

## **Impacto de técnicas baseadas em conhecimento na análise de imagens de média resolução para mapeamento do desflorestamento na Amazônia**

Raul Queiroz Feitosa<sup>1</sup>, Cristina Mattos<sup>2</sup>, Rafael Valle dos Santos<sup>1</sup>,  
Luiz Felipe Guanaes Rego<sup>3</sup>, Alex Augusto Carrera Pereira<sup>2</sup>

<sup>1</sup> PUC – Departamento de Energia Elétrica  
Rua Marquês de São Vicente 225, 22453-900, Rio de Janeiro - RJ, Brasil  
raul@ele.puc-rio.br; rvsantos@cruiser.com.br

<sup>2</sup> Fundação Aplicações de Tecnologias Críticas - ATECH  
Rua do Rócio 313, 11º andar, Vila Olímpia, 04552-000, São Paulo - SP, Brasil  
cmattos@atech.br; augusto@it.atech-mn.br

<sup>3</sup> PUC – Departamento de Geografia e Meio Ambiente  
Rua Marquês de São Vicente 225, 22453-900, Rio de Janeiro - RJ, Brasil  
regoluiz@rdc.puc-rio.br

**Abstract.** This paper investigates the potential of knowledge based techniques to improve the productivity of photo interpretation process of medium-resolution satellite images of the Amazon, and assesses the impact they may bring to the task of mapping the deforestation in this region by SIPAM (System for the Protection of the Amazon) and other regional monitoring programs. Specifically, this work estimates how much of the work conventionally performed by an analyst can be done automatically by exploring knowledge based techniques. Landsat images of Rondônia State were submitted to supervised classification; the subsequent editing of these classifications, a usually manual process that depends totally on the knowledge and experience of the analyst, was then performed using a knowledge base implemented in eCognition. The results showed that more than 30% of the editing step could be automated using these techniques, increasing the efficiency of the deforestation mapping from Landsat images in the study area.

**Palavras-chave:** image processing, knowledge based systems, Amazon, processamento de imagens, sistemas baseados em conhecimento, Amazônia.

### **1. Introdução**

Face à sua reconhecida importância global, regional e local, e às ameaças que enfrenta, a Região Amazônica tem sido o objeto de interesse por parte de muitos, de políticos a cientistas, de ambientalistas à população em geral. Em busca de medidas que garantam seu desenvolvimento sustentável e combatam o desmatamento, queimadas e impactos ambientais que caracterizam o processo de ocupação humana da Amazônia nas últimas décadas, vários programas, políticas públicas, instrumentos legais e institucionais têm sido propostos e implementados. O Projeto SIPAM (Sistema de Proteção da Amazônia) é uma destas iniciativas. Empregando modernas tecnologias, sistemas de processamento de dados e telecomunicações, e uma vasta rede de sensores terrestres, aéreos e orbitais, monitora os ecossistemas e atividades humanas na região, gerando dados para aplicações meteorológicas, ambientais, logísticas, de controle de tráfego aéreo e vigilância. Dentre as muitas ações do SIPAM está o monitoramento e mapeamento do desflorestamento, usando dados de Sensoriamento Remoto.

A tecnologia de sensoriamento remoto tem provido meios para o monitoramento de grandes áreas da superfície da terra em termos de florestas, ecossistemas, áreas produtivas e espaços urbanos. Além do crescente número de novos sensores orbitais, muitos programas de computadores têm sido desenvolvidos incorporando os recentes avanços em sensoriamento

remoto. Apesar do grande progresso observado nos últimos anos, a interpretação de imagens é ainda um processo predominantemente manual que requer grande esforço e perícia do foto-intérprete.

