

Criação de mapa temático de uso da terra com diferentes classificadores

Gleyce Kelly Dantas Araújo¹
Jerry Adriani Johann^{1,2}
Jansle Vieira Rocha¹

¹Universidade Estadual de Campinas - UNICAMP
Caixa Postal 6011 - 13081-970 – Campinas - SP, Brasil
{gleyce.dantas; jansle.rocha}@feagri.unicamp.br

²Universidade Estadual do Oeste do Paraná - UNIOESTE
Caixa Postal 0701 - 85819-110 – Cascavel - PR, Brasil
jerry.johann@feagri.unicamp.br

Abstract. The main goal of this study was to apply methods of supervised and unsupervised classification to obtain a land use map, the methodology was performed in a subset of a Landsat 5/TM image path/row 223/077, located in the west of Parana State, which is considered a typical agricultural region. Targets such as soybeans and sugar cane crops, natural vegetation, bare soil and water were selected. Urban areas were masked out due to its high variation of spectral reflectance. The results show that the merging of the two supervised classifiers, Maximum Likelihood and Mahalanobis distance gave best response. The first method resulted in a good classification of the selected themes, except for the natural vegetation; on the other hand, the second method presented good classification that specific target. The classification accuracies were evaluated through a confusion matrix, with kappa index of 0.82 and overall accuracy of 89%.

Palavras-chave: remote sensing, Landsat 5/TM, kappa index, overall accuracy, sensoriamento remoto, Landsat 5/TM, índice kappa, exatidão global.

1. Introdução

Uma das aplicações do sensoriamento remoto é distinguir e identificar as composições de diferentes materiais superficiais sejam eles tipos de vegetação, padrões de uso do solo, rochas entre outros. Esta distinção e identificação se tornam possível, em função destes materiais apresentarem comportamentos específicos ao longo do espectro eletromagnético (Crosta, 2002).

A classificação automática de imagens de satélite diz respeito a associar a cada pixel da imagem a um rótulo (vegetação, solo, água, etc.) chamado de temas. Assim, todos os pixels da imagem são associados a estes temas resultando em um mapa digital temático da área de interesse.

De acordo com Crosta (2002), existem duas abordagens na classificação de imagens multiespectrais de sensoriamento remoto. A classificação não supervisionada baseia-se no princípio de que o algoritmo do computador é capaz de identificar por si só as classes dentro de um conjunto de dados. Os métodos de classificação supervisionada fundamentam-se na disponibilidade prévia de amostras representativas, identificadas na imagem, para cada classe de interesse.

Os algoritmos classificadores utilizam, então, a informação estatística referente a essas amostras na classificação dos demais pixels da imagem. Em função disso, para que a classificação seja bem sucedida, é fundamental que as amostras de treinamento sejam homogêneas e representativas das classes de interesse.

O presente trabalho teve como objetivo aplicar métodos de classificação supervisionada e não supervisionada a fim de obter um mapa temático de uso da terra na região oeste do Paraná.

2. Material e Métodos

A aplicação das ferramentas de processamento digital de imagens foi feita em uma imagem do Estado do Paraná, precisamente em parte dos municípios de Alto Piquiri, Brasilândia do Sul, Formosa do Oeste, Jesuítas, Iracema do Oeste e Assis Chateaubriand, que pertence a mesorregião do Oeste Paranaense e localizada entre as coordenadas geográficas 53°35'W - 53°20'W e 24°10'S - 24°25'S no datum WGS84. Esta é uma área tipicamente agrícola (CUNHA, 1993). A Figura 1 mostra a localização da região de interesse para realização deste trabalho.

