

DIOGO NOSES SPINOLA

**GENERALIZAÇÃO CARTOGRÁFICA EM SIG APLICADA
A UM MAPA DE USO E COBERTURA DO SOLO EM
FORMATO VETORIAL E MATRICIAL**

VIÇOSA, MG – BRASIL

JUNHO – 2010

**UNIVERSIDADE FEDERAL DE VIÇOSA
CENTRO DE CIÊNCIAS HUMANAS, LETRAS E ARTES
DEPARTAMENTO DE GEOGRAFIA**

**GENERALIZAÇÃO CARTOGRÁFICA EM SIG APLICADA
A UM MAPA DE USO E COBERTURA DO SOLO EM FORMATO
VETORIAL E MATRICIAL**

**Monografia apresentada à disciplina GEO
481 – Monografia e seminário, do curso de
Geografia da Universidade Federal de
Viçosa, como parte das exigências para
obtenção do título de Bacharel em
Geografia.**

Autor: Diogo Noses Spinola

**Orientador: Elpídio Inácio Fernandes
Filho**

Co-Orientadora: Fernanda Ayaviri Matuk

Viçosa, MG – Brasil

Junho de 2010

Monografia defendida e aprovada em 28 de Junho de 2010 pela banca examinadora:

Elpídio Inácio Fernandes Filho

Orientador

Departamento de Solos

UFV

Fernanda Ayaviri Matuk

Co-Orientadora

Departamento de Geografia

UFV

Bruno de Carvalho Resck

Departamento de Solos

UFV

SUMÁRIO

1. INTRODUÇÃO	6
2. REVISÃO BIBLIOGRÁFICA	8
2.1. Generalização Cartográfica.....	8
2.2. Objetivos da Generalização	8
2.3. Tipos de Generalização.....	9
2.3.1. Generalização do Modelo ou Conceitual	11
2.3.2. Generalização Geométrica	11
2.4. Estruturas de Dados em Formato Vetorial x Formato Matricial	11
2.4.1. Formato Vetorial	11
2.4.2. Formato Matricial.....	12
2.5. Operadores em Dados Vetoriais	13
2.5.1. Operadores Conceituais.....	13
2.5.2. Operadores Geométricos	15
2.6. Operadores em Dados Matriciais.....	24
2.7. Trabalhos realizados	26
3. MATERIAIS E MÉTODOS.....	32
3.1. Caracterização do mapa a ser generalizado	32
3.2. Método para generalização em formato vetorial	33
3.3. Método para generalização em formato matricial	38
3.3.1. 1º Cenário	41
3.3.2. 2º Cenário.....	47
3.3.3. 3º Cenário.....	51
4. RESULTADOS E DISCUSSÃO	52
4.1. Dados vetoriais	52
4.1.1. Operadores Classificação/Agregação.....	52
4.1.2. Operador Eliminação.....	56
4.1.3. Operador Suavização.....	58
4.1.3.1. Variação de área média	58
4.1.3.2. Variação de perímetro médio.....	59
4.1.3.3. Variação de Kc médio.....	61
4.1.4. Grau de pureza das classes	62
4.2. Dados Matriciais	63
4.2.1. 1º Cenário	63
4.2.1.1. Operador Categorização.....	63
4.2.1.2. Operadores Dilatação/Erosão e Amalgamação.....	67
4.2.1.3. Operador Eliminação	70
4.2.1.4. Operador Numérico	72
4.2.1.4.1. Variação de área média	72
4.2.1.4.2. Variação de perímetro médio.....	74
4.2.1.4.3. Variação de Kc médio.....	75
4.2.1.5. Grau de pureza das classes.....	78
4.2.2. 2º Cenário	80
4.2.2.1. Operadores Dilatação/Erosão e Amalgamação.....	80

4.2.2.2.	Operador Eliminação	83
4.2.2.3.	Operador Numérico	85
4.2.2.3.1	Variação de área média.....	85
4.2.2.3.2	Variação de perímetro médio.....	86
4.2.2.3.3	Variação de Kc médio.....	88
4.2.2.4.	Grau de pureza das classes.....	90
4.2.3.	3º Cenário.....	93
4.2.3.1.	Operador Eliminação	93
4.2.3.2.	Operador Numérico	96
4.2.3.2.1	Variação de área média.....	96
4.2.3.2.2	Variação de perímetro médio.....	97
4.2.3.2.3	Variação de Kc médio.....	99
4.2.3.3.	Grau de pureza das classes.....	101
5.	CONCLUSÃO	104
6.	REFERÊNCIAS BIBLIOGRÁFICAS	107
ANEXO 1	– Resultado das variáveis para dados vetoriais.....	110
ANEXO 2	– Grau de pureza para dados vetoriais	111
ANEXO 3	– Mapas resultantes dos dados vetoriais	112
ANEXO 4	– Resultado das variáveis para dados matriciais - 1º Cenário.....	113
ANEXO 5	– Grau de pureza para dados matriciais - 1º Cenário.....	115
ANEXO 6	– Mapas resultantes dos dados matriciais - 1º Cenário.....	118
ANEXO 7	– Resultado das variáveis para dados matriciais - 2º Cenário.....	120
ANEXO 8	– Grau de pureza para dados matriciais - 2º Cenário.....	122
ANEXO 9	– Mapas resultantes dos dados matriciais - 2º Cenário.....	125
ANEXO 10	– Resultado das variáveis para dados matriciais - 3º Cenário.....	127
ANEXO 11	– Grau de pureza de dados matriciais - 3º Cenário.....	129
ANEXO 12	– Mapas resultantes dos dados matriciais – 3º Cenário	132

1. INTRODUÇÃO

A generalização cartográfica em meio digital, é hoje uma possibilidade de automação de processos antes realizados manualmente, otimizando a relação custo/benefício na produção de mapas multi-escala. A tradução do conhecimento cartográfico para formas digitais é assentada no desenvolvimento dos Sistemas de Informações Geográficas (SIG), o que exige dos profissionais que desenvolvem produtos cartográficos a formalização e padronização destes conhecimentos, para desta forma, os expressar em forma algorítmica, caracterizando a sua automatização.

No entanto, muitos autores discutem a problemática da automação completa de métodos de generalização cartográfica. McMaster e Shea (1992) realizaram uma perspectiva histórica a respeito do assunto, discutindo a possibilidade de automação. Primeiramente, os autores recorrem a um trabalho da Sociedade Americana de Cartografia, publicado em 1908 pelo cartógrafo alemão Max Eckert, que discute as dificuldades da generalização e das formas de representação da superfície terrestre. Eckert afirmava que a generalização cartográfica parte de uma interpretação subjetiva do profissional. Os autores citam ainda o trabalho de J.K Wright, que em 1942, considerava o processo de produção de mapas parte da imaginação do profissional, o que concorda com a idéia de subjetividade de Max Eckert.

O trabalho escrito por Raisz (1962) é ainda mais enfático, quando afirma que não existem regras para generalização cartográfica, no entanto, devem consistir em processos de combinação, omissão e simplificação. O autor julga que para se generalizar um mapa de forma coerente, deve-se ter bons conhecimentos geográficos e senso de proporção.

McMaster e Shea no mesmo trabalho ressaltam que nos últimos vinte anos, acadêmicos e a indústria investem em pesquisa para a automação da generalização, porém vem encontrando muitas dificuldades. Imhof (1982) afirmava que computadores e a inteligência artificial nunca terão o poder de julgamento e a sensibilidade gráfica e estética para essa finalidade, que os conteúdos e a criação gráfica estão essencialmente ligados a um trabalho crítico.

Pode-se observar então, que a questão da subjetividade da generalização de mapas, é possivelmente o maior empecilho para a automatização, pois a generalização, mesmo realizada de forma manual, não segue a critérios rígidos de execução.

Em artigo mais recente Shen e Lin (2005) discutem a respeito da problemática, questionando como descrever e representar informação geográfica e como converter o conhecimento e experiência de profissionais para o meio digital e fazer com que computadores sintetizem a subjetividade. Discute-se que o ideal para um sistema automático de generalização, necessita de qualidade e quantidade de conhecimento cartográfico, o que depende da formalização da representação dos objetos geográficos e um acordo sobre regras cartográficas bem definidas.

A ausência de uma formalidade padrão de como deve ser realizada a generalização proporcionou a produção de diversos trabalhos que abordam a utilização de determinados operadores que tem a mesma finalidade, generalizar um mapa em ambiente digital. Entretanto, o reflexo da falta de padrão gerou trabalhos com modelos de conjunto de operadores divergentes.

Os conjuntos de operadores propostos pelos autores são, em outras palavras, as técnicas necessárias para se alcançar a generalização, realizada em etapas. Muitos desses operadores estão disponíveis em SIG's comerciais em forma de algoritmos, com o pressuposto de tornarem automáticas as tarefas executadas manualmente.

Ressalta-se que nenhum desses conjuntos de operadores são processados de forma totalmente automática, pois, requerem que o usuário tenha senso crítico, conhecimento da área e estética suficientes para interferirem no processo.

Assim, o objetivo desta pesquisa é explorar os operadores para generalizar de forma semi-automática o mapa de uso e cobertura do solo na bacia hidrográfica do Córrego São Joaquim, Araponga – MG, em escala original 1:20.000 para 1:50.000 em formato vetorial e formato matricial ou raster.

A escolha da área foi devido à heterogeneidade de classes apresentadas, onde, utilizando os operadores para generalização, pode-se verificar com clareza visual os efeitos da generalização cartográfica. Além disso, um dos objetivos da pesquisa é quantificar a quantidade de informação perdida no processo. A razão da redução de escala procurou obedecer a princípios cartográficos, onde reduções de escala muito abruptas não são aconselhadas.

2. REVISÃO BIBLIOGRÁFICA

2.1. Generalização Cartográfica

Segundo Lopes (2005) generalização cartográfica é definida como um processo de adequação da base de dados e de sua representação gráfica, transformando o uso de dados geográficos a diferentes níveis de abstração, permitindo o uso da mesma informação a diferentes objetivos e usuários.

De acordo com D'Alge (2007) por generalização cartográfica se considera um processo cartográfico que é capaz de apresentar os dados em diferentes escalas (reduzidas), e também por transformações da base de dados, diminuindo desta forma a complexidade.

Para Meng (1997), a generalização de um mapa é um processo cognitivo, que deve criar visibilidade e legibilidade adaptáveis ao espaço de apresentação do mapa, em tela ou papel, aumentando sua percepção, o número de aplicações e usuários possíveis.

Pode-se citar mais um sem número de conceitos sobre o que é generalização cartográfica, pois, irá notar-se que há uma grande convergência sobre este conceito. Por outro lado, sabe-se também que o conceito de generalização cartográfica não é recente, sendo desenvolvido e estudado em paralelo com a ciência cartográfica.

O conceito de generalização digital e sua conseqüente automatização são relativamente recentes em relação à cartografia em geral. Nos últimos vinte anos a questão vem recebendo destaque e está no bojo das discussões por especialistas da área (McMaster e Shea, 1992). Segundo Meng (1997) esta problemática foi formulada pela primeira vez nos anos 1960, onde recebeu respaldo até o início dos anos de 1980, onde surgiram às contestações e divergências até 1990, onde permaneceu estagnado por meia década, havendo em 1995 uma nova retomada das pesquisas.

2.2. Objetivos da Generalização

Em geral, o maior objetivo da generalização é reduzir a complexidade de base de dados e a geometria dos objetos, pressupondo uma visualização menos poluída do conteúdo geográfico, preservando as características e integridade dos dados geográficos, reduzindo o nível de detalhe na sua representação (ESRI, 1996).

Segundo Lopes (2005) a generalização cartográfica possibilita abstrair a representação da realidade, apresentando apenas a informação essencial, o que varia do grupo de usuários ou a finalidade do mapa, ou seja, realçando as informações relevantes de forma legível para a escala reduzida. Atualmente, um dos objetivos da generalização é em relação à manutenção, atualização e distribuição dos dados geográficos, pois, com o aumento de número de usuários da internet e SIG a demanda é cada vez maior por dados geográficos em diferentes escalas.

As técnicas aplicadas em SIG's são capazes de gerar novas informações a partir do cruzamento de mapas, por exemplo, ao se avaliar temporalmente uma série de mapas de uso e cobertura do solo, porém é necessário que os mapas se encontrem na mesma escala (Caetano *et al*, 2001). Sendo assim, um objetivo que vai além da visualização dos dados.

Outra questão abordada é em relação ao custo/benefício. Ao realizar um novo mapeamento em escala reduzida, demanda-se mais tempo e gastos (Meng, 1997).

2.3. Tipos de Generalização

São reconhecidos na literatura dois tipos básicos de generalização, divididos entre Generalização do Modelo e Generalização Geométrica.

O primeiro se trata da reestruturação do banco de dados, da semântica dos objetos e suas relações, adaptando-os a escala reduzida, isto seguindo todos os preceitos de generalização, que depende do usuário e objetivos (Muller, Lagrange & Weibel 1995; ESRI, 2000). Um exemplo deste tipo de generalização é a redução de escala de um mapa pedológico, no qual as classes de solos que possuem informação até o 5º nível categórico, passariam para o 3º nível categórico.

Generalização geométrica corresponde ao tratamento gráfico dos objetos, para adequação de sua apresentação em um novo espaço gráfico devido a reduções de escala, o que torna o mapa mais legível, reduzindo os possíveis efeitos da redução de escala, como poluição visual (Muller, Lagrange & Weibel 1995; ESRI, 2000) (**Erro! Fonte de referência não encontrada.**). Um exemplo é a redução das nuances de uma linha correspondente a um rio, para uma forma geométrica mais simples.

Cabe lembrar que não são completamente independentes, pois, determinadas operações sobre o modelo acarretam em alterações geométricas, assim como algumas operações geométricas alteram os atributos do banco de dados.

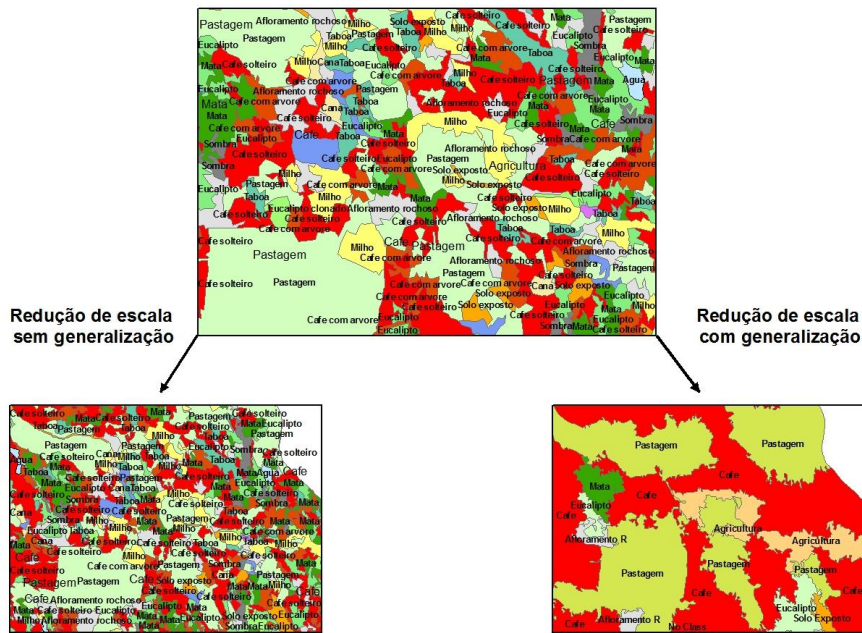


Figura 1. Redução de escala sem e com aplicação de técnicas de generalização. (Fonte: Adaptado de McMaster e Shea 1992)

A Figura 2 apresenta a relação entre a Generalização do modelo e Generalização geométrica.

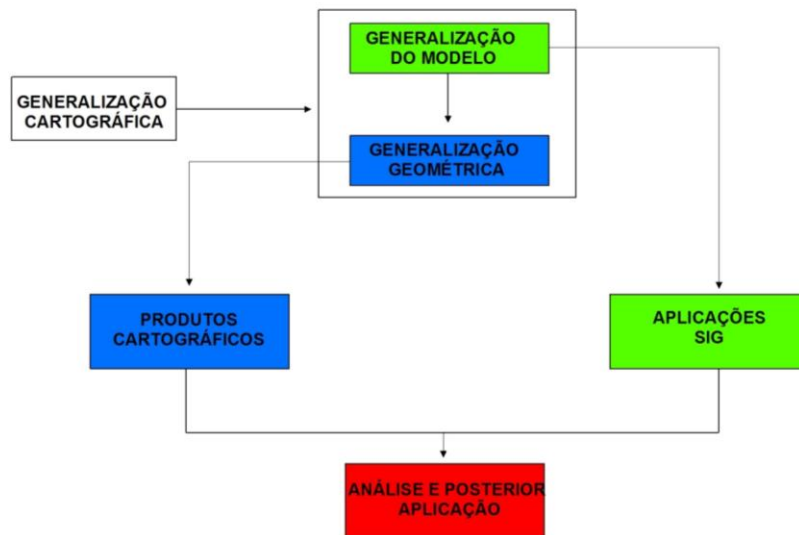


Figura 2. Relação entre generalização do modelo e generalização geométrica (Fonte: Adaptado de Lopes, 2005)

2.3.1. Generalização do Modelo ou Conceitual

A generalização do modelo é a possibilidade de manipulação da base de dados, independente da sua apresentação no mapa. Por vezes, objetos espaciais podem, devido a diferentes objetivos e usuários, ter representações em diversas escalas, o que altera sua representação interna, denominada modelo. Um dos motivos para este tipo de operação é possibilitar o acesso ao banco de dados de forma mais simples, como consultas analíticas mais específicas (Lopes, 2005; Muller et al 1995).

2.3.2. Generalização Geométrica

Este tipo de generalização está ligado principalmente a seleção de objetos que estão apresentados em um mapa com escala grande e selecionar quais objetos são essenciais para serem apresentados em um mapa com escala reduzida, assim como a redução de detalhes geométricos desses objetos, filtrando o excesso de detalhes. Considera-se nesse caso a razão de redução de escala, o propósito do mapa, usuários, o tamanho de apresentação dessas informações, tanto em tela (digital) quanto em papel (analógico). Porém, para tanto, é requisitado do profissional bom senso estético e conhecimento do espaço e dos objetos apresentados assim como suas relações de importância, no momento de operacionalizar esse tipo de generalização (Davis Junior e Laender, 1999).

2.4. Estruturas de Dados em Formato Vetorial x Formato Matricial

Antes de abordar os operadores para generalização cartográfica, é importante ressaltar que em SIG trabalha-se com dois formatos de dados, vetorial e matricial. Assim, a generalização pode ser realizada para os dois formatos, utilizando diferentes operadores para ambos, devido à distinção das estruturas.

2.4.1. Formato Vetorial

Os dados em formato vetorial correspondem a três elementos gráficos: linhas, pontos e polígonos ou área (Figura 3).

Um ponto é representado por sua coordenada espacial (x,y), além de dados não-espaciais, chamado atributos, que é a codificação interna desse ponto, indicando o que

ele representa. As linhas são um conjunto de pontos conectados em cada um de seus vértices, cada um com sua coordenada espacial e também tem sua codificação interna, indicando o atributo associado a esta linha. Um polígono ou área é definido por arcos e nós, delimitando sua região no plano, onde o ultimo ponto de uma linha é idêntico ao primeiro da próxima, ele se fecha em si mesmo e também há um atributo associado a cada polígono (Câmara, 2005).




Figura 3. Representações de dados vetoriais (Fonte: Adaptado de Câmara, 2005)

2.4.2. Formato Matricial

A estrutura de dados em formato matricial é representada por uma grade regular (Figura 4), onde cada quadrado dessa grade é denominado célula ou *pixel*, que representa um ou mais atributos. A cada uma dessas células é atribuído um código que se refere ao atributo ou objeto específico, da maneira que o SIG reconheça qual elemento ou objeto essa célula pertence. Neste tipo de estrutura, o espaço é representado por uma matriz $P(m.n)$ que é composta por m colunas e n linhas, e cada célula possui uma localização nessa coluna e linha que recebe um valor correspondente ao atributo específico, além de conterem um par de coordenadas.

Este tipo de representação entende que o espaço pode ser tratado como uma superfície plana, “recortada” por essa malha regular, e cada “recorte”, no caso, a célula ou pixel, representa uma porção do terreno. A resolução espacial, que corresponde ao

tamanho (lado x lado) de cada célula é o tamanho em área que essa célula corresponde a uma área no terreno. Por exemplo, uma célula com resolução espacial de 20 metros, representa uma área de 400m² no terreno (Câmara, 2005).

Uma das formas mais usuais de formatos matriciais são as imagens obtidas por sensoriamento remoto, ou dados onde necessitam de representações em gradientes, como níveis de poluição do ar, modelos digitais de altitude, declividade do terreno, entre outros.




Figura 4. Estrutura Matricial (Fonte: Câmara, 2005)

2.5. Operadores em Dados Vetoriais

Entende-se por operadores, as técnicas empregadas com uma finalidade específica que, reunidas alcançam o objetivo, a generalização.

Como já foi apresentado, existem dois tipos de generalização, generalização do modelo e generalização geométrica. Assim, os operadores são separados de acordo esses dois tipos, um grupo atuando sobre os atributos dos objetos e os outros sobre a geometria dos objetos, ressaltando que determinados tipos de operadores podem ao mesmo tempo, alterar os atributos e a geometria e vice-versa.

2.5.1. Operadores Conceituais

Classificação – Classifica objetos que tem características idênticas ou semelhantes passíveis de serem classificadas em uma única classe mais genérica (Robinson e Sale, 1969; McMaster e Shea, 1992; Davis, 1999). Exemplo: Em um mapa de solos detalhado originalmente até o 3º nível categórico, agrupam-se as classes com

características semelhantes até o 1º nível categórico, os reunindo em uma nova classe (Figura 5).

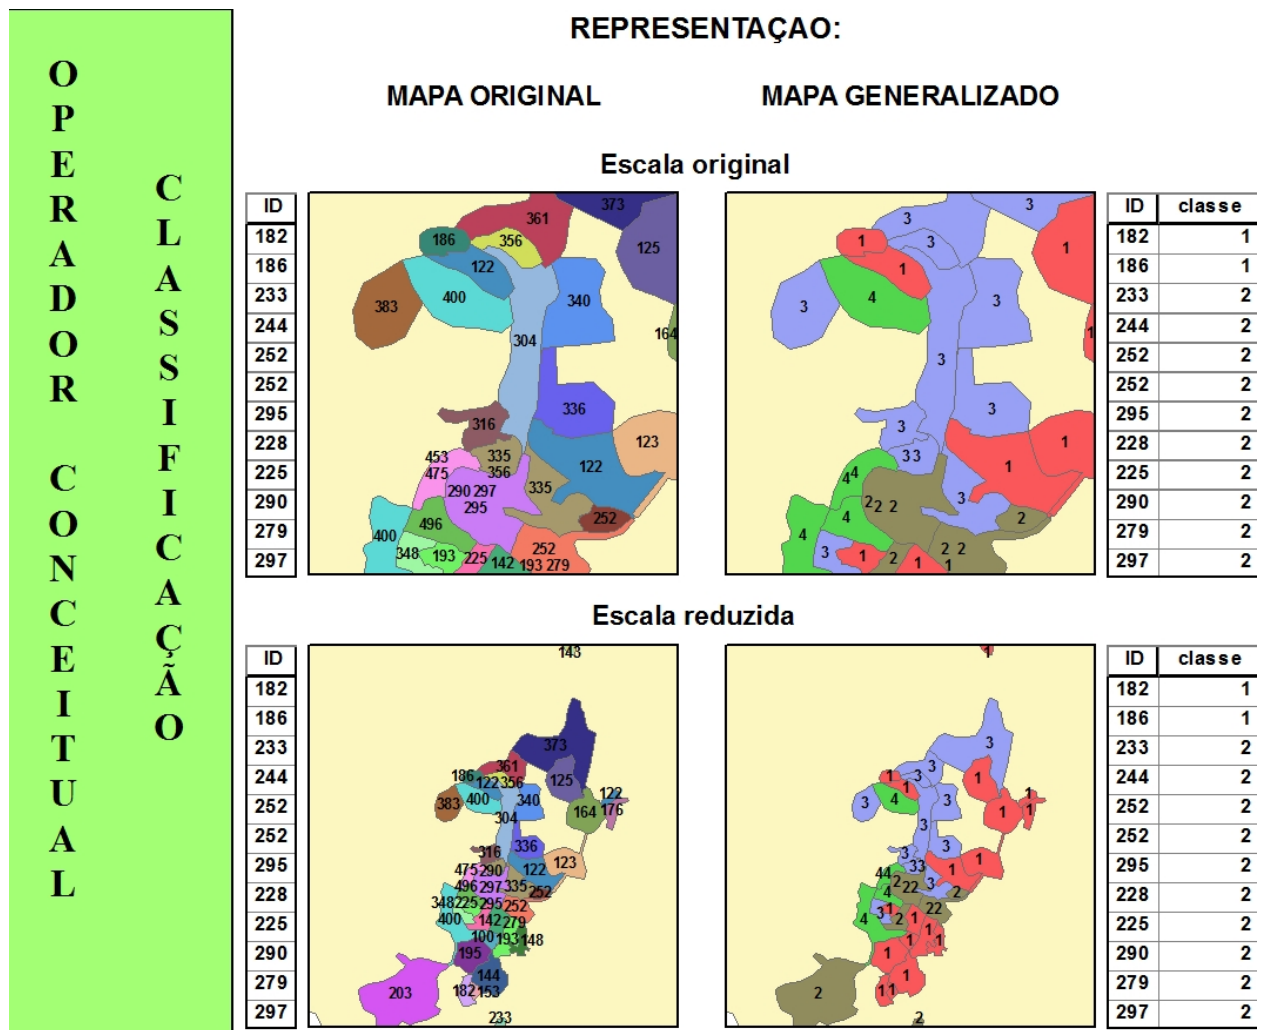


Figura 5. Operador Classificação

Agregação: Este operador agrega áreas adjacentes que tem o mesmo atributo, mas que são consideradas como indivíduos, transformando-os em um único objeto. (Lee, 1993; ESRI, 1996). Este operador pode ser considerado tanto do modelo quanto geométrico, atuando tanto nos atributos dos objetos quanto em sua geometria.

Exemplo: Classes de uso do solo são agrupadas de acordo com características de cultivo semelhantes (Figura 6).

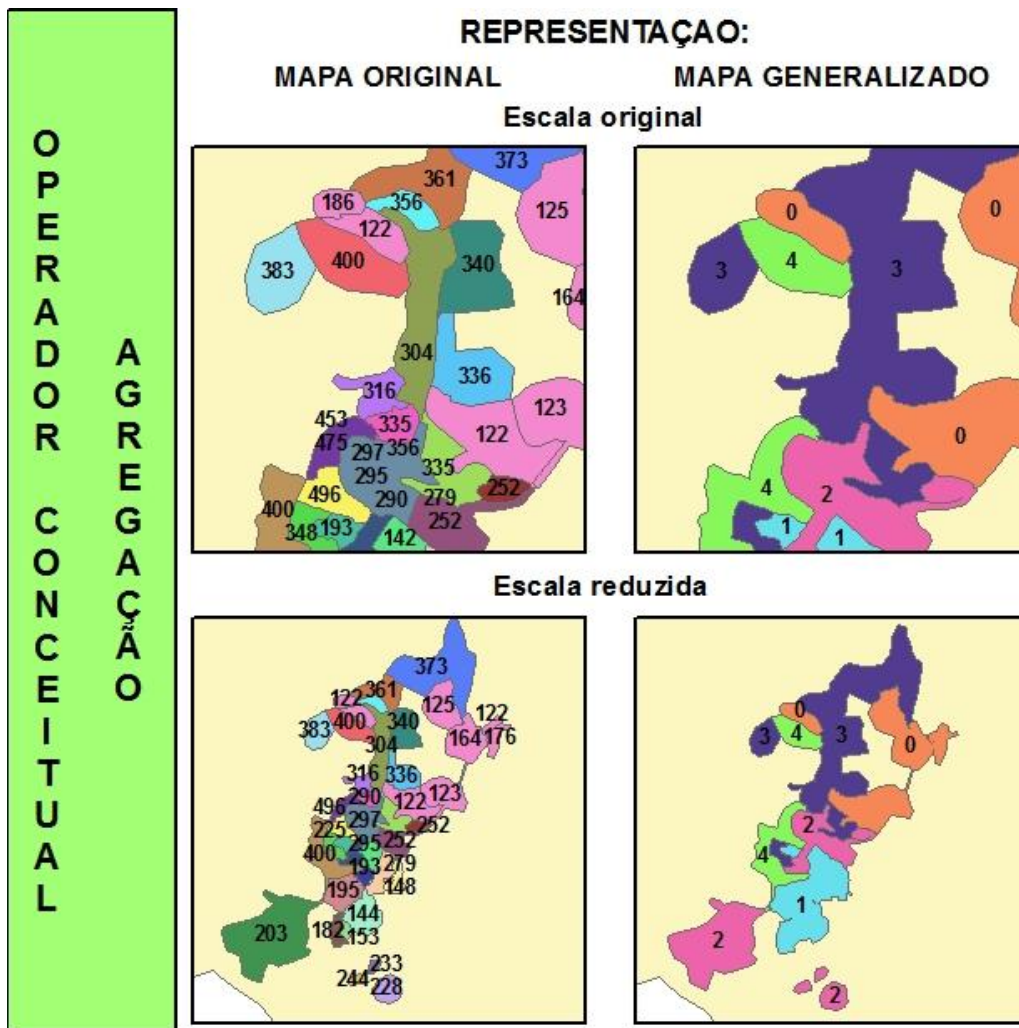


Figura 6. Operador Agregação

2.5.2. Operadores Geométricos

Colapso: Relativo à mudança de dimensão do objeto após a redução de escala. Um objeto polígono de dimensão 2-D, após a redução, seria representado por uma linha 1-D ou ponto 0-D. (McMaster e Shea, 1992; ESRI, 1996; Davis, 1999) Exemplo: Um polígono representando uma mancha urbana escala de origem seria representado por um ponto na escala reduzida (Figura 7).