Recentemente, tem crescido em todo o mundo o interesse pelos chamados Sistemas Baseados em Conhecimento (McKeown et al., 1985; Matsuyama & Hwang, 1990; Clément et al., 1993; Niemann et al., 1990; Liedtke, 1997; Bückner et al., 2001), que procuram modelar num ambiente computacional o conhecimento do foto-intérprete e emular sua capacidade de combinar dados de diferentes fontes e diferentes formatos na avaliação de imagens de sensores remotos. Tais sistemas buscam reproduzir num computador o raciocínio do foto-intérprete, de modo a realizar automaticamente grande parte da tarefa que, nos sistemas convencionais, fica a cargo do operador humano.

Escassas têm sido as soluções baseadas em conhecimento aplicadas a imagens de satélite de média resolução espacial (e.g., Landsat) (Zhang, 1998; Kunz, 1999; Kunz et al., 1997; Largouët & Cordier, 2000). Em particular, pouco se tem feito para a Região Amazônica.

O objetivo central deste trabalho é estimar o impacto de técnicas baseadas em conhecimento sobre a produtividade do processo de foto-interpretção de imagens de média resolução espacial da Região Amazônica, para o mapeamento do desflorestamento, estimando quanto das etapas manuais do processamento de imagens Landsat pode ser automatizado.

O procedimento clássico de interpretação baseado em classificação supervisionada envolve três passos principais: a) seleção de polígonos de treinamento; b) aplicação de um classificador estatístico, (e.g., máxima probabilidade); c) edição do resultado do classificador.

Destes, apenas o passo *b*) é realizado de forma automática. Os demais passos requerem a intervenção de um operador humano. Este trabalho diz respeito à automatização (pelo menos parcial) do passo *c*), mediante a modelagem do raciocínio aplicado pelo foto-intérprete na edição. Trata-se de introduzir entre os passos *b*) e *c*) um passo intermediário que recebe como entrada o resultado do classificador estatístico e realiza de forma automática parte da edição. O resultado produzido por este novo passo, ainda que não elimine completamente, reduz o trabalho a ser feito na edição, aumentando, assim, a produtividade do processo de foto-interpretção.

Neste trabalho, tomou-se um segmento de uma imagem Landsat de Rondônia como área de estudo. O ponto de partida para a análise foi a classificação pixel-a-pixel supervisionada, produzida de forma semi-automática (passos *a*) e *b*)), seguindo o procedimento usual adotado para este tipo de análise. Em seguida, montou-se uma base de conhecimento que representa o procedimento do foto-intérprete durante o passo *c*). Ao final, avaliou-se o quanto da edição manual foi realizada automaticamente pelo método baseado em conhecimento.

A seguir, são descritos a base de conhecimento construída para a área de interesse (Seção 2); a o procedimento adotado na avaliação experimental (Seção 3); os resultados obtidos (Seção 4); as principais conclusões do trabalho (Seção 5).

## 2. Base de conhecimento

A base de conhecimento utilizada neste piloto foi obtida junto a um analista com larga experiência na Amazônia e na interpretação de imagens da área alvo para o mapeamento do desflorestamento. Partindo de um relatório inicial sobre o procedimento empregado nesta interpretação de imagens, a base de conhecimento foi sendo refinada, através de um ciclo de entrevistas e implementações que se repetiu por algumas iterações até chegar à forma final.

Para simplificar o texto que se segue, utilizam-se os termos *supervisionada*, *editada* e *final* para designarem, respectivamente, a classificação supervisionada, a classificação editada manualmente pelo foto-intérprete e utilizada como referência para comparação de desempenho, e a classificação baseada em conhecimento.

## 2.1. Dados de entrada e legenda

O sistema construído tem como entrada:

- A imagem a ser classificada;
- O resultado da classificação supervisionada, que inclui as classes: *Agropecuária*, *Floresta*, *Regeneração*, *Sombra* e *Água*;
- Máscara definindo a localização das cidades;
- Máscara definindo a posição aproximada dos rios.<sup>1</sup>

As classes identificadas na classificação final são: *Agropecuária*, *Urbana*, *Nuvem*, *Floresta*, *Regeneração*, *Sombra*, *Água*.