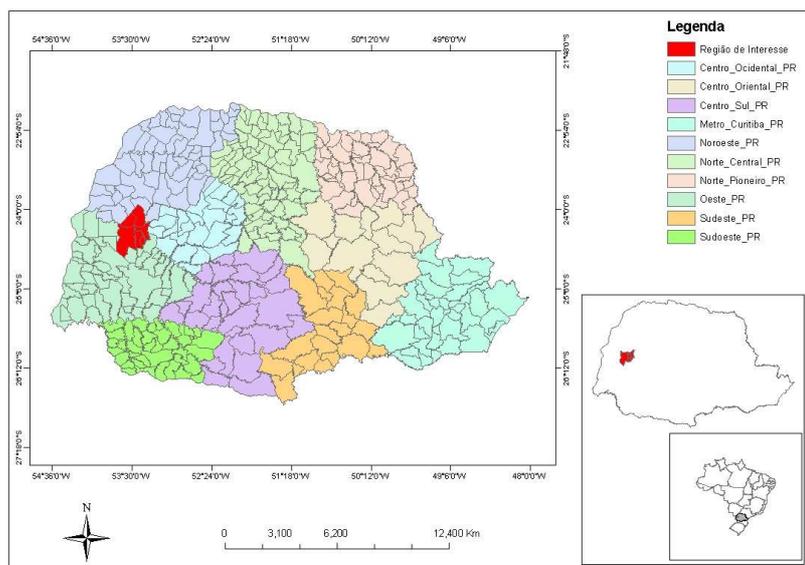


Figura 1. Localização da região de interesse.

Para realização deste trabalho foram empregadas inicialmente imagens do satélite Landsat-5/TM correspondentes às órbitas/pontos 223/077 datada de 04 de fevereiro de 2008 que foi corrigida geometricamente pela imagem Geocover do satélite Landsat-7/ETM+ com o software ENVI 4.2, apresentando um RMS de 0,391 abaixo de 0,50 recomendado (Eastman, 1998). Para esta atividade, foram utilizadas apenas as bandas 4; 5 e 3 para fazer a composição RGB453. Desta cena, realizou-se um recorte de 1024 x 1024 pixels para posterior classificação de uso do solo. Foram empregados os softwares ENVI 4.2, ARCGIS 9.2 e IDRISI KILIMANJARO para a fase de processamento das imagens.

Para aplicação dos classificadores foi feito um recorte de 1024 x 1024 pixels na cena Landsat-5/TM. Foram utilizados os classificadores: não supervisionado (IsoData) e supervisionados (Paralelepípedo, Mínima Distância, Máxima Verossimilhança, Distância de Mahalanobis).

Com base na identificação dos temas sob a composição RGB453, foram definidos os sete alvos que são: Vegetação natural, água, cana-de-açúcar, soja, solo, cidades, rodovias.

Os temas “cidades” e “rodovias” foram criados para serem usados como máscara na imagem RGB453 e não incluí-las quando aplicados os classificadores, uma vez que poderiam ser confundidos com outros alvos.

Um mapeamento de uso do solo apoiado pelo Sensoriamento Remoto necessita ser utilizado com exatidão, quando se deseja que as informações obtidas neles sejam adequadas, (MANGABEIRA et al, 2003). As análises dessas informações foram realizadas através da obtenção de matrizes de confusão ou matrizes de erros, calculando assim, o índice de exatidão

global (Equação 1) e índice kappa (Equação 2) dos resultados obtidos. Segundo Congalton (1991), uma matriz de erro pode ser usada como ponto de partida para aplicação de uma série de técnicas estatísticas, tanto descritiva quanto analítica. A Tabela 1 que apresenta a avaliação da qualidade da classificação proposta por Landis e Koch (1977) e Foody (2002), sugerem níveis recomendados para métricas de exatidão global e do índice kappa em torno de 0.85.

Tabela 1. Qualidade de classificação associada aos valores do índice kappa.

<i>Índice kappa</i>	<i>Qualidade</i>
0	Péssima
0,01 a 0,20	Ruim
0,21 a 0,40	Razoável
0,41 a 0,60	Boa
0,61 a 0,80	Muito Boa
0,81 a 1,00	Excelente

Fonte: Landis e Koch (1977).

$$EG = \frac{A}{n} * 100 \quad (1)$$

$$K = \frac{\left[n * \sum_{i=1}^r x_{ij} - \sum_{i=1}^r (x_i * x_j) \right]}{\left[n^2 - \sum_{i=1}^r (x_i * x_j) \right]} \quad (2)$$

3. Resultados e Discussão

A Figura 2 mostra o recorte de 1024 x 1024 pixels da cena Landsat-5/TM. Para uso dos classificadores, aplicou-se a máscara dos temas cidade e rodovia apresentado na Figura 3, sobre o recorte da composição RGB453.

