



COMPORTAMENTO DO SOFTWARE TERRAVIEW NA CLASSIFICAÇÃO SUPERVISIONADA EM DIFERENTES BACIAS

Mikael Timóteo Rodrigues¹, Lincoln Gehring Cardoso², Sérgio Campos³, Bruno Timóteo Rodrigues⁴ & Zacarias Xavier de Barros⁵

RESUMO: O objetivo principal desse trabalho é averiguar a atuação do software TerraView 4.2.2 desempenhando a classificação supervisionada por meio do padrão espectral em imagem Landsat 5, associada a comparação do uso da terra das bacias hidrográficas dos rios Lavapés e Capivara, inseridas no município de Botucatu/SP utilizando-se técnicas de sensoriamento remoto e geoprocessamento. As áreas de treinamento supervisionado foram definidas a partir de nove classes para bacia do Lavapés e sete para bacia do Capivara, fundamentais para o estudo e análise do uso e ocupação da terra, como mata, solo, culturas - agricultura, corpos d'água e malha urbana dentre outras classes encontradas. Tais áreas de treinamento supervisionado foram definidas por meio de polígonos que representaram as respectivas classes de uso e ocupação da terra, considerando a cor, brilho, padrão e textura emitida por cada pixel da imagem. A diferença de resultados entre as duas bacias avaliadas foi notória, onde a bacia do Capivara apresentou melhores resultados, seguramente por apresentar um número menor de classes de uso da terra e uma menor área urbana, assim causando menos confusões para o algoritmo. Outro fator evidente foi à clara diferença dos produtos derivados a partir da classificação gerada e posteriormente pós-classificados com o filtro majoritário (*majority filter*), onde sempre após a reclassificação a acurácia foi elevada, apresentado menos erros de omissão e comissão nas matrizes e suavização dos mapas classificados, com a eliminação de classes de 10 e 75 pixels por região, o que abrandou consideravelmente a estética dos mapas e conseqüentemente a diminuição de erros.

PALAVRAS-CHAVE: Geoprocessamento, Sensoriamento Remoto, Processamento de Imagens, Uso do solo.

BEHAVIOR TERRAVIEW SOFTWARE IN SUPERVISED CLASSIFICATION IN DIFFERENT WATERSHEDS

ABSTRACT: The main objective of this study is to ascertain the performance of the TerraView 4.2.2 software performing the classification oversees through the spectral pattern on Landsat 5, associated with comparing the land use of the Lavapés and Capivara's watersheds, set in Botucatu/São Paulo using remote sensing and GIS. The areas of supervised training were set from nine classes for Lavapés watershed, and seven for Capivara watershed, fundamental for the study and analysis of the use and occupation of land as forest, soil, crops - Agriculture, Water Bodies and Mesh urban, found among other classes. Such areas of supervised training were defined by polygons representing the respective classes of use and occupation of land, considering the color, brightness, pattern and texture emitted by each pixel of the image. The difference in results between the two watersheds was evaluated notorious, where the Capivara watershed showed better results, surely by having a smaller number of land use classes and a smaller urban area, thus causing less confusion for the algorithm. Another obvious factor was the clear difference of products derived from the classification generated and subsequently post-classed with the majority filter, where ever after reclassification accuracy has always been high, presented less errors of omission and commission in the headquarters and smoothing of classified maps, with the elimination of 10 and 75 pixels per region classes, which greatly slowed the aesthetics of maps and therefore decrease errors.

KEYWORDS: Geoprocessing, Remote Sensing, Image Processing, Use of the soil.

1 INTRODUÇÃO

O Sensoriamento Remoto tem papel significativo no ambiente SIG (Sistemas de Informação Geográfica), como uma das alternativas mais viáveis para extração de

informações sobre os diversos usos do solo, assim, gerando grande número de informações e possibilitando programação de ações adequadas para tomada de decisões por constituir ferramentas de articulação e informações geoespaciais (FUSHITA, et al., 2013). A partir do conhecimento das características físicas dos alvos de uma dada região, e seu comportamento espectral (interação da radiação solar com os elementos

¹ FCA/UNESP. E-mail: mikaelgeo@gmail.com

² FCA/UNESP. E-mail: cardosolg@fca.unesp.br

³ FCA/UNESP. E-mail: seca@fca.unesp.br

⁴ FCA/UNESP. E-mail: brunogta21@gmail.com

⁵ FCA/UNESP. E-mail: zacariasxb@fca.unesp.br

que compõe o mosaico da superfície terrestre como os rios, a vegetação, o tipo de solo, a rocha) é possível fazer um monitoramento das condições ambientais da área em questão e descobrir possíveis modificações (AMORIM, et al., 2007).

Múltiplos trabalhos utilizando diversas ferramentas SIG têm sido desenvolvidos com a intenção de delimitar e classificar bacias hidrográficas e os respectivos manejos do uso da terra nas mais variáveis áreas. Por outro lado, o número elevado de bandas que devem ser avaliadas, as extensas áreas de estudo com alto grau de detalhamento, torna bastante lento e trabalhoso o processo de interpretação de um determinado perímetro. Com base nessas dificuldades foram elaboradas as técnicas de classificação digital de imagens, que automatizam a metodologia de extração das imagens de satélite, minimizando a subjetividade da interpretação humana, bem como, reduzindo esforços e encurtando o tempo de trabalho do analista.

A forma mais usual e difundida entre os pesquisadores que trabalham com Sensoriamento Remoto e que foi adotada pelos softwares comerciais e livres que utilizam módulos de processamento de imagens, dividiu os classificadores em supervisionados e não-supervisionados. A classificação supervisionada, que foi empregada no presente trabalho requer conhecimentos prévios das classes de alvos, a fim de classificar a imagem nos alvos de interesse pré-fixados pelo analista, onde o algoritmo precisa ser treinado para poder diferenciar as classes uma das outras.

Dentro desse contexto, o presente trabalho teve como objetivo analisar desempenho do software TerraView bastante utilizado no Brasil e em diversas partes do mundo realizando a classificação supervisionada para mapear áreas que apresentam padrão espectral associado aos diversos usos da terra, por meio do método estatístico de Máxima Verossimilhança e a influência dos respectivos filtros no produto final da classificação.