É importante notar que a classificação supervisionada não contém as classes *Urbano* nem *Nuvem*, que aparecem nas classificações editada e final. De fato, os *pixels* destas duas classes são atribuídos à classe *Agropecuária*, na classificação supervisionada. Trata-se de uma opção do foto-intérprete, que separa estas três classes somente na fase de edição manual (após classificação supervisionada).

## 2.2. Descrição simplificada da base de conhecimento

O conjunto de regras montado para este estudo é apresentado de modo simplificado na **Tabela 1**, que indica as três principais confusões que cabem ao foto-intérprete resolver na fase de edição e, portanto, também ao sistema baseado em conhecimento desenvolvido neste estudo.

**Tabela 1.** Descrição simplificada das regras utilizadas para modelar o conhecimento utilizado pelo foto-intérprete na edição.

	Classes Finais	Descrição das Classes
1	<i>Agropecuária</i>	Definido como <i>Agropecuária</i> na classificação supervisionada e não é <i>Nuvem</i> nem região <i>Urbana</i> .
	<i>Urbano</i>	Definido na carta topográfica do IBGE.
	<i>Nuvem</i>	Definido como <i>Agropecuária</i> na classificação supervisionada e tem brilho muito alto; Áreas pequenas de <i>Agropecuária</i> fazendo fronteira com objetos de brilho muito alto são bordas de nuvens; Áreas pequenas de <i>Agropecuária</i> que projetam <i>Sombra</i> são <i>Nuvens</i> pequenas.
2	<i>Floresta</i>	Definido como <i>Floresta</i> na classificação supervisionada e possui brilho baixo.
	<i>Regeneração</i>	Tudo que é definido como <i>Regeneração</i> na classificação supervisionada.
3	<i>Sombra</i>	Objeto escuro para o qual existe <i>Nuvem</i> que projete sombra sobre ele.
	<i>Água</i>	Corpo escuro próximo à rede hidrográfica; Corpo escuro para o qual não existe <i>Nuvem</i> que projete sombra sobre ele.

A primeira confusão importante envolve as classes *Agropecuária*, *Urbano* e *Nuvem*, que possuem respostas espectrais semelhantes. A rigor, nuvens grandes possuem cor branca muito distintiva em seu centro e podem ser distinguidas espectralmente sem dificuldade. A confusão ocorre nas bordas das nuvens, com uma resposta espectral que se aproxima da de *Agropecuária*. O mesmo fenômeno se observa em nuvens pequenas.

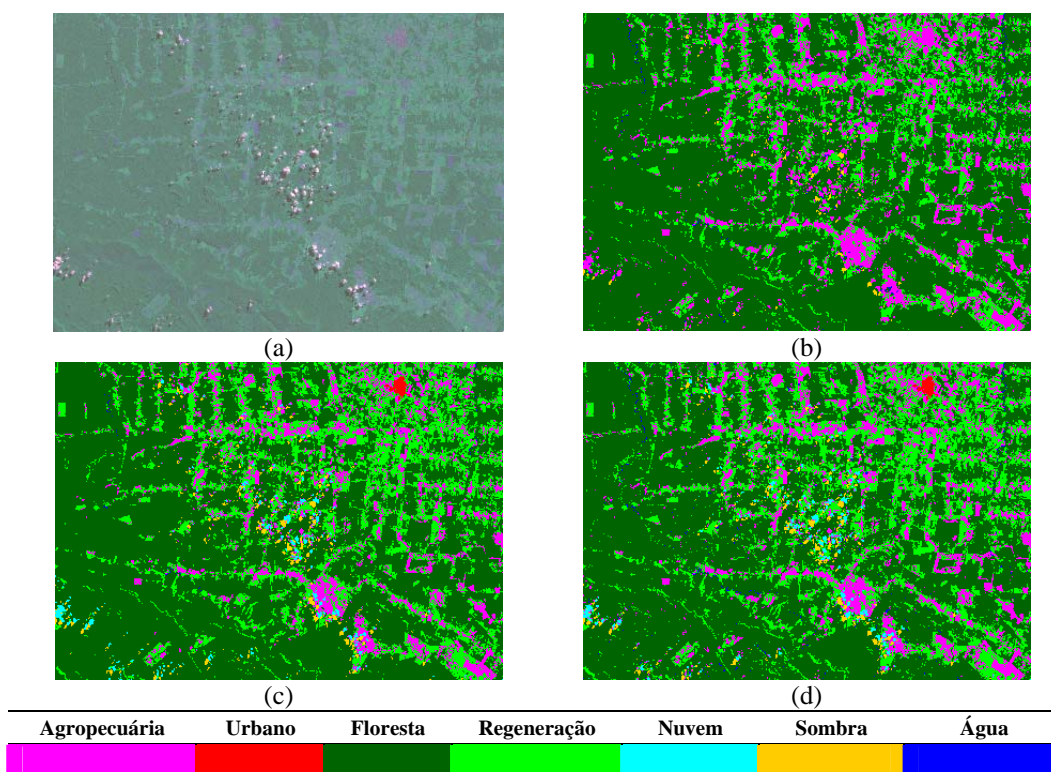
O segundo tipo importante de confusão envolve as classes *Floresta* e *Regeneração*. São coberturas vegetais que se distinguem espectralmente pelo brilho ou pela textura.