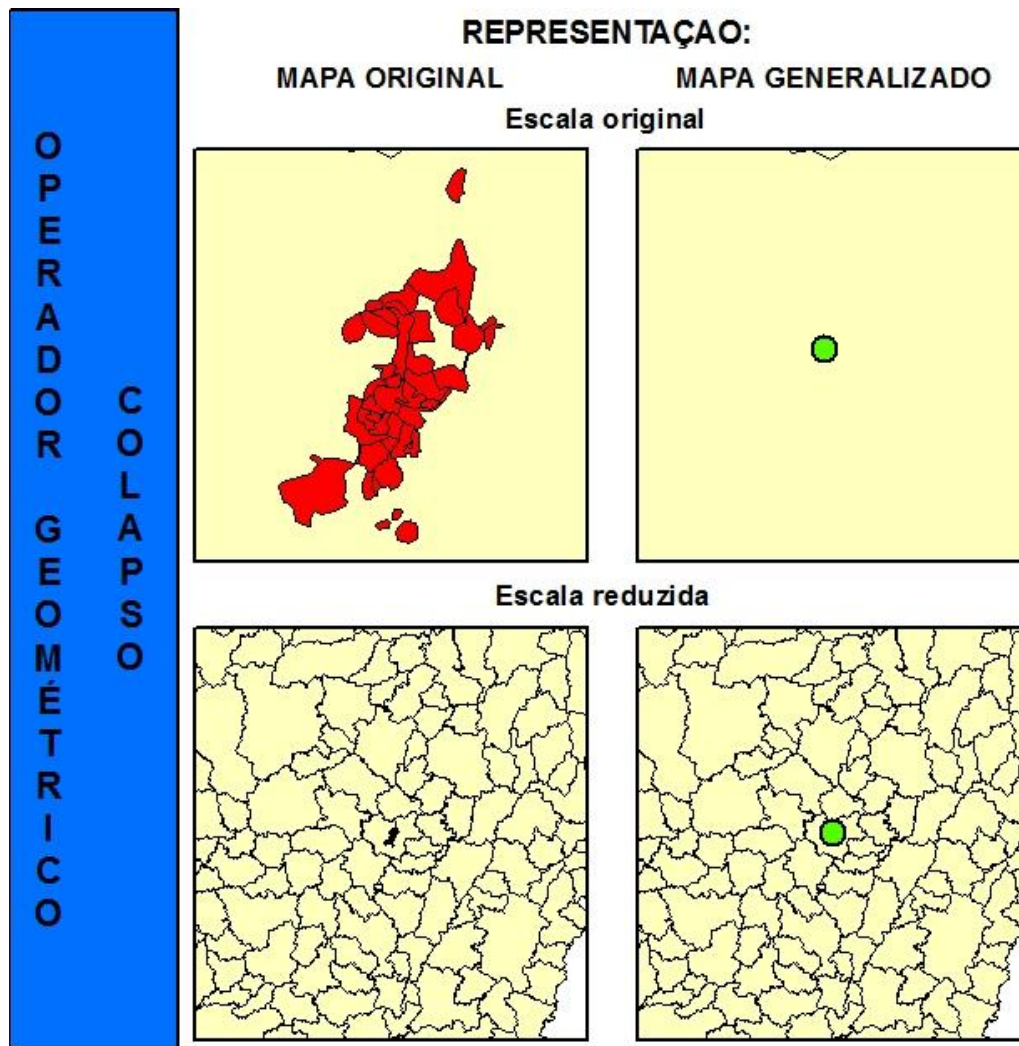


Figura 7. Operador Colapso

Exagero: Objetos importantes, porém, relativamente pequenos, e que na escala reduzida ficariam despercebidos e/ou eliminados, tem sua dimensão aumentada propositalmente para ganhar maior destaque. (McMaster e Shea, 1992; Davis, 1999). Exemplo: Num mapa hidrográfico, lagoas e/ou lagos que são relativamente pequenos, mas de importância para a finalidade são exagerados para constarem no mapa reduzido (Figura 8).

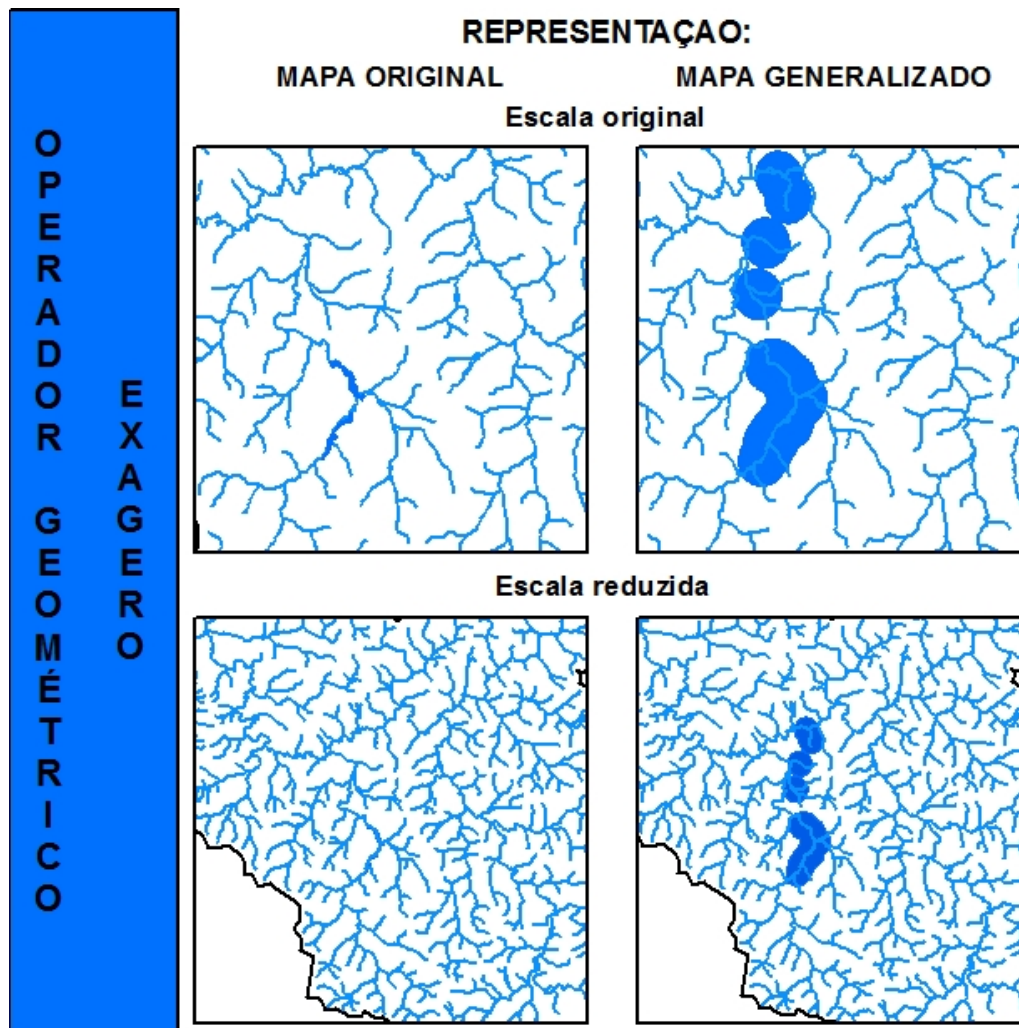


Figura 8. Operador Exagero

Deslocamento: Muda-se intencionalmente a posição de um objeto, objetivando não sobrepor outra feição adjacente. (McMaster e Shea, 1992; Davis, 1999). Exemplo: deslocamento da linha de divisa entre bairros para destacar uma rua ou avenida, que são limitantes. No entanto, segundo Muller et al (1995) este é o operador mais difícil de implementar e apesar de algumas soluções disponíveis, elas não cobrem a gama de conflitos possíveis.

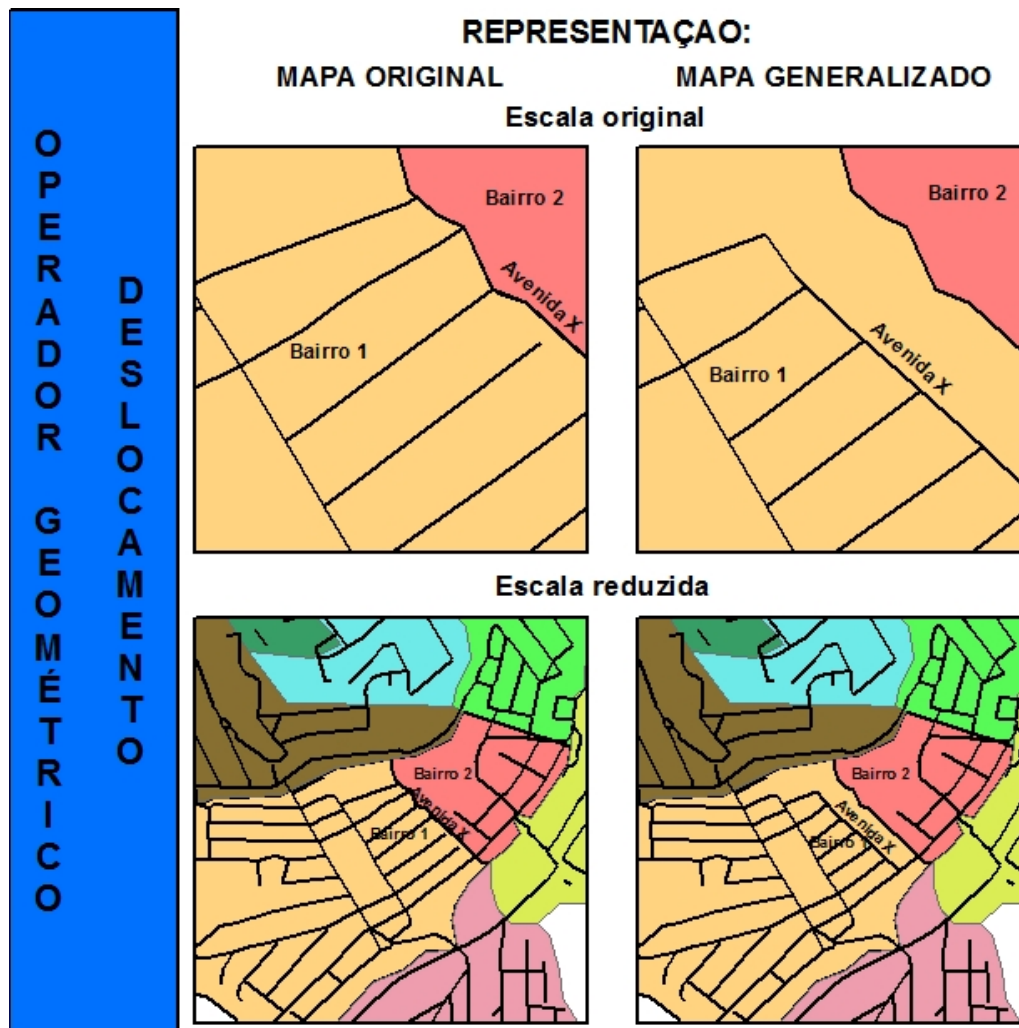


Figura 9. Operador Deslocamento

Eliminação: Quando um determinado objeto tem área inferior à área mínima mapeável (AMM) ele é eliminado do mapa final (Peng, 2000). Exemplo: Um mapa temático qualquer tem para a escala reduzida área mínima mapeável de 1 hectare, se qualquer polígono estiver abaixo deste valor, é eliminado (Figura 10).

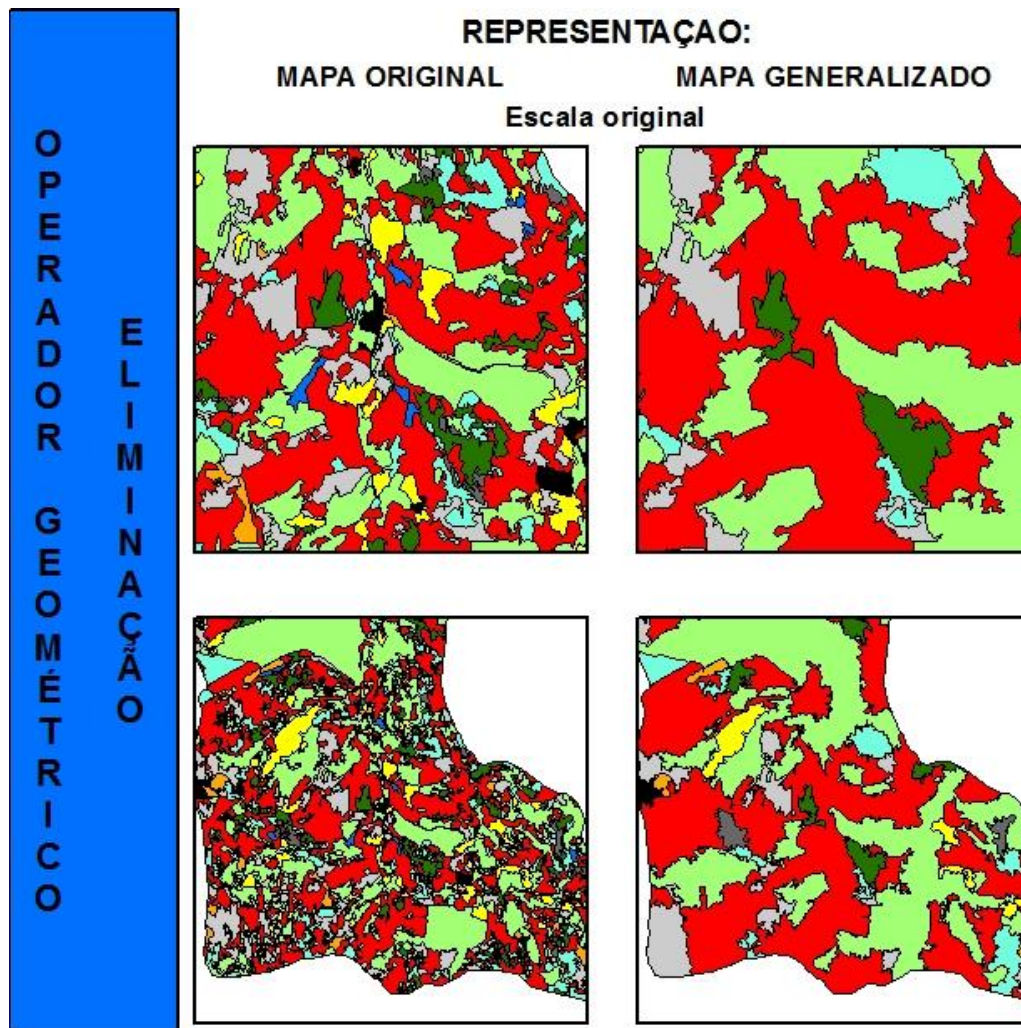


Figura 10. Operador Eliminação

Refinamento: Este operador refere-se à manutenção do aspecto geral de um grupo de objetos a partir da redução de sua complexidade, da densidade, como consequência pode-se eliminar, deslocar ou exagerar os objetos. No entanto, se preserva o aspecto geral do grupo (McMaster e Shea, 1992; ESRI, 1996; Davis, 1999). Exemplo: Em um mapa hidrográfico, eliminam-se os cursos d'água menos significativos de uma bacia hidrográfica (Figura 11).

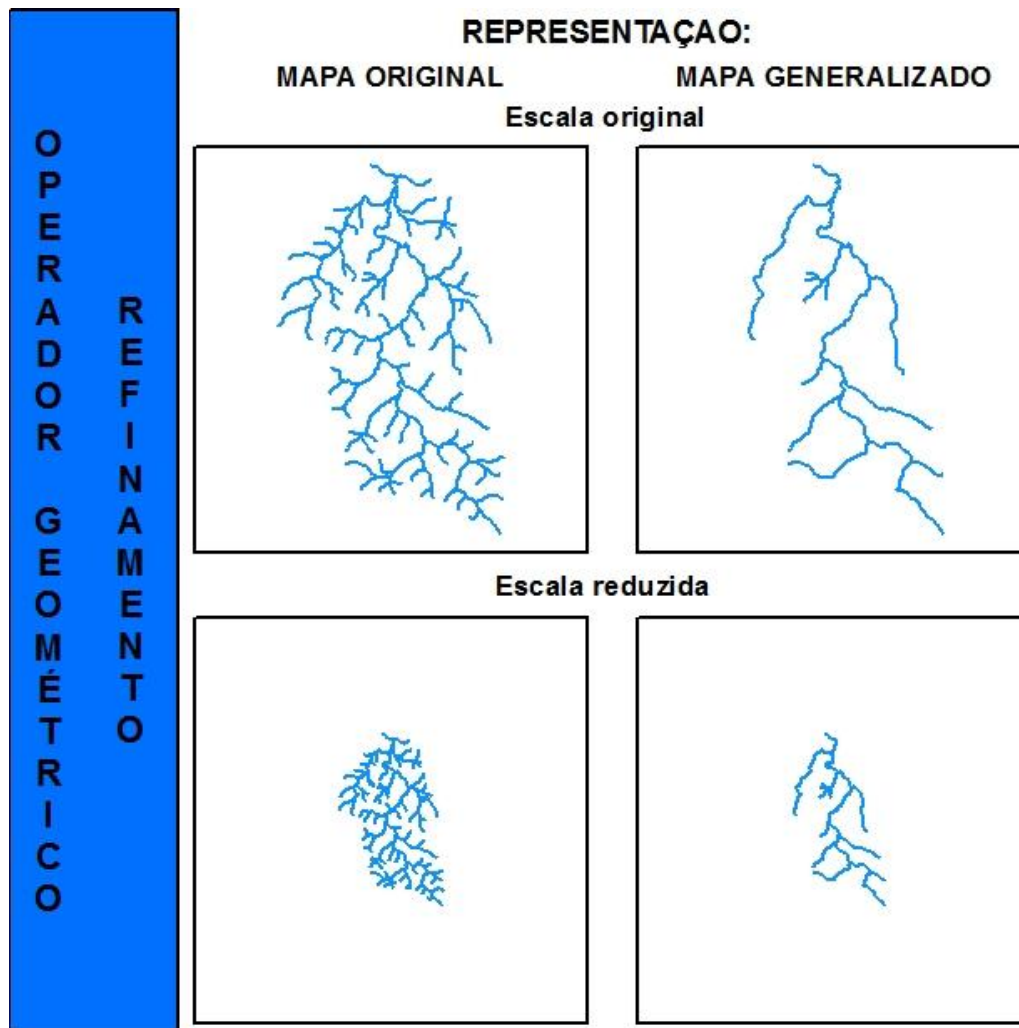


Figura 11. Operador Refinamento

Simplificação: Retira-se do polígono e/ou linha os vértices considerados redundantes, desnecessários, e retém os vértices considerados essenciais, que preservam o aspecto característico do objeto. (McMaster e Shea, 1992; ESRI, 1996; Davis, 1999; Peng, 2000; Lopes, 2005). Exemplo: Eliminam-se vértices desnecessários para representação de curvas de nível (Figura 12).

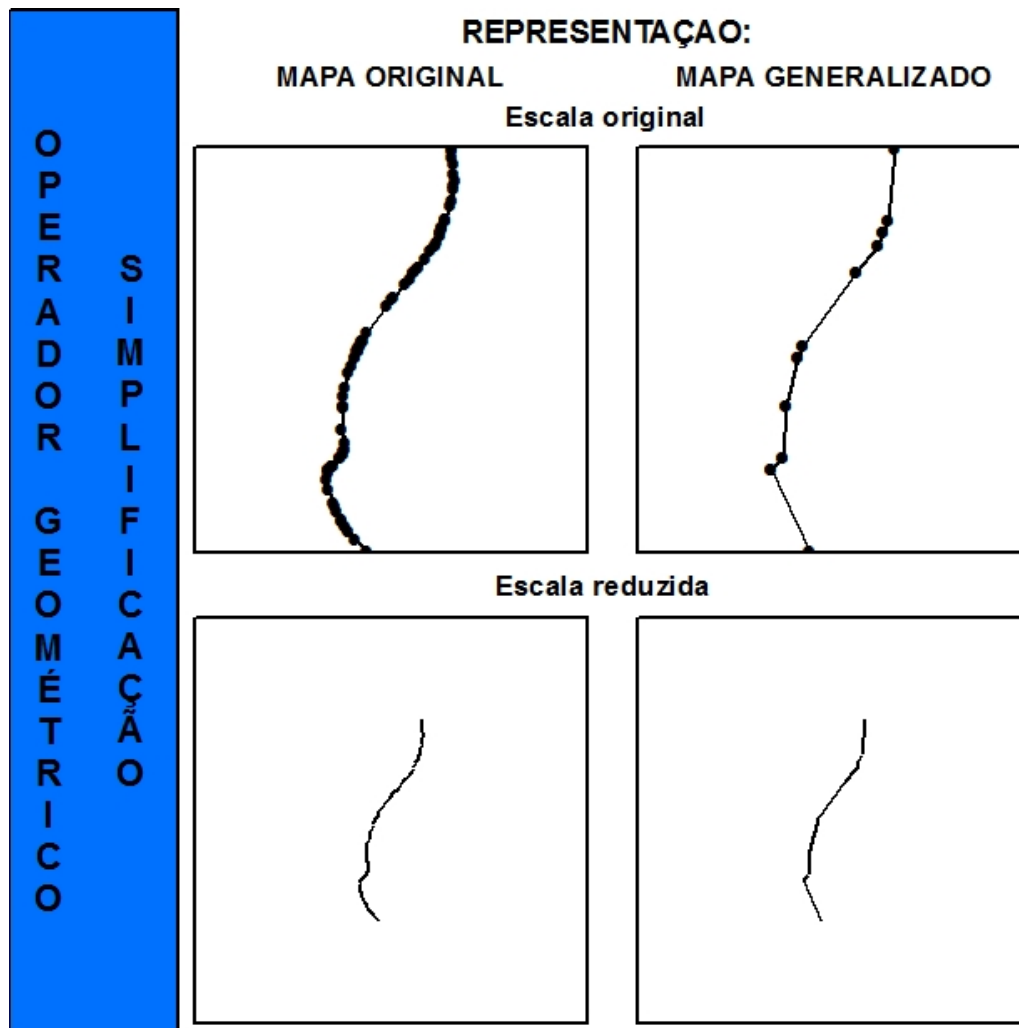


Figura 12. Operador Simplificação

Suavização: Os vértices são deslocados de forma a reduzir a angularidade dos objetos, diminuindo as “quinas” nas bordas, garantindo uma representação esteticamente mais agradável. Este operador é comumente utilizado após a simplificação, pois, após a eliminação de vértices é comum observar uma maior angularidade (McMaster e Shea, 1992; Davis, 1999; Lopes, 2005). Exemplo: Após eliminar os vértices das curvas de nível, aplica-se este operador para garantir um aspecto mais natural (Figura 13).




Figura 13. Operador Suavização

Unificação: Quando duas linhas paralelas, de mesmo atributo, se encontram muito próximas, são unidas em uma única linha. (McMaster e Shea, 1992; Davis, 1999). Exemplo: Quando duas rodovias paralelas, de sentidos opostos, são representadas com um pequeno espaço entre si, na redução de escala este pequeno espaço torna-se impossível de ser representado, assim, as linhas se unem (Figura 14).

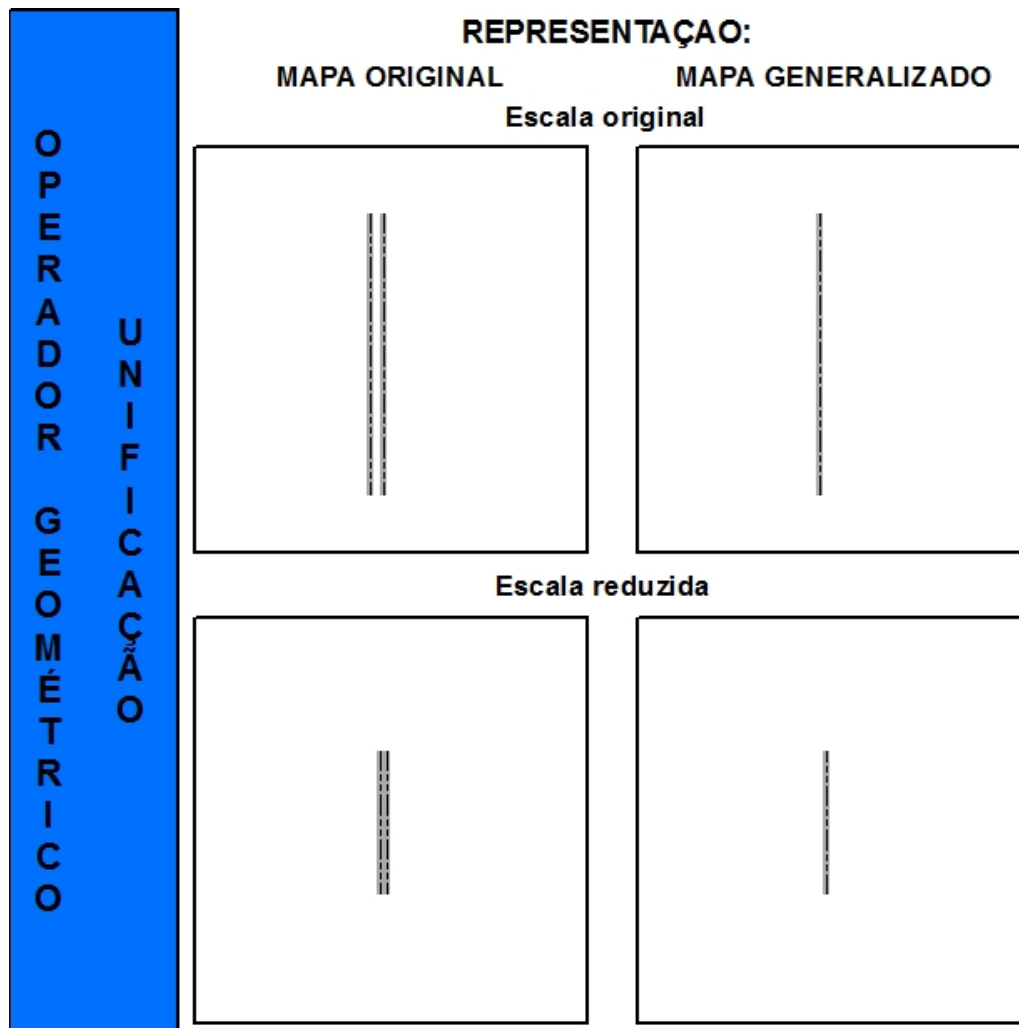


Figura 14. Operador Unificação

Destaque: Altera a maneira de apresentar um objeto, ou seja, o seu símbolo, porém, não modifica suas dimensões, apenas o torna mais adequado ao novo espaço de visualização, tornando-o mais legível. (McMaster e Shea, 1992 e Davis, 1999). Exemplo: num mapa turístico, os símbolos relativos à localização de restaurantes, bancos, postos de gasolina e outros serviços são destacados (Figura 15).

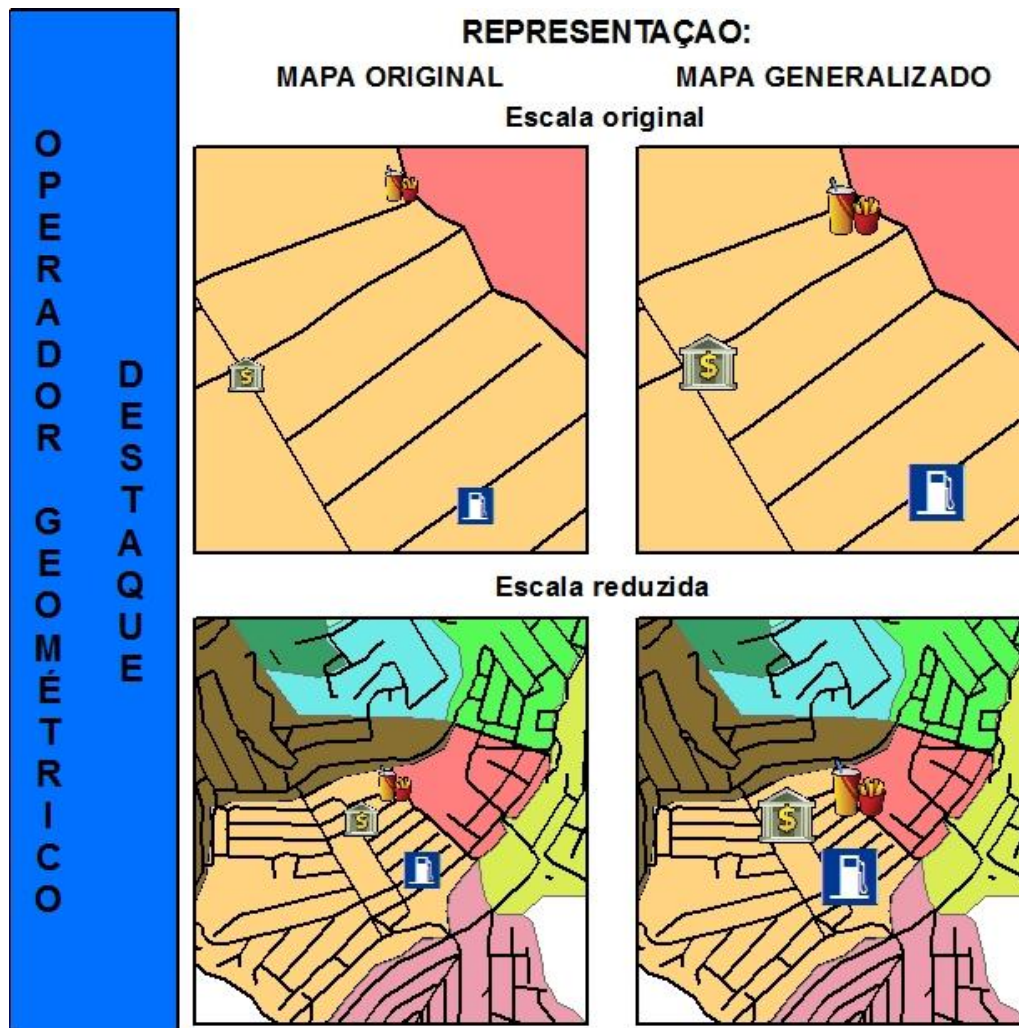


Figura 15. Operador Destaque

2.6. Operadores em Dados Matriciais

Enquanto a generalização dos dados vetoriais pode ser dividida no campo de atributos e no campo geométrico, a generalização de dados em formato matricial é essencialmente ligada ao campo dos atributos, onde a unidade lógica é a célula (ou *pixel*) que é atribuída um conjunto de propriedades (Nunes e Barreiro, 2001).