2 MATERIAL E MÉTODOS

A área de estudo abrange as bacias hidrográficas dos rios Lavapés e Capivara, situadas no Município de Botucatu, região Centro-Oeste do Estado de São Paulo entre as coordenadas geográficas 22° 47' 10" a 22° 52' 38" de latitude S e 48° 22' 07" a 48° 26' 38" de longitude W (Figura 1).

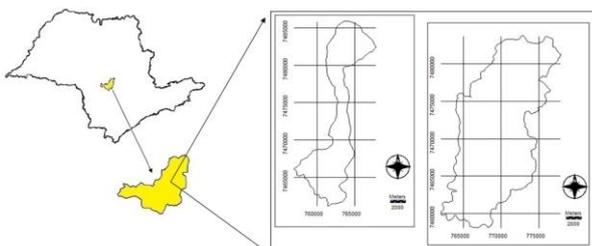


Figura 1 - Localização das bacias hidrográficas dos rios Lavapés e Capivara.

Para realização do georreferenciamento da área de interesse, foi obtido pelos softwares IDRISI versão Selva e o ArcGIS 10.1, utilizando como pontos de controle a base cartográfica da carta planialtimétrica da folha Botucatu (SF-22-R-IV-3), escala 1:50000 e equidistância vertical de 20m situada no fuso 22, Datum Córrego Alegre.

Para a classificação supervisionada por máxima verossimilhança também conhecida como "MAXVER", foram utilizados dados coletados pelo sensor Thematic Mapper de uma imagem do satélite LANDSAT-5, atuando com sete bandas espectrais, de forma que no presente trabalho, será utilizado três, com a composição RGB, composto pelas das bandas 3, 4 e 5 (TM3, TM4 e TM5) com escala 1:50000, na órbita 220, ponto 76 inserida no mosaico de recobrimento sobre o estado de São Paulo, com resolução de 30 X 30 metros, com data de passagem em 19 de setembro de 2011.

A imagem orbital foi registrada no software ArcGIS 10.1 com auxílio da carta planialtimétrica da folha Botucatu SF-22-R-IV-3, onde a mesma foi exportada para o formato GEOTIFF.

A partir da imagem de satélite, elaborou-se um mapa da verdade terrestre do uso e ocupação das terras nas bacias hidrográficas dos rios Lavapés e Capivara utilizando-se do software QGIS 2.2.0 (Figura 2). Para auxiliar na interpretação visual das áreas de cobertura vegetal, foi utilizado o Google Earth como ferramenta de apoio, permitindo delimitar com maiores detalhes as ocupações, onde foram identificadas 9 classes de uso e cobertura para bacia do rio Lavapés e 7 classes para bacia do rio Capivara no ano de 2011 por meio da imagem derivada do sensor TM a bordo do Landsat 5. De posse do arquivo completo vetorizado, o mesmo foi exportado em formato GEOTIFF para o IDRISI Selva edição 17.0 (EASTMAN, 2012).

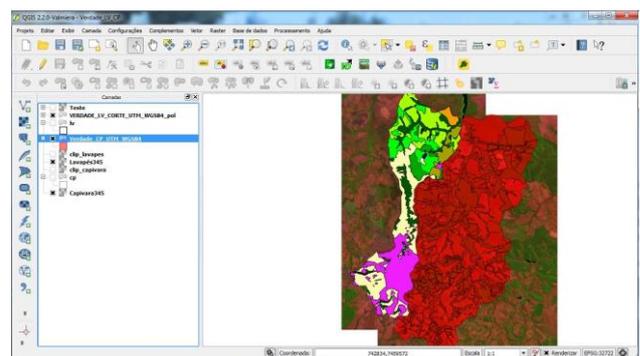


Figura 2 - Processo de digitalização da Verdade Terrestre.

As áreas de treinamento supervisionado foram definidas por meio de polígonos que representaram as respectivas classes de uso e ocupação da terra, considerando a cor, brilho e textura emitida por cada pixel da imagem. Assim, cada polígono supervisionado, teve um conjunto de pixel com o mesmo contexto, iguais feições e padrões, sendo consolidado o mesmo objeto irradiante.

Área de treinamento (training sites) é uma amostra homogênea da classe com toda a variabilidade dos níveis de cinza. É recomendado que o usuário adquira mais de uma área de treinamento (CROSTA, 1992), utilizando o maior número de informações disponíveis, como trabalhos de campo, mapas, dentre outras informações. O número de "pixels" de treinamento de uma classe aumenta com a complexidade da área a ser classificada. Neste trabalho, foram utilizados 47 training sites para a bacia do rio Lavapés e 55 para a bacia do rio Capivara.

Assim sendo, a classificação supervisionada MAXVER (máxima verossimilhança) foi realizada por meio do software TerraView, onde foram definidas amostras de treinamento (Figura 3), tomando como base o Manual Técnico de Uso da Terra do IBGE (2006), por meio de polígonos representados nos três aplicativos, onde os mesmos representam as classes de uso e ocupação da terra, conforme a tonalidade de cor, texturas e padrão dos alvos identificados, sendo assim divididos em: Água, Cana 1, Cana 2, Cana 3, Citrus, Mata, Pastagem, Solo em Cultivo e Área Urbana para bacia do rio Lavapés, bem como Cana, Citrus, Mata, Pastagem, Solo em Cultivo, Áreas Úmidas e Área Urbana para bacia do rio Capivara.

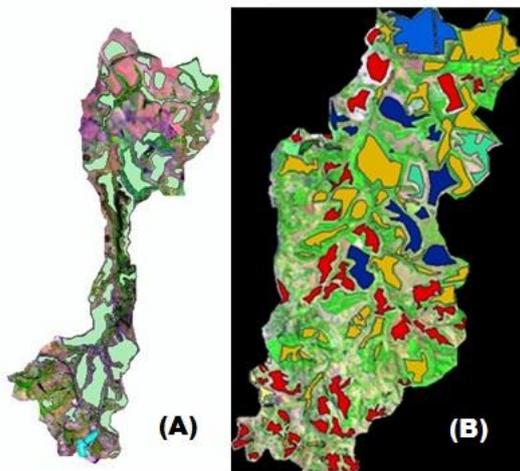


Figura 3 - Amostras de treinamento (training sites) nas bacias dos rios Lavapés (A) e Capivara (B).