O último tipo de confusão relevante ocorre entre as classes *Sombra* e *Água*, que se caracterizam por valores espectrais muito baixos em todas as bandas.

<sup>1</sup> Dados sobre áreas urbanas e hidrografia foram obtidos a partir de cartas topográficas do Instituto Brasileiro de Geografia e Estatística (IBGE), na escala 1:250.000.

### 3. Design do experimento

Um protótipo implementando o modelo de conhecimento gerado foi construído, utilizando as ferramentas eCognition e MATLAB. A base para esta avaliação foi uma imagem LANDSAT, cena 231/066, de 2002, bandas 3, 4 e 5, em projeção UTM. Para este experimento foi selecionado um segmento da cena contendo 2098 linhas e 1485 colunas, numa imagem em formato TIFF, no qual todas as classes da legenda estão representadas. A **Figura 1a** mostra o segmento selecionado, utilizando uma composição das bandas 3, 4 e 5 nos canais RGB.



**Figura 1.** (a) Segmento de imagem utilizado no experimento; (b) Resultado da classificação supervisionada; (c) Resultado da classificação editada; (d) Resultado da classificação final, com base em conhecimento<sup>2</sup>.

Para a classificação supervisionada, utilizou-se um classificador de *pixels*. Segmentos com área de até 16 *pixels* foram eliminados e associados às classes de seus vizinhos. Foram usados ainda, como dados auxiliares, cartas topográficas do IBGE localizando as áreas urbanas e a rede hidrográfica.

O primeiro passo adotado foi segmentar a imagem, utilizando exclusivamente um critério de homogeneidade relacionado apenas à resposta espectral. A segmentação foi realizada de modo a garantir que todos os *pixels* de cada segmento tivessem uma única classe associada na classificação supervisionada. Todo o processo de interpretação baseado em conhecimento considerou cada segmento como um objeto indivisível, caracterizado por sua resposta espectral média, área e posição em relação aos outros objetos da imagem.

A **Figura 1b** mostra o resultado da classificação supervisionada. O resultado da edição manual é apresentado na **Figura 1c**.

<sup>2</sup> Imagens completas disponíveis em [http://www.ele.puc-rio.br/~raul/ATECH/Segmento\\_de\\_teste.tif](http://www.ele.puc-rio.br/~raul/ATECH/Segmento_de_teste.tif), <http://www.ele.puc-rio.br/~raul/ATECH/Supervisionada.tif>, <http://www.ele.puc-rio.br/~raul/ATECH/Editada.tif>, [http://www.ele.puc-rio.br/~raul/ATECH/Final\\_Corrigida.tif](http://www.ele.puc-rio.br/~raul/ATECH/Final_Corrigida.tif) (a, b, c e d, respectivamente).