Um modelo de generalização matricial foi desenvolvido por McMaster e Monmonier em 1989 (McMaster e Veregin 1996; Muller 1991), onde propuseram quatro operadores básicos:

Estrutural: Esta ligada a reestruturação da matriz, diminuindo o número de *pixels* e aumentando seu tamanho. Porém, a estrutura é mantida. Com o aumento do tamanho dos *pixels* de 20 metros para 50 metros, por exemplo, a área do terreno representada pelo *pixel* passará de 400 m² para 2.500 m², desta forma, alterando a

representação do terreno. Exemplo: Num mapa de uso e cobertura com tamanho de *pixel* de 20 metros, ou 400m^2 , este *pixel* representa uma área no terreno que corresponde a 100m^2 de plantio de café e 300m^2 de mata, num *pixel* de 50 metros, abrangendo uma área maior, o *pixel* corresponde no terreno 200m^2 plantio de café, 2.000m^2 de mata e 300m^2 plantio de cana.

Numérica: Também denominada filtros espaciais, este tipo de generalização atua principalmente redução da complexidade da imagem reduzindo as variações de valores da matriz. Este operador causa uma espécie de “borramento” na imagem, diminuindo os contrastes, através de uma máscara ou janela que percorre toda a imagem tendo um núcleo (*pixel*) central e alterando seu valor de acordo com os valores vizinhos. Exemplo: Aplicação de um filtro majoritário, ou de maioria, onde o *pixel* central recebe o valor mais frequente dos seus vizinhos, isso varia de acordo com o tamanho da máscara aplicada.

Categorização: Envolve métodos de redução de detalhes através do agrupamento em classes mais genéricas como o agrupamento por temas (uso, tipo de solo) ou por intervalos de valor. Exemplo: Em um mapa municipal, ruas, avenidas, edificações, etc, seriam categorizadas como malha urbana.

Categorização numérica: Este operador é denominado na literatura de sensoriamento remoto como *classificação de imagens*. Ao invés da imagem ter no valor do *pixel* o valor de nível de cinza, esses valores são classificados em classes, transformando a imagem em um mapa temático, facilitando sua visualização e interpretação. Três técnicas são bem conhecidas no campo do Sensoriamento Remoto, o algoritmo da Máxima Verossimilhança (MaxVer); Paralelepípedo e Distância Mínima.

Há ainda outros tipos de operadores, como abordados por Meng (1997):

Eliminação: Segue o mesmo princípio do operador de mesmo nome para dados vetoriais, no entanto, aqui se considera o conjunto de *pixels* que determinam uma área, sendo assim, o conjunto de *pixels* que não correspondem a AMM são excluídos.

Amalgamação: *Pixels* de mesmo valor que estão próximos, porém, não estão conectados, passam a se conectar. É usualmente aplicado a grupo de *pixels* que tem a AMM insuficiente, pois, após esta operação podem passar a ter área superior e não serem excluídos.

Dilatação: Os agrupamentos de *pixels* são expandidos de acordo com o limiar proposto, em número de *pixels*.

Erosão: Aplica-se este operador após a dilatação, removendo *pixels* espúrios.

Os operadores propostos por Meng (1997) costumam operar de forma sequencial, da seguinte forma: Aplica-se o operador dilatação em agrupamentos de *pixels* com área mínima mapeável inferior ao exigido, após, aplica-se o operador erosão que retorna com o valor de *pixel* proposto no operador anterior, os *pixels* dilatados pelo operador dilatação que não se conectaram, são excluídos pelo operador erosão, os que conectaram foram amalgamados, e por fim, o operador eliminação, onde grupos de *pixels* que não tem área superior à AMM são excluídos.

É importante ressaltar que não é necessário o emprego de todos os operadores (tanto em vetorial como matricial) para se generalizar um mapa, isto irá depender essencialmente das características dos objetos contidos no mapa.

2.7. Trabalhos realizados

Alguns trabalhos chegaram à conclusão sobre o uso de um conjunto de operadores e diferentes algoritmos.

O trabalho realizado por D 'Alge (2007) faz uma adaptação do conjunto de operadores propostos por McMaster e Shea (1992). É realizado aqui a generalização do mapa de vegetação da Amazônia brasileira na escala original 1:250.000 para 1:1.000.000; 1:5.000.000 e 1:15.000.000 de forma gradativa, sem mudança de escala abrupta.

Seu método é baseado em três etapas: limpeza de dados, onde utiliza o operador simplificação; simplificação da base de dados, utilizando o operador classificação e agregação e a última etapa denominada simplificação cartográfica, onde faz o uso dos operadores de eliminação e novamente simplificação. Porém, neste caso, simplifica-se as linhas utilizando diferentes tolerâncias baseadas na razão de mudança de escala. Os operadores foram utilizados separadamente nas quatro folhas que unidas constituem o mapa da área de estudo

Para tanto, aplicou-se na última etapa de simplificação três diferentes algoritmos: Douglas e Peucker; Razão Área-Perímetro e Distância Acumulada. Os softwares utilizados foram TERRAVIEW e SPRING.

Antes de continuar, cabe explicar o funcionamento dos três algoritmos.

Douglas e Peucker (Figura 16): É um algoritmo disponível em quase todos os SIG's comerciais. É um método de avaliação global, pois avalia a linha como um todo. Este método é baseado no uso de distâncias perpendiculares entre um segmento de

reta que liga o primeiro e o último ponto da linha e os pontos que constituem essa reta. Desta forma, se nenhum ponto da linha encontra-se mais afastado do que certa distância vertical ao segmento de reta que liga os extremos da linha, esse segmento de reta é então, suficiente para representar a linha. O valor da distância vertical é a tolerância definida pelo usuário. No entanto, é um método que peca por não ter uma relação direta entre a tolerância definida e a razão de mudança de escala pretendida.




Figura 16. Método de simplificação de linhas de Douglas e Peucker (Fonte: D'Alge, 2007).

Razão Área-Perímetro: Utiliza o mesmo procedimento de análise global da linha utilizado no método de Douglas-Peucker. No entanto, diferencia-se por adotar a razão área/perímetro que é calculada a partir da tolerância definida. O uso deste método permite que triângulos formados por três pontos que tenha um ângulo agudo ($>0^\circ < 90^\circ$) muito pequeno possam ser detectados de modo mais eficiente que no método de Douglas e Peucker.

Distância Acumulada: Neste método, o primeiro ponto é “âncora” e a partir dele são calculados os somatórios das distâncias entre os pontos, segmentos de reta, subsequentes até que esse somatório seja maior que a tolerância determinada, eliminando todos os pontos nesse trecho. Quando ultrapassa a tolerância, o último ponto lido é o novo âncora e recomeça o somatório. Diferentemente dos algoritmos anteriores, este não considera a linha em sua totalidade.

No entanto, o autor ressalta que não existem regras definidas na escolha das tolerâncias, para tanto, criou duas diferentes regras, uma para as rotinas Douglas e Peucker e Razão Área Perímetro e outra para a rotina de Distância Acumulada.

Para as duas primeiras rotinas, estipulou-se que a tolerância mínima para eliminar redundância nas linhas digitais seria de 0,1 mm, sendo assim, a regra considerada foi multiplicar essa tolerância mínima pela razão de escala adotada, na

primeira generalização de 1:250.000 para 1:1.000.000 a tolerância foi então de 0,4 mm. O autor, subjetivamente, adiciona mais um valor de tolerância para as duas rotinas, pela soma e subtração de 0,1 mm à tolerância básica usada para a mudança de escala que se pretende fazer.

Para a rotina de Distância acumulada, baseou-se na idéia de acuidade visual, estipulada pelo Padrão de Exatidão Cartográfica (PEC) como sendo 0,2 mm. Utilizado então, como a tolerância mínima, e como nas rotinas anteriores, multiplica-se esse valor pela razão de escala pretendida. Novamente, o autor testa o valor de tolerância definido pela soma e subtração de 0,1 pela tolerância básica usada na mudança de escala que se pretende fazer.

A maneira de analisar os dados foi de forma quantitativa, a partir das estatísticas geradas de: número de polígonos por plano de informação; número de linhas por plano de informação; número de vértices no total de linhas de um plano de informação. Também foi analisada de forma qualitativa, comparando visualmente por sobreposição os mapas gerados com mapas já publicados com a mesma escala, obtidos no IBGE.

A primeira etapa de análise dos resultados foi de acordo com a seqüência de operadores utilizados.

O primeiro, limpeza de dados, utilizando o operador simplificação de linhas, com tolerância padrão de 0,1 mm, foi avaliado estatisticamente a partir do número de vértices eliminados. Constatou-se que houve redução de vértices superior a 20% em todos os quatro mapas, com um mínimo de 23,7% e máximo de 40,6%. Esta variação é normal, pois, a redução de vértices considerados redundantes varia de acordo com o conteúdo de cada mapa. Pode-se notar que não houve mudança relevante na estética dos mapas apresentados, o que corrobora a idéia da redundância dos pontos (ou vértices).

Na segunda etapa de análise dos dados, utilizando os operadores classificação e agregação. Nesta etapa, segundo o autor, foram definidas algumas regras para classificar e agregar as diferentes taxonomias apresentadas em seus mapas, cada uma de acordo com a mudança de escala, quanto mais reduzida a escala, mais generalizada, conseqüentemente, será a taxonomia adotada. Pode-se perceber que houve uma homogeneização dos mapas, pois, classes taxonomicamente idênticas ou semelhantes foram agregadas.

Na ultima etapa, simplificação cartográfica, foram utilizados os operadores de e eliminação de polígonos e simplificação de linhas de acordo com tolerância definida pela razão de escala. Para eliminar os polígonos, foi adotado um padrão proposto pelo

PEC de 0,25 mm na escala do mapa e outro critério, mais subjetivo, de 1 mm na escala do mapa, onde polígonos menores que essas medidas (na escala alvo) são eliminados. As quantidades de polígonos eliminados aumentaram numa proporção direta da redução de escala.

No último operador de simplificação de linhas, onde foram comparadas as rotinas para os três algoritmos verificou-se que se manteve o padrão de diminuição de vértices de acordo com o aumento da tolerância e a diminuição de escala para todos os casos.

A rotina utilizada no algoritmo Douglas e Peucker foi a que eliminou o maior número de vértices, seguido da Razão Área-Perímetro e Distância Acumulada.

Na análise dos resultados visuais, notou-se que na redução de escala de 1:250.000 para 1:1.000.000 foi satisfatório, mas, a medida que se reduzia a escala, foram detectados problemas topológicos, isto para os três algoritmos. A rotina para o algoritmo Distância acumulada foi a que apresentou a menor quantidade de problemas topológicos, no entanto, como não analisa a linha em sua totalidade, deixou de selecionar vários pontos considerados críticos pelos dois outros algoritmos.

No trabalho publicado por Dal Santo e Loch (2008) foram aplicados dois algoritmos de simplificação de linhas disponíveis no SIG ArcGis para avaliação dos resultados.

Os algoritmos foram Douglas e Peucker e uma adaptação do algoritmo de Wang (ESRI, 1996). Este último é um algoritmo que trabalha com reconhecimento de arcos, analisando suas características e eliminando os mais insignificantes, porém, preserva a forma principal do objeto.

Neste trabalho não foram utilizados outros operadores, apenas o de simplificação. A escolha das tolerâncias foi definida de forma subjetiva, trabalhando-se com as tolerâncias de 10 m e 20 m para ambos os algoritmos.

Na rotina aplicada sobre o algoritmo Douglas e Peucker observou-se uma grande redução de vértices, com 94% de redução para tolerância de 10 m e 97% para tolerância de 20 m. A rotina aplicada sobre o algoritmo Wang preservou uma quantidade muito elevada de vértices, eliminando 35% com tolerância de 10 m e 45% com tolerância de 20 m.

Na análise visual, pode-se perceber que a linha original sofreu grande perturbação geométrica e topológica utilizando as rotinas do algoritmo Douglas e Peucker, e no algoritmo de Wang, as rotinas utilizadas apresentaram menor eliminação

de pontos, assim, a forma da linha original não sofreu grandes modificações, e apresentou melhores resultados visuais e topológicos.

O trabalho produzido por Carvalho Junior *et al* (2005) objetivou generalizar o mapa de solos de Minas Gerais na escala original de 1:500.000 para 1:1.000.000. Para tanto, utilizou-se de três operadores, um operador geométrico, eliminação, e dois operadores de generalização do modelo, classificação e agregação.

Em princípio, o autor reclassificou as classes de solos do mapa original de acordo com a taxonomia do Sistema Brasileiro de Classificação de Solos, proposto pela Embrapa em 1999. Nesta fase, as unidades de mapeamento foram ajustadas em relação ao primeiro componente de cada unidade de mapeamento, reduzindo de 297 para 114 unidades.

O passo seguinte, foi a agregação de polígonos adjacentes com o mesmo valor de atributo específico, diminuindo de 3.067 polígonos para 2.388.

O operador geométrico utilizado eliminou polígonos que estivessem abaixo do limite estipulado de área mínima mapeável, reduzindo a quantidade de polígonos para 1.262.

O autor considerou que a generalização empregada apresentou bons resultados, pois, manteve a proporção de área dos solos, não alterando de forma expressiva a ocorrência de cada classe de solo, sendo assim, coerente com o mapa original.

O Grupo de Detecção Remota (sensoriamento remoto) do Instituto Geográfico Português, elaborou uma extensão para ambiente ArcView 3.2 (ESRI) para generalização em formato matricial, denominada *RasterGen* (Nunes e Caetano, 2006)

Essa extensão se baseia nos operadores de generalização numérica e categórica definidos por McMaster e Monmonier (1989) em forma seqüencial, que também utiliza operadores descritos por Meng (1997).

Existem três módulos disponíveis, *Custom Boundary Clean*, *Gen Min* e *Gen Max*, cada um operando de acordo com uma determinada seqüência de operações. Aqui, cabe uma observação importante, nesta extensão, é feita uma tabela de prioridade entre as classes (isso para todos os três módulos), que ajudam cada algoritmo a realizar suas operações, por exemplo, quando tem sobreposição de classes, a que tiver maior prioridade prevalece.

No primeiro módulo, é utilizado o operador de eliminação de grupos de *pixels* com área inferior à AMM determinada. Pode-se ainda aplicar um filtro de maioria, aplicando uma janela 3x3 com quatro ou oito vizinhos, onde o *pixel* central tem seu

valor alterado de acordo com os *pixels* predominantes na vizinhança. A operação de expansão e erosão também é disponibilizada neste módulo, atuando apenas sobre os grupos de *pixels* com área inferior a área mínima mapeável, que no final dessa operação, podem obter valores superiores e não serem eliminados.

No segundo módulo, *Gen Min*, também é adotado o operador eliminação. Enquanto o primeiro módulo atua sobre todo o mapa ou sobre as áreas inferiores a AMM, o módulo *Gen Min* atua sobre as áreas inferiores à AMM até um limiar definido pelo usuário. Além disso, existe uma diferença fundamental em relação ao primeiro módulo, pois, se houve um grupo de *pixels* de área inferior a AMM, mas não houver *pixels* próximos pertencentes à mesma classe, é permitido aproveitar a existência de *pixels* contíguos de outras classes para fazer a generalização, levando em conta a prioridade de uma classe sobre a outra.

O módulo *Gen Max* é semelhante aos outros dois, no entanto, a diferença fundamental é que o ponto de partida do algoritmo é sobre os grupos de *pixels* com área igual ou superior à AMM. O algoritmo aproveita a existência de grupos de *pixels* contíguos com área inferior à AMM, assim, esses grupos de *pixels* são agregados à grupos de áreas maiores, eliminando o grupo menor, no entanto, também é utilizada a prioridade de uma classe sobre a outra.

Podemos observar diante dos trabalhos expostos, que cada autor utiliza de sua própria experiência, subjetividade e indução no momento de escolher e aplicar seus operadores, e obtêm diferentes resultados. Desta forma, fica explícito que quando se vai generalizar um mapa não existe um conjunto “correto” de operadores e algoritmos, pois, depende do objetivo, do conteúdo do mapa, da razão de mudança de escala e outros fatores que implicam nesta decisão.

Há certa carência de trabalhos que aplicaram os operadores de generalização em seus trabalhos, principalmente em dados matriciais. O trabalho desenvolvido pelo Instituto Geográfico Português, descrito anteriormente, elaborou a extensão *Raster Gen*, onde agrupa algoritmos existentes nos SIG's da ESRI em três módulos, contribui de forma expressiva para padronizar de forma coerente a generalização, buscando a automatização completa do processo.

3. MATERIAIS E MÉTODOS

3.1. Caracterização do mapa a ser generalizado

Para a realização desta pesquisa, foi adquirida uma imagem em formato matricial de uso e cobertura do solo da bacia hidrografia do Córrego São Joaquim, Araponga – Minas Gerais, que foi produto da dissertação de Portes (2010). Esta imagem foi classificada automaticamente utilizando o classificador por regiões Bhattacharya e foram geradas 15 classes.

Esse produto foi gerado a partir de imagem de satélite IKONOS com resolução espacial de 4 metros em escala 1:20.000. Esta imagem então, já foi generalizada de acordo com o operador *categorização* proposto por McMaster e Monmonier (1989), pois, cada *pixel* da imagem original corresponde a um nível de cinza, que foram agrupados nas 15 classes, onde cada uma destas classes correspondiam a um determinado intervalo de valor de nível de cinza.

Mapas derivados de imagem de satélites com alta resolução espacial são em geral para publicações em escalas grandes, com conteúdos mais específicos e detalhados, como neste caso, em que Portes (2010) obteve um mapa de classificação do uso e cobertura do solo em áreas que ocorrem manejo convencional e agroecológico. No sistema agroecológico encontra-se uma maior variedade de culturas nas propriedades rurais do que nos sistemas convencionais, gerando assim, maior heterogeneidade de grupos de *pixels* no resultado da classificação.

A bacia hidrográfica está localizada na Zona da Mata mineira, região dos “mares de morros”, apresentando relevo bastante acidentado (RESENDE, 1996), desta forma, condiciona o uso agrícola em pequenas propriedades, sendo assim, mais outro fator que contribui para a heterogeneidade da classificação.

A Tabela 1 apresenta as classes de uso e cobertura do solo, com suas respectivas áreas totais (hectares) e em relação ao total da área da bacia.

Tabela 1. Área total e relativa ao total da área da bacia

CLASSES	Área total (ha)	Área relativa (%)	Número de polígonos
Aflor.rochoso	74	6,27	182
Água	7	0,47	23
Café com árvore	59	2,84	244
Café solteiro	264	25,80	363
Cana	14	0,94	38
Cana queimada	1	0,11	5
Eucalipto	70	4,61	224
Eucalipto clonado	11	0,95	29
Mata	76	6,15	192
Milho	41	3,55	91
Pastagem	386	43,45	169
S/Classificação	13	0,82	44
Solo exposto	25	1,80	77
Sombra	12	0,82	42
Taboa	30	1,42	98
TOTAL	1.083	100	1.821

Todo o trabalho foi executado em ambiente ArcGis 9.3 (ESRI, 2007). Este SIG disponibiliza uma variada gama dos operadores necessários para a realização desta pesquisa.

A metodologia será descrita em duas partes, onde a primeira serão abordados os métodos e operadores utilizados no formato vetorial e na segunda parte serão descritos os métodos e operadores para o formato matricial.

3.2. Método para generalização em formato vetorial

O início dos trabalhos no formato vetorial consistiu em transformar a base de dados original, que se encontrava em formato matricial, para vetorial. Antes de executar esse procedimento, um primeiro operador, que pode ser utilizado para os dois tipos de dados, foi executado, o operador *classificação* (em *raster* a nomenclatura é categorização), onde a tabela de atributos do arquivo original, foi reclassificada de forma a diminuir a quantidade de classes originais. Para executar esses passos, utilizou-se a caixa de ferramentas *Spatial Analyst* com a ferramenta *Reclassify* (Figura 17).

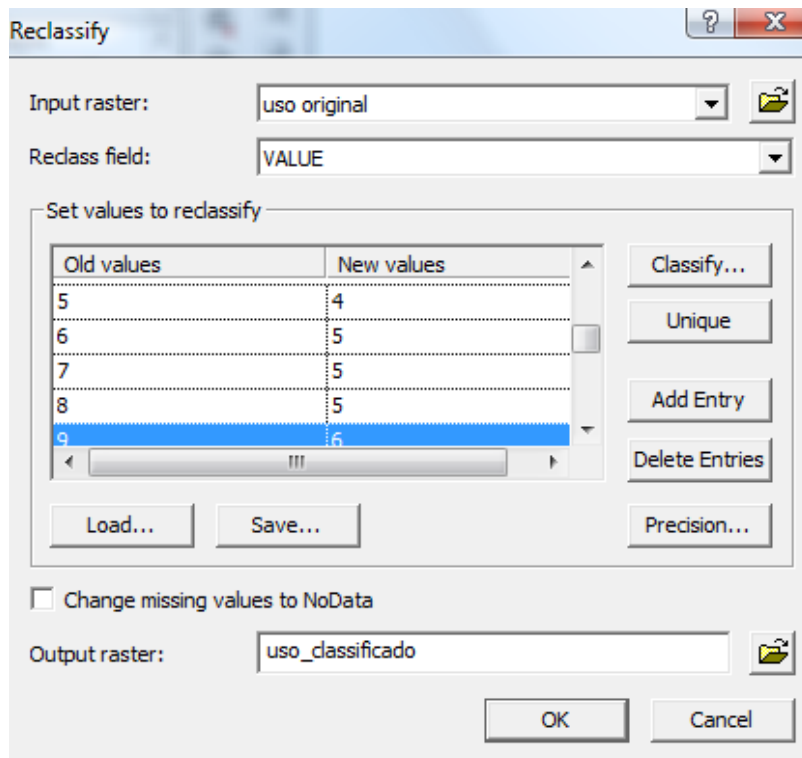


Figura 17. Ferramenta Reclassify.

A reclassificação das classes objetivou classificar os semelhantes tipos de uso do solo em classes mais genéricas.

O próximo passo foi converter o formato de dados, utilizando a caixa de ferramentas *Spatial Analyst* executando a ferramenta *Convert Raster to Feature*.

Naturalmente, quando se reclassifica as classes em um grupo maior, em dados formato *raster*, o operador *agregação* é executado, pois, no formato *raster*, não existe “limite” entre classes como nos arquivos vetoriais, a agregação é feita no momento da reclassificação, e quando são exportados para vetor, os limites entre classes semelhantes, que seriam eliminados, já não existem mais.

Estes dois operadores, *classificação* e *agregação*, são parte dos operadores conceituais, que operam sobre a tabela de atributo dos dados.

O primeiro operador geométrico utilizado foi *eliminação*, onde as áreas que tinham área inferior à AMM foram eliminadas. Para determinar a AMM foi utilizada a

$$\text{Lado} = \text{escala alvo} \times \text{acuidade visual} \quad (\text{Equação 1:})$$

$$\text{Lado} = \text{escala alvo} \times \text{acuidade visual} \quad (\text{Equação 1})$$

Onde:

- Área em m² = lado x lado / 100m;
- AMM em hectares = Área / 10.000 m².

Neste caso aplica-se:

- Lado = 50.000 x 0,2 / 100 = 100 m;
- Área em m² = 100x100 = 10.000 m²;
- AMM em hectares = 10.000 / 10.000 = 1 ha.

O algoritmo disponível no SIG utilizado encontra-se na caixa de ferramentas *Data Management Tools – Generalization*, na ferramenta *Eliminate* (Figura 18). Este algoritmo elimina a classe com a área inferior a tolerância aplicada, AMM, e a substitui pela classe vizinha de maior área.

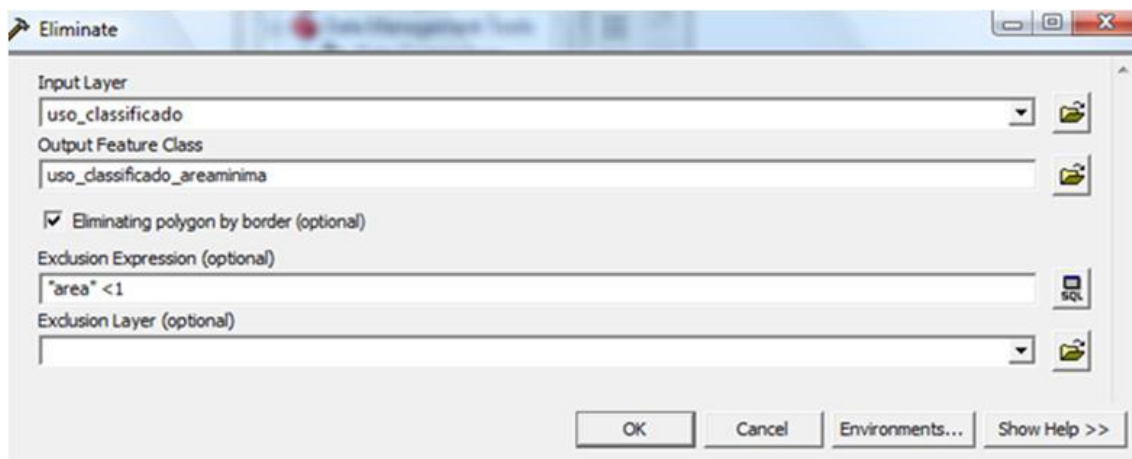


Figura 18. Ferramenta Eliminate.

O próximo operador geométrico foi *suavização*, este operador suaviza as bordas rearranjando os vértices dos polígonos e/ou adicionando novos vértices. Neste caso, como o arquivo foi produto de uma importação de formato *raster*, verificou-se que os polígonos gerados apresentaram muitas “quinas”, demandando o uso deste operador.

Foram aplicados dois diferentes algoritmos, disponíveis na caixa de ferramentas *Data Management Tools - Generalization*, ferramenta *Smooth Polygon* (Figura 19). São encontrados aqui dois diferentes algoritmos:

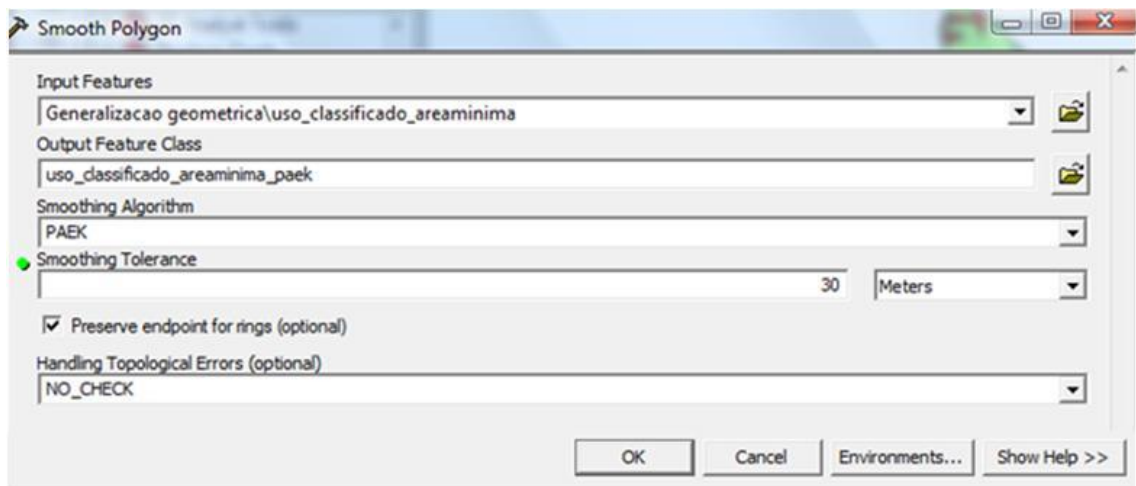


Figura 19. Ferramenta Smooth Polygon

PAEK: É sigla para *Polynomial Approximation with Exponential Kernel*, produz polígonos suavizados e podem ser adicionados novos vértices na linha original, a tolerância especificada determina a localização de novos vértices ou deslocamento dos existentes. No nosso caso foi especificada uma tolerância de 30 metros (Figura 20).

