral da área em estudo e posteriormente o capítulo quatro descreve os materiais e métodos adotados. No quinto capítulo os resultados são apresentados e discutidos para finalmente as conclusões obtidas serem delineadas no capítulo seis.

Sumário

1	Introdução	2
1.1	Caracterização do Problema	2
1.2	Objetivos e Metas	2
2	Fundamentação Teórica	3
2.1	Classificação de imagens	3
2.1.1	Avaliação da classificação	5
3	Área em Estudo	7
4	Material e Métodos	8
4.1	Material	8
4.1.1	Imagens utilizadas	8
4.1.2	Programa Barreto	8
4.2	Métodos	9
4.2.1	Cenário I	10
4.2.2	Cenário II	10
4.2.3	Cenário III	10
4.2.4	Cenário IV	10
4.2.5	Cenário V	10
5	Resultados e discussões	11
6	Conclusões	22
	Referências Bibliográficas	24

Capítulo 1

Introdução

1.1 Caracterização do Problema

A necessidade de se conhecer, mapear e monitorar, tanto os recursos naturais como as migrações internas da população, visando uma ocupação mais controlada de seu território e a utilização de seus recursos de forma mais racional, tem incentivado a execução de projetos de levantamento e mapeamento da superfície terrestre (COUTINHO, 1997). Recentes avanços nas áreas de Sensoriamento Remoto e do Geoprocessamento, lançaram no mercado diversas ferramentas para execução dessa tarefa, entre elas, a classificação de imagens provindas de satélites que possibilitam um nível de percepção mais global.

Embora a experiência com imagens obtidas por meio de sensores ópticos seja maior, imagens de micro-ondas vêm sendo intensamente utilizadas devido a sua independência em relação a fonte de iluminação e condições climáticas. A união das informações obtidas por ambas as fontes pode gerar cenários mais representativos da realidade. (SILVA, 2013) desenvolveu um classificador de imagens por regiões utilizando testes de hipótese baseados em distâncias estocásticas. O programa recebe como dados de entrada a imagem original, uma segmentação da imagem original e as respectivas amostras de teste e treinamento e retorna a classificação por regiões da imagem original juntamente com um mapa correspondente à incerteza da classificação.

1.2 Objetivos e Metas

Neste projeto pretende-se gerar produtos oriundos de classificações individuais de fontes distintas visando a modelagem de suas respectivas incertezas. Serão utilizadas duas imagens, ALOS/PALSAR e LANDSAT5/TM, relativas à parte da Floresta Nacional do Tapajós (FLONA) e arredores. Esta área se localiza na Amazônia brasileira, abrangendo parte do município de Belterra, no estado do Pará, mesorregião do Baixo Amazonas (REIS, 2014). Por meio do programa desenvolvido por (SILVA, 2013), serão geradas as respectivas classificações e mapas de incertezas de ambas as imagens e a partir destas serão gerados novos cenários de forma a mesclar as informações obtidas pelas classificações individuais. No total serão gerados cinco cenários sendo os dois primeiros obtidos a partir do programa inicial e as três posteriores serão geradas a partir das incertezas correspondentes à essas classificações. Após a obtenção dos resultados será feita uma análise comparativa entre os cenários gerados e suas respectivas incertezas.

Capítulo 2

Fundamentação Teórica

Esse capítulo tem como objetivo apresentar brevemente os conceitos fundamentais para compreensão do trabalho desenvolvido. A abordagem da teoria é feita de maneira breve uma vez que o aprofundamento nos temas em questão não é o objetivo principal deste relatório.

2.1 Classificação de imagens

O sensoriamento remoto tem como um dos seus principais objetivos a extração das informações contidas nas imagens e a sua codificação em documentos que possam ser lidos nas formas de tabelas, gráficos ou mapas. A necessidade de automatizar o processo de extração de informações das imagens eliminando a subjetividade da interpretação humana e reduzindo o esforço de trabalho analista deu origem às técnicas de classificação digital de imagens. O resultado final de uma classificação é um mapa digital temático, isto é, um mapa de pixels classificados, representados por símbolos, gráficos ou cores (MENESES, 2012).

Os diversos métodos de classificação em uso podem ser divididos segundo diferentes critérios, entre eles, classificação supervisionada ou não-supervisionada e classificação por pixel ou por região. A maioria dos classificadores executa a classificação por pixel, que se utiliza somente da informação espectral de cada pixel para encontrar regiões homogêneas, a partir de medidas de distâncias ou de probabilidade de um pixel pertencer a uma classe específica. Na classificação por regiões o processo de decisão leva em consideração um agrupamento de pixels que é usado como unidade de classificação.

A classificação por região exige a utilização de imagens segmentadas, em que os pixels da imagem estejam agrupados em conjuntos homogêneos (regiões) segundo algum critério. Uma das mais clássicas abordagens empregadas na classificação por regiões utiliza distâncias estocásticas entre as distribuições estatísticas que modelam regiões pré-segmentadas nas imagens e as distribuições que modelam as amostras de treinamento, representantes das classes.

Ao contrário da classificação não-supervisionada, a classificação supervisionada requer conhecimentos prévios das classes de alvos, a fim de classificar a imagem nas classes de interesse pré-fixadas. Há vários métodos de classificação supervisionada, entre eles, a máxima verossimilhança. O classificador por máxima verossimilhança considera a ponderação das distâncias entre as médias dos valores dos pixels das classes, utilizando parâmetros estatísticos. Assume que todas as bandas têm distribuição normal e calcula a probabilidade de um dado pixel pertencer a uma classe específica. Nesta classificação cada pixel é destinado à classe que tem a mais alta probabilidade, isto é, a máxima verossimilhança. Neste trabalho foi utilizado um classificador supervisionado por regiões desenvolvido por (SILVA, 2013).

Uma das possíveis soluções a serem utilizadas na classificação por regiões, especialmente sob o viés de classificação por modelagem estatística, consiste na utilização de distâncias estocásticas. Neste

caso, a atribuição de determinada classe a cada segmento se dá pela menor distância estocástica entre o modelo estatístico que representa o conjunto de pixels contidos no segmento em questão e o que representa o conjunto de pixels nas amostras de treinamento, para o caso da classificação por regiões supervisionada. A utilização das estatísticas derivadas das distâncias e suas distribuições assintóticas, pode representar uma melhoria ao processo de classificação por regiões, por permitir obter um indicativo de confiabilidade da classificação de cada segmento da imagem, através da informação do p valor de cada teste de hipótese.

Com base no desenvolvimento analítico formal proposto por (SALICRU et al., 1994), que possibilitou a derivação de expressões para diversas distâncias estocásticas, obtém-se a estatística de teste de hipótese s_ϕ^h , conforme a equação a seguir:

$$s_\phi^h(\theta_1, \theta_2) = \frac{2mnv}{m+n} d_\phi^h(\theta_1, \theta_2),$$

em que $\theta_1 = (\theta_{11}, \dots, \theta_{1M})$ e $\theta_2 = (\theta_{21}, \dots, \theta_{2M})$ são os estimadores de máxima verossimilhança de θ_1 e θ_2 com M parâmetros, baseados em amostras independentes de tamanhos m e n .

Obedecendo determinadas condições de regularidade, se $m, n \rightarrow \infty$, e $\theta_1 = \theta_2$, então

$$\frac{2mnv}{m+n} d_\phi^h(\theta_1, \theta_2) \xrightarrow{\mathcal{D}} \chi_M^2,$$

em que $\xrightarrow{\mathcal{D}}$ denota convergência em distribuição e χ_M^2 é a distribuição Qui-quadrado com M graus de liberdade, que corresponde ao número de parâmetros em θ_i para algum i .

Para valores suficientemente grandes de m e n , a hipótese nula ($H_0 : \theta_1 = \theta_2$) pode ser rejeitada ao nível de significância η se $Pr(\chi_M^2 > s) \leq \eta$.

O nível de significância é um valor real positivo que indica a porcentagem de pixels da distribuição de probabilidade de uma classe que será classificada como pertencente a essa classe.