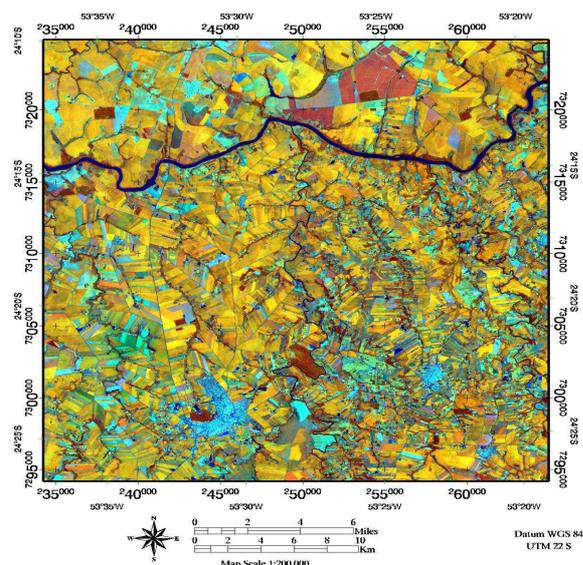


Figura 2. Recorte de 1024 x 1024 pixels da cena Landsat-5.

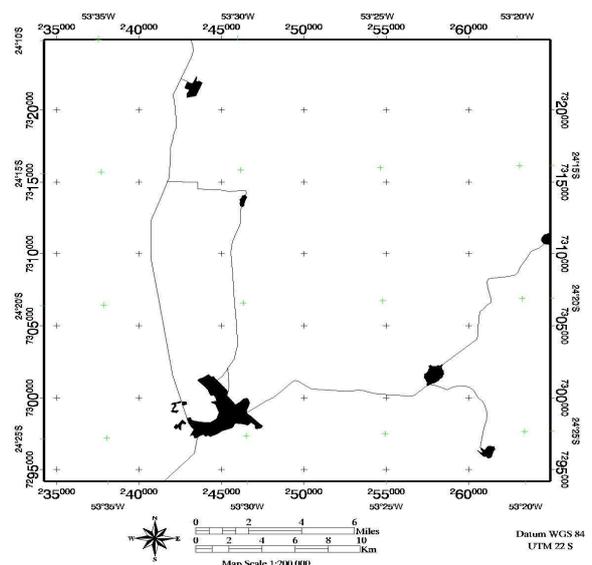


Figura 3. Máscara das cidades e rodovias.

3.1 Classificadores

IsoData: Na análise desse classificador (não supervisionado) identificou-se 18,90% de área como sendo soja, um percentual de 26,60% de cana-de-açúcar, um total de 23,24% de solo, apenas 2,53% de água e a maior parte (28,73%) como vegetação, conforme Tabela 1. A visualização da Figura 4 mostra que o resultado não foi bom, pois a maior parte da área caracteriza-se como áreas de solo exposto e soja, o que para o classificador estão apenas em 3° e 4° lugares, respectivamente.

Paralelepípedo: O resultado da aplicação do método de classificação supervisionado de paralelepípedo é mostrado na Figura 5. Verifica-se que grande parte da imagem ficou na cor preta, ou seja, muitos pixels da imagem não foram classificados em nenhum dos temas propostos. Observou-se que o classificador teve dificuldade na avaliação de todos os temas da imagem. Este método apresenta algumas limitações, pelo fato de alguns pixels não se enquadrarem dentro dos valores que definem os paralelepípedos.

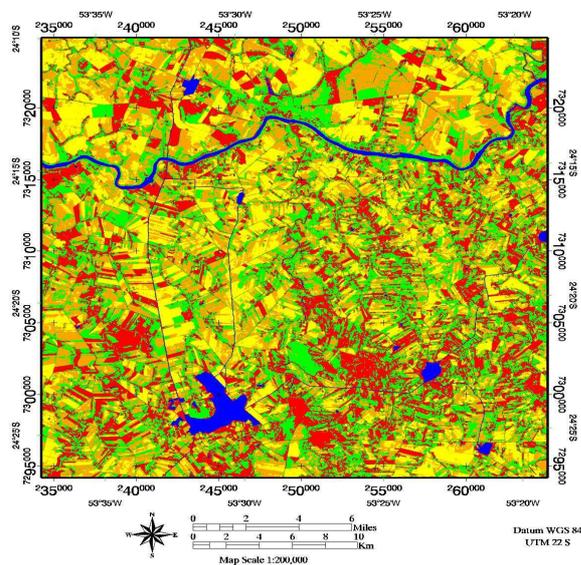


Figura 4. Resultado da aplicação do classificador não supervisionado "IsoData".