#### 4. Resultados

Os resultados da aplicação do modelo de conhecimento estão apresentados na **Figura 1d**. As **Tabelas 2 e 3** apresentam estes resultados na forma de matrizes de confusão respectivamente da Classificação Supervisionada e da Classificação Final Baseada em Conhecimento, em ambos os casos em relação à Classificação Editada, usada como referência. Os valores das tabelas são expressos em números de *pixels*.

**Tabela 2.** Matriz de confusão da classificação supervisionada em relação à classificação editada.

Supervisionada	Editada						
	Agropecuária	Urbano	Nuvem	Floresta	Regeneração	Sombra	Água
Agropecuária	<b>268269</b>	<b>5189</b>	<b>27502</b>	13056	49807	252	68
Urbano	<b>0</b>	<b>0</b>	<b>0</b>	0	0	0	0
Nuvem	<b>0</b>	<b>0</b>	<b>0</b>	0	0	0	0
Floresta	833	0	177	<b>2056160</b>	<b>125595</b>	20466	127
Regeneração	11316	3	254	<b>25794</b>	<b>490144</b>	29	22
Sombra	0	0	0	3	0	<b>11541</b>	<b>47</b>
Água	909	9	169	3006	237	<b>2842</b>	<b>1704</b>

**Tabela 3.** Matriz de confusão da classificação final em relação à classificação editada.

Final	Editada						
	Agropecuária	Urbano	Nuvem	Floresta	Regeneração	Sombra	Água
Agropecuária	<b>261823</b>	<b>0</b>	<b>4440</b>	11897	49305	133	57
Urbano	<b>0</b>	<b>5201</b>	<b>0</b>	0	0	0	0
Nuvem	<b>6336</b>	<b>0</b>	<b>23057</b>	1138	312	74	11
Floresta	354	0	109	<b>1977044</b>	<b>14763</b>	2550	40
Regeneração	11872	0	324	<b>97516</b>	<b>601143</b>	44	26
Sombra	702	0	172	3049	35	<b>29774</b>	<b>76</b>
Água	240	0	0	7375	225	<b>2555</b>	<b>1758</b>

Pode-se ver nas tabelas os três tipos principais de confusões citados na seção 2.2, entre as classes: *Agropecuária* × *Urbano* × *Nuvem*; *Floresta* × *Regeneração*; *Sombra* × *Água*.

A discussão que se segue analisa o desempenho do protótipo construído do ponto de vista de sua capacidade de resolver cada um destes três tipos principais de confusões.

##### 4.1. *Agropecuária* × *Urbano* × *Nuvem*

Como já foi mencionado, a classificação supervisionada não contém as classes *urbano* e *nuvem*, que só aparecem nas classificações editada e final. Todos os *pixels* destas classes aparecem como *Agropecuária* na classificação supervisionada. Ao unificar as três classes em *Agropecuária*, o erro de omissão para esta classe fica muito reduzido na classificação supervisionada. Isto se reflete nos resultados das tabelas que mostram um valor de reconhecimento da classificação supervisionada mais alto do que da classificação final para *Agropecuária* (268269 contra 261823). Isto ocorre, no entanto, em prejuízo das classes *Urbano* e *Nuvem*, ignoradas na classificação supervisionada.

A classificação final apresenta um resultado muito mais equilibrado entre as três classes do que a classificação supervisionada. Identifica-se a maioria dos *pixels* da classe *Nuvem* e a totalidade dos *pixels* da classe *Urbano*, ainda que ao custo de uma redução (cerca de 2%) na identificação dos *pixels* da classe *Agropecuária*.

Cálculos simples usando os dados das tabelas permitem concluir que o erro de omissão para *Agropecuária*, *Urbano* e *Nuvem* passou respectivamente de 5%, 100% e 100% na classificação supervisionada para 7%, 0% e 18% na classificação final, uma melhora significativa.