Suponha uma imagem com r segmentos disjuntos C_1, \dots, C_r . Para cada segmento C_i , com $1 \leq i \leq r$, os vetores de parâmetros θ_i são estimados pelo método de máxima verossimilhança. A classificação ocorre de forma supervisionada. O usuário seleciona k classes de interesse em forma de amostras, com as quais estimam-se por máxima verossimilhança os parâmetros θ_ℓ , $1 \leq \ell \leq k$.

São computadas $r \times k$ estatísticas de teste para verificação da hipótese nula $H_0 : \theta_i = \theta_\ell$ para cada segmento $1 \leq i \leq r$ e cada classe $1 \leq \ell \leq k$.

A classificação com base na mínima estatística de teste consiste em atribuir ao segmento C_i a t -ésima classe se

$$S_\phi^h(\theta_i, \theta_t) < S_\phi^h(\theta_i, \theta_\ell)$$

$\forall t \neq \ell$. Uma vez que o segmento C_i foi rotulado com a classe t , o p -valor do teste de hipóteses é calculado por

$$p_{i,t} = \Pr(\chi_\nu^2 > s_\phi^h(\theta_i, \theta_t))$$

em que ν corresponde ao número de parâmetros do modelo estatístico considerado: $\nu = q^2$ para o caso da distribuição Wishart, $\nu = q(q+3)/2$ para a distribuição Gaussiana multivariada com q variáveis e $\nu = 2$ para a distribuição par de intensidades. O p -valor fornece um indicativo de confiabilidade da decisão. A partir da obtenção dos p -valores para cada segmento classificado, é gerado um mapa em que se mostra, para cada segmento, uma tonalidade de cinza correspondente ao p -valor calculado no teste de hipótese. Esse mapa apresenta visualmente portanto um indicativo de confiabilidade da classificação obtida para certa imagem. Além disso, adotando-se um determinado nível de significância, como por exemplo 5%, obtém-se um novo produto que indica os segmentos cuja hipótese nula não foi rejeitada ao nível de confiança considerado. Este produto pode ser tomado como indicativo da qualidade da classificação (SILVA, 2013).

2.1.1 Avaliação da classificação

Uma das últimas etapas da classificação digital de imagens é a da validação dos resultados da classificação. Nessa etapa é avaliada a acurácia da classificação. Um resultado com 100% de acurácia significa que todos os pixels da imagem foram classificados de forma correta, segundo um conjunto de dados que compõe a *verdade de campo*. A acurácia normalmente é expressa em termos de índices que são calculados a partir da chamada matriz de confusão. Tais índices expressam a concordância entre a imagem classificada e o conjunto de amostras de referência. A matriz de confusão compara classe por classe a relação entre os dados de referência e os correspondentes resultados da classificação. O número de linhas e colunas dessa matriz devem ser iguais ao número de classes espectrais do estudo. Erros de omissão (exclusão) e de comissão (inclusão) de cada classe são calculados a partir dessa matriz. Os valores da diagonal principal da matriz quadrada correspondem ao número de pixels que foram corretamente classificados.

Uma matriz de confusão genérica é representada na Tabela 2.1, onde, para uma dada classe C_i , a quantidade n_{ij} representa o “número de amostras” classificadas na classe i , sendo que são ocorrências da classe j , n_{i+} e n_{+i} representam respectivamente as proporções marginais com relação a coluna (referência) i e linha (classificação) i , e N o número total de amostras.

Tabela 2.1: Matriz de Confusão (SILVA, 2013).

		Referência				
		C_1	C_2	\dots	C_k	
C l a s s	C_1	n_{11}	n_{12}	\dots	n_{1k}	n_{1+}
	C_2	n_{21}	n_{22}	\dots	n_{2k}	n_{2+}
	\vdots	\vdots	\vdots	\ddots	\vdots	\vdots
	C_k	n_{k1}	n_{k2}	\dots	n_{kk}	n_{k+}
		n_{+1}	n_{+2}	\dots	n_{+k}	N

Outras medidas descritivas podem ser obtidas a partir dessa matriz de confusão. Uma delas é a exatidão global (ω), que é obtida dividindo-se o número total de pontos corretamente classificados (soma dos elementos da diagonal principal) pelo número total de pontos de validação.

$$\omega = \frac{1}{N} \cdot \sum_{i=1}^k n_{ii}$$

O índice kappa (κ) é outro método muito utilizado na avaliação dos resultados de classificação. Esse índice varia de 0 (concordância nula) a 1 (concordância perfeita) e é obtido de acordo com a seguinte fórmula:

$$\kappa = \frac{\omega - \tau}{1 - \tau}$$

onde $\tau = \frac{1}{N^2} \cdot \sum_{i=1}^k n_{i+}n_{+i}$.

Um valor de coeficiente de concordância *kappa* (tabela 2.2) é estimado para cada matriz de confusão obtida, consistindo em um valor que representa quão bem a classificação resultante concorda com a classificação dos dados de referência.

Tabela 2.2: Níveis do coeficiente $kappa(\kappa)$ associados a diferentes termos qualitativos.

κ	Qualificação
$\kappa \leq 0$	Péssimo
$0 < \kappa \leq 0,2$	Ruim
$0,2 < \kappa \leq 0,4$	Razoável
$0,4 < \kappa \leq 0,6$	Bom
$0,6 < \kappa \leq 0,8$	Muito Bom
$0,8 < \kappa \leq 1$	Excelente

Outra medida de informação importante de qualidade é a variância amostral do índice kappa ($var(\kappa)$) que é estimada pela seguinte equação:

$$var(\kappa) = \frac{1}{N} \left(\frac{\omega(1-\omega)}{(1-\omega)^2} + \frac{2(1-\omega)(2\omega\tau - \psi)}{(1-\tau)^3} + \frac{(1-\omega)^2(\phi - 4\tau)^2}{(1-\tau)^4} \right)$$

onde $\psi = \frac{1}{N^2} \sum_{i=1}^k n_{ii}(n_{i+} + n_{+i})$ e $\phi = \frac{1}{N^3} \sum_{i=1}^k \sum_{j=1}^k n_{ij}(n_{j+} + n_{+i})$.

Capítulo 3

Área em Estudo

A área em estudo corresponde à parte da Floresta Nacional (Flona) do Tapajós e arredores. Trata-se de uma importante unidade de conservação da natureza localizada na Amazônia brasileira às margens do Rio Tapajós, na região do estado do Pará. A figura 3.1 ilustra a área em estudo assim como seus limites políticos e geográficos acompanhados de uma imagem LANDSAT5/TM em composição colorida 5(R) 4(G) 3(B), adquirida em 29 de junho de 2010.

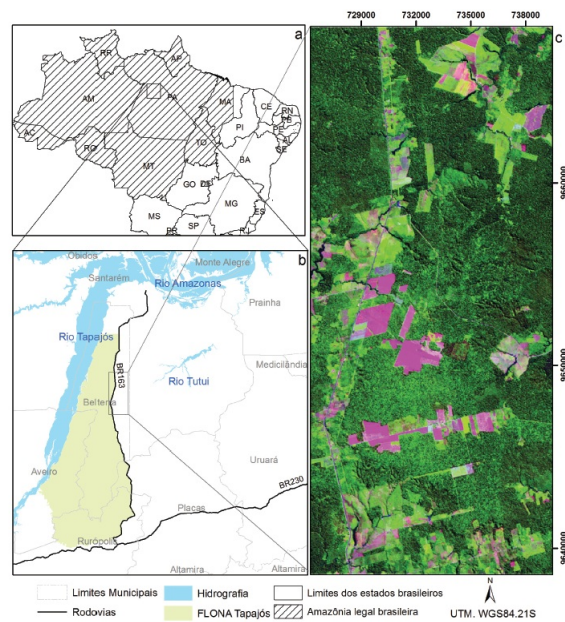


Figura 3.1: Localização da área em estudo. a) localização em relação à Amazônia legal brasileira; b) localização em relação aos limites políticos e geográficos; c) recorte aproximado da área de estudo de Imagem LANDSAT5/TM de 29 de junho de 2010. Fonte:(REIS 2014, em fase de elaboração).