Também foi utilizado no TerraView, como forma de pós-classificação, a extensão Filtro Majoritário (*majority filter*) para a "limpeza" de pixels que possivelmente tenham sido classificados de forma equivocada pelo algoritmo do software (Figura 4), aparecendo como pequenos pontos dentro de classes maiores, uniformizando as classes de uso e eliminando pontos isolados, classificados diferentemente de grupos vizinhos. Contudo, é gerada uma segunda classificação do mesmo SIG (TerraView) com menos ruídos, por sua vez, com menor erro agregado.

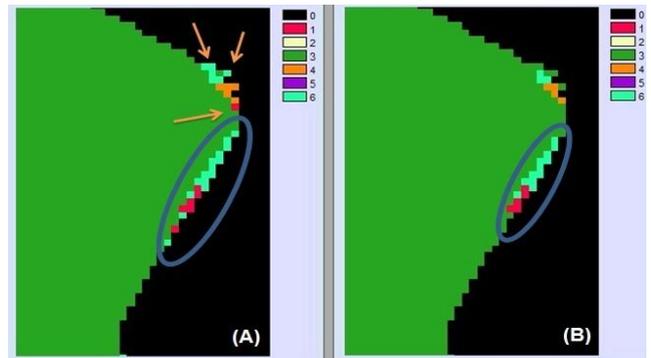


Figura 4 - Classificação supervisionada sem filtro (A); Pós-classificação com uso do majority filter (B).

O software livre Terraview 4.2.2 possui em sua extensão de Filtro Majoritário a flexibilidade da escolha referente à quantidade de pixels que o usuário pode eliminar por classes em sua pós-classificação (Figura 5), ou seja, reduzir os ruídos de pixels classificados em classes não pertencentes ao mesmo. Com essa opção, o usuário pode fazer inúmeras tentativas de pós-classificação até chegar a uma acurácia mais próxima da desejada.

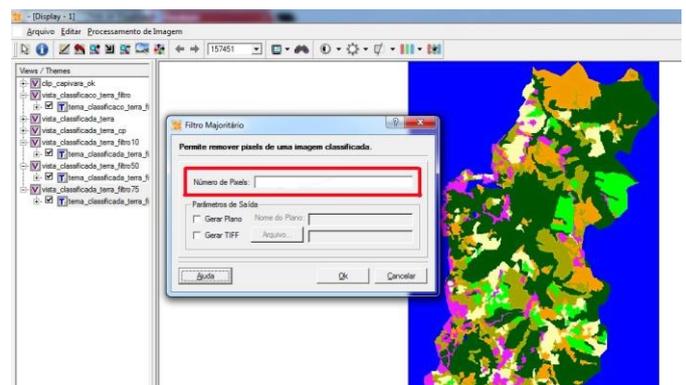


Figura 5 - Extensão de Filtro Majoritário do TerraView e sua opção de escolher a quantidade de pixel que o usuário pode eliminar por classes.

Foram elaborados vários testes de pós-classificação com números de exclusão de pixels baixo, moderado e altos, porém, a acurácia tende a cair quando se eleva bastante o número de exclusão de ruídos, pois com altos grupos de pixels migrados de uma classe para outra, o algoritmo tende a mover não só os pixels que causam ruídos, mas também pixel que já se encontra em sua classe verdadeira, assim, fazendo o sentido inverso do que seria uma satisfatória pós-classificação.

Para identificar a melhor classificação, foram cruzados os mapas de MAXVER derivados do TerraView com a verdade terrestre, onde a mesma se caracteriza como a real utilização do solo, apontando a exatidão (acurácia) de cada classificação, cruzando matrizes de pixel ou conjuntos de pixels. O índice Kappa (Tabela 1) é o mais recomendado por utilizar todas as células da matriz ao

invés de somente os elementos diagonais, diferentemente de métodos que fazem uso apenas da Exatidão Global, utilizando dados derivados dos cruzamentos das classes, onde os mesmos se situam na diagonal principal da matriz de confusão, o que garante ao índice Kappa uma maior precisão da acurácia em relação aos outros métodos devido à medição de um pixel estar corretamente classificado, em relação à probabilidade de estar incorretamente classificado, avaliando a acurácia temática por ser mais sensível as variações de erros de omissão e comissão, também conhecido na literatura como erro de inclusão. (DEMARCHI et. al., 2011).

Desta forma, o erro de omissão representa os pixels “perdidos” para outras classes, bem como o erro de comissão reflete os pixels “recebidos” de outras classes. Na matriz de erro, o erro de omissão indica a probabilidade de uma unidade amostral de referência estar corretamente classificada e o erro de inclusão representa a probabilidade que um pixel classificado no mapa, represente a categoria no terreno. Erros de inclusão ocorrem quando um ponto é identificado como de uma classe, quando na realidade pertence à outra categoria, enquanto que os erros de omissão ocorrem quando um ponto é identificado como pertencente à outra categoria, quando, na realidade, é membro de uma determinada classe (PIROLI, 2010).

Tabela 1 - Intervalos de caracterização da acurácia em relação a verdade terrestre.

Valor de Kappa	Qualidade da Classificação
<0,00	Péssima
0,00 – 0,20	Ruim
0,20 – 0,40	Razoável
0,40 – 0,60	Boa
0,60 – 0,80	Muito boa
0,80 – 1,00	Excelente

Fonte: Landis e Koch (1977).