É interessante ainda mencionar que o método baseado em conhecimento pouco alterou o

número de *pixels* da classe *Agropecuária* atribuídos à classe *Regeneração*. De fato, não se levantou junto ao foto-intérprete a lógica aplicada para transferir *pixels* da classe *Regeneração* na classificação supervisionada para a classe *Agropecuária* durante a edição (**Tabela 1**).

#### 4.2. Floresta × Regeneração

As **Tabelas 2 e 3** mostram claramente a dificuldade para separar as classes *Floresta* e *Regeneração*. Novamente, neste caso, deve-se analisar o comportamento do protótipo para estas duas classes em conjunto. Observa-se que a classificação final identifica um pouco menos *pixels* da classe *Floresta* do que a própria classificação supervisionada. Por outro lado, há uma melhora expressiva na identificação da classe *Regeneração*. O uso de conhecimento permitiu passar de 2% e 26% para 6% e 10% para estas respectivas classes.

Neste ponto, vale a pena introduzir um comentário que se aplica especialmente, mas não apenas, a estas duas classes. O foto-intérprete comparou os resultados da classificação final com a classificação editada e, para várias regiões da imagem, considerou que a classificação final foi superior à editada, particularmente para estas duas classes. É, portanto, de se supor que os indicadores de desempenho apresentados nas **Tabelas 2 e 3** seriam melhores, caso se utilizasse como referência uma classificação editada mais correta.

Uma análise mais acurada das confusões indicou que a maior parte das discrepâncias entre a classificação editada e a final ocorre em *pixels* junto às bordas de segmentos adjacentes que pertencem a classes que se confundem, ou em segmentos muito finos de uma classe colocados no meio da outra com que se confunde. Verificou-se que 87% da área total de discrepâncias entre *Regeneração* na classificação editada e *Floresta* na final estão sobre istimos com espessura igual a um *pixel*. Para o caso em que a editada indica *Floresta* e a final indica *Regeneração*, este valor é igual a 37%.

#### 4.3. Sombra × Água

A confusão entre *Sombra* e *Água* é freqüente em classificação de imagens, pois ambas se apresentam como regiões escuras. Foi na separação entre estas classes que, neste protótipo, fez-se o uso mais extensivo e bem sucedido das técnicas baseadas em conhecimento.

As matrizes de confusão mostram que a maioria dos *pixels* erroneamente atribuídos a *Floresta* na classificação supervisionada foram corrigidos para *Sombra* na final. Isto se deu em duas etapas. Inicialmente, os *pixels* escuros foram atribuídos a uma classe auxiliar chamada *Corpo\_Escuro\_0*. Desta forma, a quase totalidade dos *pixels* escuros atribuídos a *Floresta* na supervisionada foram associados à classe *Corpo\_Escuro\_0*. Na etapa seguinte, estes *pixels* escuros foram separados em *Sombra* e *Água*, explorando técnicas baseadas em conhecimento. Basicamente, foram atribuídos à classe *Água* os *pixels* escuros próximos de rios. Esta informação estava disponível em mapas de hidrografia que, devido à baixa resolução, fornecem apenas a posição aproximada dos rios sobre a imagem. Criou-se, assim, uma regra nebulosa que leva em conta a distância do objeto a ser classificado à posição dos rios mais próximos indicada nos mapas. Para identificar um *pixel* escuro como *Sombra*, o método baseado em conhecimento verifica a existência de *Nuvem* a uma distância e numa determinada direção, que potencialmente estaria projetando sombra sobre aquele corpo escuro.

As matrizes de confusão mostram que o método conseguiu separar eficientemente estas duas classes e, assim, produzir um aumento dos valores de reconhecimento (valores nas diagonais) não apenas para *Sombra*, mas também para *Água*.