A ocupação desta região começou com a assinatura do Decreto-Lei 1.106 de 16 de junho de 1970. Em decorrência da ocupação, observa-se a presença de mosaicos de vegetação secundária em diversos níveis de desenvolvimento, pastagens e áreas cultivadas inseridas em uma matriz de floresta primária (ARAGÃO, 2004). No exterior da Flona, são encontradas áreas mecanizadas para a produção de grãos, como soja, arroz, milho e sorgo. Existem relatos de atividades de extração de madeira e de minério, caça e pesca nos rios Tapajós e Cupari (ESCADA et al., 2009). Outro fato que chama atenção é a ocorrência de incêndios, causados principalmente pelo uso inadequado do fogo para manejar pastagens e preparar áreas para o plantio (IBAMA, 2004).

Capítulo 4

Material e Métodos

Neste capítulo são descritos os materiais utilizados para o desenvolvimento do projeto assim como a metodologia adotada para sua execução.

4.1 Material

4.1.1 Imagens utilizadas

Os dados selecionados para o trabalho proposto contemplam imagens óticas e de micro-ondas ilustradas na figura 4.1. As imagens são oriundas do sensor *Thematic Mapper (TM)* do satélite LANDSAT5, enquanto as de micro-ondas do sensor *Phase Array L-Band Synthetic Aperture Radar (PALSAR)* do satélite *Advanced Land Observing System (ALOS)*.

As imagens LANDSAT5/TM propostas datam de 23 de junho de 2008 e de 29 de junho de 2010, ambas obtidas do catálogo do INPE (INPE, 2013a). As imagens ALOS/PALSAR datam de 15 de junho de 2008 e de 21 de junho de 2010, escolhidas por serem as datas mais próximas onde havia imagens dos dois sensores disponíveis e em épocas onde se espera que as condições climáticas sejam semelhantes.




Figura 4.1: a) Imagens LANDSAT5/TM de 29 de junho de 2010 em composição colorida 1(R) 2(G) 3(B); b) Imagens ALOS/PALSAR de 21 de junho de 2010 em composição colorida 1(R) 2(G) 3(B).

O produto LANDSAT/TM padrão disponibilizado pelo INPE possui correção radiométrica e correção geométrica de sistema. Ele é disponibilizado no sistema de projeção UTM (Universal Transverse Mercator) e datum WGS84 (World Geodetic System 1984) (INPE, 2013b).

4.1.2 Programa Barreto

A ferramenta base utilizada para execução do trabalho proposto foi o programa para classificação desenvolvido por (SILVA, 2013). Tal programa realiza a classificação de regiões de imagens utilizando testes de hipóteses baseados em distâncias estocásticas. O programa foi desenvolvido na linguagem IDL (Interactive Data Language) e executado no ambiente ENVI (software para visualização e análise de imagens digitais).

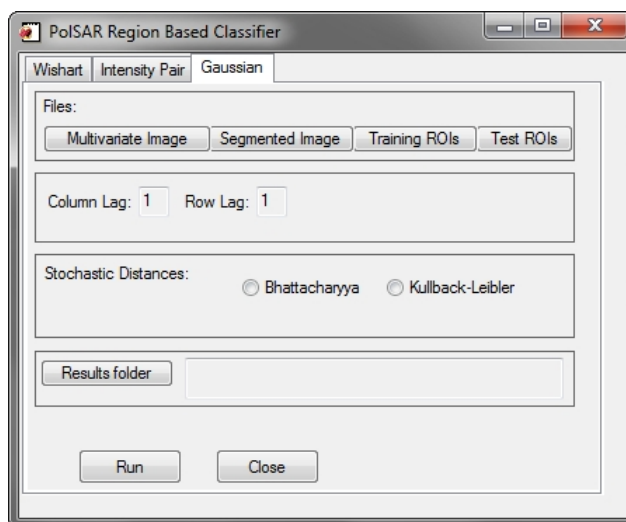


Figura 4.2: Interface Gráfica do classificador por regiões desenvolvido por Silva, 2013.

A figura 4.2 apresenta a interface gráfica do programa que recebe como dados de entrada a imagem original a ser classificada, uma segmentação dessa imagem, uma vez que a classificação é por região, e as amostras de teste e treinamento correspondentes. Após sua execução, o programa retorna a imagem classificada e como diferencial em relação a outros classificadores, retorna também um mapa de incertezas correspondente a classificação final. Esse mapa de incerteza indica os segmentos para os quais a hipótese nula do teste não foi rejeitada ao nível de significância de 5%. A figura 4.3 descreve como ocorre o processo de classificação utilizado para desenvolvimento do classificador.

4.2 Métodos

A metodologia adotada originou cinco diferentes cenários a partir dos resultados individuais das classificações das imagens TM e SAR obtidas pelo programa de (SILVA, 2013), com o intuito de gerar produtos oriundos de classificações individuais de fontes distintas para modelagem de suas respectivas incertezas. Para geração dos cenários utilizou-se o software ENVI, escrito na linguagem IDL.

Inicialmente, os cenários seriam originados com base nos p-valores de cada classificação individual, uma vez que este corresponde à certeza com que cada classificação foi realizada, porém, notou-se que uma porcentagem grande de valores p foram próximos de zero, tornando-se inviável sua utilização no trabalho. Todavia, tanto o valor p quanto a estatística s são indicativos do grau de incerteza (quanto menor o valor p, maior a incerteza, e quanto maior a estatística s, maior a

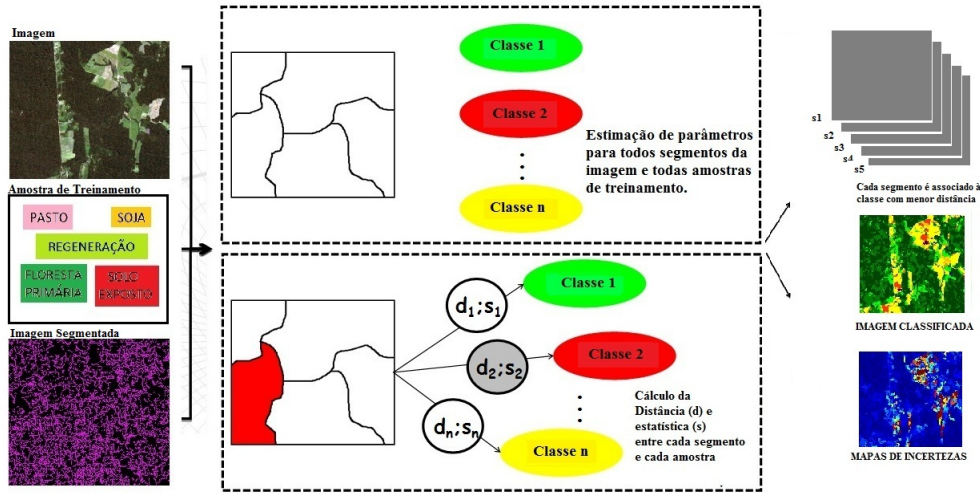


Figura 4.3: Visão geral do processo de classificação utilizado por Silva, 2013.

incerteza). Portanto, decidiu-se calcular o grau de incerteza da classificação através das estatísticas s , por meio da metodologia descrita a seguir. É importante citar o fato de que uma normalização da estatística s foi necessária uma vez que a mesma não trata-se de uma probabilidade. Após tal normalização, embora $s \in [0, 1]$, o parâmetro continua não sendo uma probabilidade mas passa a ser uma possibilidade.

Sejam k classificações por região baseadas em n classes e m segmentos. Cada região r_{ij}^k onde $i \in \{1, 2, \dots, m\}$, $j \in \{1, 2, \dots, n\}$, possui n parâmetros $(p_{ij}^k, d_{ij}^k, s_{ij}^k)$ associados. Os parâmetros p (probabilidade) e s (estatística) indicam a incerteza da classificação em relação a cada uma das n classes. Desta maneira, a classe j associada à região i será aquela que possui o maior p -valor ou menor valor s . O parâmetro d é a distância estocástica associada e também decresce com o aumento do valor p .