3 RESULTADOS E DISCUSSÃO

Em decorrência da variação temporal das culturas encontradas na área estudada, é que durante a o processo de escolha de amostras de treinamento (training sites) e a elaboração da verdade terrestre, o usuário tem que determinar várias subclasses da mesma cultura, como elaborado por Rodrigues; Rodrigues; Tagliarini (2014), ou avaliar todas as amostras em uma mesma classe, onde desta forma irá ocorrer um grande desvio padrão e por sua vez uma confusão entre classes e diminuição significativa da acurácia. Na imagem de composição RGB (Figura 6) podemos observar essa variação fenológica, da cana de açúcar, assim, subdividida em três subclasses.

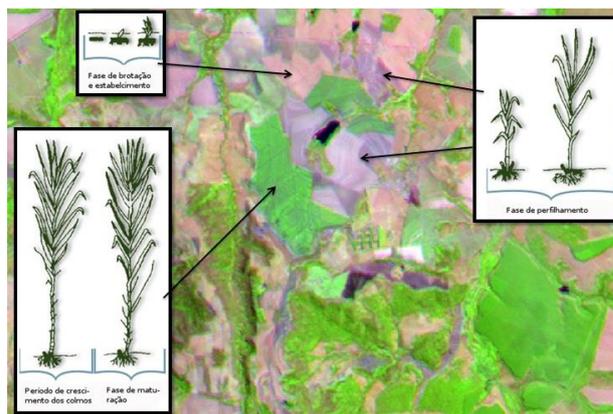


Figura 6 - Imagem de composição RGB e subclasses da cana de açúcar com diferentes respostas espectrais.

Na região das bacias do Lavapés e Capivara são praticados múltiplos tipos de manejo, onde pode ser encontrado plantios de culturas desde a escala de subsistência, passando por pequenas e médias propriedades rurais, até maiores estruturas agroindustriais, assim, constituindo um panorama de grande complexidade a ser mapeado e posteriormente modelado, onde a lista de ocupação e uso das terras é muito diversificado.

Um agravante à metodologia são as plantas daninhas, comuns em pastagens e solos cultivados com diversas formas de cultura, pois elas ocasionam interferência no padrão espectral das referidas classes, assim, proporcionando “ruído” que altera a resposta espectral pura das culturas induzindo a erros de classificação digital.

Outra dificuldade para o mapeamento da região estudada, fazendo-se uso de imagens de orbitais é a ambigüidade espectral entre classes de mesma cultura. Tais erros podem ser inferidos pela apreciação de índices de exatidão específicos para cada classe da modelagem, para tanto, erros de omissão e comissão.

A verdade terrestre referente à bacia do rio Lavapés (Figura 7) foi obtida como resultado da real utilização do uso do solo na área de estudo, assim, realizado o índice para comparação com as classificações MAXVER provenientes do TerraView.

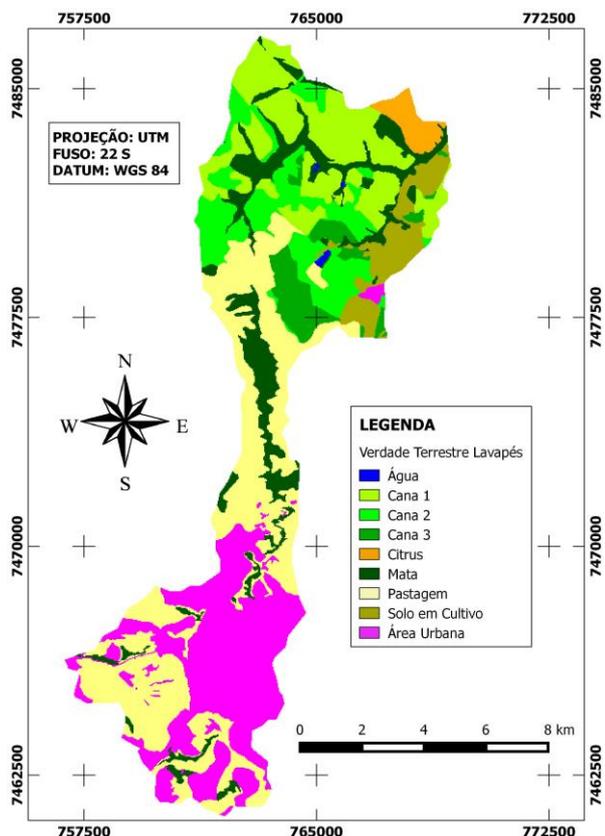


Figura 7 - Verdade terrestre da bacia do rio Lavapés.

A classificação supervisionada derivada do software TerraView (Figura 8) por meio do aplicativo MAXVER (modelagem do algoritmo da máxima verossimilhança), que considera a ponderação das distâncias entre as médias dos níveis do conjunto de pixels das amostras por classes, apresentou resultado razoável com relação ao índice Kappa, com valor na ordem de 0.21.

O Terraview possui em sua extensão de Filtro Majoritário a flexibilidade da escolha referente à quantidade de pixels que pode ser eliminado por classes em sua pós-classificação, onde o usuário estabelece a quantidade de pixel por bloco.

Por tal ferramenta apresentar esta mobilidade de inúmeras tentativas a pós-classificação com seu Filtro Majoritário, foram modeladas e consideradas para o presente resultado, as pós-classificações com retirada de grupos 10 pixels e grupos com 75 para redução de ruídos provocados por pixels fora de suas respectivas classes. O grupo de 10 pixels foi considerado por ser valor mínimo significativo de uma pós-classificação com o TerraView. Todavia, o grupo de 75 pixels foi considerado por apresentar o valor majoritário máximo referente a grupos de pixels removidos que causam suavização e melhor acurácia.

Os testes feitos com valores maiores que 75 (90, 150, 200 e 250) ocasionaram uma maior homogeneização das classes, porém uma acurácia menor. Isso ocorreu devido a um grande deslocamento de pixels, onde o algoritmo desloca os grupos de pixels ruidosos (que estavam

classificados incorretamente), mas também os grupos classificados em suas classes corretas, desta forma a pós-classificação com valores acima de 75 pixels suaviza o mapa e modifica classes corretas.