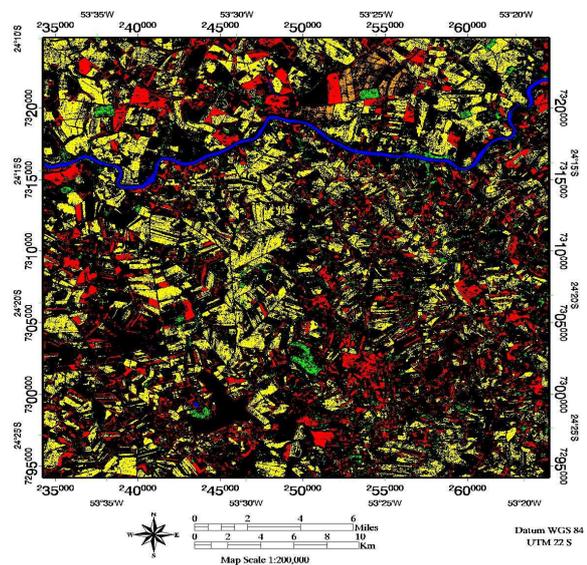


Figura 5. Resultado do método de classificação supervisionado paralelepípedo.

Mínima Distância: Analisando a Figura 6 nota-se que nenhum pixel da imagem deixou de ser classificado. Entretanto as áreas (rodovias e cidades) especificadas como máscara foram equivocadamente contabilizadas como água (cor azul). Dentre os dois últimos temas, principalmente a cana-de-açúcar ficou com um percentual de área muito maior que na realidade existe, provavelmente em função da confusão que o classificador fez com áreas de soja e solo exposto. De forma geral, o resultado deste classificador ficou razoavelmente bom havendo apenas algumas confusões nas classificações dos temas.

Máxima Verossimilhança: A Figura 7 apresenta um bom resultado desse classificador quando comparado aos métodos anteriores. Entretanto, observou-se alguma confusão na classificação do tema vegetação que foi subestimado e também apresentou alguns pixels não classificados, entretanto, o restante dos alvos está bem definido.

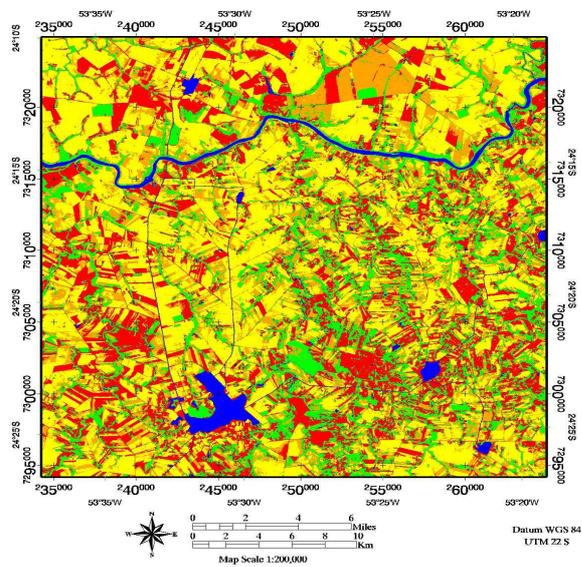


Figura 6. Resultado do método de classificação supervisionado de Mínima Distância.

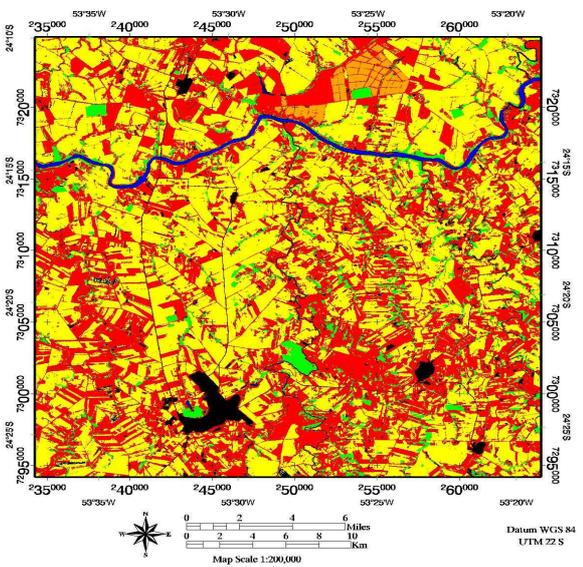


Figura 7. Resultado do método de classificação supervisionado de Máxima Verossimilhança.