Bezier: Neste algoritmo são geradas curvas entre os vértices e não necessita definir tolerância (Figura 20).

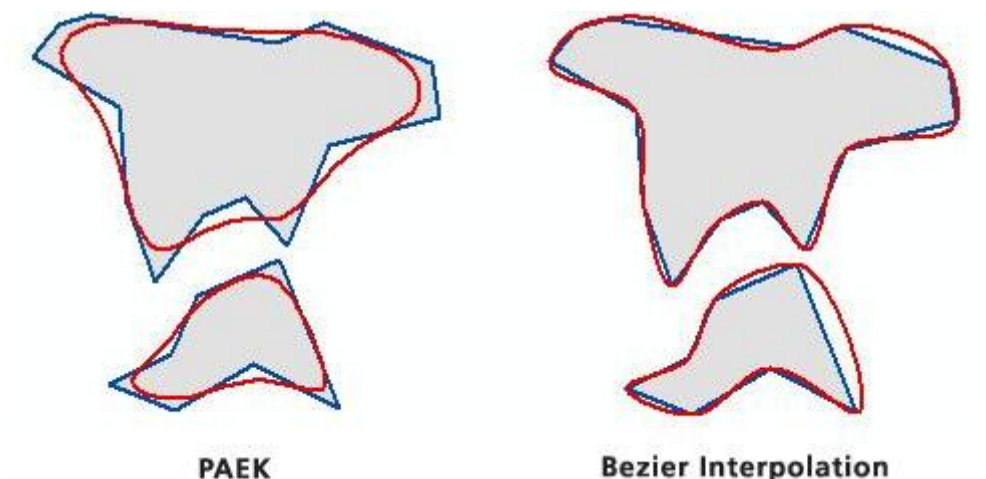


Figura 20. Algoritmo PAEK e Bezier

Para avaliar qual algoritmo produziu melhores resultados, que no nosso entendimento significa o que menos alterou as formas dos polígonos, foram adotados quatro valores de variação: área média, perímetro médio, coeficiente de compacidade (K_c) e o desvio-padrão médio (para cada parâmetro) para cada classe. Cada uma destas variáveis foram extraídas do mapa anterior à suavização, ou seja, o mapa após aplicar o

operador *eliminação*. Estas variáveis extraídas foram a base de valores para comparação entre os dois algoritmos de suavização. Desta maneira, foi elaborado um gráfico comparativo com as variáveis: área média, perímetro médio e coeficiente de compacidade médio. O desvio-padrão é um dado complementar e não foi exposto em gráfico, apenas em tabela. Entende-se que o algoritmo que menos provocou modificações nas variáveis em estudo foi o mais eficaz.

O parâmetro Coeficiente de compacidade (K_c) é usualmente utilizado para análise morfométrica de bacias hidrográficas. Esta equação permite conhecer o grau de irregularidade de um polígono. O valor mais próximo de 1 tende para forma de círculo, formas irregulares são superiores à este valor (Villela e Matos, 1975) $K_c = 0,28 \times P/\sqrt{A}$ (Equação 2).

$$K_c = 0,28 \times P/\sqrt{A} \quad (\text{Equação 2})$$

Onde:

P = Perímetro

A = Área

Terminada a utilização dos operadores, o passo seguinte foi quantificar as áreas perdidas de cada classe que ao longo do processo de generalização foram a incorporadas em outras classes.

O arquivo original, em formato *raster*, foi novamente exportado para vetorial, porém, sem reclassificar, ou seja, o arquivo foi exportado com os dados brutos, sem a execução de qualquer tipo de operador. Foi realizada uma tabulação cruzada, comparando o mapa original com o final, após a utilização de todos os operadores descritos e aplicação dos dois algoritmos de suavização. A ferramenta para executar essa operação encontra-se na caixa de ferramentas *Spatial Analyst – Zonal – Tabulate Área*.

Por último, foi realizada uma análise visual dos resultados em escala reduzida, comparando o mapa original, com os dois produtos finais, resultantes dos algoritmos PAEK e Bezier. O esquema da Figura 21 apresenta a sequência dos operadores utilizados.

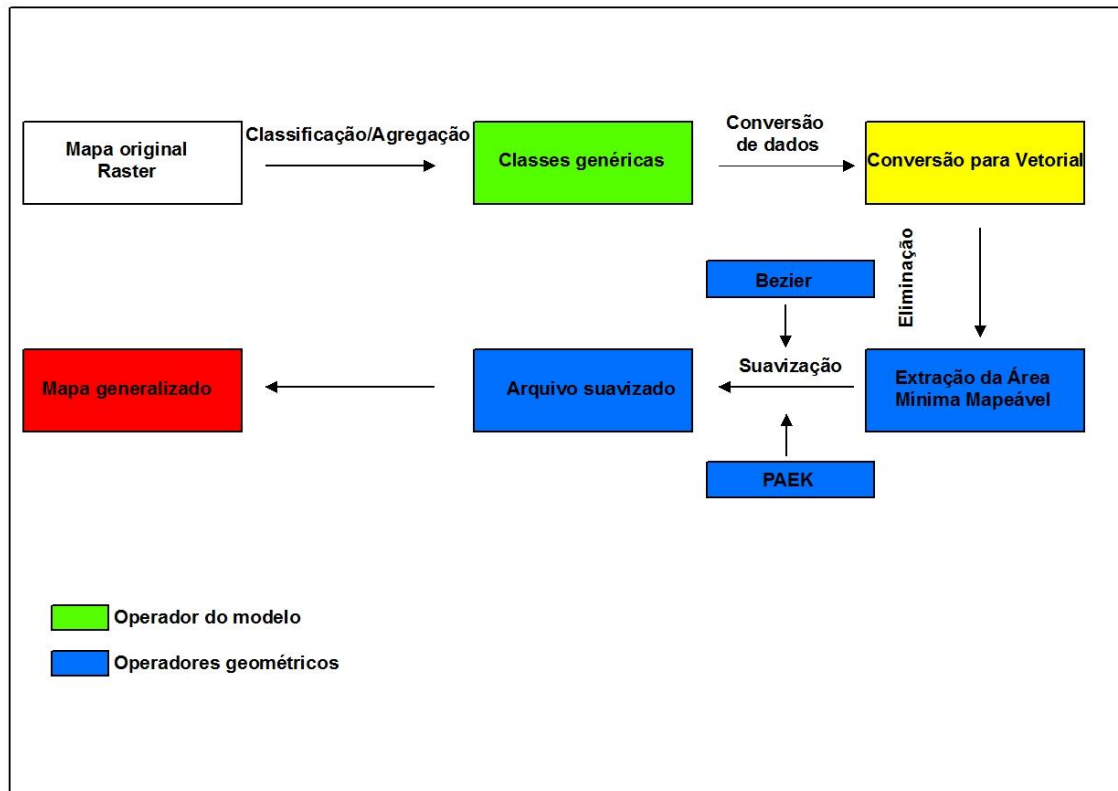


Figura 21. Sequência para formato vetorial.

3.3. Método para generalização em formato matricial

Para generalização em formato matricial, foram aplicados os operadores: categorização, dilatação e erosão, amalgamação, eliminação e numérica.

Foram realizados três cenários distintos, os dois primeiros alterando a aplicação dos operadores *dilatação e erosão* e o último não utilizando estes operadores. Nesta pesquisa, entendeu-se que o operador amalgamação é resultado da aplicação destes operadores, assim, o último cenário é uma contra-prova, verificando a real necessidade do uso de tais operadores, se a amalgamação preservou grupos de pixels que poderiam ser eliminados mas, que após este operador, apresentaram área superiores à AMM.

Na Figura 22 é apresentado um modelo da atuação dos operadores dilatação, erosão e amalgamação. Na figura da esquerda, a cor amarela representa os pixels dilatados, a figura da direita representa os pixels erodidos e amalgamados.




Figura 22. Atuação dos operadores dilatação e erosão

O SIG utilizado oferece duas maneiras de utilizar esses operadores. Na caixa de ferramentas *Spatial Analyst - Generalization*, ferramenta *Boundary Clean* encontra-se este algoritmo que utiliza dilatação e erosão consecutivamente, permitindo o operador a escolher três tipos diferentes de rotinas, de acordo com prioridades, por área ou definida pelo usuário.

No Sort: Aqui a prioridade de uma classe dilatar e erodir sobre a outra é definida pelo usuário.

Descend: Nesta rotina a prioridade é de áreas maiores sobre as menores.

Ascend: Ao contrário da última, a prioridade é de áreas menores (independente da AMM) sobre as maiores.

Para esta pesquisa, decidiu-se utilizar a rotina *Ascend*, pois, o mapeamento original na área de estudo originou uma grande variedade de agrupamentos de *pixels* com áreas pequenas, que por vezes, estão próximas, porém, não conectadas.

A outra maneira de utilização dos operadores está presente na caixa de ferramentas *Spatial Analyst - Generalization*, ferramenta *Expand* (expansão ou dilatação) e na ferramenta *Shrink* (erosão), separadamente.

A diferença fundamental entre o primeiro algoritmo descrito e os dois utilizados de forma separada é que utilizando as ferramentas *Expand* e *Shrink* separadamente, o SIG permite que o usuário determine quais agrupamentos de *pixels* quer aplicar a função e quantos *pixels* quer dilatar e erodir. Em outras palavras, permite reunir os agrupamentos de *pixels* com à AMM inferior a tolerância estabelecida, expandi-los e depois os erodir, de forma que, esses agrupamentos de *pixels* terão uma oportunidade de se amalgamarem a agrupamentos semelhantes que estão próximos e não conectados, com a possibilidade da sua área final ser superior à AMM e então não serem eliminados.

No primeiro cenário proposto utilizou-se a ferramenta *Boundary Clean* e o segundo cenário utilizará as ferramentas de dilatação e erosão separadamente. Um método de avaliar qual algoritmo de dilatação e erosão foi mais eficaz é verificar qual deles permitiu menor “invasão” de uma classe sobre a outra. Pois, quando um grupo de *pixels* é expandido e erodido, células de diferentes classes podem sobrepor umas às outras, acarretando em perda de área de um grupo para outro.

Para tanto foi utilizado um método comum em técnicas de classificação de imagens, que é o Índice de Exatidão Global (total) e Índice Kappa que podem ser derivados partir de uma matriz de confusão $m \times m$, onde m são as classes analisadas. As linhas da matriz representam as áreas derivadas do mapa de referência enquanto as colunas representam as classes após a aplicação do algoritmo.

O Índice de Exatidão Global indica o número de *pixels* corretamente classificados dividido pelo número total de *pixels* do mapa de referência. A análise da matriz de confusão apresenta, para cada classe, erros de omissão e de comissão. Os erros de omissão podem ser descritos como a omissão no mapa de determinados grupos de *pixels* das classes originais, que são classificados como outra classe. Os erros de comissão são determinados *pixels* que são atribuídos à uma classe do mapa final ao qual não pertence, enquanto deveriam estar em outra classe. Ou seja, enquanto o erro de omissão reflete os *pixels* “perdidos” para outra classe, o erro de comissão reflete os *pixels* “recebidos” por outra classe.

O Índice Kappa (Equação 3) nos revela a exatidão do mapa final, em referência ao mapa original, e é derivado a partir do Índice de Exatidão Total e o valor esperado calculado usando as marginais da matriz de confusão.

De acordo com Congalton (1991) o valor apresentado pelo Índice Kappa é considerado satisfatório na precisão de uma classificação temática, porque considera toda a matriz de confusão no seu cálculo, incluindo os elementos da diagonal principal (concordância real), utilizado no Índice de Exatidão Global, além dos elementos marginais da matriz, os quais representam as discordâncias na classificação.

$$\text{Índice Kappa (K)} = \frac{(\text{valor observado} - \text{valor esperado})}{1 - \text{valor esperado}} \quad (\text{Equação 3})$$

Onde:

Valor observado = Índice de exatidão total

Valor esperado = Valor calculado usando as marginais da matriz de erros

O Índice Kappa é dividido por intervalos de valores conforme nível de aceitação, como indicado por SOARES (2001):

Tabela 2. Intervalo de valores do Índice Kappa

$K \leq 0,2$	Péssimo
$0,2 < K \leq 0,4$	Razoável
$0,4 < K \leq 0,6$	Bom
$0,6 < K \leq 0,8$	Muito bom
$0,8 < K \leq 1,0$	Excelente

No primeiro cenário, as áreas menores tiveram prioridade sobre as áreas maiores e no segundo, apenas as áreas inferiores à AMM determinada tiveram prioridade sobre as demais, no terceiro não se utilizou estes operadores. Os outros operadores foram utilizados da mesma forma para os três cenários.

Para os três cenários, foi realizada uma tabulação cruzada entre o mapa original e o mapa final, após todos os processos, para determinar o grau de pureza de cada classe final, da mesma maneira que foi feito nos dados vetoriais.

3.3.1. 1º Cenário

O primeiro passo foi classificar as classes originais em classes genéricas que contenham características semelhantes, utilizando o operador *categorização*, diminuindo de 15 para 10 classes de uso e cobertura do solo. Para tanto, foi utilizada a ferramenta *Reclassify* (Figura 17), disponível na caixa de ferramentas *Spatial Analyst*.

Em seguida foi aplicado os operadores *dilatação*, *erosão*. Aqui foi utilizada a ferramenta *Boundary Clean* (Figura 23), com a rotina *Ascend*, priorizando as menores áreas, ressaltando que aqui é independente da AMM, pois agrupamentos de *pixels* com áreas superiores à AMM, mas, menores que os agrupamentos adjacentes, tiveram prioridade.




Figura 23. Ferramenta Boundary Clean

O operador *eliminação* foi aplicado em seguida, com o mesmo conceito de AMM que foi apresentado para dados vetoriais, porém, neste caso a relação é ao nível do *pixel*. A AMM foi determinada como 1 hectare, que é equivalente à 625 *pixels* de acordo com a Equação 4.

$$AMM_p = \frac{AMM}{A_p} \quad (\text{Equação 4})$$

Onde:

- AMM_p = Número de *pixels* mínimo por região;
- AMM = área mínima mapeável;
- A_p = área do *pixel*.

Neste caso aplica-se:

$$AMM_p = \frac{10000 \text{ m}^2}{16} = 625 \text{ pixels}$$

Para utilizar esse operador no SIG foi seguida a seguinte rotina na ferramenta *Raster Calculator*, da caixa de ferramentas *Spatial Analyst*:

regiongroup([arquivo de saída do boundary clean], #, EIGHT, WITHIN)
(Figura 24)

A ferramenta *region group* individualiza com novos identificadores os agrupamentos de *pixels*.

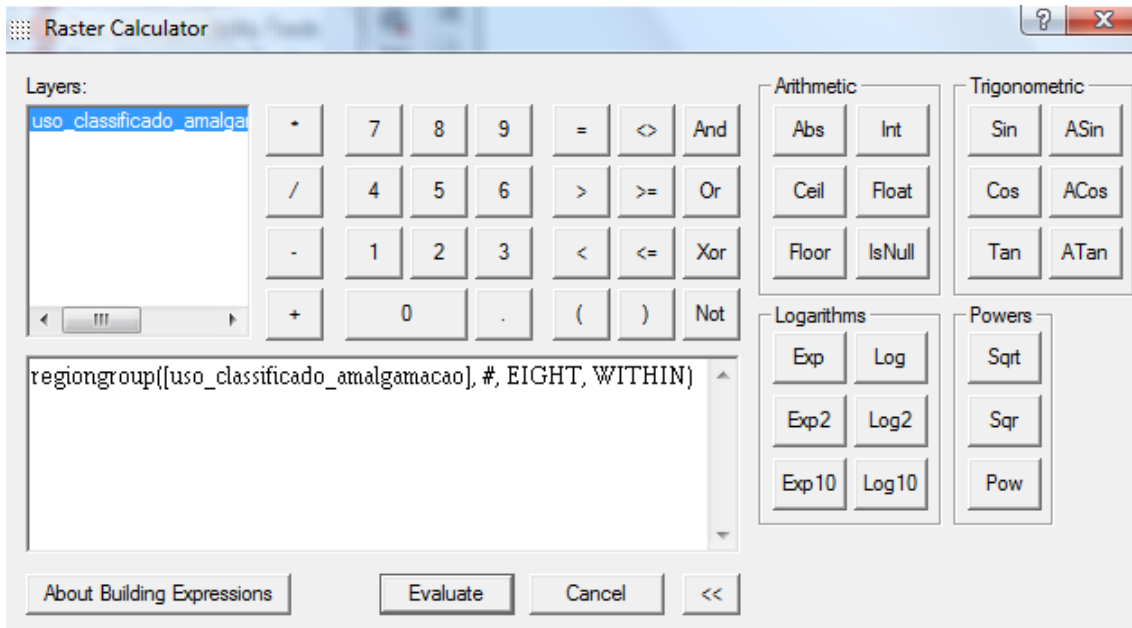


Figura 24. Ferramenta Region Group.

Select([arquivo de saída do region group], 'count > 625') (Figura 25)

Esta ferramenta seleciona os agrupamentos de *pixels* individualizados pela ferramenta anterior que tem número de *pixels* (*count*) acima do valor determinado. Os valores abaixo do determinado receberam um valor nulo.

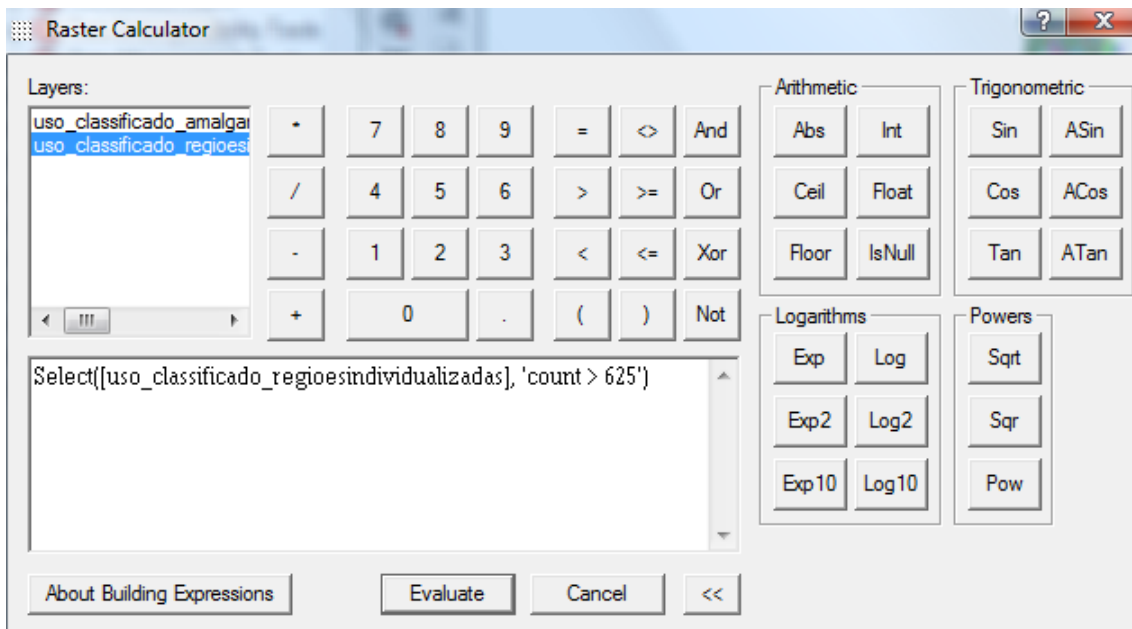


Figura 25. Ferramenta Select

Nibble([arquivo de saída do boundary clean],[arquivo de saída do select])
(Figura 26)

Nesta ferramenta é executada uma álgebra de mapas, onde o *raster* original é multiplicado com as áreas selecionadas no passo anterior. As regiões que tinham abaixo de 625 *pixels* foram eliminadas e foram substituídas pelo vizinho mais próximo de acordo com o mapa original.

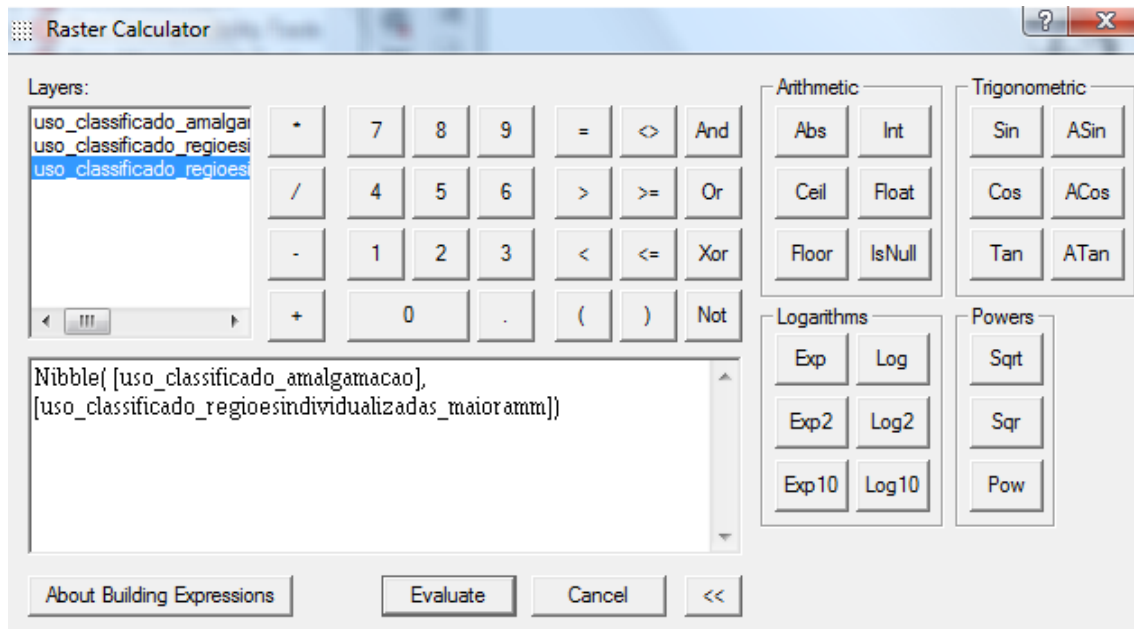


Figura 26. Ferramenta Nibble.

Em seguida, com o mapa apresentando apenas as regiões com área apresentável, aplicou-se o operador *numérico*, um filtro majoritário, onde a célula central, a partir de uma “janela” de tamanho opcional, que tem uma quantidade de *pixels* vizinhos, cada um com um valor. A partir dos valores predominantes dos vizinhos, o valor do *pixel* central é alterado de acordo com esse valor majoritário. Este operador implica na suavização das bordas, tornando o mapa esteticamente mais agradável, especialmente quando se reduz a escala.

O algoritmo selecionado para este operador é encontrado na caixa de ferramentas *Spatial Analyst – Neighborhood* na ferramenta *Focal Statistics* (Figura 27). Utilizou-se duas técnicas disponíveis no algoritmo com três rotinas para cada uma. Na primeira foi aplicada uma janela espacial retangular (Figura 28) de 3x3; 6x6 e 9x9, com 9; 36 e 81 *pixels* vizinhos respectivamente. A seguinte com janela espacial circular (Figura 29) de 3x3; 6x6 e 9x9 com 9; 36 e 81 *pixels* vizinhos respectivamente, para a célula central, assim, nestes grupos de vizinhos o valor mais encontrado é atribuído à célula central.

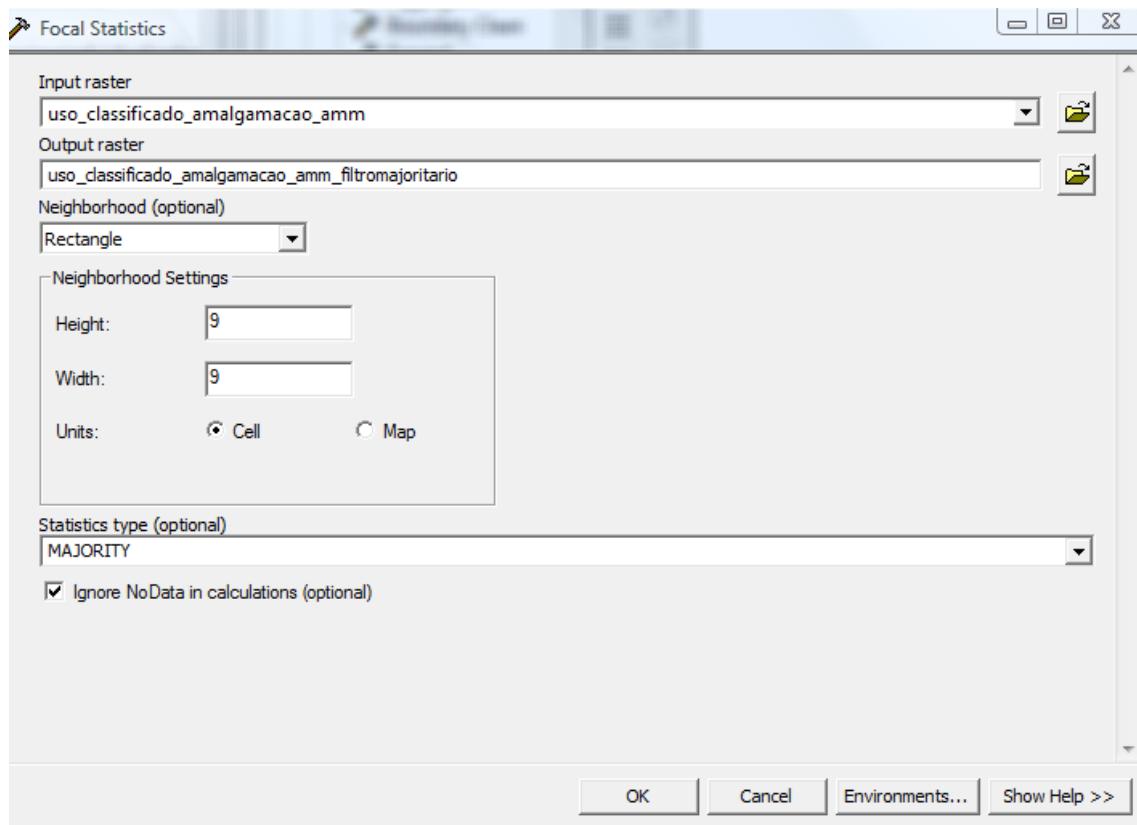


Figura 27. Ferramenta Focal Statistics




Figura 28. Filtro espacial retangular

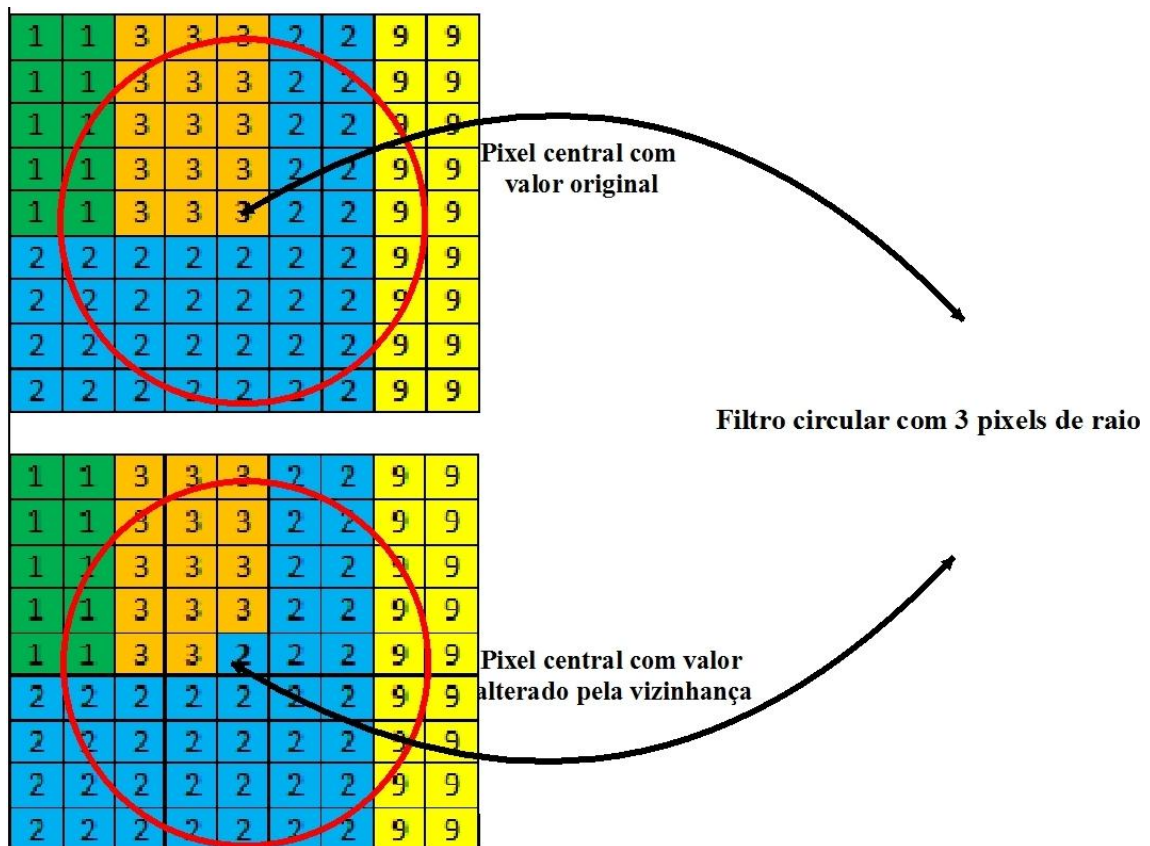


Figura 29. Filtro espacial circular

A proposta para a utilização diferentes técnicas e rotinas é avaliar qual foi a que menos modificou as formas dos objetos que compõem o mapa, de forma similar à avaliação realizada sobre os dados vetoriais. Neste caso, levou-se em consideração variação da área média, perímetro médio, Kc médio e desvio-padrão médio, para mensurar os resultados dos filtros.