#### 4.4. Avaliação global

Os experimentos realizados não permitem estimar diretamente a redução do tempo de edição

alcançado pela modelagem do conhecimento. É, contudo, possível estimar a proporção da área corrigida manualmente pelo foto-intérprete na edição e automaticamente pelo uso de técnicas baseadas em conhecimento. A **Tabela 4** mostra estes valores.

**Tabela 4.** Número de *pixels* corrigidos pelo manualmente foto-intérprete durante a edição manual e automaticamente pelo método baseado em conhecimento.

MÉTODO	Agropecuária/Urbano/Nuvem	Floresta/Regeneração	Sombra/Água
supervisionada	46361	217498	23853
base em conhecimento	24549	185615	5566

A diferença entre a segunda e terceira linhas da **Tabela 4** indicam a proporção do trabalho de edição realizada automaticamente pelo protótipo. O método baseado em conhecimento foi capaz de realizar 47% do trabalho de edição para o grupo de classes *Agropecuária/Urbana/Nuvem*. Para o grupo *Sombra/Água*, foi possível corrigir automaticamente mais de 75% da área a ser corrigida. Já para o grupo *Floresta/Regeneração*, o ganho foi de aproximadamente 15%. Em média, obteve-se um ganho de 49% para os três grupos considerados.

Quanto ao desempenho global, para a imagem utilizada, o protótipo foi capaz de realizar automaticamente 33% do trabalho de edição, em termos de área corrigida.

A base de conhecimento construída não levou em conta a ocorrência relativa de cada classe na imagem. Se a distribuição das áreas na imagem entre as classes fosse diferente, o desempenho medido poderia ser também muito distinto. O grupo de classes para as quais o modelo trouxe menos benefício foi exatamente o grupo mais freqüente. Pode-se estimar o ganho de desempenho numa situação em que todas as classes ocorressem na imagem na mesma proporção. Basta normalizar as matrizes de confusão, dividindo os valores das colunas pela soma da coluna correspondente. A **Tabela 5** mostra a porcentagem dos *pixels* de cada classe que demandariam correção após a classificação supervisionada e após a classificação final. A última coluna desta tabela apresenta o valor médio. Ela indica que, nesta hipótese, a classificação baseada em conhecimento realizaria 80% do trabalho de edição.

**Tabela 5.** Percentual dos *pixels* de cada classe corrigidos a partir da classificação supervisionada e a partir da classificação baseada em conhecimento.

MÉTODO	Agropecuária	Urbano	Nuvem	Floresta	Regeneração	Sombra	Água	Média
Supervisionada	5	100	100	2	26	67	13	45
Base em conhecimento	7	0	18	6	10	15	11	9

#### 4.5. Generalização

Alguns aspectos limitam a generalização dos resultados e conclusões deste experimento:

- Como o desempenho do protótipo foi distinto para os diferentes tipos de confusão, a eficiência global depende da ocorrência das classes na imagem utilizada;
- A qualidade dos dados de referência depende da experiência do foto-intérprete; não foram usados dados de verdade de campo para validar a classificação de referência;
- Somente um segmento de imagem foi utilizado para as análises;
- O potencial das técnicas baseadas em conhecimento foi explorado aqui de modo apenas preliminar. A base de conhecimento construída pode ser ainda bastante enriquecida com impactos potenciais importantes sobre o desempenho. O uso de dados multi-temporais é particularmente promissor, mas embora seja utilizado pelo foto-intérprete, não foi modelado neste experimento.

Uma avaliação definitiva do potencial destas técnicas para a automatização dos procedimentos de edição requererá um trabalho minucioso, para a construção de uma base de conhecimento que represente mais fielmente o raciocínio do foto-intérprete durante a edição. Isto

significa, na prática, realizar a parte mais importante que envolve a maior parcela do investimento necessário para o desenvolvimento de um sistema de classificação baseado em conhecimento. Um dos propósitos deste trabalho foi procurar evidências que justifiquem tal investimento. Neste sentido, os resultados obtidos são encorajadores e comprovam que métodos baseados em conhecimento são uma abordagem promissora para a automatização do processo de interpretação de imagens, mesmo para os níveis de resolução usados neste trabalho.