Distância de Mahalanobis: Este classificador conseguiu uma melhor avaliação de áreas com vegetação. Todos os pixels da imagem foram classificados em algum tema, como verificados na Figura 8. De forma geral, houve diferenças significativas de área entre o método de Máxima Verossimilhança e o método de Mahalanobis. Entretanto, deste último método utilizou-se apenas o tema vegetação, que neste caso representou 22,58% da imagem e os demais temas utilizou-se o método Máxima Verossimilhança, gerando assim, um classificador em que se juntaram os melhores resultados destes dois métodos que será apresentado na sequência.

Fusão do classificador supervisionado de Máxima Verossimilhança e Distância de Mahalanobis: O resultado da fusão dos classificadores supervisionados de Máxima Verossimilhança e Distância de Mahalanobis é mostrado na Figura 9. Ao fazer uma comparação visual entre a área original e o classificador observa-se que o resultado ficou satisfatório, uma vez que maior parte das áreas de solo exposto, vegetação, soja, água e cana-de-açúcar observadas na Figura 2 correspondem realmente a estes temas.

A Tabela 2 apresenta os resultados estatísticos da imagem, segundo aplicação dos classificadores. De modo geral, verificou-se que o método paralelepípedo não mostrou um bom resultado, uma vez que pouco mais de 70% da imagem não foi classificada. Nos outros métodos todos os pixels foram classificados, sendo alguns de forma confusa para a compreensão de um mapa, com exceção do classificador Máxima Verossimilhança que não conseguiu classificar 4,20% dos pixels da imagem e classificou apenas 5,67% de vegetação, porém para outros alvos sua classificação está de acordo com a imagem real.

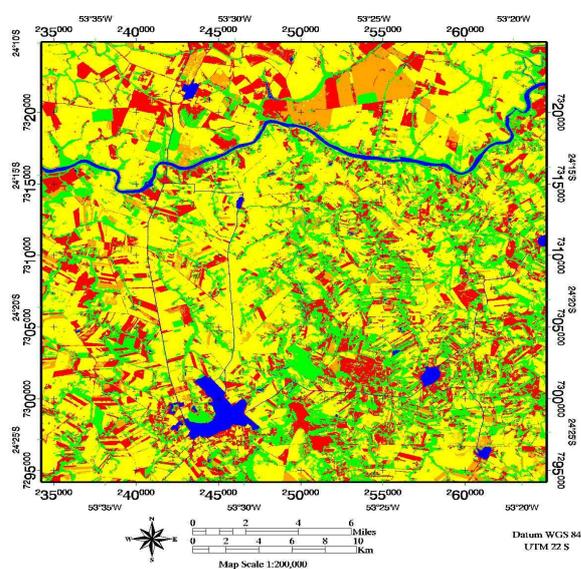


Figura 8. Resultado do método de classificação supervisionado Distância de Mahalanobis.

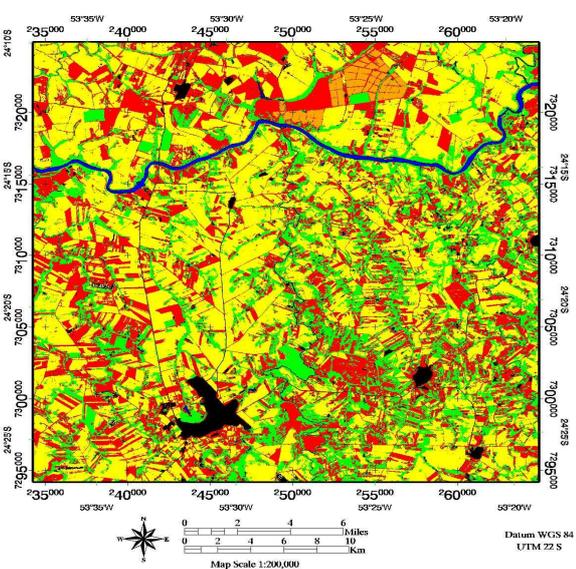


Figura 9. Resultado da fusão do método de classificação supervisionado de Máxima Verossimilhança e Mahalanobis.