A Figura 30 demonstra o esquema utilizado na generalização deste primeiro cenário em ambiente matricial ou raster.

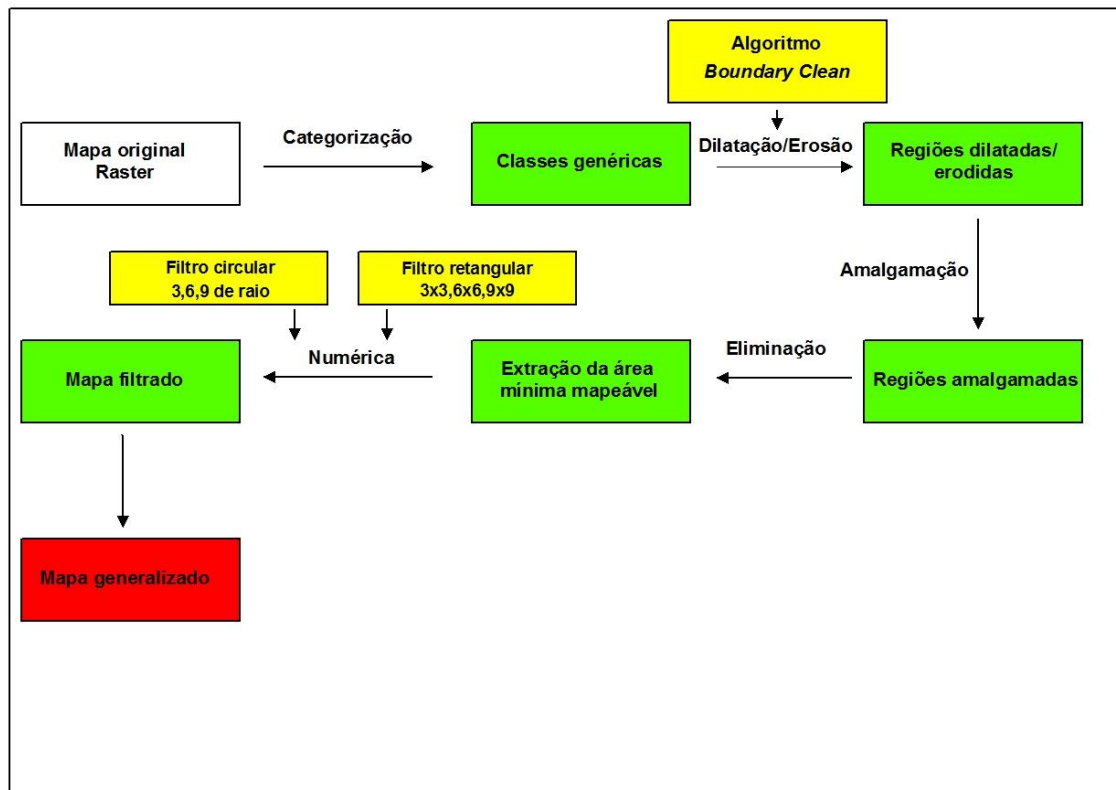


Figura 30. Esquema para o primeiro cenário

3.3.2. 2º Cenário

Como foi ressaltado anteriormente, a única diferença entre os dois cenários foi na escolha do algoritmo utilizado para aplicação dos operadores dilatação, erosão. Neste cenário, ao contrário do anterior, estes operadores foram aplicados separadamente e atuando apenas nas áreas inferiores à AMM.

De posse do mapa já classificado, utilizou-se a ferramenta *Region Group* da caixa de ferramentas *Spatial Analyst – Generalization*. Esta ferramenta individualiza os grupos de *pixels* com novos identificadores, porém, na tabela de atributos existe uma

coluna que mostra à qual classe estes grupos pertencem.

No operador *dilatação*, foi utilizada a ferramenta *Expand* da caixa de ferramentas *Spatial Analyst – Generalization*. Na ferramenta anterior, *Region Group*, todos os grupos de *pixels* foram individualizados, num total de 1.296 grupos, cada um com um identificador diferente. Esta ferramenta necessita “saber” para operar em quantos *pixels* os grupos serão expandidos e quais destes grupos serão utilizados, ou seja, é necessário informar quais os identificadores dos grupos que estão com área inferior à AMM. Visto a quantidade de grupos que tem essa especificação, 1.141, o que geraria um grande esforço manual e um maior tempo gasto, optou-se utilizar a ferramenta *Raster Calculator*, da caixa de ferramentas *Spatial Analyst*.

Foi necessário então, a partir da tabela de atributos do arquivo gerado pela ferramenta *Region Group*, selecionar todos os grupos que tem a área inferior à AMM. A partir daí, exportar estes grupos para formato .DBF, e no *Microsoft Office Excel* transformá-los para arquivo texto .TXT.

Na ferramenta *Raster Calculator* executa-se a seguinte equação (Nome arq = Expand.([output Region Group], np, FILE, RzSO) (Equação 3):

$$\text{Nome arq} = \text{Expand.}([\text{output Region Group}], \text{np}, \text{FILE}, \text{RzSO}) \quad (\text{Equação 3})$$

Onde:

- Nome arq = nome do arquivo a ser criado;
- Expand = função utilizada;
- Output Region Group = arquivo de saída da ferramenta Region Group;
- np = quantidade de *pixels*;
- RzSO = localização da pasta no sistema operacional.

Neste caso, a quantidade de *pixels* para dilatar foi determinada em 1 (**Erro!**

Fonte de referência não encontrada.)

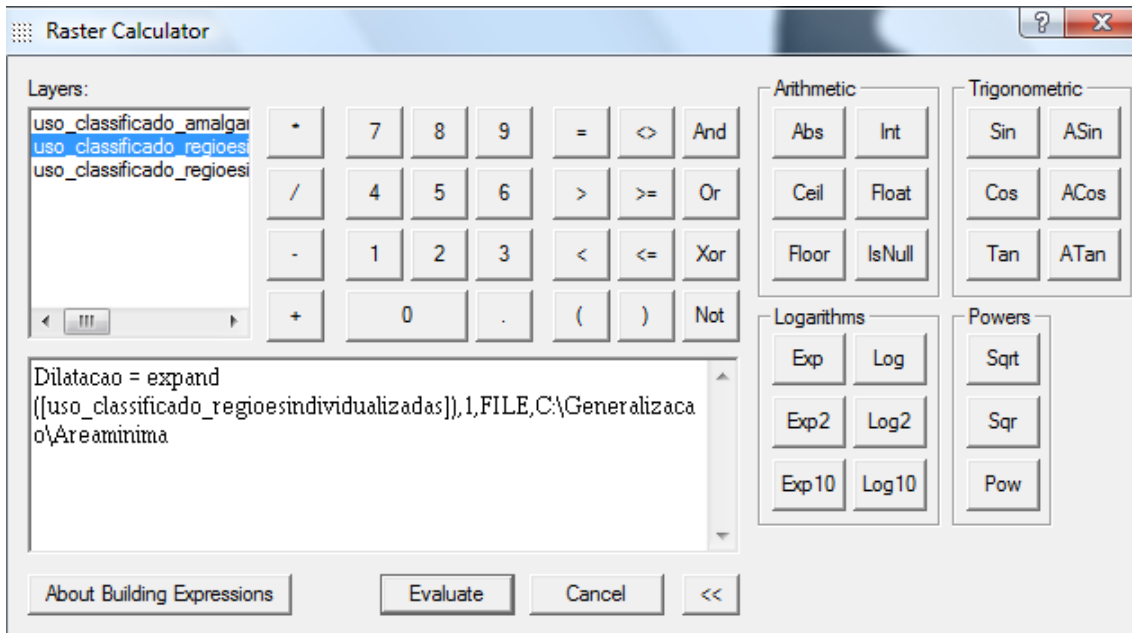


Figura 31. Ferramenta Expand

De posse do arquivo de saída, foi aplicado o operador *erosão*. Da mesma forma que o algoritmo anterior, este exige as mesmas especificações e é encontrado na mesma caixa de ferramentas, utilizando a ferramenta *Shrink*. Assim, a mesma equação foi utilizada, no entanto, ao invés de expandir, este algoritmo erode a mesma quantidade de *pixels* que foram expandidos (um), mas que não se conectaram (Nome arq = Shrink.([output Dilatacao], np, FILE, RzSO) (Equação 4 e Figura 32). Nota-se que agora, o arquivo de entrada é o arquivo de saída do último operador.

$$\text{Nome arq} = \text{Shrink}.\text{([output Dilatacao], np, FILE, RzSO)} \quad (\text{Equação 4})$$

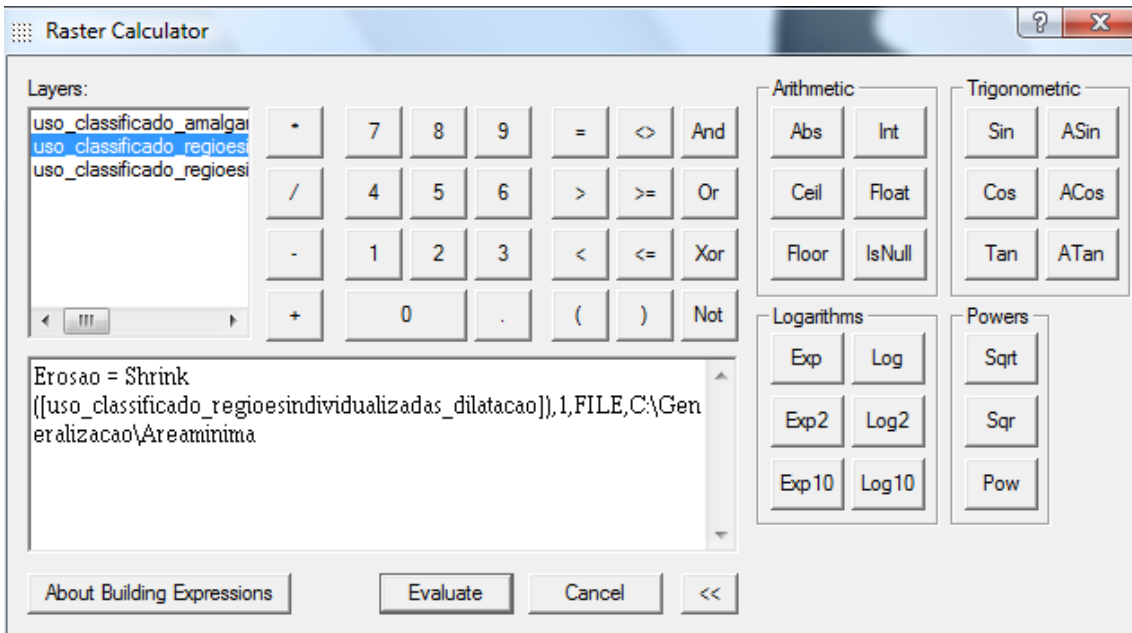


Figura 32. Ferramenta Shrink

Por fim, aplica-se o operador *eliminação* e em seguida o operador *numérico*. A Figura 33 apresenta o esquema utilizado neste cenário.

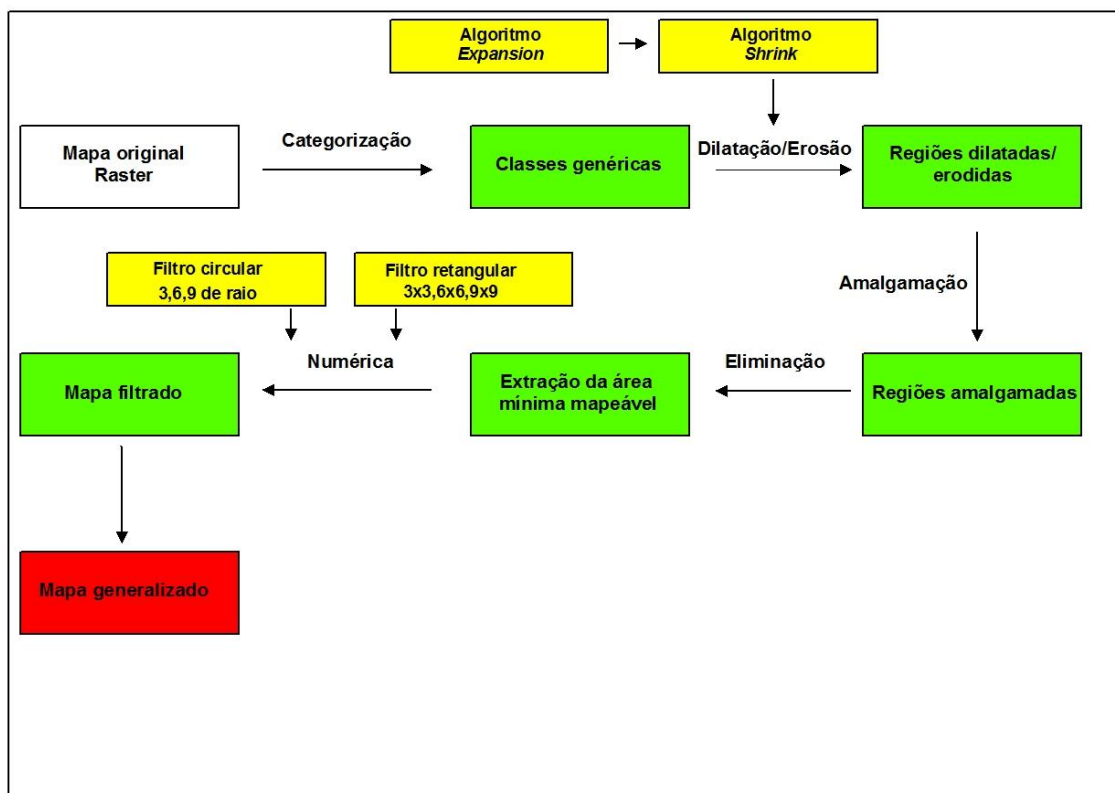


Figura 33. Esquema para o segundo cenário

3.3.3. 3º Cenário

A diferença fundamental deste último caso para os demais é a não utilização dos operadores *dilatação, erosão e amalgamação*.

Entende-se que o objetivo destes operadores é preservar determinados objetos que tem áreas inferiores à AMM, que estão próximas, mas não conectadas. Porém, para verificar se houve necessidade da aplicação destes operadores neste mapa, eliminou-se este passo, reduzindo as etapas do processo.

A maneira encontrada de averiguar se foi necessário o uso desses operadores foi realizada através da quantificação de número de grupos de *pixels*, ou seja, se utilizando os operadores citados houve, após o operador *eliminação*, uma quantidade maior de agrupamentos de *pixels*, então esses operadores conseguiram reter mais grupos do que se não fossem utilizados, caso contrário, se houve a mesma quantidade de grupos ou um número inferior, podemos afirmar que para este caso, não teve a necessidade de se dilatar, erodir e amalgamar. Sendo assim, foi seguida a sequência de operadores: categorização, eliminação, numérica. Utilizando os mesmos algoritmos, rotinas, tolerâncias e avaliações.

A Figura 34 apresenta o esquema utilizado neste cenário.

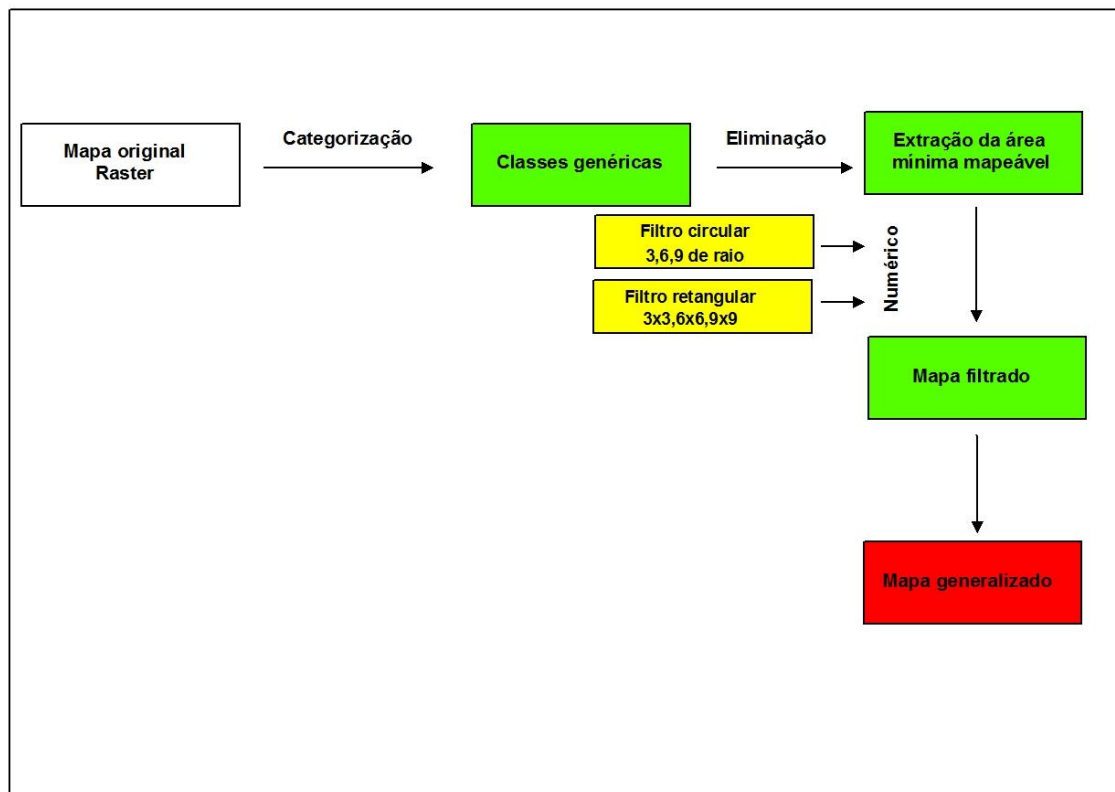


Figura 34. Esquema para o terceiro cenário

4. RESULTADOS E DISCUSSÃO

4.1. Dados vetoriais

4.1.1. Operadores Classificação/Agregação

Na conversão dos dados originais em formato *raster* para vetorial utilizou-se o operador classificação que reclassificou as classes, o que consequentemente ocasionou a agregação das classes.

A Tabela 3 demonstra numericamente os efeitos da aplicação desses operadores. Houve redução de 15 classes originais para 10 classes mais abrangentes, onde se procurou classificar com o mesmo nome as classes que são semelhantes.

Tabela 3. Resultado do operador Classificação.

CLASSE	Área total (ha)	Área relativa (%)	Nº de polígonos	Nova classe	Área total (ha)	Área relativa (%)	Nº de polígonos
Mata	76	7	192	Mata	76	7	192
Café solteiro	264	24,37	363	Café	323	29,82	312
Café c/ árvore	59	5,45	244				
Eucalipto	70	6,46	224	Eucalipto	81	7,46	235
Eucalipto	11	1	29				
Solo exposto	25	2,33	77	Solo exposto	25	2,33	77
Milho	41	3,79	91	Agricultura	56	7,52	123
Cana	14	1,30	38				
Cana queimada	1	0,1	5				
Água	7	0,64	23	Água	7	0,64	23
Taboa	30	2,77	98	Pastagem	416	42,49	167
Pastagem	386	35,64	169				
Aflor. rochoso	74	6,85	182	Aflor. rochoso	74	6,85	182
Sombra	12	1,1	42	Sombra	12	1,1	42
S/ Classificação	13	1,2	44	S/ Classificação	13	1,2	44
TOTAL	1.083	100	1.821	TOTAL	1.083	100	1.397

Nota-se que as classes Café Solteiro e Café com árvore, apesar de serem um tipo de agricultura não foram classificadas como tal, pois, devido a sua importância na região e a sua extensão em área, optou-se por individualizar essas classes como Café.

O número de polígonos foi reduzido, como era esperado, em aproximadamente 23%. Com a diminuição de classes, e o conseqüente agrupamento, determinados limites que dividiam 2 ou mais polígonos que agora são semelhantes, se reduzem a um único polígono.

A Figura 35 apresenta o mapa original com 15 classes e a Figura 36 apresenta o mapa após aplicar o operador *classificação*, ambos em escala original, 1:20.000

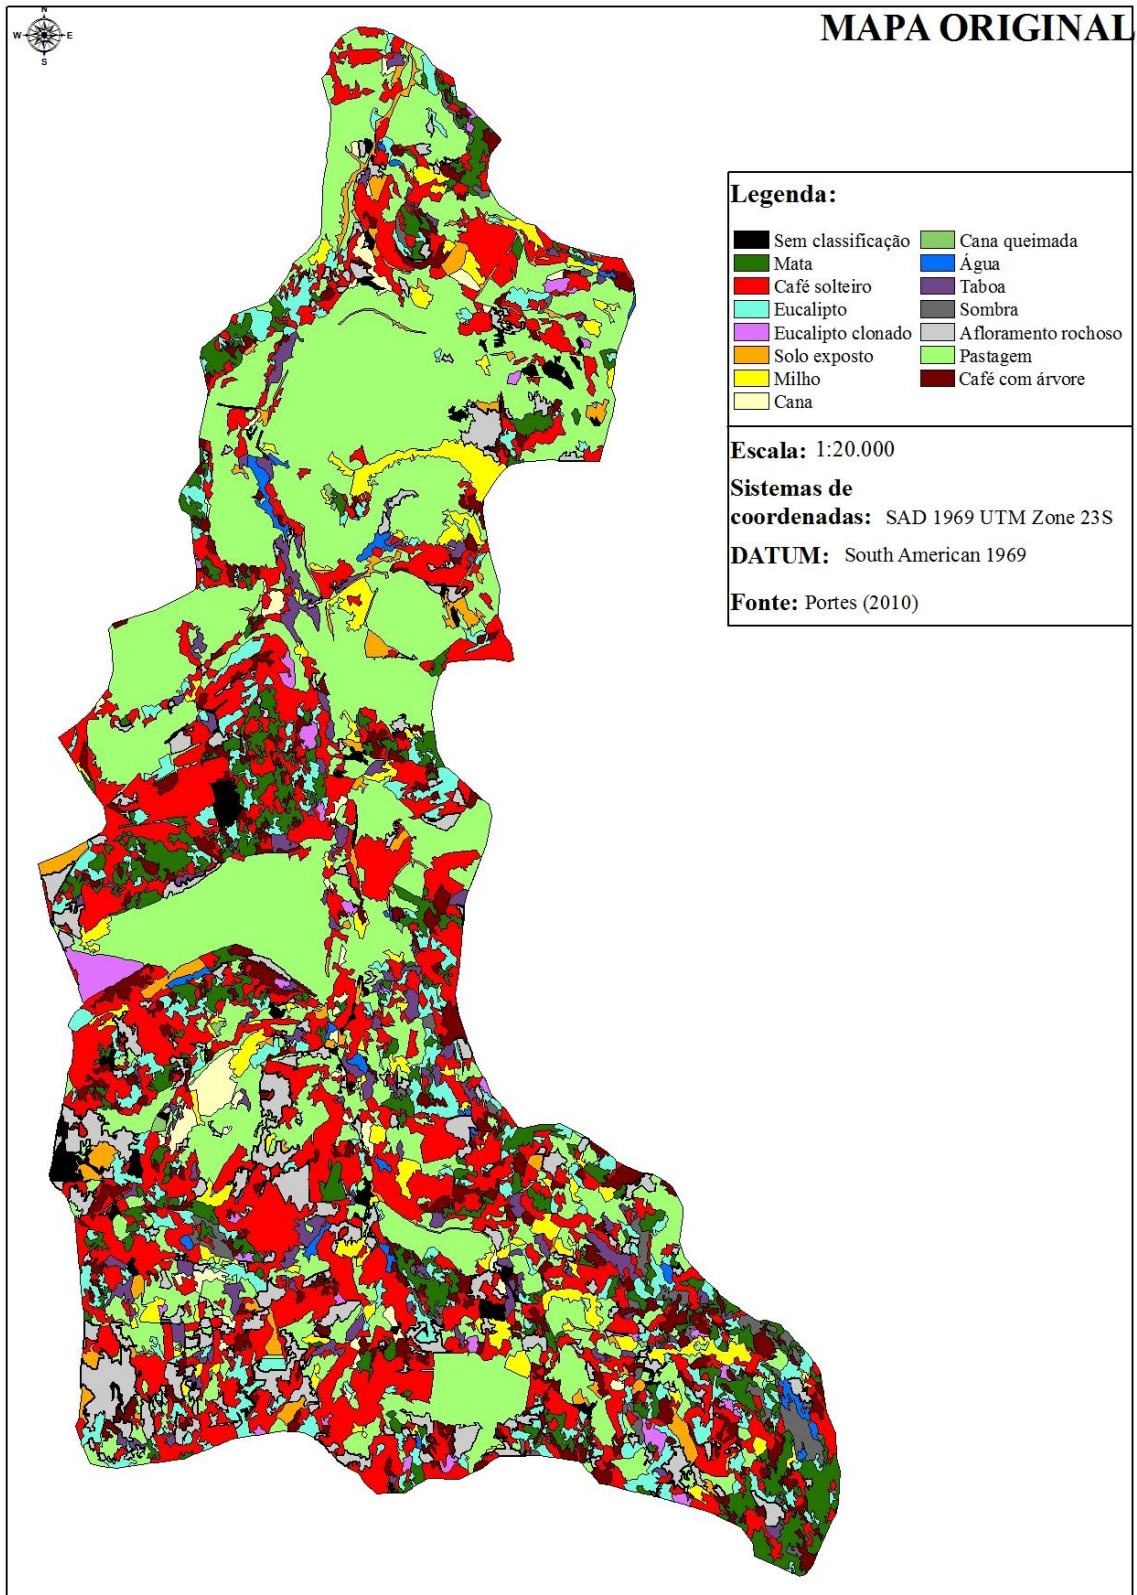


Figura 35. Mapa original

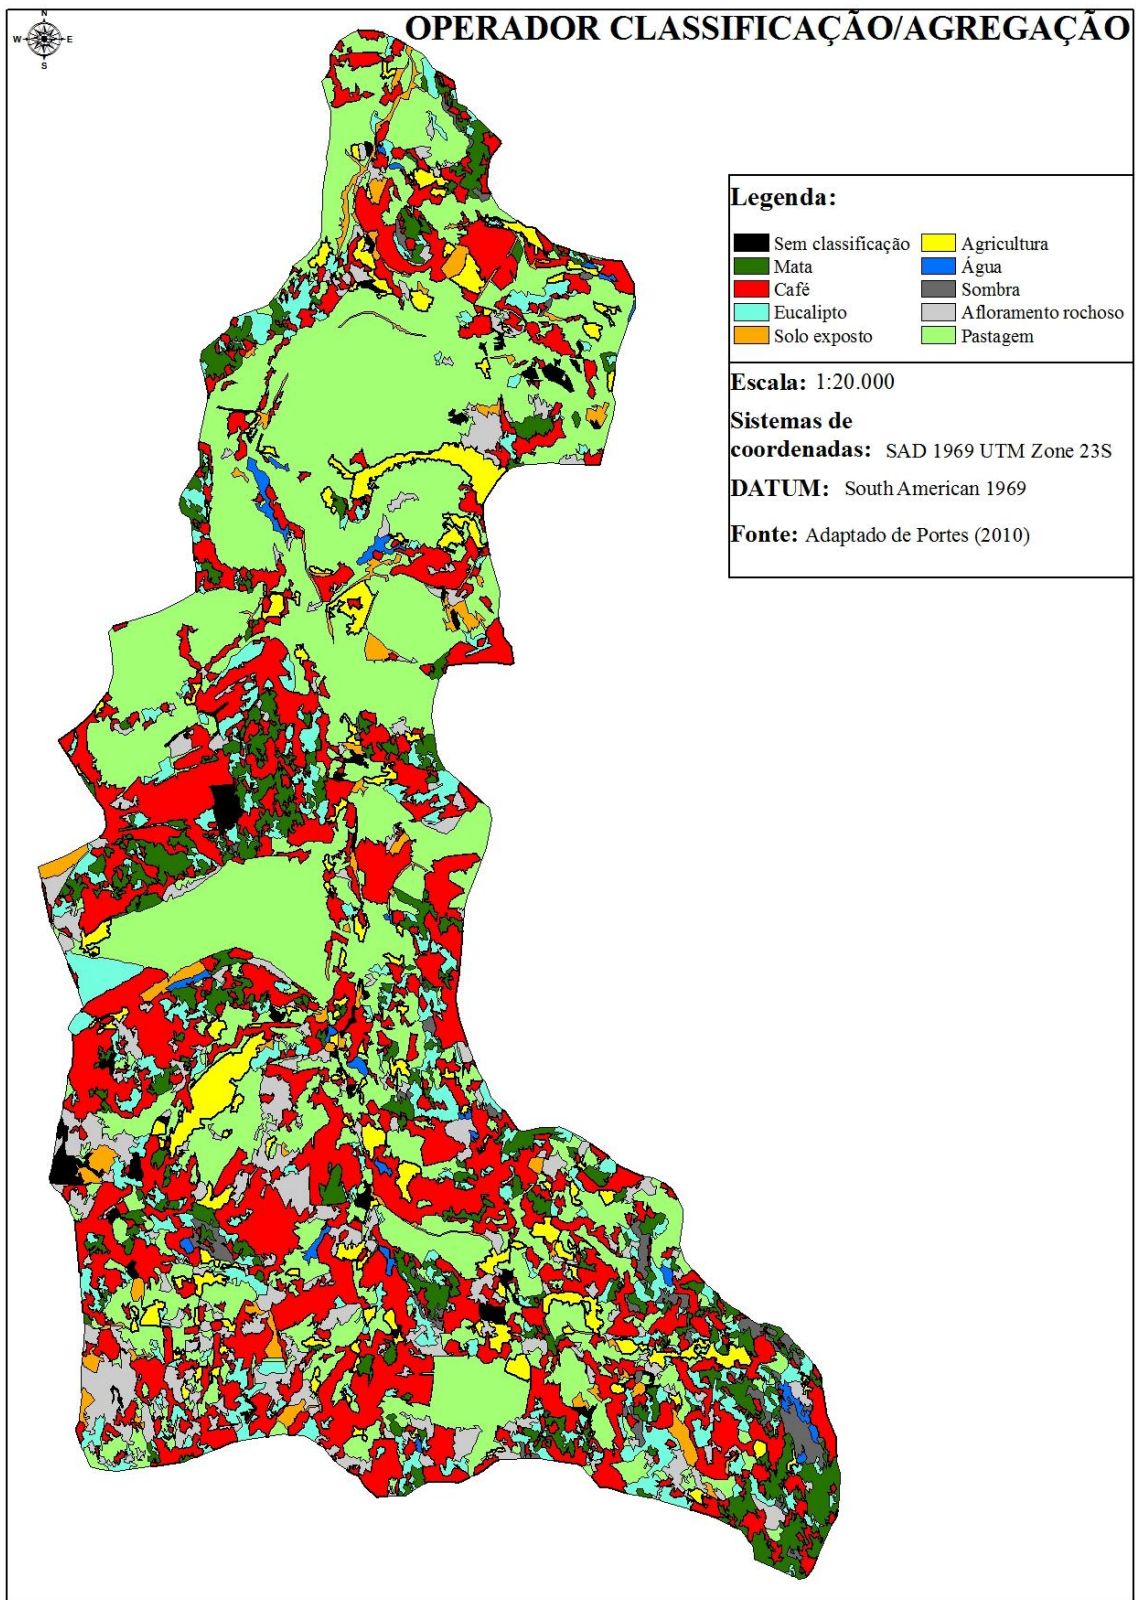


Figura 36. Mapa resultante do operador *classificação*.