Considere $k = 2$ correspondente às imagens LANDSAT5/TM (T) e ALOS/PALSAR (R) classificadas com base em n classes e m regiões, $r_{ij}^T \implies (p_{ij}^T, d_{ij}^T, s_{ij}^T)$ e $r_{ij}^R \implies (p_{ij}^R, d_{ij}^R, s_{ij}^R)$ onde $i \in \{1, 2, \dots, m\}$, $j \in \{1, 2, \dots, n\}$. O mapa de incerteza associado a classificação de cada região possui n valores para cada uma das m regiões e pode ser baseado tanto no p -valor quanto na estatística s correspondente. Adotando como parâmetro de incerteza o valor de s normalizado, é possível construir os seguintes cenários.

4.2.1 Cenário I

Corresponde à classificação das imagens LANDSAT5/TM. Seu respectivo mapa de incertezas guarda o mínimo dos valores s obtidos por região, ou seja, mínima estatística por região.

$$r_{il}^T \implies (p_{il}^T, d_{il}^T, s_{il}^T)$$

onde $s_{il}^T = \min \{s_{i1}^T, s_{i2}^T, \dots, s_{in}^T\}$.

4.2.2 Cenário II

Corresponde à classificação das imagens ALOS/PALSAR. Seu respectivo mapa de incertezas guarda o mínimo dos valores s obtidos por região, ou seja, mínimo estimador por região.

$$r_{iv}^R \implies (p_{iv}^R, d_{iv}^R, s_{iv}^R)$$

onde $s_{iv}^R = \min \{s_{i1}^R, s_{i2}^R, \dots, s_{in}^R\}$.

4.2.3 Cenário III

O cenário III origina-se da mesclagem dos resultados de incertezas dos dois cenários anteriores. Comparando-se as incertezas dos cenários I e II, adota-se a classificação correspondente a menor incerteza entre estes.

$$r_{iu}^{TR} \implies (p_{iu}^{TR}, d_{iu}^{TR}, s_{iu}^{TR})$$

onde $s_{iu}^{TR} = \min \{s_{il}^T, s_{iv}^R\}$.

4.2.4 Cenário IV

Neste cenário, utilizam-se os n valores s correspondentes à cada uma das m regiões das classificações iniciais. Cada uma das m regiões pertencentes as classificações (T e R) possuem valores de incertezas correspondentes a cada uma das n classes. Fixando-se uma mesma região em ambas imagens classificadas efetua-se o produto entre as incertezas associadas às diferentes classes. Após realizar o produto dessas incertezas seleciona-se o menor dos valores entre os produtos resultantes. A classe correspondente ao mínimo dos produtos será associada à região em questão.

$$r_{ie}^{T*R} \implies (p_{ie}^{T*R}, d_{ie}^{T*R}, s_{ie}^{T*R})$$

onde $s_{ie}^{T*R} = \min \{s_{i1}^T * s_{i1}^R, s_{i2}^T * s_{i2}^R, \dots, s_{in}^T * s_{in}^R\}$.

4.2.5 Cenário V

Este último cenário inclui um tipo de lógica que tem por objetivo modelar modos de raciocínio aproximados ao invés de precisos. Nest caso, as proposições podem ter valores intermediários entre verdadeiro e falso e a veracidade destas é uma função que pode assumir qualquer valor entre 0 (absolutamente falso) e 1 (absolutamente verdadeiro). Essa lógica é conhecida como lógica Fuzzy (ou difusa) e visa modelar modos de raciocínio imprecisos, tendo os casos precisos como situações limites.

O objetivo da utilização deste tipo de lógica na classificação de imagens é mostrar que uma tomada de decisão pela classificação mais representativa da realidade pode ser relativa uma vez que a imagem de uma determinada região pode não possuir necessariamente uma classificação exata.

Desta forma, ainda utilizando-se resultados das classificações T e R, se no cenário anterior a incerteza foi originada do mínimo dos produtos, no cenário atual ela será fruto do produto entre os mínimos das estatísticas.

$$r_{ig}^F \implies (p_{ig}^F, d_{ig}^F, s_{ig}^F)$$

onde $s_{ig}^F = \min \{s_{il}^T * s_{iv}^R\}$.

Capítulo 5

Resultados e discussões

Na aplicação da metodologia descrita em capítulo anterior, adotou-se cinco classes oriundas de divisões maiores, são elas: Floresta Primária (FP), Regeneração (REG), Solo Exposto (SE), Pasto e Soja. A classe *Regeneração* inclui Floresta Degradada e Vegetação Secundária (inicial, intermediária e avançada) enquanto a classe *Pasto* engloba Pasto limpo, Pasto sujo e Pousio. Uma descrição de cada uma das classes é dada a seguir.

Floresta Primária (FP): floresta em que a ação humana não provocou ações significativas em suas características originais de estrutura e espécies;

Floresta Degradada (FD): floresta degradada por atividades de fogo ou por desmatamento seletivo, de forma que suas características originais tenham sido alteradas, mas ainda possuam porte florestal;

Vegetação Secundária (Avançada) (VS3): florestas secundárias em avançado estágio de desenvolvimento, com predomínio de árvores geralmente entre 13 e 17 metros, mas ocorrência de árvores emergentes e, em menor grau, arbustos e herbáceas;

Vegetação Secundária (Intermediária) (VS2): áreas com presença de vegetação secundária com poucas espécies herbáceas e predominância de árvores de pequeno porte e arbustos;

Vegetação Secundária (Inicial) (VS1): áreas de vegetação secundária com predominância de herbáceas e arbustos;

Pasto Limpo (PL): áreas com vegetação típica de pastagens, com predomínio de herbáceas;

Pasto Sujo (PS): áreas com vegetação típica de pastagens, com presença de espécies arbustivas, árvores e espécies invasoras;

Área Cultivada (AC): culturas de grãos;

Área em Pousio (AP): áreas agrícolas em pousio, cobertas por palha ou vegetação esparsa;

Solo Exposto (SE): áreas predominantemente de solo exposto.

Para a geração das classificações, foi utilizada uma segmentação da imagem contendo $m = 17568$ regiões. A partir das classificações das imagens TM e PALSAR foram gerados cinco cenários distintos e seus respectivos mapas de incertezas representados na figura 5.1.