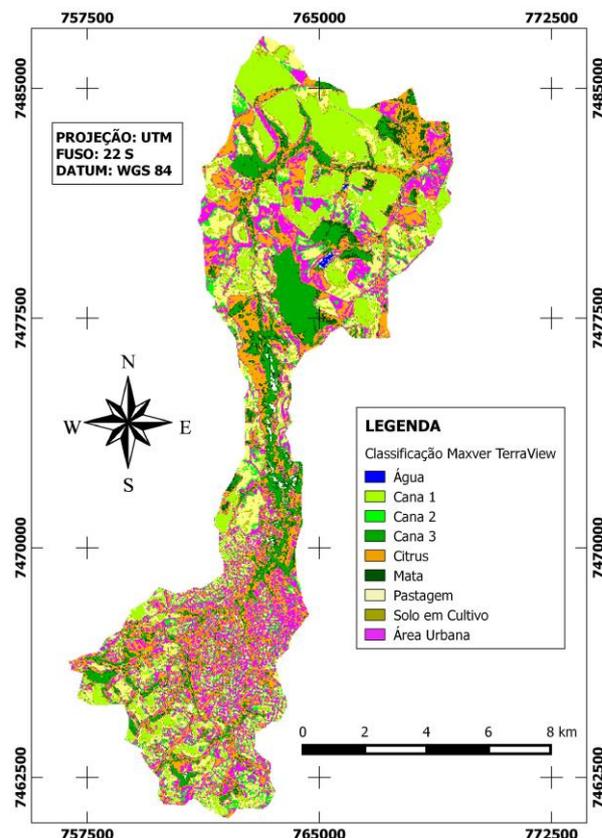


Figura 8 - Classificação Supervisionada TerraView.

Assim sendo, a modelagem da pós-classificação com retirada de grupos 10 pixels por região reduziram de forma bastante significativa os ruídos de pixels isolados elevando a acurácia das primeiras classificações do TerraView, saindo de 0,21 (onde faziam parte do intervalo referente a “razoável” segundo Landis e Koch, 1977) saltando para ordem de 0.45 (Figura 9), onde o mapa foi suavizado e suas estimativas recalculadas, elevando a acurácia de classificação para o intervalo de “boa” segundo a escala Kappa. As classes mata, solo em cultivo, cana 2 e pastagem que vinham apresentando erros de omissão nas outras matrizes, apresentaram mais acertos nas suas respectivas classes, porém, a água passou a ter mais pixels confundidos com a mata. Com o uso do filtro (grupo de 10 pixels) os valores globais em diagonal foram remodelados, assim, elevando significativamente a acurácia do mapeamento.

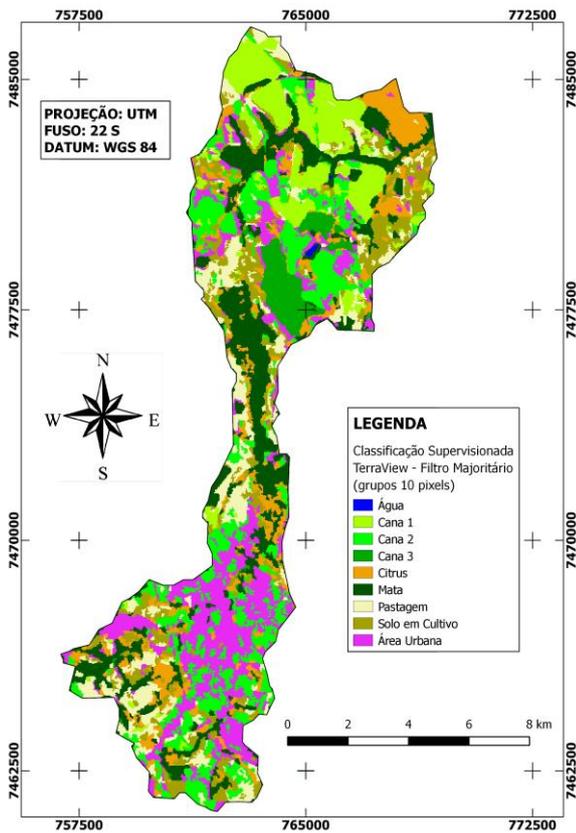


Figura 9 - Classificação Supervisionada TerraView 4.2.2 com Filtro Majoritário (grupos 10 pixels).

Melhorando ainda mais a suavização e as estimativas de realinhamento de matriz e acurácia (Figura 10), a modelagem da pós-classificação com retirada de grupos 75 pixels por região atingiu a ordem de 0,523, observando-se um grande aumento na acurácia permitindo uma menor inclusão de pontos de outras classes, assim, tornando-se a melhor classificação supervisionada da bacia do Lavapés, com mais de 50% de acerto.

Pode ser notado de forma clara, que o desempenho do classificador com a retirada de grupos 75 pixels por região foi bastante semelhante à retirada do grupo de 10, uma vez que se passou a existir menos erros de omissão, bem como menos erros de comissão que determinam grupos pixels ou pixel isolado que são atribuídos a uma classe do mapa final ao qual não pertence, enquanto deveriam estar em sua classe de origem (outra classe diferente da que foi classificada).

A classe de água continuou sendo interferida pela mata, porém, com uma pequena melhoria no valor global. O citrus apresentou melhor ajuste ao filtro 75, confundindo apenas 74 pixels com a classe mata.