4.1.2. Operador Eliminação

O próximo operador utilizado foi *eliminação*, onde as áreas inferiores à 1 hectare foram eliminadas. Este operador, aplicado no material desta pesquisa, demonstrou ser o que mais influenciou no mapa original. Como pode ser observado na Tabela 4 em termos de valores de área e número de polígonos em relação ao mapa classificado.

Tabela 4. Resultado do operador Eliminação.

CLASSE	Área total (ha)	Área relativa (%)	Nº de polígonos	CLASSE	Área total (ha)	Área relativa (%)	Diferença de área (%)	Nº de polígonos	Redução de polígonos
Mata	76	7,00	192	Mata	47	4,35	-38,15	14	92,70
Café	323	29,82	312	Café	406	37,50	25,69	30	90,38
Eucalipto	81	7,46	235	Eucalipto	35	3,23	-56,79	13	94,46
Solo exposto	25	2,33	77	Solo exposto	12	1,10	-25,00	6	92,20
Agricultura	56	7,52	123	Agricultura	30	2,80	-46,42	9	92,68
Água	7	0,64	23	Água	1	0,09	-85,71	1	95,65
Pastagem	416	42,49	167	Pastagem	496	45,79	19,23	14	91,61
Aflor. rochoso	74	6,85	182	Aflor. rochoso	40	3,69	-45,95	11	93,95
Sombra	12	1,10	42	Sombra	10	0,90	-16,66	3	92,85
S/ classificação	13	1,20	44	S/ classificação	6	0,55	-53,8	2	95,45
TOTAL	1.083	100,00	1.397		1.083	100,00		103	92,62

De acordo com os valores expostos na Tabela 4, nota-se que apenas a classe Café e Pastagem tiveram acréscimo de área, justamente as classes com maior área. Deve-se a isto, o fato que o algoritmo utilizado elimina as áreas inferiores à AMM que são substituídas pelo polígono adjacente com maior área, justificando assim o acréscimo de área dessas classes.

A Figura 37 apresenta o mapa após a aplicação deste operador em escala original.

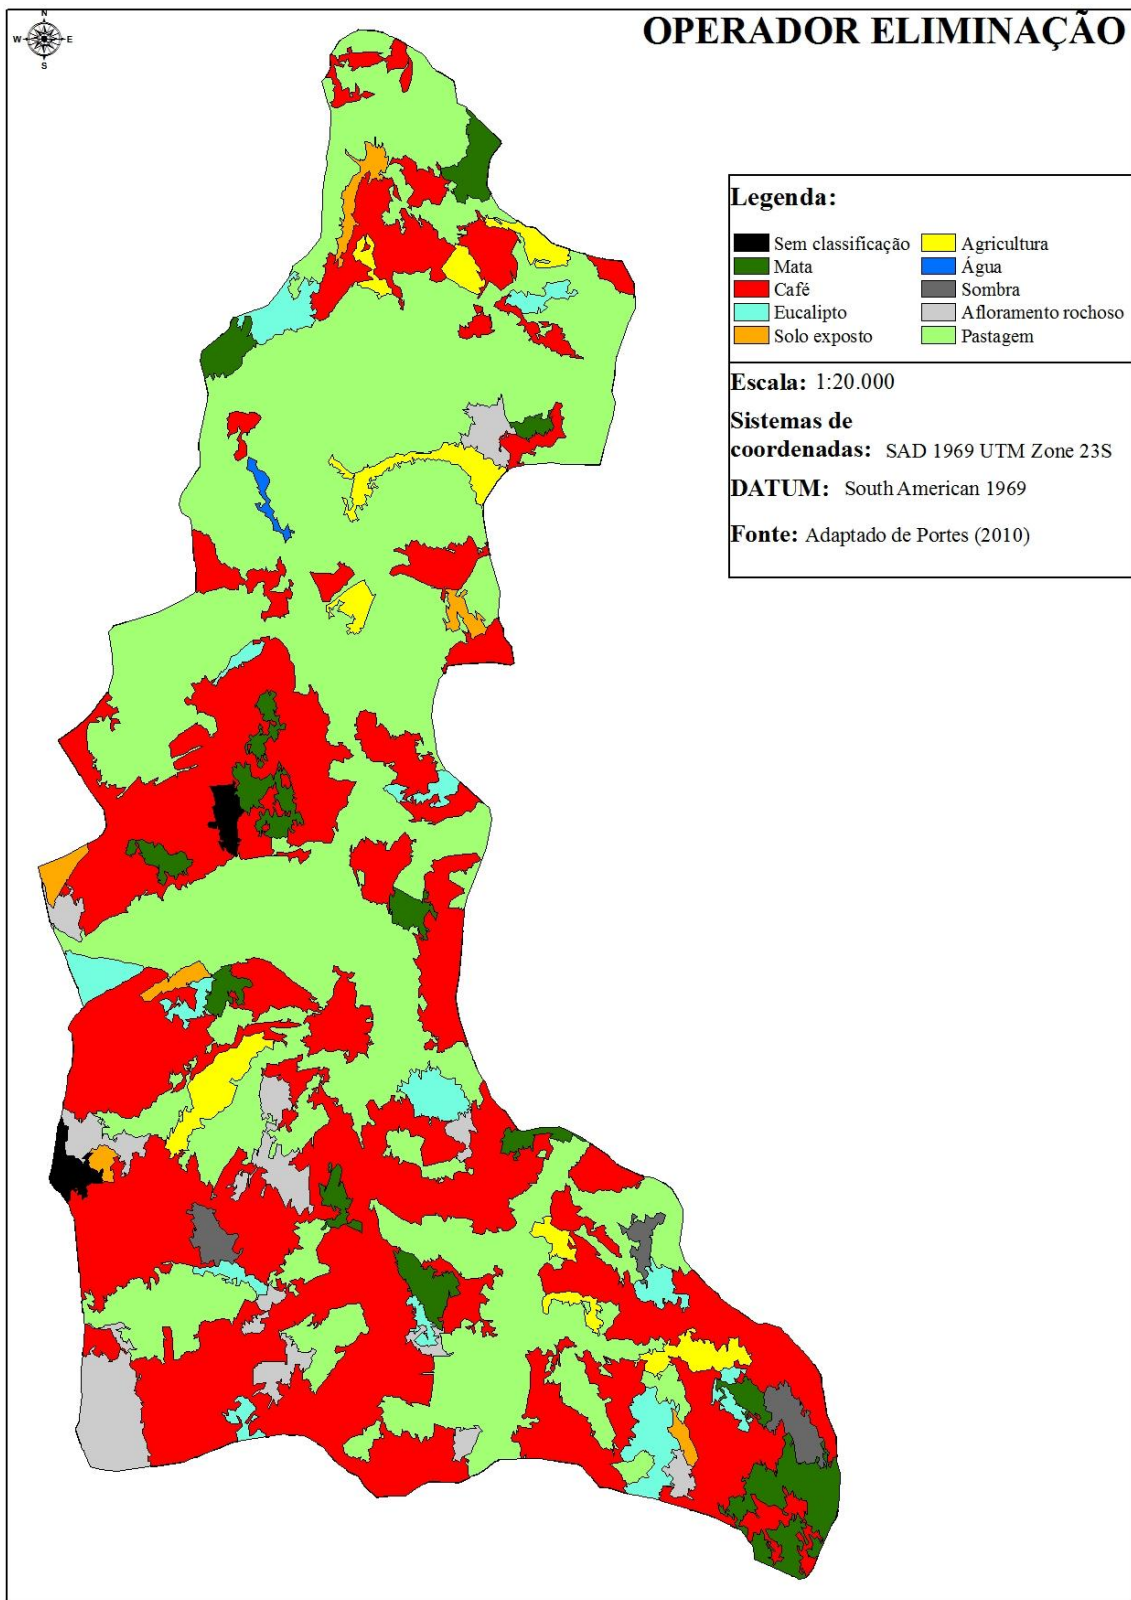


Figura 37. Mapa resultante do operador *Eliminação*.

A radical mudança da aparência mapa após eliminar áreas menores que 1 hectare esta diretamente e indiretamente influenciada pelos fatores físicos da área, históricos e do mapeamento realizado.

A região é predominantemente montanhosa, favorece assim uma mudança de ambientes em pequeno espaço, contribuindo também, além de questões históricas, o cultivo em pequenas propriedades, predominantemente familiar, e muitas delas adotam o manejo agroecológico, significando mais tipos de cultivo no espaço da propriedade. Somando esses fatores particulares da região, com o material utilizado para o mapeamento, uma imagem de satélite de alta resolução espacial, tem-se então, uma grande diversidade de mapeamento, além de uma heterogeneidade de classes mapeadas, uma grande quantidade de polígonos. Essa grande quantidade de informação por área favoreceu um mapa com muitas áreas pequenas, que de acordo com o critério utilizado, foram excluídas.


4.1.3. Operador Suavização

O operador *suavização* foi aplicado em dois diferentes algoritmos, PAEK e Bezier, o primeiro utilizando uma tolerância de 30 metros e o segundo não exige tolerância.

A maneira numérica utilizada para mensurar o resultado desses algoritmos foi a partir da variação de área média, perímetro médio, coeficiente de compacidade médio e os respectivos valores de variação de desvios-padrão para cada classe.

4.1.3.1. Variação de área média

A Tabela 11 no Anexo 1 demonstra os valores de variação de área média e desvio padrão, a Figura 38 apresenta os valores de variação de área média.



1- Afloramento rochoso 2- Agricultura 3- Água 4- Café 5- Eucalípto 6- Mata 7- Sem classificação 8- Pastagem 9- Solo exposto 10- Sombra

Figura 38. Variação de área média

Nota-se que não houve expressiva variação de área média e desvio-padrão para os dois algoritmos, que atuaram nas bordas dos polígonos, reajustando os vértices e retirando os ângulos demasiadamente agudos.

4.1.3.2. Variação de perímetro médio

A Tabela 12 no Anexo 1 apresenta a variação do perímetro médio e variação do desvio-padrão e a Figura 39 apresenta os valores referentes à variação do perímetro médio.




Figura 39. Variação de perímetro médio

1- Afloramento rochoso 2- Agricultura 3- Água 4- Café 5- Eucalipto 6- Mata 7- Sem classificação 8- Pastagem 9- Solo exposto 10- Sombra

Podemos notar que este parâmetro sofreu modificações relevantes utilizando o algoritmo PAEK. Exceto a classe “sombra”, todas as outras tiveram um decréscimo no perímetro médio variando entre -13,67% para classe “solo exposto” a 20,40% para classe “mata”, significando que houve redução nos ângulos agudos, tendendo a bordas mais suaves, esteticamente mais agradáveis. No entanto, tende também produção de informação errônea, pois, no terreno os limites naturais não tendem necessariamente a ter bordas arredondadas e os cultivos (agricultura, café, eucalipto) também não.

A mesma tendência de decréscimo foi observada no parâmetro de desvio-padrão para o algoritmo PAEK, excetuando a classe “sem classificação” e “água”. Houve neste caso uma menor dispersão de valores entre os perímetros dos polígonos, aproximando-se da homogeneidade.

O algoritmo Bezier não apresentou valores expressivos de variação de perímetro médio, variando entre 2,62% para classe “solo exposto” a 3,43% para classe “sombra”, ao contrário do algoritmo anterior foram valores positivos, o que não necessariamente significa que houve acentuação dos ângulos agudos, pois, valores desta ordem não permitem essa conclusão. A possível diferença entre os resultados dos algoritmos deve-se que o algoritmo PAEK permite a inclusão de novos vértices, além de controle da tolerância, o algoritmo Bezier apenas rearranja os vértices, a flexibilidade neste caso é menor.

O desvio-padrão para o algoritmo Bezier também sofreu pequenas modificações, excetuando a classe “pastagem”.

4.1.3.3. Variação de Kc médio

A Tabela 13 no Anexo 1 apresenta os valores de variação do coeficiente de compacidade (Kc) e do desvio-padrão e a Figura 40 apresenta os valores de variação de Kc.




Figura 40. Variação de Kc

1- Afloramento rochoso 2- Agricultura 3- Água 4- Café 5- Eucalípto 6- Mata 7- Sem classificação 8- Pastagem 9- Solo exposto 10- Sombra

O algoritmo PAEK, como era esperado, de acordo com os resultados da variação do perímetro médio, apresentou expressivas variações negativas de Kc, significando uma tendência ao arredondamento, com valores variando de -13,30% para classe “solo exposto” à -20,31% para classe “mata”. As bordas dos polígonos mais suavizadas pela redução do perímetro causam essa tendência ao arredondamento.

De maneira similar, o desvio-padrão para este algoritmo seguiu a mesma tendência de queda, variando entre 0% para as classes “água” e “sem classificação” à -29,57% para classe “mata”. Esta discrepância de valores das classes citadas, deve-se que os valores de Kc dos polígonos para o mapa base eram homogêneos para as classes com 0% de variação no desvio-padrão e apresentaram valores mais discrepantes na classe “mata”. Este algoritmo então manteve a homogeneidade para as classes com 0%

de variação no desvio-padrão e forçou uma homogeneização para o restante dos valores, pois, também apresentarem valores expressivos.

O algoritmo Bezier também não causou variações expressivas neste parâmetro, pois, como o K_c é uma razão entre perímetro e área, e essas duas variáveis sofreram modificações irrelevantes, era esperado que não houvesse alterações relevantes no K_c e no desvio-padrão.

Algumas classes fogem a tendência do grupo, é natural que haja certas discordâncias, porque cada polígono apresenta algum tipo de forma geométrica específica. O algoritmo atua sobre essas formas de maneira idêntica, no entanto, os resultados produzidos podem ser diferentes.

4.1.4. Grau de pureza das classes

Foi realizada uma tabulação cruzada entre o mapa original e o mapa final apresentando quanto das classes originais foram perdidas para outras classes e quanto foi preservado na classe original ou classe generalizada semelhante.

Entende-se que este tipo de dado é fundamental como resultado no processo de generalização, deixando claro para o usuário quais classes estão contidas naquelas representadas no mapa, e quanto isto representa no mapa final.

A Tabela 14 no Anexo 2 apresenta os resultados finais para o algoritmo PAEK. Os valores estão expressos em porcentagem.

Os números destacados em vermelho significam a porcentagem de área da classe original que foi preservada na classe final.

A classe final “água” manteve o maior grau de pureza com 92,48% do seu polígono contendo apenas a classe original “água” e a classe “sombra” foi a que menos representa a classe original com 46,68% de pureza, menos da metade desta classe é, de acordo com o mapeamento original, de fato sombra.

Em termos práticos, isto significa que em uma determinada classe representada no mapa, não existem apenas uma só classe, coexistem diversas outras, como em nosso caso.

A Tabela 15 no Anexo 2 apresenta os dados para o algoritmo Bezier. Os valores estão expressos em porcentagem.

De maneira similar ao primeiro algoritmo, a classe “água” se manteve mais íntegra com 91,81% e a classe “sombra” com menor grau de pureza, 46,67%,

novamente, correspondendo à menos da metade da representação da classe com o mesmo nome.

A partir do exposto, podemos notar, excetuando a classe “água”, que todas as classes tiveram modificações relevantes a partir do mapa original e nesse aspecto, os algoritmos demonstraram pouca variação entre si.

A Figura 66 no Anexo 3 apresenta o mapa resultante do algoritmo PAEK e o mapa resultante do algoritmo Bezier em escala reduzida. A Figura 67 no Anexo 3 apresenta os mesmos mapas para em escala ampliada.

Percebe-se que o algoritmo PAEK produziu maior suavização das bordas, eliminando as sinuosidades. O algoritmo Bezier é menos agressivo, preservando mais a forma original dos objetos.

4.2. Dados Matriciais

4.2.1. 1º Cenário

4.2.1.1. Operador Categorização

O primeiro operador aplicado aqui foi *categorização*, diminuindo de 15 classes originais para 10. A Tabela 5 apresenta o resultado deste operador.

Tabela 5. Resultado do operador categorização

CLASSE	Área total (ha)	Área relativa (%)	Grupos de pixels	Nova classe	Área total (ha)	Área relativa	Grupos de pixels
Mata	76	7	192	Mata	76	7	171
Café solteiro	264	24,37	363	Café	323	29,82	281
Café com árvore	59	5,45	244				
Eucalipto	70	6,46	224	Eucalipto	81	7,46	225
Eucalipto clonado	11	1	29				
Solo exposto	25	2,33	77	Solo exposto	25	2,33	70
Milho	41	3,79	91	Agricultura	56	7,52	119
Cana	14	1,30	38				
Cana queimada	1	0,1	5				
Água	7	0,64	23	Água	7	0,64	23
Taboa	30	2,77	98	Pastagem	416	42,49	155
Pastagem	386	35,64	169				
Aflor.rochoso	74	6,85	182	Aflor.rochoso	74	6,85	176
Sombra	12	1,1	42	Sombra	12	1,1	35
S/Classificação	13	1,2	44	S/Classificação	13	1,2	41
TOTAL	1.083	100	1.821	TOTAL	1.083	100	1.296

Como apresenta a tabela, os resultados são idênticos aos resultados sobre os dados vetoriais.

A Figura 41 apresenta o mapa original e a Figura 42 apresenta o mapa após o uso deste operador, em escala original.

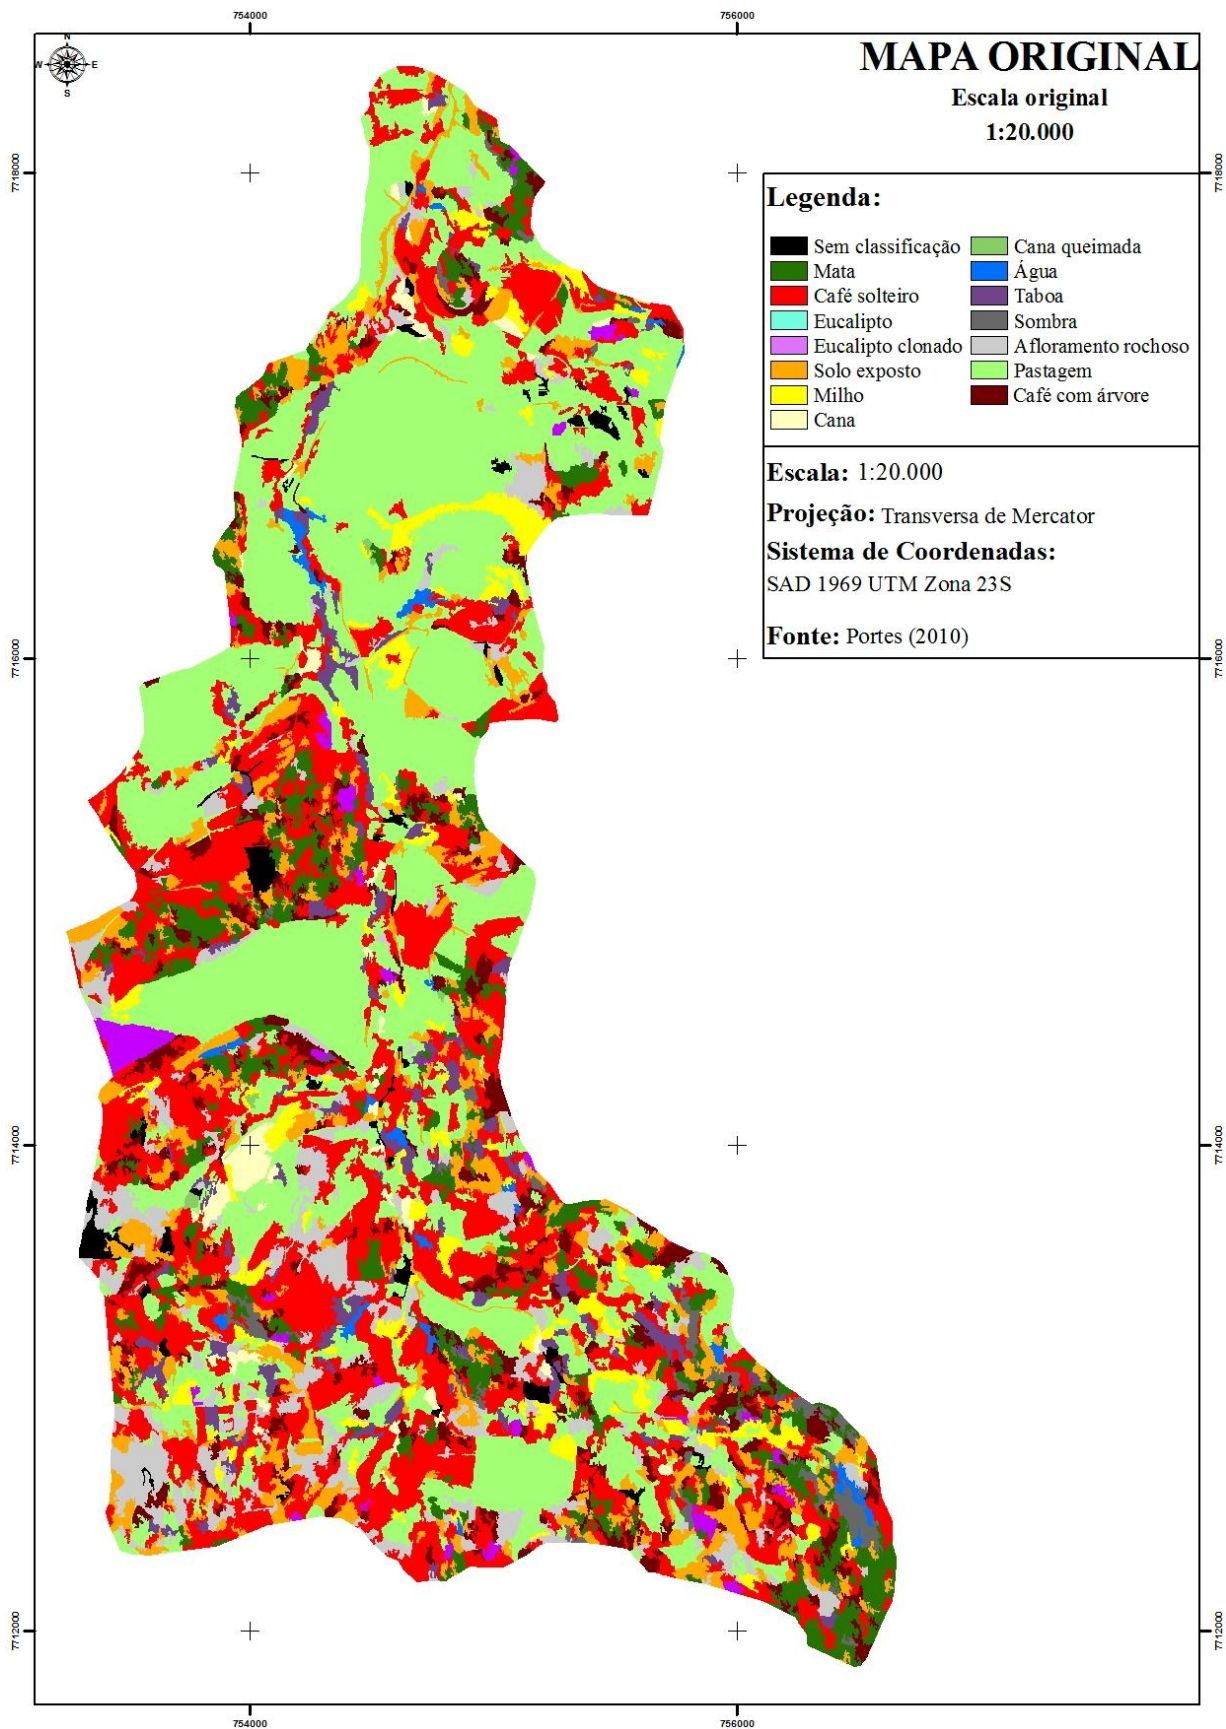


Figura 41. Mapa original

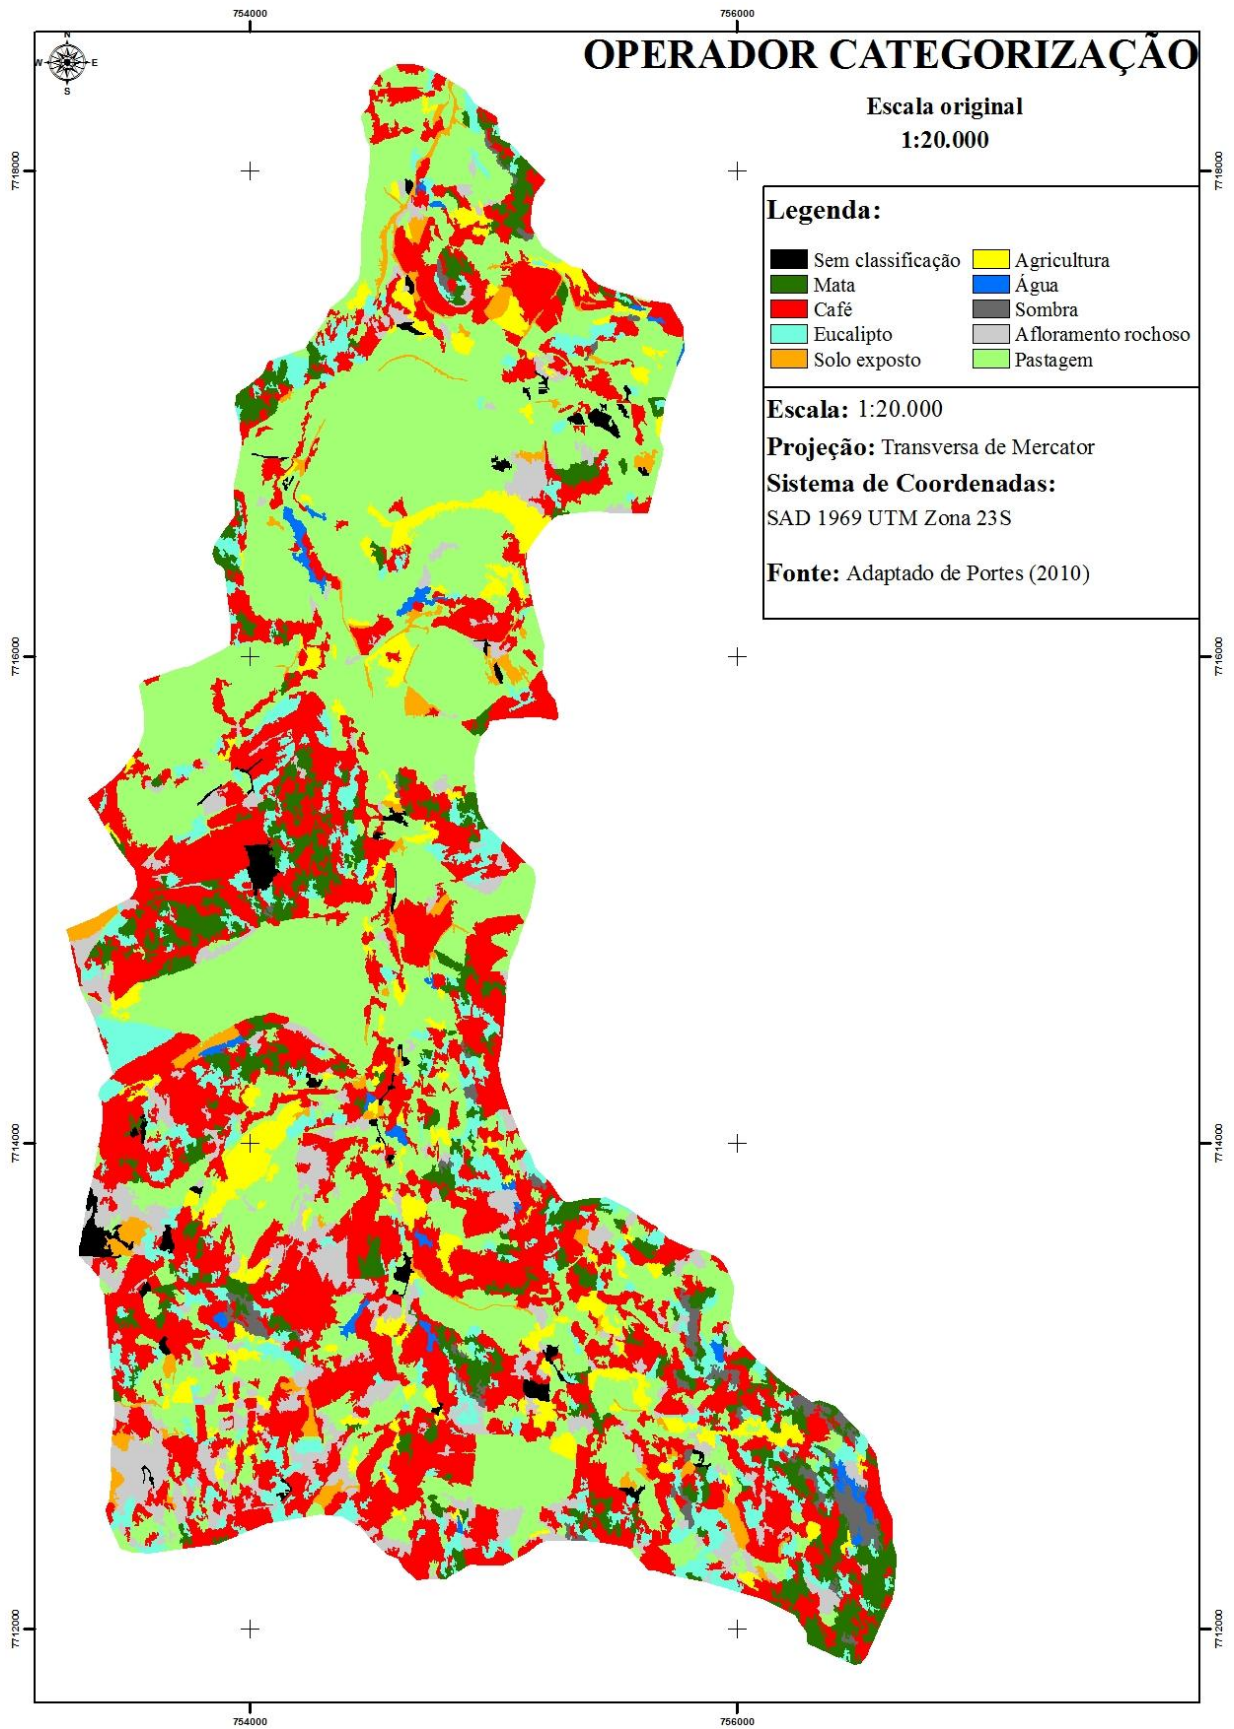


Figura 42. Mapa resultante do operador categorização

4.2.1.2. Operadores Dilatação/Erosão e Amalgamação

O próximo operador foi *dilatação* e *erosão* a partir do algoritmo *Boundary Clean*, que aplica os dois operadores consecutivamente. A Tabela 6 apresenta o valor relativo ao Índice de Exatidão Total através da Matriz de Confusão. É exposto o Índice Kappa, para demonstrar o grau de pureza preservado por este algoritmo.