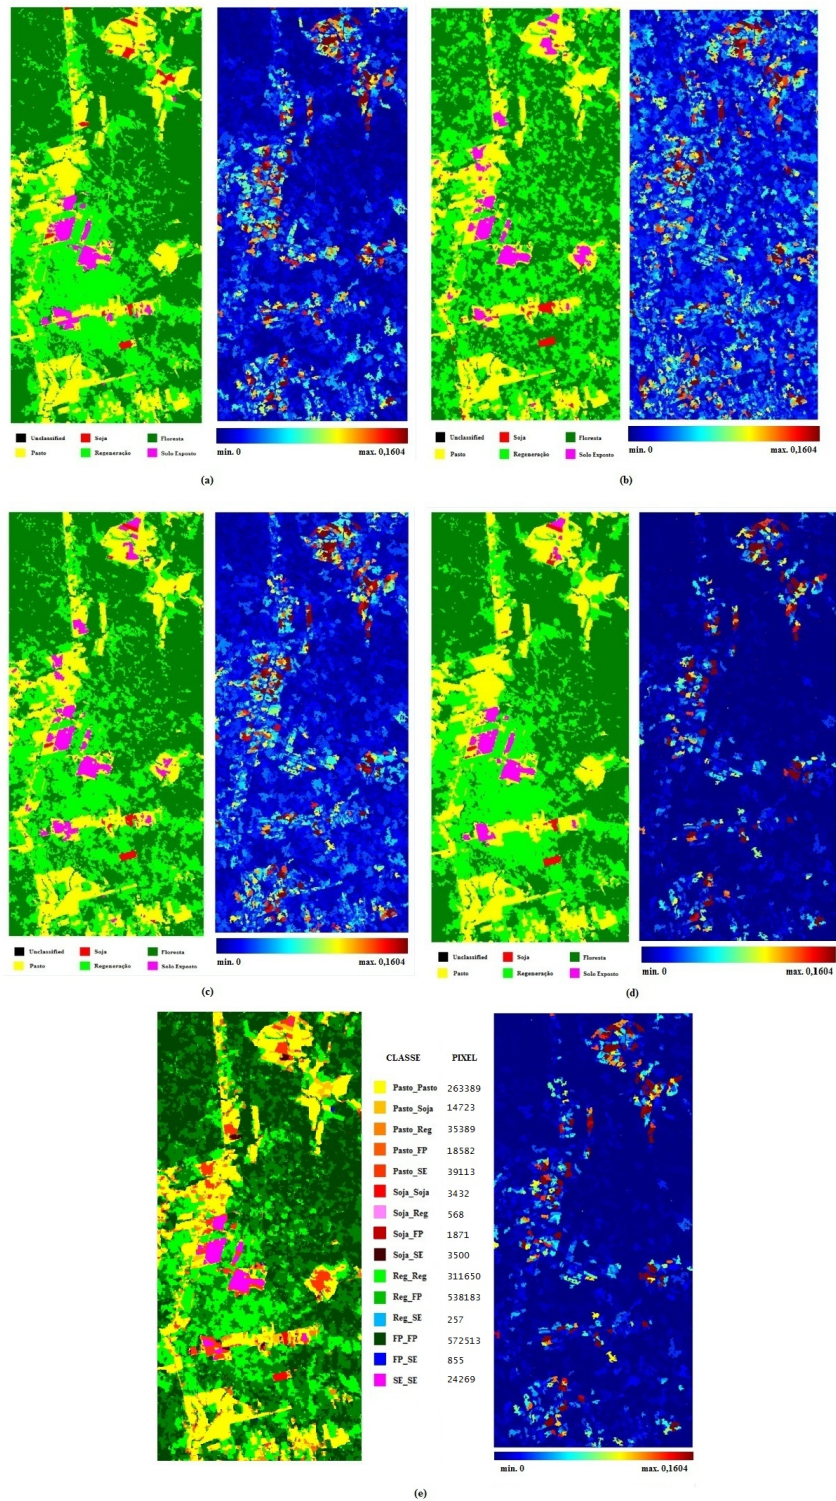


Figura 5.1: Classificações: a)cenário I; b) cenário II; c) cenário III; d)cenário IV; e) cenário V.

O primeiro cenário correspondente à classificação da imagem TM e seu respectivo mapa de incerteza é apresentado na figura 5.2. Observando a classificação resultante do primeiro cenário,




Figura 5.2: Cenário I.

percebe-se que algumas regiões da imagem não foram classificadas. Tais regiões foram preenchidas com a cor preta e a respectiva incerteza desta região é expressa pela expressão -NAN (not a number). Tal problema na classificação possui, até o momento, causas desconhecidas. Desconfia-se que tal problema foi originado no cálculo das distâncias no processo de classificação uma vez que o mesmo envolve o cálculo de inversas de matrizes de covariância dos dados (bandas). Se essas bandas, para um dado segmento forem altamente correlacionadas, o cálculo das inversas das matrizes podem ficar comprometidos devido a problemas numéricos. Isto aparentemente ocorreu para a classificação da TM.

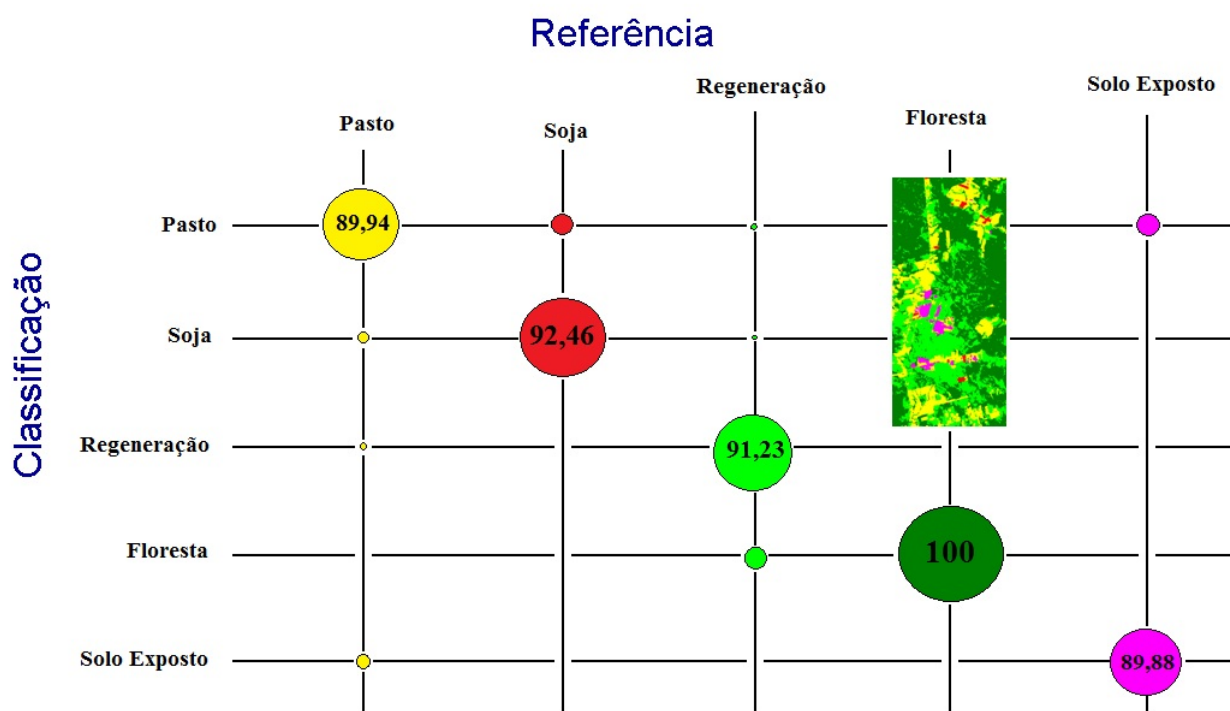


Figura 5.3: Matriz de confusão Cenário I.

A matriz de confusão do cenário I é apresentada na figura 5.3. Observa-se na matriz os erros de comissão (inclusão) e omissão (exclusão) efetuados pelo classificador assim como a porcentagem de acertos para cada classe estudada. Para a classe Floresta, por exemplo, a exatidão foi 100%, ou seja, todos os pixels associados à tal classe foram classificados corretamente. Desta maneira, para essa classe não houveram erros de omissão ou comissão. Já no caso da classe Pasto, a exatidão foi de 89,94% e observa-se que alguns erros foram cometidos embora os mesmos sejam pequenos. Parte das amostras pertencentes à classe Pasto foram classificadas como pertencentes às classes Soja, Regeneração e Solo exposto, caracterizando erros de omissão. Observa-se também que parte dos elementos pertencentes à classe Soja foram classificados como pasto, caracterizando um erro de comissão para a classe Pasto.

O segundo cenário correspondente à classificação da imagem SAR e seu respectivo mapa de incerteza é apresentado na figura 5.4. A classificação proveniente do sensor de micro-ondas apresenta




Figura 5.4: Cenário II.

um nível de incerteza maior em relação ao cenário anterior. Como era esperado, a classificação se mostrou bem mais confusa que aquela apresentada pelo cenário I. Embora o trabalho com imagens de radar possua suas vantagens devido à fatores como a independência em relação à fonte de iluminação e condições climáticas, um ruído característico desse tipo de sensor resulta em granulações na imagem final.

A qualidade radiométrica das imagens de radar é afetada por esse parâmetro instrumental que diz respeito à coerência de onda. Luz coerente é aquela formada por ondas de mesma frequência, fase e direção. No radar, a onda emitida é altamente coerente e devido a isso um ruído denominado Speckle está sempre associado aos sensores de radar.