Tabela 2. Estatística da proporção dos temas obtidos pelos classificadores.

<i>Temas</i>	<i>IsoData</i>	<i>Paralelepípedo</i>	<i>Mínima distância</i>	<i>Máxima Verossimilhança</i>	<i>Mahalanobis</i>	<i>MaxVer_Mah.</i>
Vegetação	28,73%	0,87%	18,07%	5,68%	22,58%	21,53%
Água	2,53%	0,81%	2,73%	0,89%	2,56%	0,85%
Cana-de-açúcar	26,60%	0,40%	20,15%	1,65%	7,27%	1,63%
Soja	18,90%	17,09%	35,98%	48,83%	50,10%	44,94%
Solo exposto	23,24%	7,76%	23,08%	38,77%	17,49%	26,85%
Não classificado (cidades/rodovias)	0,00%	73,07%	0,00%	4,20%	0,00%	4,20%

Nota: MaxVer_Mah = Fusão Máxima Verossimilhança e Mahalanobis.

Com a fusão dos classificadores Máxima Verossimilhança e Distância de Mahalanobis, as estatísticas das áreas mostradas na Tabela 3 a maior proporção da imagem foi classificada como soja, seguido de solo exposto, vegetação, cana-de-açúcar, água e finalmente um total de 4,20% que se referem às áreas das cidades e rodovias. Desta forma, dos 94.371,84ha da imagem recortada, foi constatado que 42.412,23ha tinham o cultivo de soja, havia um total de 25.335,81ha com solo exposto e outros 20.322,45ha eram de algum tipo de vegetação (mata ciliar, mata nativa, reflorestamento) e apenas 1.539,18ha apresentaram o cultivo da cana-de-açúcar. Outros 800,10ha eram de água e 3.962,07ha referiam-se à área das cidades e principais rodovias na imagem.

Tabela 3. Análise da área da imagem fusionada pelos dois classificadores supervisionados de Máxima Verossimilhança e Distância de Mahalanobis.

<i>Temas</i>	<i>Porcentagem</i>	<i>Porcentagem Acumulada</i>	<i>Área Imagem (m²)</i>	<i>Área Imagem(Km²)</i>	<i>Área Imagem (ha)</i>
Vegetação	21,53%	21,53%	203.224.500	203,22	20.322,45
Água	0,85%	22,38%	8.001.000	8,00	800,10
Cana-de-açúcar	1,63%	24,01%	15.391.800	15,39	1.539,18
Soja	44,94%	68,95%	424.122.300	424,12	42.412,23
Solo	26,85%	95,80%	253.358.100	253,36	25.335,81
Não classificado (cidades/rodovias)	4,20%	100,00%	39.620.700	39,62	3.962,07
TOTAL	100%	-	943.718.400	943,72	94.371,84

3.2 Métodos de avaliação da acurácia dos resultados

Foram distribuídos 200 (duzentos) pontos amostrais, segundo a técnica de amostragem estratificada, dentro do limite da área de trabalho. A partir destes pontos gerou-se a matriz de confusão entre a referência, ou seja, a imagem RGB453 (recorte de 1024 x 1024 pixels) e o classificador (fusão do classificador supervisionado de Máxima Verossimilhança e Distância de Mahalanobis). O resultado é mostrado na Tabela 4. O ideal seria a comparação com a referência terrestre, porém os padrões de uso na região são bastante conhecidos nesta composição RGB, e a checagem foi realizada tendo como base na imagem Landsat, composição RGB453.

Os dados da diagonal principal representam o número de acertos obtidos pelas duas referências. Os “erros de inclusão” foram nulos para os temas “água”, “cana-de-açúcar” e “soja”. Já o “solo exposto” e a “vegetação” apresentaram, respectivamente, erros de 8,47% e 36,96%. Assim, pode-se dizer que 8,47% dos pixels de “solo exposto” eram pertencentes a outros temas (soja com 6,78% e vegetação com 1,69%), porém, o classificador classificou como se fossem pixels de “solo exposto”. Desta forma, 80,00% (6,78/8,47) deste “erro de inclusão” ocorreram com o tema “soja” e o restante com o tema “vegetação”.