Adotou-se aqui o termo, grau de pureza, da mesma forma que na análise da tabulação cruzada, pois, o objetivo de calcular o Índice de Exatidão Global e o Índice Kappa sobre este algoritmo é verificar o quanto de cada classe perdeu ou adquiriu novas áreas advindas de diferentes classes. O conveniente é obter o mínimo de sobreposição entre as classes.

Os valores das classes estão expressos em hectares.

Tabela 6. Matriz de confusão

CLASSE	Café	Pastagem	Solo exposto	Eucalipto	Agricultura	Mata	Aflor.rochoso	Sombra	S/classificação	Água	Total	% Corr.	E.O. (%)
Café	308,36	3,59	0,22	3,81	0,86	3,69	2,15	0,24	0,15	0,19	323,30	95,38	4,62
Pastagem	4,14	405,94	0,67	0,86	1,44	0,39	1,57	0,05	0,38	0,09	415,59	97,68	2,32
Solo exposto	0,32	1,19	22,79	0,03	0,03	0,00	0,11	0,00	0,07	0,01	24,58	92,71	7,29
Eucalipto	1,76	0,49	0,01	77,71	0,08	0,89	0,36	0,13	0,03	0,00	81,51	95,34	4,66
Agricultura	0,55	0,81	0,04	0,09	54,12	0,08	0,16	0,01	0,01	0,01	55,92	96,79	3,21
Mata	2,58	0,15	0,00	1,14	0,05	71,74	0,09	0,43	0,02	0,02	76,27	94,05	5,95
Aflor.rochososo	1,46	0,94	0,09	0,33	0,23	0,04	71,09	0,01	0,05	0,00	74,29	95,68	4,32
Sombra	0,12	0,00	0,00	0,13	0,01	0,24	0,00	11,67	0,00	0,08	12,29	94,99	5,01
S/classificação	0,09	0,30	0,10	0,01	0,02	0,00	0,07	0,00	12,36	0,00	12,99	95,15	4,85
Água	0,06	0,05	0,00	0,01	0,02	0,00	0,02	0,04	0,00	7,07	7,30	96,91	3,09
Total	319,48	413,52	23,95	84,17	56,91	77,10	75,65	12,62	13,11	7,52	1084,08		
E.C. (%)	3,48	1,83	4,86	7,67	4,89	6,96	6,03	7,52	5,73	6,03			
IET (%)	96,20												

Todas as classes apresentaram mais de 90% área assinalados corretamente após a aplicação do algoritmo, a classe “solo exposto” com um valor ligeiramente inferior aos demais, com 92,71% e a classe “pastagem” apresentou maior pureza no mapa final com 97,68% de preservação da classe. Consecutivamente, a primeira classe apresentou maior Erro de Omissão, com 7,29% de sua área classificada como outra classe e a segunda com 2,32% de sua área classificada como outra classe

A classe que mais adquiriu áreas oriundas de outras classes foi “eucalipto” com 7,67% e a classe “pastagem” foi a que menos adquiriu novas áreas, com 1,83% de Erro de Comissão. O Índice Kappa calculado para as classes foi de 94,91%.

De acordo com os níveis de aceitação o valor é considerado excelente. Além deste valor, a comparação entre os Índices Kappa de cada algoritmo é que define qual foi mais eficaz.

A Figura 43 apresenta o mapa após a aplicação deste operador, em escala original.

O título do mapa está “operador amalgamação”, pois, como já foi dito, entendeu-se nesta pesquisa que o operador *amalgamação* é fruto da aplicação dos operadores *dilatação* e *erosão*.

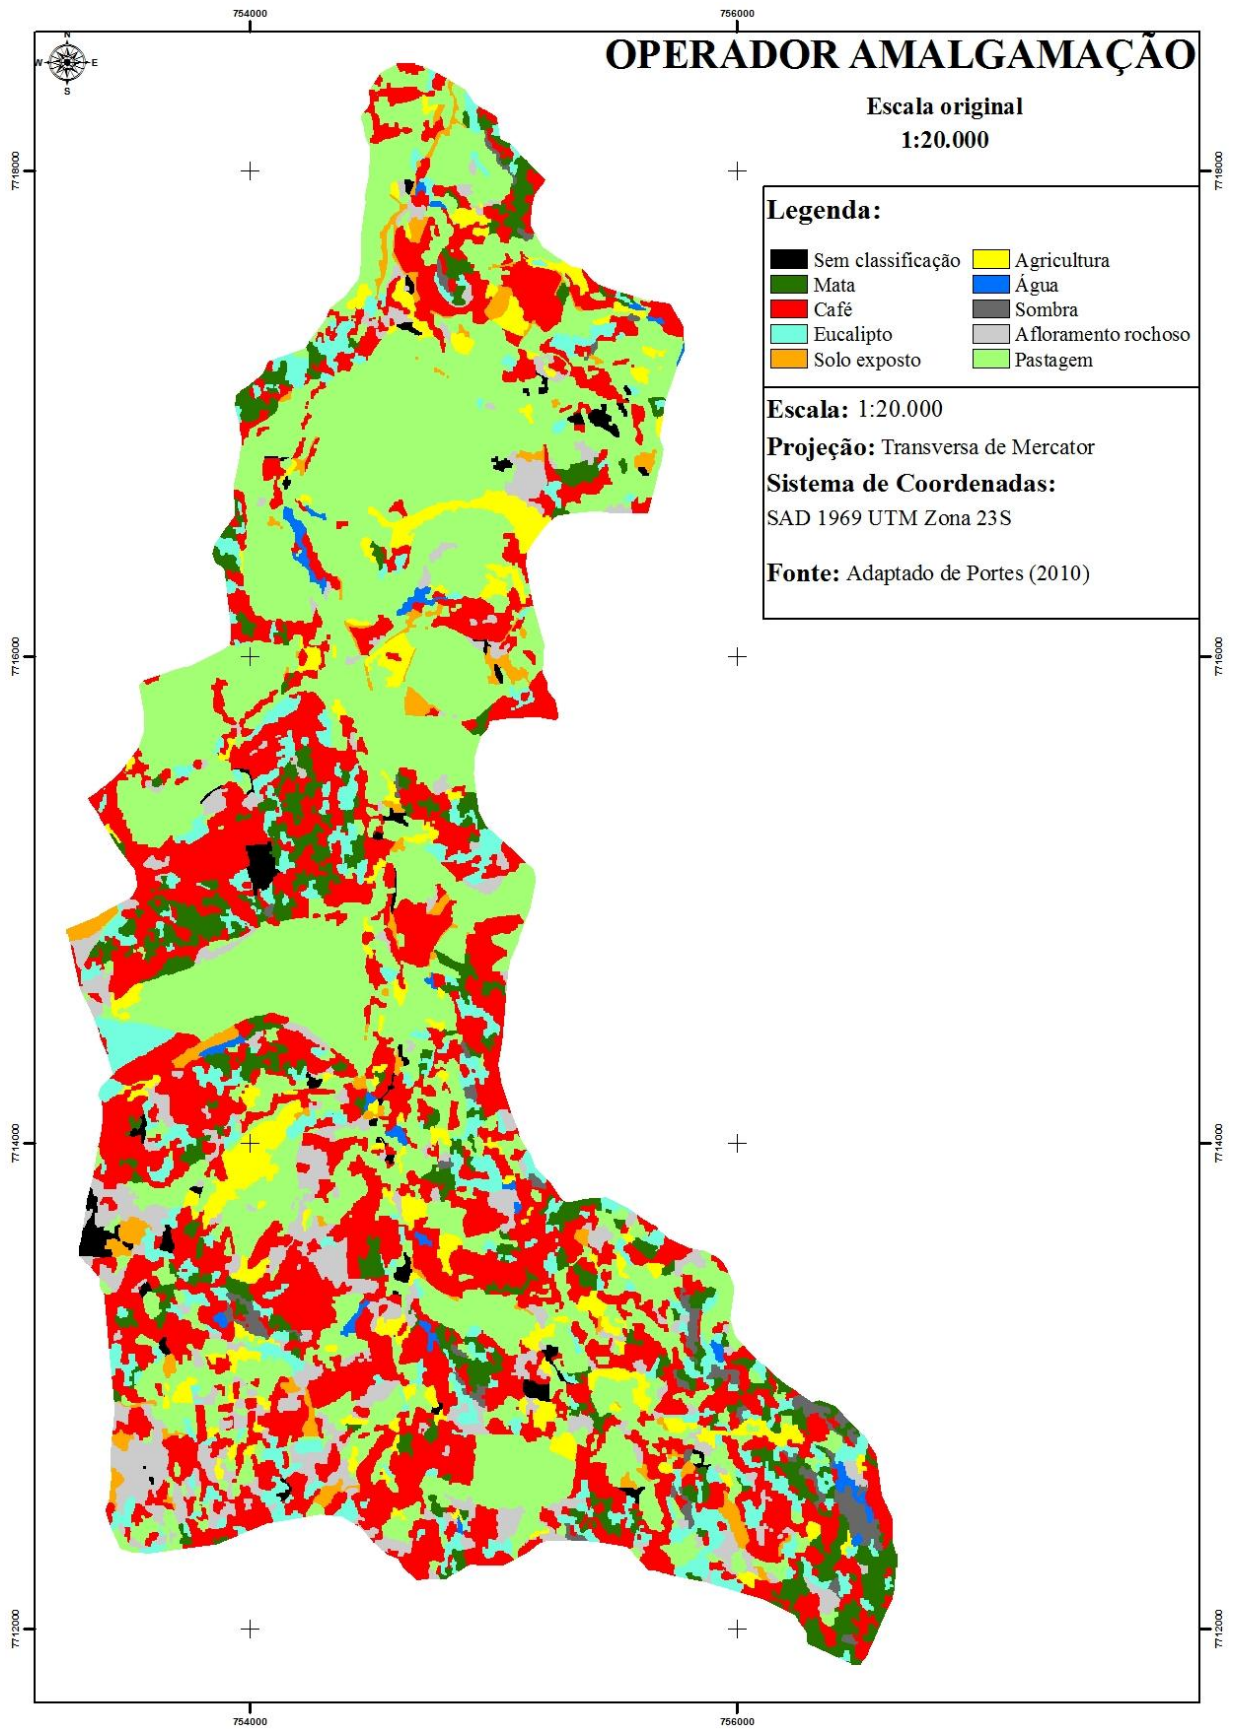


Figura 43. Mapa resultante do operador amalgamação

4.2.1.3. Operador Eliminação

O próximo operador analisado é *eliminação* que de acordo com o cálculo proposto, foi de 1 hectare ou 625 *pixels*. A Tabela 7 apresenta os resultados após este operador.

Tabela 7. Resultado do operador eliminação

CLASSE	Área total (ha)	Área relativa (%)	Grupos de <i>pixels</i>	CLASSE	Área total (ha)	Área relativa (%)	Diferença de área (%)	Grupos de <i>pixels</i>	Redução de grupos de <i>pixels</i>
Mata	77	7,1	171	Mata	50	4,61	-35,06	16	-90,64
Café	319	29,45	281	Café	400	36,93	25,39	58	-79,35
Eucalipto	85	7,84	225	Eucalipto	40	3,69	-52,94	15	-93,33
Solo exposto	25	2,33	70	Solo exposto	12	1,10	-52	6	-91,42
Agricultura	56	5,17	119	Agricultura	32	2,95	-42,85	10	-91,59
Água	7	0,64	23	Água	2	0,18	-71,42	1	-95,65
Pastagem	413	38,15	155	Pastagem	490	45,24	18,64	31	-80,00
Aflor.rochoso	75	6,92	176	Aflor.rochoso	41	3,78	-45,33	12	-93,18
Sombra	13	1,2	35	Sombra	10	0,92	-23,07	3	-91,42
S/Classificação	13	1,2	41	S/classificação	6	0,55	-53,84	2	-95,12
TOTAL	1.083	100	1.296		1.083	100		154	-88,11

Apesar de a área eliminada ser a mesma dos dados vetoriais, a maneira de eliminação ocorre de maneira diferente, enquanto as áreas eliminadas em formato vetorial são substituídas pelo polígono adjacente de maior área, as áreas eliminadas em formato matricial recebem um atributo nulo e por álgebra de mapas recebem o atributo do vizinho mais próximo (ao grupo de *pixels* eliminados) do mapa anterior à eliminação, no entanto, a alteração entre os dois tipos de dados foi pequena.

Da mesma maneira que aplicado sobre os dados vetoriais, este operador foi o que mais causou alteração nas áreas e na estética do mapa. A classe que mais sofreu perdas de áreas foi “água” com 71,42% de perda e a classe “café” obteve 36,93% de área em relação ao mapa anterior. A classe “água” também foi a que mais perdeu representatividade visual, com 95,65% de seus grupos de *pixels* eliminados. Todas as classes, no entanto, perderam aproximadamente 90% de sua representatividade, isto significa que houve redução de heterogeneidade do mapa, com grupos de *pixels* maiores, como o caso da classe “café” que obteve ganho de área, mas 79,35% de perda de grupos de *pixels*, aliás, foi a classe que menos perdeu representatividade. É justamente este parâmetro que evidencia a “limpeza” visual do mapa. A Figura 44 apresenta o mapa após aplicação deste operador.

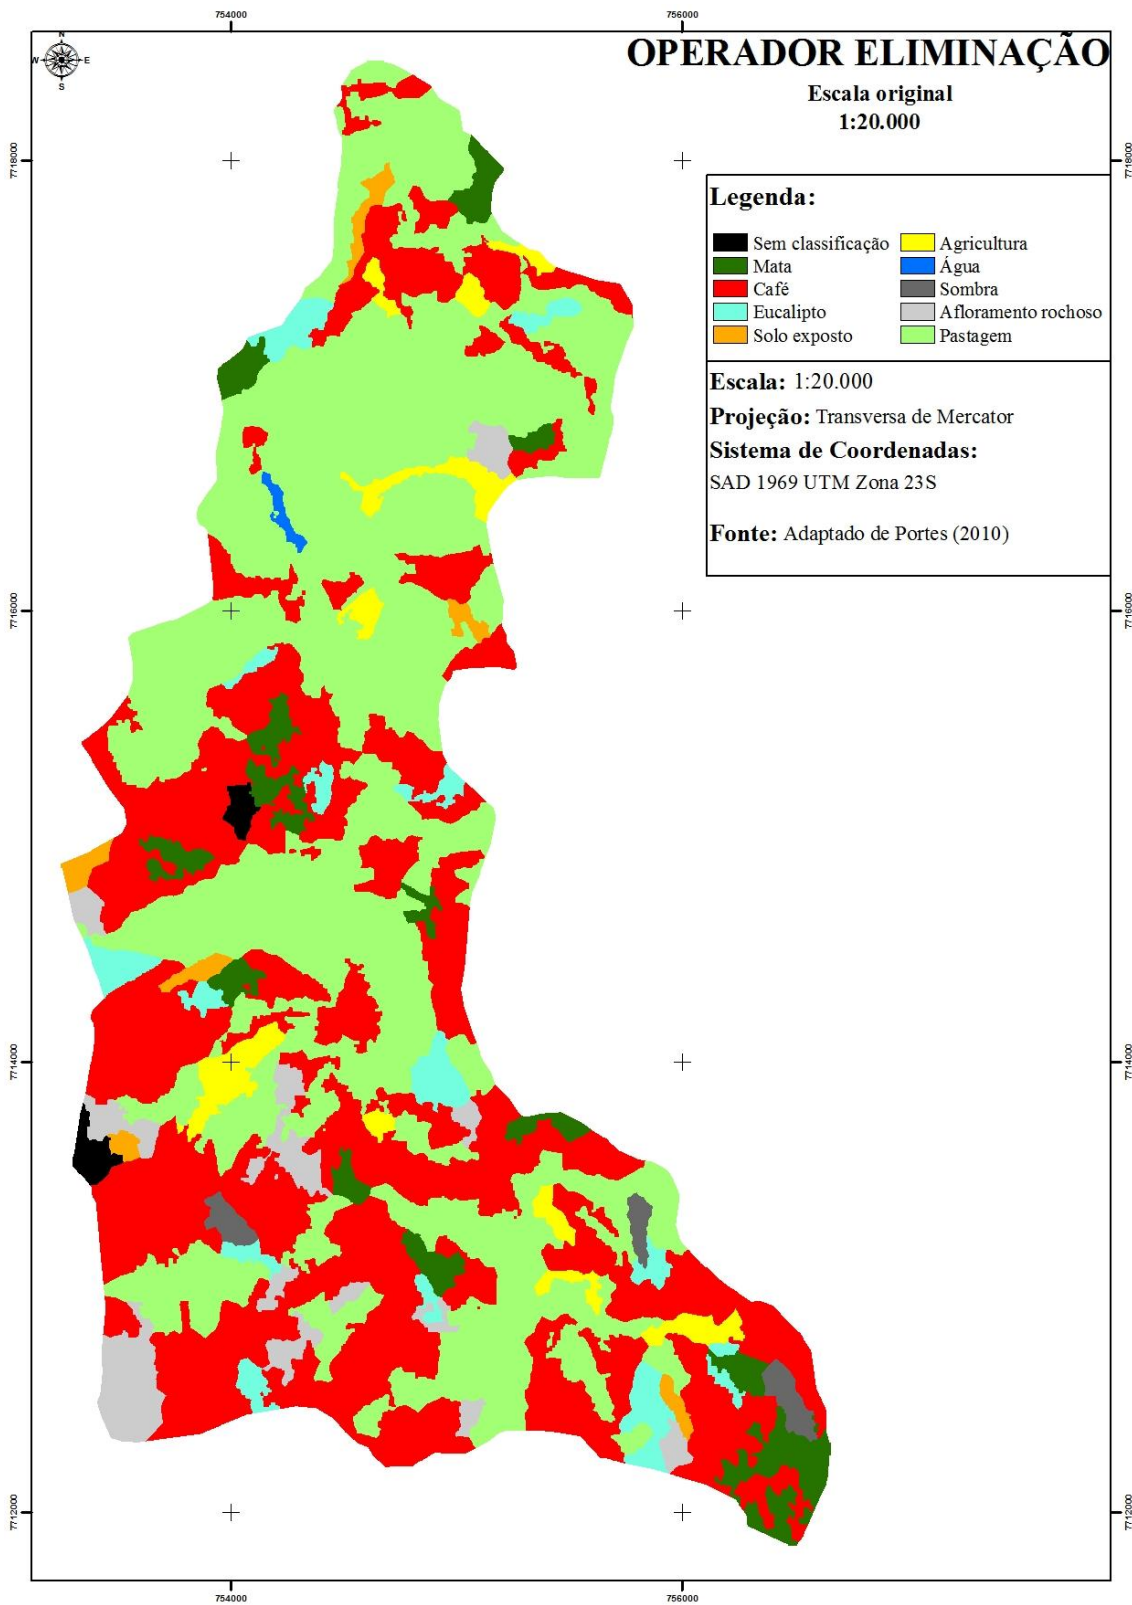


Figura 44. Mapa resultante do operador eliminação


4.2.1.4. Operador Numérico

4.2.1.4.1 Variação de área média

Foram aplicados dois tipos de filtros e para cada um foram utilizadas três tolerâncias. Para avaliar a atuação de cada um foram utilizados as mesmas variáveis que nos dados vetoriais: variação de área média; variação de perímetro médio; variação de Kc médio e a variação do desvio-padrão para cada um, como dado auxiliar.

A Tabela 16 no Anexo 4 se refere à variação de área média e desvio-padrão para filtro circular com 3; 6 e 9 *pixels* de raio.

A Figura 45 apresenta um gráfico referente ao mesmo parâmetro, exceto o desvio-padrão.



1- Afloramento rochoso 2- Agricultura 3- Água 4- Café 5- Eucalípto 6- Mata 7- Sem classificação 8- Pastagem 9- Solo exposto 10- Sombra


Figura 45. Variação de área média para filtro circular

Houve clara predominância de valores positivos de variação de área média para todas as rotinas.

Pode-se notar que há uma tendência de acentuação dos valores a medida que o raio é aumentado, com baixos valores relativos à janela com 3 de raio e valores relativamente altos produzidos pela janela com 9 de raio. Porém, a despeito da análise do grupo, a variação de área relativa ao mapa anterior não foi drástica, apenas a classe “sem classificação” para janela com 9 de raio apresentou valores considerados altos. Para o parâmetro desvio-padrão, entretanto, chamou atenção a discrepância entre os

valores apresentados, sugerindo que houve modificação nas áreas dos grupos de *pixels*, mas, como a variação de área não acompanhou essa forte alteração de valores, sugere que houve perda de área em alguns grupos de *pixels* e ganho proporcional em outros, da mesma classe.

A Tabela 17 no Anexo 4 e a Figura 46 apresentam as variações de área referentes aos filtros retangulares.



1- Afloramento rochoso 2- Agricultura 3- Água 4- Café 5- Eucalipto 6- Mata 7- Sem classificação 8- Pastagem 9- Solo exposto 10- Sombra


Figura 46. Variação de área média para filtro retangular

De maneira similar ao filtro circular, houve pequena alteração na área média em relação ao mapa anterior, porém, mais suave e segue-se a tendência de aumento na área média ao aumento do tamanho da janela. Houve acréscimo de área na classe “água” para janela 3x3 com valor superior ao filtro anterior, porém, em valores reais, o aumento foi pequeno, apenas 0,14 hectare. A classe “sem classificação” novamente obteve o maior crescimento de área, considerando que é uma classe de área pequena, 6 ha e apenas 2 grupos de *pixels*, é possível que esta alteração sempre positiva e superior as demais tenha a ver com a forma de seus dois grupos de *pixels*, no entanto, só é possível concluir algo de acordo com a análise do Kc, que veremos adiante.

Em relação ao desvio-padrão, percebeu-se aqui valores menores, mas, heterogêneos da mesma forma que o anterior.

4.2.1.4.2 Variação de perímetro médio

A Tabela 18 no Anexo 4 apresenta os valores referentes à variação de perímetro médio e desvio-padrão para filtro circular e a Figura 47 apresenta os valores referentes as variações de perímetro médio para o mesmo tipo de filtro.



1- Afloramento rochoso 2- Agricultura 3- Água 4- Café 5- Eucalipto 6- Mata 7- Sem classificação 8- Pastagem 9- Solo exposto 10- Sombra


Figura 47. Variação de perímetro médio para filtro circular

Para este parâmetro todos os valores de raio de janela apresentaram valores negativos, indicando que este filtro tendeu à homogeneização as formas dos grupos de *pixels*.

Como era de esperar, houve redução maior na janela com 9 de raio, é um filtro mais “agressivo”, pois, abarca um maior número de *pixels* em sua análise.

Ao contrário do desvio-padrão relativo à área, aqui houve uma maioria negativa, com anomalias na classe “eucalipto” com valor positivo de 3,43% para janela com 9 de raio e a classe “sem classificação” com expressivos valores positivos em todas as tolerâncias, mais uma vez indicando que há nesta classe, alguma especificidade. A classe “água” não é considerada anomalia, pois, só tem um grupo de polígonos. A classe “sombra” para raio 6 também apresentou comportamento anormal, pois, fugindo da tendência de queda constante de acordo com o tamanho do raio, apresentou queda superior à janela com 9 de raio.

A Tabela 19 no Anexo 4 apresenta os valores referentes à variação de perímetro médio e desvio padrão para filtro retangular e a Figura 48 apresenta os valores referentes às variações de perímetro médio para o mesmo tipo de filtro.



1- Afloramento rochoso 2- Agricultura 3- Água 4- Café 5- Eucalípto 6- Mata 7- Sem classificação 8- Pastagem 9- Solo exposto 10- Sombra


Figura 48. Variação de perímetro médio para filtro retangular

Na análise dos valores, podemos notar que houve a mesma tendência de queda do perímetro médio, porém, ligeiramente mais suave que o filtro circular, deve-se este fato a própria geometria da janela, onde a primeira, circular, procura justamente imprimir esta geometria nos objetos, assim, justificando maior queda de perímetro.

Os valores de desvio-padrão seguiram a queda observada nos filtros circulares, também foram mais suaves e sem homogeneidade entre as classes. A classe “sem classificação” novamente apresentou valores positivos e altos, diferente do resto das classes, e a classe “sombra” para janela com 6 de raio também apresentou comportamento diferenciado, além de ser o único valor positivo entre as janelas para a mesma classe, apresentou valor consideravelmente maior que no filtro anterior.

4.2.1.4.3 Variação de Kc médio

A Tabela 20 no Anexo 4 apresenta os valores referentes à variação de Kc médio e desvio padrão para filtro circular e a Figura 49 apresenta os valores referentes às variações de Kc médio para o mesmo tipo de filtro.



1- Afloramento rochoso 2- Agricultura 3- Água 4- Café 5- Eucalípto 6- Mata 7- Sem classificação 8- Pastagem 9- Solo exposto 10- Sombra

Figura 49. Variação de Kc médio para filtro circular


Para valores de variação de Kc médio, houve também redução em todas as classes e para todas as janelas, novamente, apresentando queda proporcional ao tamanho do raio.

A queda de Kc médio para as classes era esperada, de acordo com a análise das variáveis

A classe “sem classificação”, não demonstrou anomalias, pois, seu Kc médio era o mais baixo dentre as classes, 1,77 de média, o que justifica o comportamento anormal das variáveis anteriores, pois, como seus grupos de *pixels* tendem ao círculo, a sua vizinhança provavelmente deve conter mais *pixels* da mesma classe, ao contrário de áreas alongadas (Kc mais alto), onde a possibilidade é maior de se encontrar *pixels* de outras classes em sua vizinhança. Devido à característica deste filtro (pixel a pixel) levando em consideração a vizinhança de cada célula, grupos de *pixels* com Kc baixo, podem apresentar este tipo de comportamento.