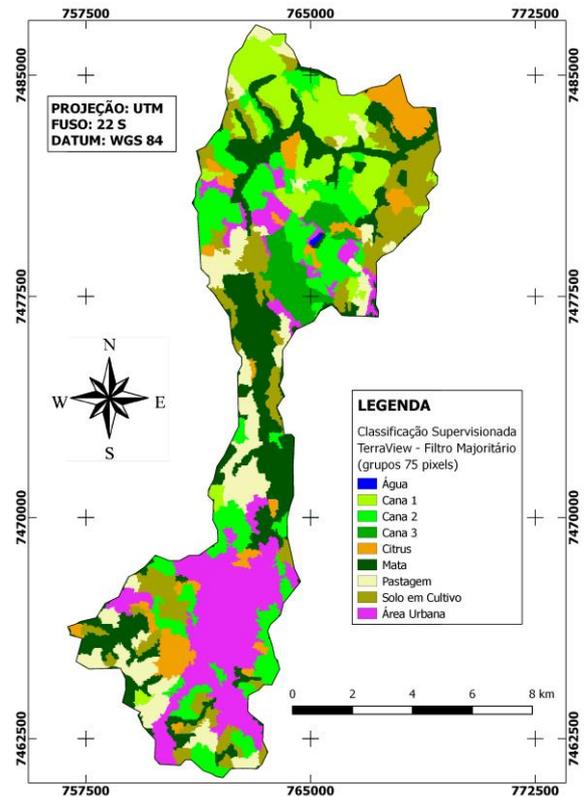


Figura 10 - Classificação Supervisionada TerraView 4.2.2 com Filtro Majoritário (grupos 75 pixels).

Tal como a bacia do rio Lavapés, a verdade terrestre referente à bacia do rio Capivara (Figura 11) foi obtida como resultado da real utilização do uso do solo na área de estudo, em seguida realizado as classificações.

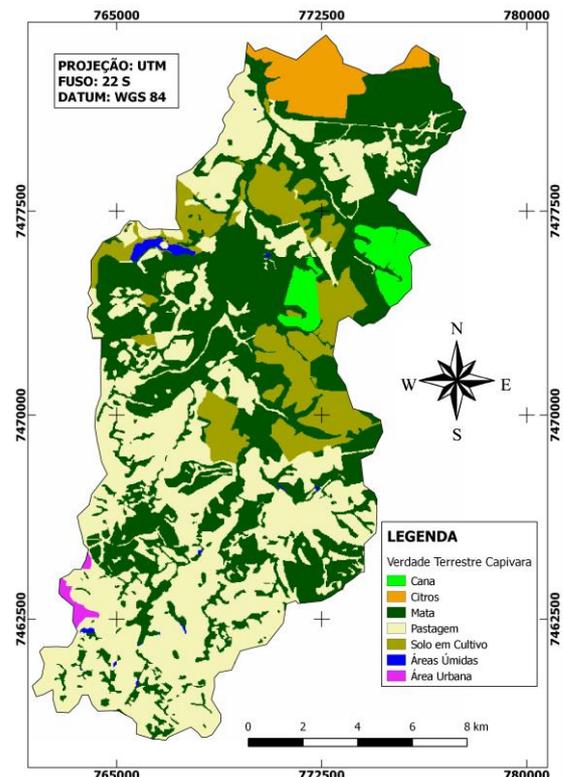


Figura 11 - Verdade terrestre da bacia do rio Capivara.

As classificações da bacia do Capivara tiveram desempenho superior às classificações da bacia do Lavapés, pois a área urbana inserida nesta bacia é muito maior do que a malha urbana da bacia do Capivara, onde tal classe gerou muito ruído em classes distintas, fato corroborado por Andrade e Silva (2011), onde esta mesma classe interferiu negativamente causando confusão ao algoritmo e consequentemente diminuição da acurácia.

Desta forma, as classificações da bacia do Capivara processadas pelo TerraView 4.2.2, foram observadas que as classes com maiores erros de comissão foram solo em cultivo, área urbana e a pastagem. Alguns maiores erros de omissão foram observados para a cana, a mata e novamente a pastagem, por apresentar a classes com maior área dentro da bacia, consequentemente com vários pontos de ambiguidade espectral confundindo o processamento do algoritmo, o que deu origem a uma classificação (Figura 12) com um valor Kappa na ordem de 0,476, sendo considerada uma boa modelagem segundo os intervalos de acurácia da Tabela 1.

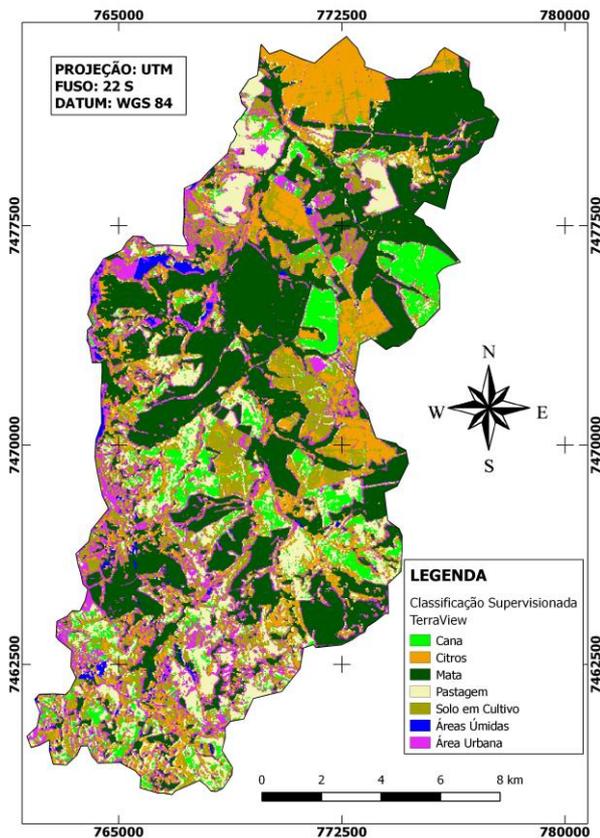


Figura 12 - Classificação Supervisionada TerraView.

Os erros de omissão juntamente com os erros de comissão indicam que pouco mais de 53% das áreas reais foram mapeados como outros usos, consequentemente, 47% foram corretamente mapeados, isso porque as confusões na interpretação decorrentes das semelhanças entre as classes mais afetadas pelos erros, além do fator ambiguidade espectral também são

afetadas pelo relevo acidentado onde as referentes classes se encontram.

Desta forma, a imagem orbital utilizada neste no presente trabalho é detentora também da variável textura, que representa a rugosidade topográfica da superfície, podendo ter suas estimativas relativamente transformadas devido à variação vertical de altura da superfície nos vales das bacias, que por sua vez influencia nos tipos de dosséis da vegetação.