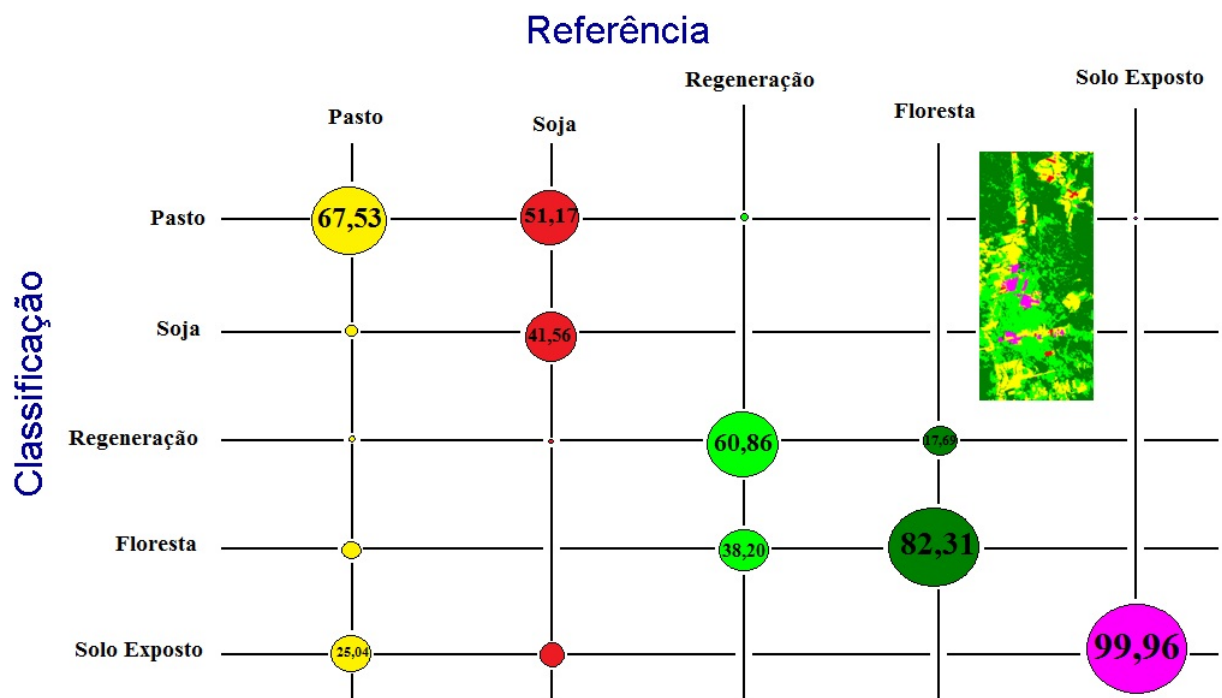


Figura 5.5: Matriz de confusão Cenário II.

A matriz de confusão para o cenário II apresenta uma exatidão inferior a maior parte das classes em relação aquela estudada no primeiro cenário. Entretanto, a classe Solo Exposto foi melhor classificada pelo segundo cenário.

O terceiro cenário correspondente à mesclagem de ambas classificações e seu respectivo mapa de incerteza é apresentado na figura 5.6.




Figura 5.6: Cenário III.

Esse cenário, basicamente, pega aquilo que existe de melhor no cenário I e no cenário II. Desta maneira era de se esperar que o valor das incertezas fossem menores em relação ao cenário II uma vez que além de considerar às classificações relativas às melhores certezas de ambos os cenários, ocorre um acréscimo de informação por parte do radar.

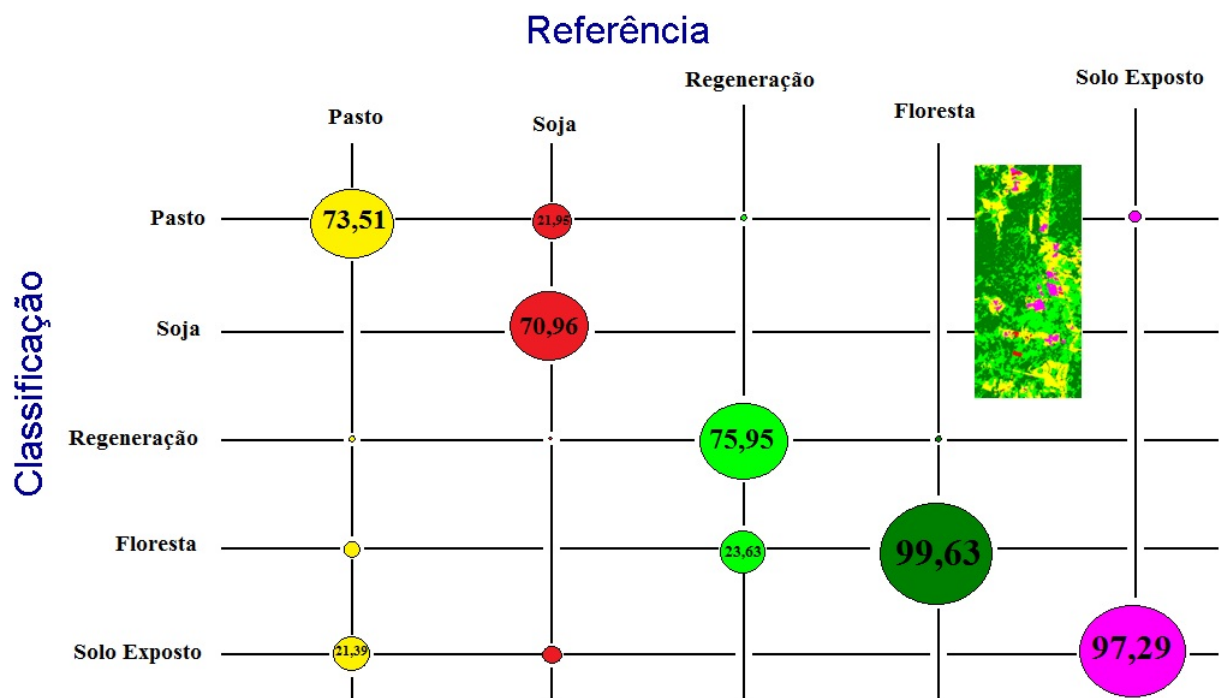


Figura 5.7: Matriz de confusão Cenário III.

Ainda assim, nota-se na matriz de confusão (Figura 5.7) que ocorre um equilíbrio em relação aos resultados dos cenários anteriores. Mas, o cenário I continua sendo aquele que possui maior exatidão e menor incertezas.

O quarto cenário correspondente ao mínimo dos produtos e seu respectivo mapa de incerteza é apresentado na figura 5.8.




Figura 5.8: Cenário IV.

Claramente esse cenário foi o melhor classificado até o momento em relação ao cenário I considerando-se as incertezas porém, sua matriz de erros mostra boa exatidão apenas em relação à algumas das classes em estudo (figura 5.9).

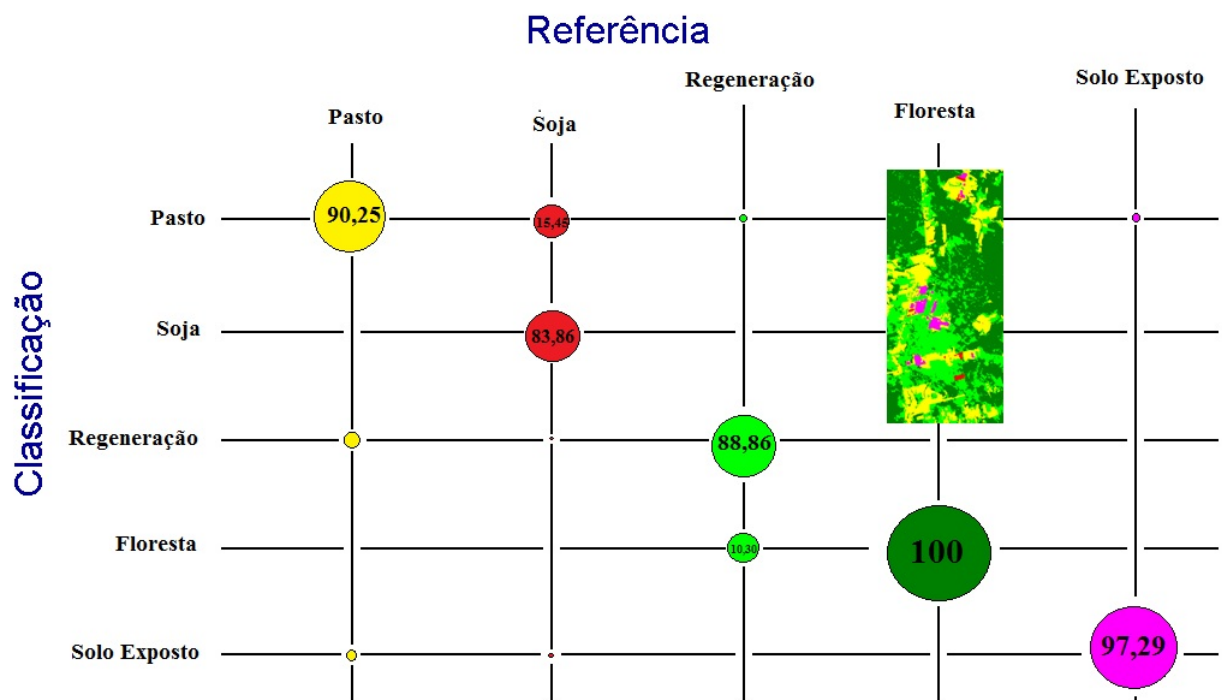


Figura 5.9: Matriz de confusão Cenário IV.