Tabela 4. Matriz de erro ou matriz de confusão.

<i>Referência (classificador MaxVer_Mah)</i>	<i>Referência (Imagem RGB453)</i>					<i>Total geral</i>	<i>Erro de Inclusão</i>
	<i>Água</i>	<i>Cana-de-açúcar</i>	<i>Soja</i>	<i>Solo Exposto</i>	<i>Vegetação</i>		
Água	2	0	0	0	0	2	0,00%
Cana-de-açúcar	0	2	0	0	0	2	0,00%
Soja	0	0	91	0	0	91	0,00%
Solo Exposto	0	0	4	54	1	59	8,47%
Vegetação	0	0	7	10	29	46	36,96%
Total geral	2	2	102	64	30	200	-
Erro de Omissão	0,00%	0,00%	10,78%	15,63%	3,33%	-	-

Do total das 200 amostras, pela soma da diagonal principal da matriz de erros observou-se que 178 amostras foram classificadas corretamente. Com base nisto, obteve-se o índice de exatidão global (EG) de 89%. Ou seja, 89% das amostras foram corretamente identificadas pelo classificador quando comparada com a do recorte da imagem RGB453, mostrando um bom resultado do classificador.

Já o índice kappa (K) foi determinado para avaliar a exatidão dos dados permitindo uma visualização dos resultados da classificação temática em relação ao recorte da imagem RGB453. O resultado indicou um coeficiente kappa de 0.8278.

Como o índice kappa refere-se a um método para avaliar a concordância ou discordância entre duas situações, pode-se dizer que houve uma concordância de 82,78% das amostras na área de interesse, deste modo a classificação na área estudada aproximou-se da realidade do campo.

4. Conclusões

Foram realizadas várias simulações de classificação de temas na imagem, não supervisionadas e supervisionadas. Dentre elas, a fusão entre o classificador supervisionado de Máxima Verossimilhança e o de Mahalanobis foi o que apresentou o melhor resultado.

Na análise da acurácia da fusão dos classificadores Máxima Verossimilhança e Distância de Mahalanobis, aplicados ao recorte da imagem RGB453, verificou-se uma Exatidão Global de 89% e um Coeficiente Kappa de 82,78%, evidenciando que a fusão destes classificadores apresentou um excelente resultado. Esses dados demonstram o bom índice de acerto na interpretação do uso do solo na região estudada, mesmo trabalhando-se com um satélite como o Landsat-5/TM que possui uma resolução espacial de 30m.

5. Agradecimentos

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Capes, pelo apoio financeiro.

Referências Bibliográficas

CONGALTON, R.G. **A review of assessing the accuracy classificatons of remotely sensed data.** Remote Sensing Environment, v. 37, p.35-46, 1991.

CUNHA, M. S. **Dinâmica da modernização agropecuária do norte paranaense, 1970-85.** (UEL C972D) Monografia (Graduação em Ciências Econômicas) - Fundação Universidade Estadual de Londrina, 1993. Londrina. 121 p.

CROSTRA, A. P. **Processamento digital de imagens de sensoriamento remoto.** 4 ed. rev. Campinas: Instituto de Geografia – UNICAMP, 2002. p164.

EASTMAN, J. Ronald – **Manual do usuário** - Exercícios tutoriais Idrisi for Windows, versão 2.0. Tradução para o português, H. Hasenack e E. Weber. Porto Alegre, 1998. 240p.

FOODY, G. M. Status of land cover classification accuracy assessment. **Remote Sensing of Environment**, v. 80, n. 1, p. 185-201, 2002.

LANDIS, J.R.; KOCH, G.G. The measurement of observer agreement for categorical data. **Biometrics**, v. 33, n. 1, p. 159-174, 1977.

MANGABEIRA, J. A. C., AZEVEDO, E. C., LAMPARELLI, R. A. C. Avaliação do levantamento do uso das terras por imagens de satélite de alta e média resolução espacial. **Comunicado técnico 11.** Campinas: Embrapa, 2003.15p.