Para minimizar a corrupção dos ruídos causados por padrão espacial errôneo, considerando os grupos de pixels vizinhos, foi utilizado mais uma vez o filtro majoritário do TerraView na pós-classificação com retirada de grupos 10 pixels por classe e/ou região, obtendo uma melhora significativa referente as outras classificações, porém, ainda permanecendo com o resultado de “boa” classificação segundo a Tabela 1, com valor na ordem de 0,50.

Por meio da Figura 13, nota-se que a imagem processada pelo método de classificação supervisionada por meio de filtros tende a possuir resultados mais condizente com a realidade dos produtos orbitais derivados do Landsat 5, onde todos os usos apresentaram valores de acurácia superiores a classificação supervisionada clássica, onde apenas se utiliza as áreas de treinamento (*training sites*).

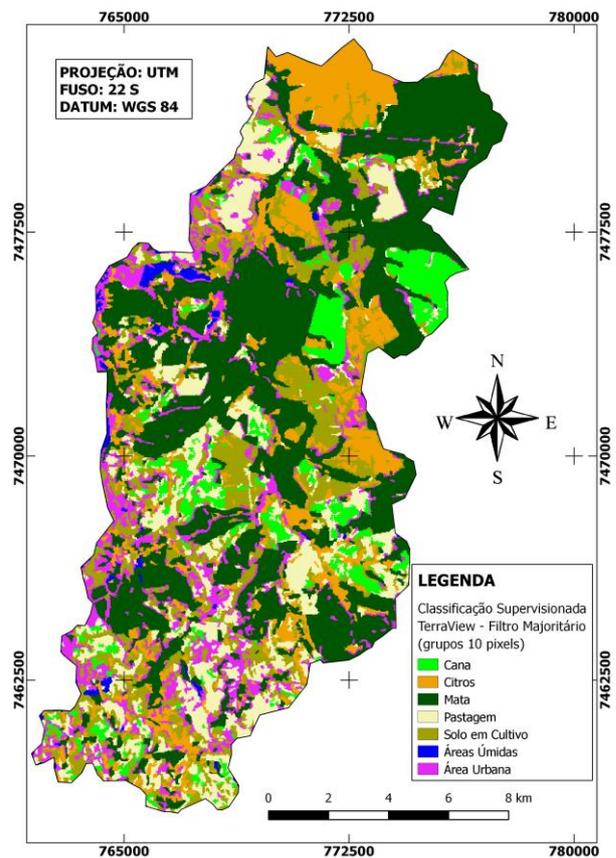


Figura 13 - Classificação Supervisionada TerraView com Filtro Majoritário (grupos 10 pixels).

De modo geral, com todas as variáveis que podem causar tendência ao erro, pode-se dizer que os resultados da modelagem derivada da pós-classificação do TerraView fazendo-se uso da retirada do grupo de 75 pixels por classes de uso da terra foi mais coerente, atingindo um coeficiente Kappa na ordem de 0,515, alcançando mais de 50% de acerto referente a verdade terrestre. O filtro majoritário, onde a célula principal, a partir de um aspecto, teve uma contagem numérica de pixels adjacentes, cada um com um valor, onde a partir de tais valores predominantes, estima o pixel central alterado de acordo com os valores majoritário dos grupos. Esta função provocou um novo delineamento e suavização das bordas de todas as classes de uso, tornando o mapa aparentemente mais agradável, com um visual livre de ruídos (Figura 14).

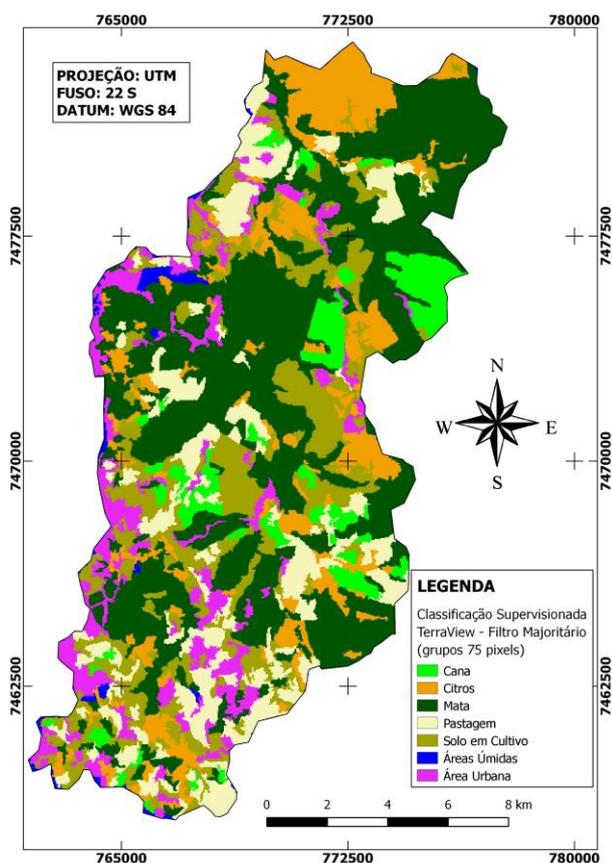


Figura 14 - Classificação Supervisionada TerraView com Filtro Majoritário (grupos 75 pixels).

Assim como foi discutido na pós-classificação do Lavapés, a reclassificação faz-se uso no filtro majoritário e exclusão dos grupos de pixels por região, a retirada de grupos elimina de forma satisfatória os ruídos a abranda as classes e todo o mapa classificado por se tornar mais confortável ao visualizá-lo, porém, grandes grupos de classes classificados pelo algoritmo de forma equivocada não serão eliminados ou realocados pelo filtro, pois este apenas elimina grupos ruidosos.

Ao ser trabalhado acima de 75 pixels por exclusão, o filtro passa a retirar pixels corretamente classificados e a alocar-los em grupos que não pertencem, ou seja, acima do valor de 75 o caminho de limpeza passa a ser inverso reduzindo a acurácia, acentuando os erros de comissão.