O último cenário é o cenário correspondente à lógica Fuzzy e seu respectivo mapa de incerteza é apresentado na figura 5.10 e sua matriz para análise na figura 5.11.

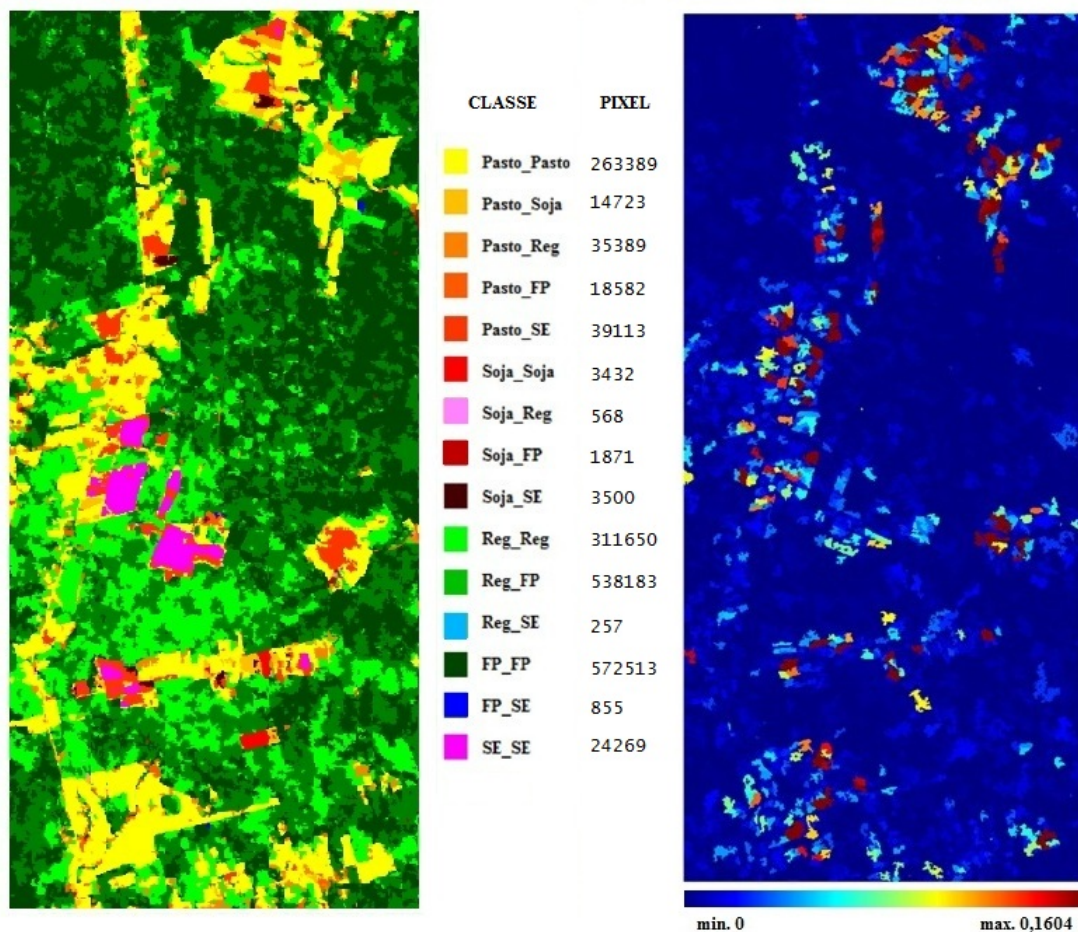


Figura 5.10: Cenário V.

A lógica Fuzzy mostra-se um fator positivo pois permite uma classificação em classes mistas com menor incerteza. Esse cenário como pode ser visto nas figuras 5.12, 5.13 e 5.14, teve a maior acurácia global e as menores incertezas médias por classe. Sua matriz de confusão não pode ser gerada como nos casos anteriores uma vez que na classe Fuzzy, aparecem classes que não existem nas amostras de testes das imagens em questão. Ainda assim, conhecendo-se a verdade de campo pode-se estimar o quanto de acertos tal cenário apresentou em relação às classes.

Neste caso, se uma quantidade de pixels foi classificada como pasto soja e pertence à classe pasto, tal decisão é considerada válida assim como o seria se pasto soja pertencesse à classe soja. Utilizando esse raciocínio a matriz de análise foi construída para o cenário V.

Observando-se a acurácia global de todos os resultados das classificações originadas, temos o cenário Fuzzy em uma posição superior. Os cenários I e IV possuem acurácias próximas todavia, em relação às incertezas, o cenário IV tem uma posição melhor por possuir menor incerteza. O cenário II, correspondente a classificação originada a partir de uma imagem SAR, possui a pior acurácia global em relação aos outros cenários.

classes	REFERÊNCIA					
	Pasto	Soja	Reg	FP	SE	TOTAL
Pasto_Pasto	4728	158	49	0	0	4935
Pasto_Soja	106	965	0	0	0	1071
Pasto_Reg	28	3	146	0	0	177
Pasto_FP	343	0	84	0	0	427
Pasto_SE	1619	0	0	0	454	2073
Soja_Soja	0	905	0	0	0	905
Soja_Reg	0	0	18	0	0	18
Soja_FP	0	0	0	0	0	0
Soja_SE	326	156	0	0	0	482
Reg_Reg	29	0	11502	0	0	11531
Reg_FP	0	0	8171	1163	0	9334
Reg_SE	0	0	0	0	0	0
FP_FP	0	0	636	5412	0	6048
FP_SE	0	0	0	0	0	0
SE_SE	157	0	0	0	4013	4170
TOTAL	7336	2187	20606	6575	4467	41171

Figura 5.11: Matriz para análise - Cenário V.




Figura 5.12: Incerteza média por classe para o cenário V.