## 5. Comentários Finais

Este documento apresenta uma estimativa do potencial das chamadas abordagens baseadas em conhecimento para a automatização da interpretação de imagens Landsat da Região Amazônica. No experimento realizado, a modelagem empregada foi capaz de corrigir automaticamente 1/3 dos erros produzidos na classificação supervisionada convencional, reduzindo na mesma proporção o trabalho de edição manual, através da modelagem do raciocínio empregado pelo foto-intérprete na fase de edição.

Performances melhores poderão ser obtidas com o aperfeiçoamento da base de conhecimento. Apesar do número reduzido de imagens utilizadas e do tempo limitado para o desenvolvimento da base de conhecimento e do protótipo, os resultados encorajam que se estenda o trabalho, através de um esforço para complementar a base de conhecimento e validá-la sobre mais imagens de teste, incluindo outras cenas e outras datas de aquisição. Também encorajam o uso desta metodologia para o desenvolvimento de novas ferramentas para análise mais automática de imagens de Sensoriamento Remoto com base em conhecimento.

## Referências

- Bückner, J.; Stahlhut, O.; Pahl, M.; Liedtke., C.-E. GEOAIDA - A knowledge based automatic image data analyser for remote sensing data. In: Congress on Computational Intelligence Methods and Applications - CIMA 2001, 19-22 Jun 2001, Bangor, Wales, United Kingdom. **Proceedings...** 2001. CD-ROM.
- Clément, V.; Giraudon, G.; Houzelle, S.; Sandakly, F. Interpretation of remotely sensed images in a context of mutisensor fusion using a multispecialist architecture. **IEEE Transactions on Geoscience and Remote Sensing**, v. 31, n. 4, p. 779-791, Jul. 1993.
- Kunz, D. Investigation of synergy effects between satellite imagery and digital topographic databases by using integrated knowledge processing. **Int. Archives of Photogrammetry and Remote Sensing**, v. 32, Part 7-4-6 W6, 1999. Disponível em: <<http://www.data-fusion.org/ps/sig/meeting/Spain99ps/kunz.pdf>>. Acesso 12 nov.04.
- Kunz, D.; Schilling, K.; Vögtle, T. A new approach for satellite image analysis by means of a semantic network. In: Förstner, W.; Plumer, L. (ed.), **Semantic Modeling**. Basel: Birkhäuser, 1997. p. 20-36. Disponível em: <<http://citeseer.nj.nec.com/kunz97new.html>>. Acesso em: 12 nov. 2004.
- Largouët, C.; Cordier, M.-O. Timed automata model to improve the classification of a sequence of images. In: European Conference on Artificial Intelligence – ECAI'2000, 20-25 Aug. 2000, Berlin, Germany. **Proceedings...** 2000. p.156-160.
- Liedtke, C.-E. AIDA: a system for the knowledge based interpretation of remote sensing data. In: 3rd Int. Airborne Remote Sensing Conference & Exhibit, 7-10 Jul. 97, Copenhagen, Denmark. **Proceedings...** 1997. p. 313-320.
- Matsuyama, T.; Hwang, V. **SIGMA, a knowledge-base aerial image understanding system**. Advances in computer vision and machine intelligence. New York: Plenum, 1990.
- McKeown, D.M.; Harvey, W.A.; McDermott, J.. Rule based interpretation of aerial imagery. **IEEE PAMI**, v. 7, n. 5, p. 570-585, 1985.
- Niemann, H; Sagerer, G.; Schröder, S.; Ernest, F.K. A semantic network system for pattern understanding. **IEEE Transactions PAMI**, v. 12, n. 9, p. 883-905, Sep. 1990.
- Zhang, Y. Detection of urban householding development using multisensor satellite data. **International Archives of Photogrammetry and Remote Sensing**, v. 32, n. 3/1, p.292-299, 1998.