4 CONCLUSÕES

Devido os mais variados estágios de desenvolvimento e produção da Cana e de outras culturas presente nas bacias, bem como grandes áreas de solo preparado para o manejo, onde ora emitem diversas respostas espectrais de um mesmo uso, ora classes distintas apresentaram assinaturas espectrais idênticas ou muito próximas, o que caracterizou um alto grau de confusão na interpretação do algoritmo, contribuindo para resultados razoáveis (intervalos de 0,20 – 0,40) e resultados bons (intervalos de 0,40 – 0,60).

Ficou evidente a diferença dos produtos derivados a partir da classificação supervisionada por máxima verossimilhança pós-classificados com os filtros majoritários, onde após a reclassificação a acurácia foi elevada, apresentado menos erros, bem como suavização dos mapas classificados.

Existe a necessidade de ser utilizado em trabalhos futuros imagens com melhor resolução espacial, principalmente se a área a ser estudada for detentora de classe complexas como áreas urbanas e culturas iguais com estágios fenológicos distintos, pois uma imagem com melhor resolução espacial, assim distinguindo com mais propriedade objetos que são espacialmente próximos, e também com uma melhor resolução espectral para diferenciar alvos que possam apresentar respostas espectrais semelhantes em um determinado intervalo do comprimento de onda.

Inúmeros estudos que se fizeram uso de imagens Landsat para classificação supervisionada e alcançaram altos índices, utilizaram áreas de estudo com escalas muito maiores e menos detalhadas. Por sua vez, usuários de classificação supervisionada que trabalharam com áreas de escala local, consequentemente, mais detalhada, tiveram problemas com erros de acurácia e seus algoritmos classificadores devido ao alto detalhamento e as semelhanças das respostas espectrais, atrelado a uma resolução espacial de 30 x 30 metros.

É importante salientar que, provavelmente, se incorporados subdivisões espectrais de usos que apresentam tempos fenológicos distintos, bem como imagens com melhor resolução espacial, aplicação dos métodos em uma área com mais homogeneidade, com superfície menos rugosa e espectralmente menos ruidosa devido a sombras e outros aspectos que provocam dispersão de ondas eletromagnéticas, os resultados de acurácia para o TerraView 4.2.2 (MAXVER), serão possivelmente mais elevados e confiáveis, pois tal ferramenta apresenta um alto poder de processamento de dados digitais.

5 AGRADECIMENTO

Os autores agradecem ao CNPq pela concessão da bolsa de Pós-Graduação, sem a qual não seria possível a realização deste trabalho.

6 REFERÊNCIAS

- ANDRADE, E. L.; SILVA, U. M. Avaliação da classificação não-supervisionada em imagens de alta resolução, utilizando a lógica fuzzy. XV Simpósio Brasileiro de Sensoriamento Remoto - SBSR. 2011, Curitiba, PR. **Anais...** São José dos Campos: INPE, 2011, p. 7418-7425.
- AMORIM, R. F.; ALMEIDA, S. A. S.; CUELLAR, M. Z.; COSTA, A. M. B.; GOMES, C. Mapeamento de Uso e Ocupação do solo na Bacia Hidrográfica Piranhas/Açu, utilizando imagens CBERS e técnicas de classificação supervisionada. XIII Simpósio Brasileiro de Sensoriamento Remoto - SBSR.. 2007, Florianópolis, SC. **Anais...** São José dos Campos: INPE, 2007, p. 3710.
- DEMARCHI, J. C.; PIROLI, E. L.; ZIMBACK, C. R. L.. Análise temporal do uso do solo e comparação entre os índices de vegetação NDVI e SAVI no município de Santa Cruz do Rio Pardo - SP usando imagens Landsat-5. **Ra'e ga** (UFPR), v. 21, p. 234-271, 2011.
- EASTMAN, J. R.. **IDRISI Selva** – GIS and Image Processing Software – version 17.0. Worcester-MA/USA: Clark Labs, 2012.
- CROSTA, A. P. **Processamento Digital de Imagens de Sensoriamento Remoto**. IG/UNICAMP, Campinas – SP, v 1, p 193, 1992.
- FUSHITA, A. T.; REIS, R. R.; FARESIN, L.; SANTOS, J. E. Desempenho da classificação supervisionada em diferentes programas: comparação por meio do uso da terra e do índice de naturalidade da paisagem. XVI Simpósio Brasileiro de Sensoriamento Remoto - SBSR. 2013, Foz do Iguaçu, PR. **Anais...** São José dos Campos: INPE, 2013, p. 6465.
- IBGE. Instituto Brasileiro de Geografia e Estatística. **Carta topográfica**: folha de Botucatu (SF-22-R-IV-3). Serviço gráfico do IBGE, 1969. Escala 1:50.000.
- IBGE. Instituto Brasileiro de Geografia e Estatística. **Manual Técnico de Uso da Terra**. 2ª ed., Rio de Janeiro: IBGE, 2006.
- INPE. Instituto Nacional de Pesquisas Espaciais - Divisão de Geração de Imagens (DGI-INPE). **Banco de Dados Geográficos**. Disponível em:<<http://www.dgi.inpe.br/>>. Acesso em: 08 jul. 2015.
- INPE. Instituto Nacional de Pesquisas Espaciais - Divisão de Geração de Imagens (DGI-INPE). **Catálogo de Imagens**. Disponível em:<<http://www.dgi.inpe.br/>>. Acesso em: 15 abr. 2013.
- LANDIS, R.; KOCH, G. G. The measurement of observer agreement for categorical data. **Biometrics**, v.33, n.1, p.159-174, Mar. 1977.
- PIROLI, E. L.. **Introdução ao geoprocessamento**. Ourinhos: Unesp/Campus Experimental de Ourinhos, 2010. 46p.
- RODRIGUES, M. T.; RODRIGUES, B. T.; TAGLIARINE, F. S. N. Comparação do desempenho de Sistemas de Informação Geográfica (IDRISI Selva e ArcGIS®) por meio de processamento digital de imagem. **Revista Fórum Ambiental da Alta Paulista**, Tupã, v. 10, n. 2, p. 265-280, 2014.