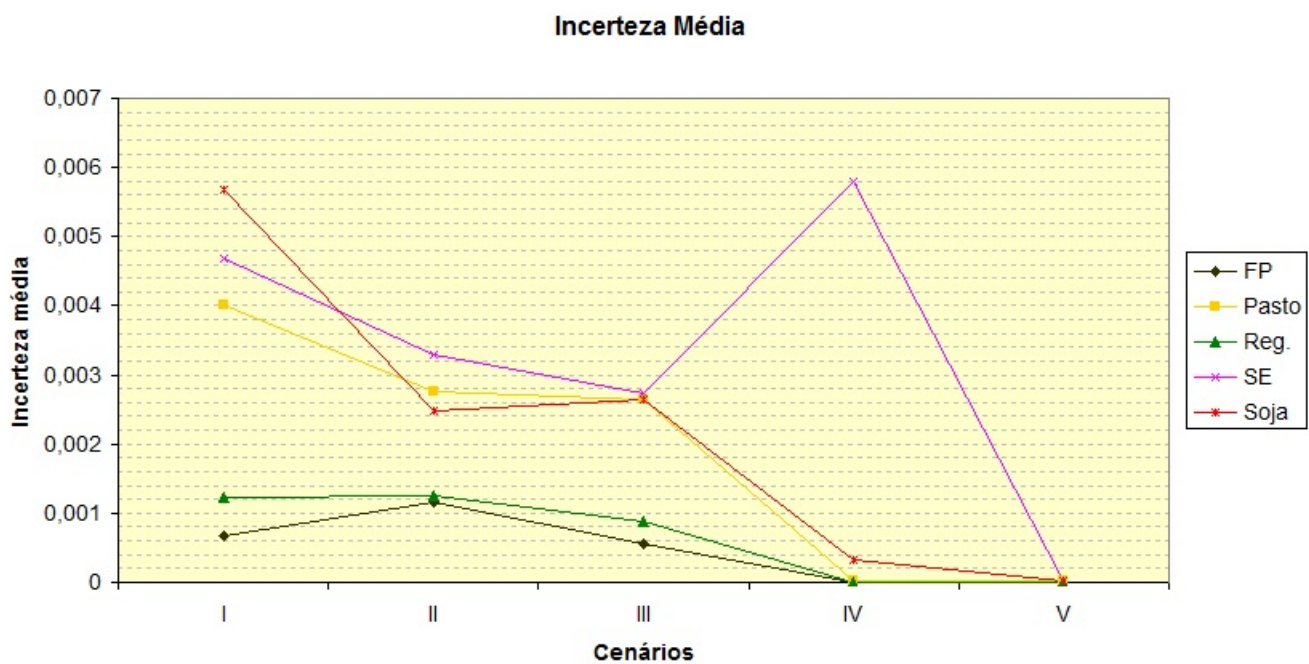


Figura 5.13: Incerteza média por classe para todos os cenários.

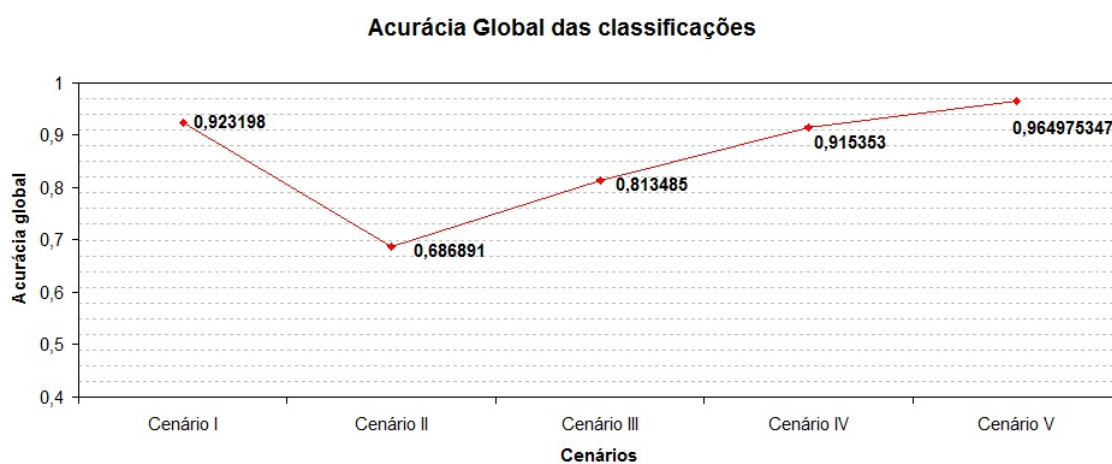


Figura 5.14: Acurácia global de todas as classificações.

Capítulo 6

Conclusões

A definição do melhor resultado de classificação pode ser um conceito relativo pois depende fortemente de seu objeto de estudo. Como observado por exemplo nas classificações geradas no trabalho, o cenário I mostrou-se um ótimo resultado para o estudo da classe Floresta, porém, o cenário II mostrou maior exatidão para a classe Solo Exposto.

A utilização de informações provenientes de fontes distintas pode ser um fator positivo na classificação. Como visto nos resultados apresentados, há, no geral, a diminuição das incertezas médias das classes e um aumento da acurácia global no cenário V, relativo à TM.

A lógica Fuzzy mostra-se um fator positivo pois permite uma classificação em classes mistas com menor incerteza.

Alguns problemas foram encontrados e merecem atenção. Entre eles o fato da TM não haver classificado algumas regiões, cujo motivo pode estar relacionado a existência de matriz singular no processo numérico para o cálculo da distância. O erro poderá também estar relacionado à implementação do classificador.

O fato do valor p ser muito próximo de zero também é um problema a ser investigado. Alguns dos motivos pelos quais isso ocorre pode estar relacionado às hipóteses iniciais adotadas. Considera-se que os dados possuam distribuições gaussianas e sejam independentes, porém, a correlação espacial dos dados altera o tamanho das amostras. A existência de mais classes do que as trabalhadas como apresentado no início do capítulo relativo aos resultados é outro motivo relevante que deve ser levado em consideração.

Será dada continuidade ao trabalho com o objetivo de investigar e procurar soluções para esses problemas.

Referências Bibliográficas

- [1] ARAGÃO, L. E. O. C. *Modelagem dos padrões temporal e espacial da produtividade primária bruta na região do Tapajós: uma análise multi-escala*. 286 p. (INPE-11423-TDI/951). Tese(Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2004.
- [2] Coutinho, A.C. *Segmentação e Classificação de Imagens LANDSAT-TM para o Mapeamento dos usos da Terra na Região de Campinas, SP*. - Dissertação (Mestrado em Ciências)- Departamento de Ecologia Geral do Instituto de Biociências da Universidade de São Paulo / USP, 1997.
- [3] ESCADA, M. I. S.; AMARAL, S.; RENNÓ, C. D.; PINHEIRO, T. F. *Levantamento do uso e cobertura da terra e da rede de infraestrutura no distrito florestal da BR- 163*. São José dos Campos, 2009. 52 p.(INPE-15739-RPQ/824). Disponível em: < [http : //www.dpi.inpe.br/arquivos_pime/RPQ_PIME_20090422.pdf](http://www.dpi.inpe.br/arquivos_pime/RPQ_PIME_20090422.pdf) >. Acesso em: 05 jun. 2014.
- [4] IBAMA. *Floresta Nacional do Tapajós Plano de Manejo*. Volume i - Informações gerais. Brasil: IBAMA: [s.n.], 2014. Disponível em: < [http : //www.icmbio.gov.br/portal/images/stories/imgs_unidades_coservacao/flona_tapajoss.pdf](http://www.icmbio.gov.br/portal/images/stories/imgs_unidades_coservacao/flona_tapajoss.pdf) >. Acesso em: 13 jun. 2014.
- [5] INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). *Catálogo LANDSAT5 2013a*. Disponível em: < [http : //www.dgi.inpe.br](http://www.dgi.inpe.br) >. Acesso em: 12 de jan. 2013.
- [6] INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). *Biblioteca Digital de Fotos de Campo da OBT. 2013b*. Disponível em: < [http : //www.obt.inpe.br/fototeca/](http://www.obt.inpe.br/fototeca/) >. Acesso em: 9 de out. 2013.
- [7] Meneses, P. R.; Almeida, T. *Introdução ao Processamento de Imagens de Sensoriamento Remoto* - Universidade de Brasília. Brasília 2012.
- [8] Reis, M. S. *Detecção de mudanças de uso e Cobertura da Terra utilizando dados óticos e de Micro-ondas em uma região da Amazônia Brasileira* - Dissertação (Mestrado em Sensoriamento Remoto)- Instituto Nacional de Pesquisas Espaciais / INPE, 2014.
- [9] SALICRU, M.; MORALES, D.; MENENDEZ, M. L.; PARDO, L. *On the applications of divergence type measures in testing statistical hypotheses*. Journal of Multivariate Analysis, v. 51, n. 2, p. 372-391, November 1994.

- [10] Silva, W. B. *Classificação de regiões de imagens utilizando testes de hipóteses baseados em distâncias estocásticas: aplicações a dados polarimétricos*. - Tese (Doutorado em Sensoriamento Remoto)- Instituto Nacional de Pesquisas Espaciais / INPE, 2013.