Os valores de variação de desvio-padrão não apresentaram aqui nenhum valor positivo, e ao contrário das outras variáveis, apresentou certo padrão de valores para cada tamanho de janela.

A Tabela 21 no Anexo 4 apresenta os valores referentes à variação de Kc médio e desvio padrão para filtro retangular e a Figura 50 apresenta os valores referentes às variações de Kc médio para o mesmo tipo de filtro.



1- Afloramento rochoso 2- Agricultura 3- Água 4- Café 5- Eucalípto 6- Mata 7- Sem classificação 8- Pastagem 9- Solo exposto 10- Sombra

Figura 50. Variação de Kc médio para filtro retangular

Neste tipo de filtro, os valores para todas as janelas foram menos acentuados que o anterior, circular. Os valores apresentados para janela 3x3 são em alguns casos inexpressivos. Demonstrando que apenas a janela 9x9 força a geometria dos objetos com mais severidade. Significa que não houve alteração drástica nas formas originais dos objetos, apenas um “suave” arredondamento.

Os valores de desvio-padrão também apresentaram valores menos acentuados, apenas a classe “sombra” sofreu uma queda maior na janela com 3 de raio, em relação ao filtro anterior.

4.2.1.5. Grau de pureza das classes

A próxima análise demonstra o grau de pureza de cada classe final em relação à original, indicando quais classes foram mais preservadas em termos de área após a aplicação dos operadores. A Tabela 22 no Anexo 5 apresenta os valores, expressos em porcentagem, para os filtros circulares com 3 de raio.

Os números destacados em vermelho significam a porcentagem de área da classe original que foi preservada na classe final.

Cabe ressaltar que este resultado é fruto de todos os operadores, diferenciando apenas no tipo de filtro e a tolerância especificada, neste caso, 3 de raio.

Podemos notar que as classes foram sensivelmente alteradas, pois, nenhuma delas contém acima de 80% de sua classe original. A classe “sombra” foi a mais alterada, com 50,93% de pureza, ou seja, nesta classe, apenas 50,93% é de fato sombra. A classe mais conservada foi “pastagem” com 77,21% de pureza.

A Tabela 23 no Anexo 5 apresenta o mesmo índice para o filtro circular com 6 de raio.

De acordo com os resultados expostos nesta tabela, pode-se notar que houve ligeira queda dos valores de grau de pureza em relação a primeira tolerância. Novamente a classe “sombra” apresentou menor grau de pureza com 50,61% e a classe “pastagem” 71,84% com maior pureza na classe final.

A Tabela 24 no Anexo 5 apresenta o mesmo índice para o filtro circular com 9 de raio.

Acompanhando o resultado anterior, e mantendo a coerência, observa-se novamente tendência de ligeira queda nos valores de pureza. A classe “sombra” com menor valor, 50,71% e a classe “pastagem” com o maior, 75,59%.

Apesar do filtro com 9 de raio ser o filtro que mais modifica os valores das variáveis estabelecidas anteriormente, em relação ao grau de pureza das classes não o modifica de forma acentuada.

A Tabela 25 no Anexo 5 apresenta os valores, expressos em porcentagem, para os filtros retangulares de janela 3x3.

Pode-se dizer que estes resultados continuam demonstrando estabilidade, apesar de ter havido um pequeno acréscimo no grau de pureza em relação ao filtro circular com 3 de raio, que consideramos o equivalente para este filtro. Parece que este índice não depende da atuação dos filtros.

As classes “sombra” e “pastagem”, novamente apresentaram os valores mais baixos e altos, com 50,83% e 77,49% respectivamente.

A Tabela 26 no Anexo 5 apresenta o mesmo índice para o filtro retangular de janela 6x6.

De forma semelhante à tabela anterior, os resultados para esta tolerância são coerentes entre si. Apresentando ligeira tendencia de queda para as classes, continuando com a classe “sombra” com 50,89% e a classe “pastagem” 77,05% com os menores e maiores valores respectivamente.

A Tabela 27 no Anexo 5 apresenta o mesmo índice para o filtro retangular de janela 9x9.

Estes resultados também são coerentes, porque preservam a característica que foi observada ao longo das outras variáveis, que foi a pequena variação dos valores. Com as mesmas classes apresentando menor e maior grau de pureza, “sombra” com 50,63% e “pastagem” com 76,67% respectivamente.

Realizada a análise numérica, a Figura 68 no Anexo 6 demonstra o mapa original, que foi o mapa após a aplicação do operador *eliminação* e os mapas resultantes dos filtros circulares em escala original, porém, devido a área de apresentação, optou-se por capturar apenas uma área da bacia.

É clara a diferença entre as tolerâncias, a janela com 3 de raio suaviza as bordas de maneira pouco perceptível em certas áreas, causando pouca modificação em relação ao mapa anterior.

Com 6 de raio as mudanças começam a ficar mais notáveis, as sinuosidades das áreas são mais preenchidas, com menos ângulos agudos.

Já com 9 de raio, a diferença é abrupta em relação ao mapa original, as áreas são alteradas a ponto de eliminar alguns pequenos grupos de *pixels* e arredondar por completo alguns outros.

A **Erro! Fonte de referência não encontrada.**no Anexo 6 apresenta o mesmo modelo para as tolerâncias com o filtro retangular.

Nas tolerâncias para filtro retangular, nota-se pouca diferença entre a janela 3x3 e o mapa original, assim como a diferença entre a janela 6x6 para a primeira não é tão drástica como para o filtro circular, para janela 9x9 a diferença em relação aos demais e ao mapa original é grande, os objetos se apresentam mais suaves, porém, a diferença não foi tão expressiva quanto constatada no filtro circular.

De acordo com as análises numéricas, este resultado era esperado, pois, podemos notar de acordo com as alterações das variáveis que o filtro retangular sempre apresentou menores variações.

4.2.2. 2º Cenário

De acordo com a metodologia empregada, a diferença básica entre este cenário com o anterior foi a diferença na aplicação dos operadores *dilatação*, *erosão* e *amalgamação*, não sendo necessário expor novamente os resultados para o operador *categorização*.

Cabe lembrar que a maneira de utilizar os operadores em questão foi diferente devido o uso de outro algoritmo, que trata de maneira separada, primeiro dilatando, depois outro algoritmo erode e conseqüentemente amalgama.

4.2.2.1. Operadores Dilatação/Erosão e Amalgamação

A Tabela 8 apresenta o valor relativo ao Índice de Exatidão Total e Índice Kappa, para demonstrar o grau de pureza deste algoritmo.

Adotou-se aqui o termo, grau de pureza, da mesma forma que na análise da tabulação cruzada, pois, o objetivo de calcular o Índice de Exatidão Global e o Índice Kappa sobre este algoritmo é verificar o quanto de cada classe perdeu ou adquiriu novas áreas advindas de diferentes classes. O conveniente é obter o mínimo de sobreposição entre as classes.

Os valores das classes estão expressos em hectares.

Tabela 8. Matriz de confusão

CLASSE	Café	Pastagem	Solo exposto	Eucalipto	Agricultura	Mata	Aflo.rochoso	Sombra	S/classe	Água	Total	% Corr.	E.O. (%)
Café	315,12	1,20	0,16	2,59	0,53	2,04	1,26	0,14	0,07	0,09	32,32	97,49	2,51
Pastagem	2,13	410,26	0,35	0,45	0,84	0,22	0,89	0,02	0,27	0,10	415,57	98,72	1,28
Solo exposto	0,04	0,08	24,39	0,00	0,00	0,00	0,02	0,00	0,01	0,01	24,58	99,24	0,76
Eucalipto	0,30	0,10	0,00	80,72	0,03	0,21	0,03	0,06	0,02	0,00	81,50	99,04	0,96
Agricultura	0,15	0,11	0,01	0,03	55,56	0,00	0,02	0,00	0,00	0,00	55,91	99,37	0,63
Mata	0,50	0,02	0,00	0,42	0,01	75,05	0,02	0,20	0,00	0,00	76,25	98,42	1,58
Aflor.roch	0,28	0,12	0,07	0,17	0,02	0,00	73,58	0,00	0,00	0,00	74,28	99,06	0,94
Sombra	0,05	0,00	0,00	0,04	0,01	0,08	0,00	11,99	0,00	0,08	12,29	97,62	2,38
S/classe	0,00	0,01	0,04	0,00	0,00	0,00	0,00	0,00	12,93	0,00	12,99	99,38	0,62
Água	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	7,28	7,30	99,80	0,20
Total	318,64	411,94	25,03	84,45	57,04	77,64	75,85	12,44	13,31	7,58	1083,96		
E.C. (%)	1,10	0,41	2,58	4,42	2,59	3,33	3,00	3,60	2,99	3,98			
IET (%)	98,43												

Todas as classes apresentaram mais de 95% da área assinalados corretamente após a aplicação do algoritmo, a classe “café” com um valor ligeiramente inferior aos demais, com 97,49% e a classe “água” apresentou maior pureza no mapa final com 99,80% de preservação da classe. Consecutivamente, a primeira classe apresentou maior Erro de Omissão, com 2,51% de sua área classificada como outra classe e a segunda com 0,20% de sua área classificada como outra classe.

A classe que mais adquiriu áreas oriundas de outras classes foi “eucalipto” com 4,42% e a classe “pastagem” foi a que menos adquiriu novas áreas, com 0,41% de Erro de Comissão. O Índice Kappa calculado para as classes foi de 97,90%

De acordo com os níveis de aceitação o valor é considerado excelente. Este valor então é superior ao analisado no primeiro cenário, um aumento na acurácia de 2,99%.

A Figura 51 apresenta o mapa após a aplicação deste operador, em escala original.

O título do mapa está “operador amalgamação”, pois, como já foi dito, entendeu-se nesta pesquisa que o operador *amalgamação* é fruto da aplicação dos operadores *dilatação e erosão*.

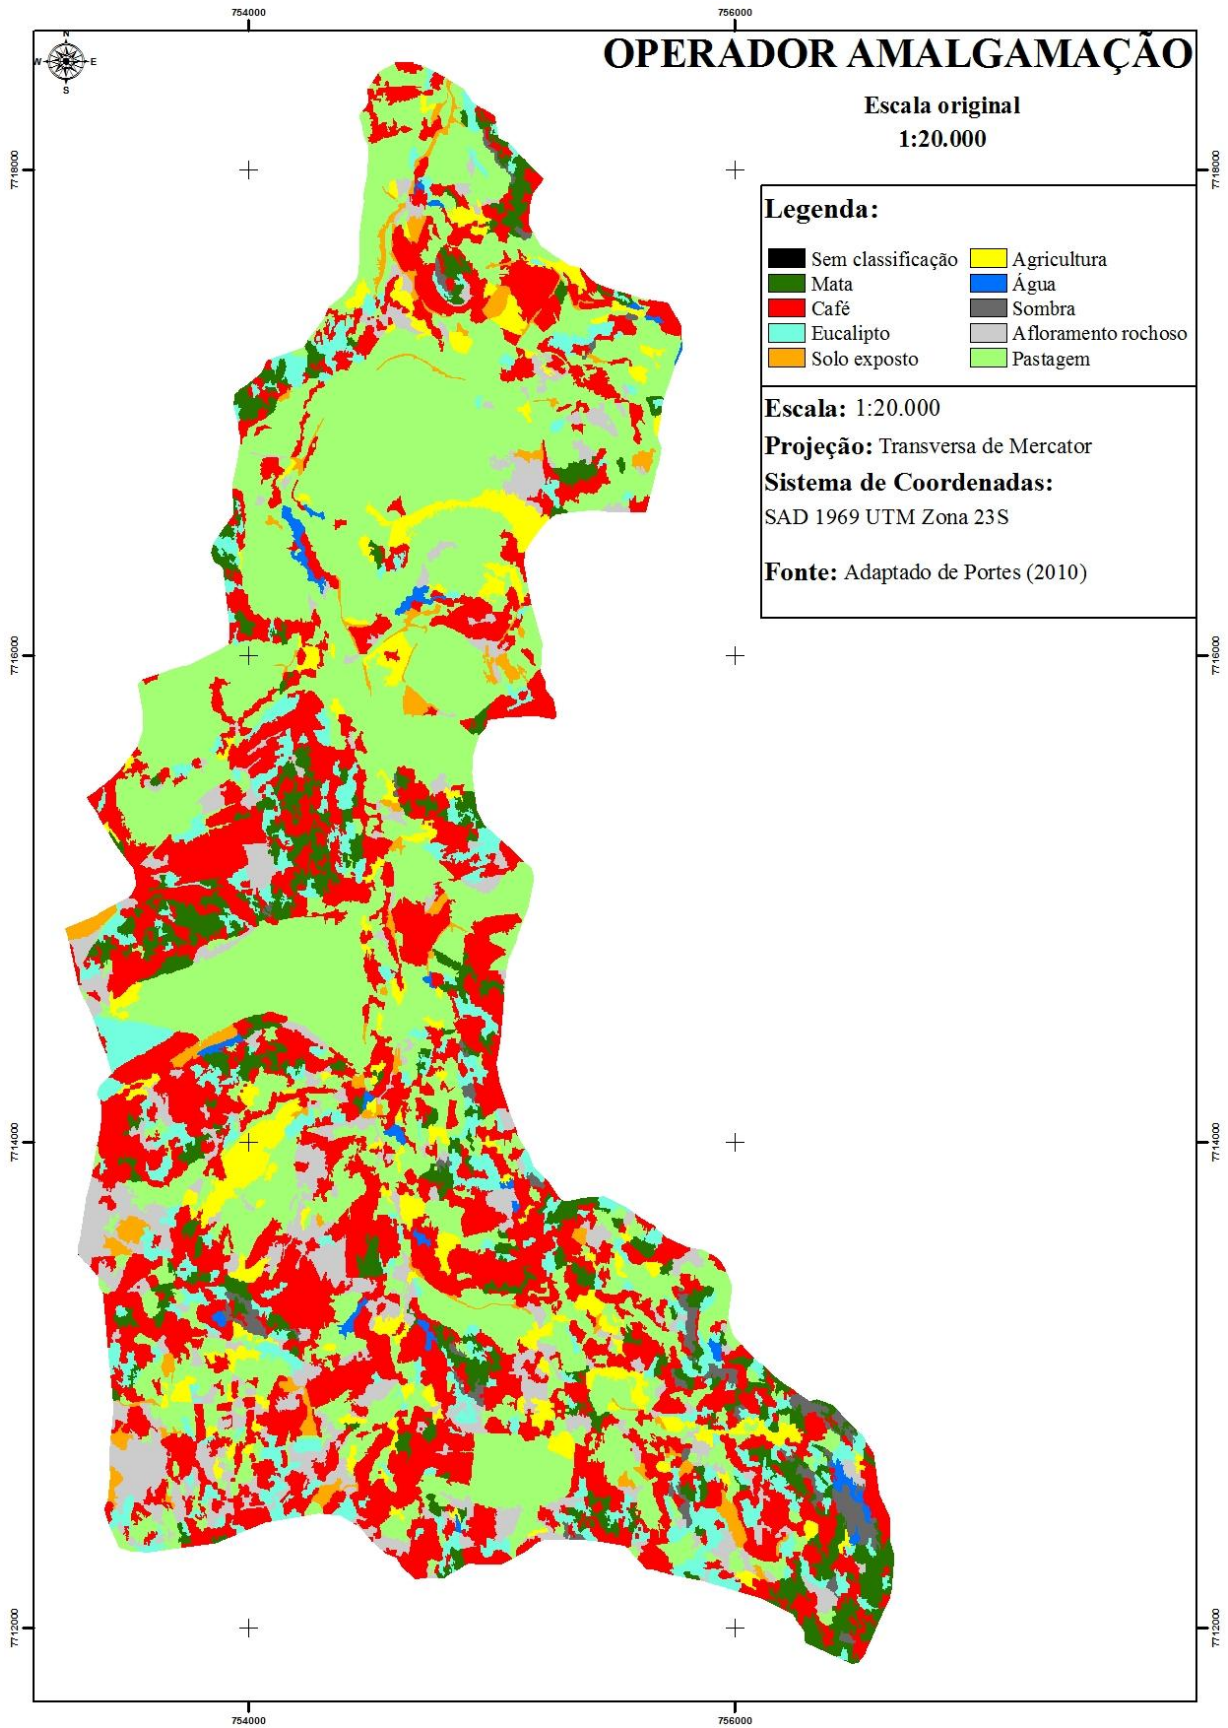


Figura 51. Mapa resultante do operador amalgamação

4.2.2.2. Operador Eliminação

O próximo operador analisado é *eliminação* que de acordo com o cálculo proposto, foi de 1 hectare ou 625 *pixels*. A Tabela 9 apresenta os resultados após este operador.

Tabela 9. Resultado do operador eliminação

CLASSE	Área total (ha)	Área relativa (%)	Grupos de <i>pixels</i>	CLASSE	Área total (ha)	Área relativa (%)	Diferença de área (%)	Grupos de <i>pixels</i>	Redução de grupos de <i>pixels</i> (%)
Mata	77	7	171	Mata	50	4,61	-35,06	16	-90,64
Café	318	29,40	281	Café	406	37,48	27,67	59	-79,00
Eucalipto	85	7,84	225	Eucalipto	40	3,70	-52,94	15	-93,33
Solo exposto	25	2,30	70	Solo exposto	13	1,2	-48,00	6	-91,42
Agricultura	57	5,30	119	Agricultura	31	2,86	-45,61	10	-91,59
Água	7	0,64	23	Água	1	0,1	-85,71	1	-95,65
Pastagem	412	38,12	155	Pastagem	491	45,35	19,17	31	-80,00
Aflor. rochoso	76	7	176	Aflor.rochoso	36	3,32	-52,63	10	-94,31
Sombra	13	1,2	35	Sombra	9	0,83	-30,76	3	-91,42
S/Classificação	13	1,2	41	S/classificação	6	0,55	-53,84	2	-95,12
TOTAL	1.083	100	1.296		1.083	100		153	-88,19

Semelhante ao primeiro cenário e aos dados vetoriais, este operador foi o que mais causou alteração nas áreas e na estética do mapa. A classe que mais sofreu perda de áreas foi novamente “água”, porém, aqui a perda foi maior em relação ao primeiro cenário, com 85,71%, a classe café obteve ganhos de 27,67%, também superior ao primeiro cenário. A classe “água” e “sem classificação” foram as que mais perderam representatividade no mapa, com perdas de grupos de *pixels* de 95,65% e 95,12% respectivamente. Neste cenário, a perda de representatividade foi parecida com ao primeiro, com a maioria das classes perdendo acima de 90% de grupos de *pixels* e aqui houve a perda de um grupo de pixel a mais em relação ao cenário anterior. Este fato, além do Índice Kappa, indica que não houve clara superioridade entre um algoritmo ou outro para o operador *amalgamação*.

A Figura 52 apresenta o mapa após aplicação deste operador.

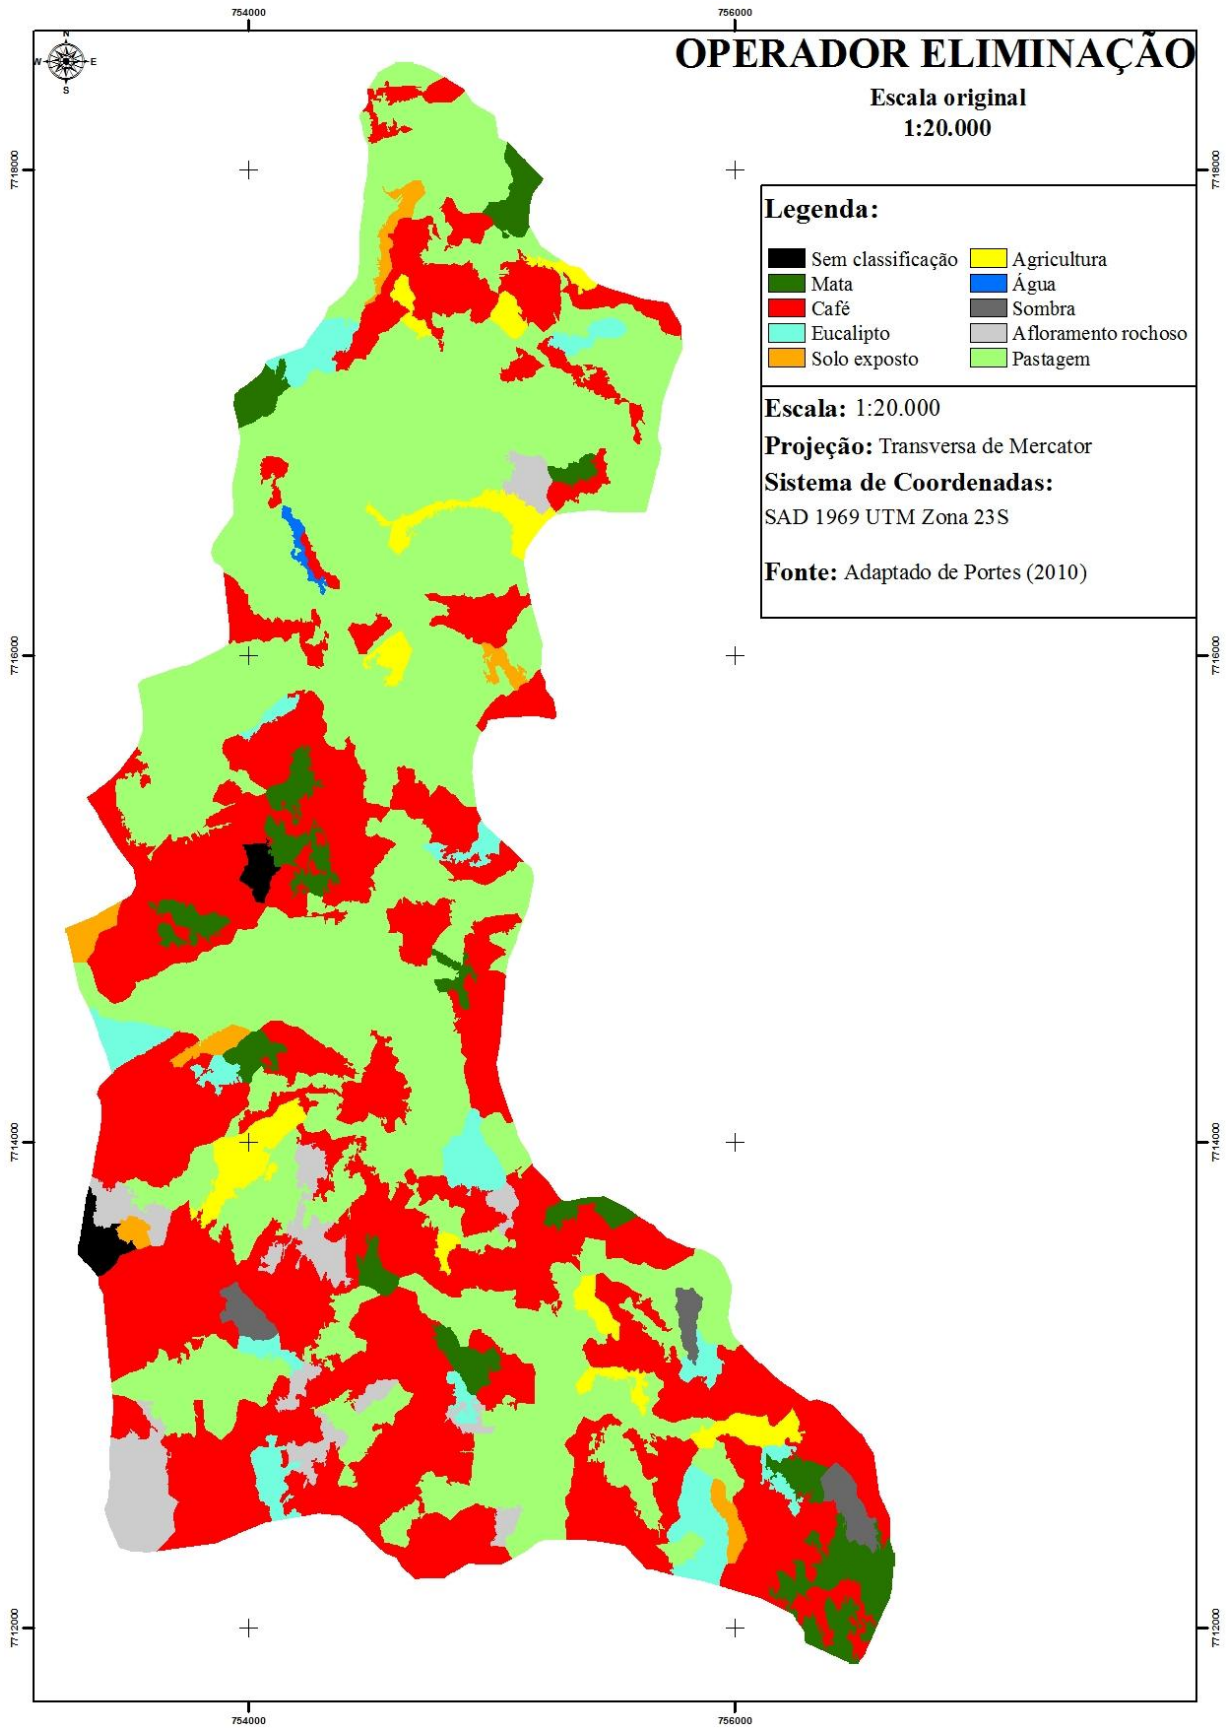



Figura 52. Mapa resultante do operador eliminação

4.2.2.3. Operador Numérico

Foram aplicados dois tipos de filtros e para cada um foram utilizadas três tolerâncias. Para avaliar a atuação de cada um foram utilizados as mesmas variáveis que nos dados vetoriais: variação de área média; variação de perímetro médio; variação de Kc médio e a variação do desvio-padrão para cada um, como dado auxiliar.

4.2.2.3.1 Variação de área média

A Tabela 28 no Anexo 7 se refere à variação de área média e desvio-padrão para filtro circular com 3; 6 e 9 *pixels* de raio, a Figura 53 apresenta a variação de área média.



1- Afloramento rochoso 2- Agricultura 3- Água 4- Café 5- Eucalípto 6- Mata 7- Sem classificação 8- Pastagem 9- Solo exposto 10- Sombra


Figura 53. Variação de área média para filtro circular

Observa-se no gráfico que houve predominância de valores positivos para todas as tolerâncias. A medida que o raio é aumentado, tem-se o aumento na variação de área, exceto para as classes “água”, onde houve uma forte anomalia negativa para janela com 9 de raio, com -20,44% de área, “solo exposto” com -6,54% para janela com 3 de raio .

Em relação ao primeiro cenário, os valores são próximos, no entanto, a variação negativa da classe “água” aqui foi mais brusca e a classe “solo exposto” não apresentou valor negativo.

Para valores de desvio-padrão, algumas classes apresentaram valores crescentes mais retilíneos, outros mais abruptos, denotando que em alguns casos houve forte variação área entre os grupos de *pixels* em comparação com o mapa anterior.

A Tabela 29 no Anexo 7 e a Figura 54 apresentam as variações de área referentes aos filtros retangulares.



1- Afloramento rochoso 2- Agricultura 3- Água 4- Café 5- Eucalipto 6- Mata 7- Sem classificação 8- Pastagem 9- Solo exposto 10- Sombra

Figura 54. Variação de área média para filtro retangular


Assim como no primeiro cenário, para este tipo de filtro as variações são mais tênues em relação ao filtro circular. Não se nota aqui nenhuma forte anomalia negativa ou positiva. Apenas as classes “água” e “sombra” apresentaram valores negativos, porém, da mesma maneira que os a maioria valores positivos, foram inferiores a 5%.

Novamente, a classe “sem classificação”, como no primeiro cenário, apresentou um acréscimo superior aos demais, para janela 9x9.

Em relação ao desvio-padrão, nota-se aqui valores menores e mais coerentes com o aumento da tolerância, mas, heterogêneos entre as classes da mesma forma que o filtro anterior.

4.2.2.3.2 Variação de perímetro médio

A Tabela 30 no Anexo 7 apresenta os valores referentes a variação de perímetro médio e desvio padrão para filtro circular e a Figura 55 apresentam os valores referentes as variações de perímetro médio para o mesmo tipo de filtro.



1- Afloramento rochoso 2- Agricultura 3- Água 4- Café 5- Eucalípto 6- Mata 7- Sem classificação 8- Pastagem 9- Solo exposto 10- Sombra


Figura 55. Variação de área média para filtro circular

Para este parâmetro todos os valores de raio de janela apresentaram valores negativos, indicando que este filtro tendeu à homogeneização as formas dos grupos de *pixels*. Em relação ao primeiro cenário, as variações negativas foram maiores para todas as tolerâncias, indicando que houve redução mais acentuada dos ângulos agudos, inclusive para janela com 3 de raio que costuma ser mais branda. A fins de comparação, enquanto no primeiro cenário (para 3 de raio) a classe “afloramento rochoso” variou - 4,79, neste cenário a variação foi de -30,43%.

Permanece aqui a coerência entre as tolerâncias, com a mais alta, 9 de raio, apresentando valores mais expressivos.

O desvio-padrão apresentou valores negativos com mais intensidade que no primeiro cenário, porém, apresentando variação constante de acordo com a tolerância assim como o cenário anterior. Apenas a classe “sem classificação” apresentou valores positivos

A Tabela 31 no Anexo 7 apresenta os valores referentes à variação de perímetro médio e desvio padrão para filtro retangular e a Figura 56 apresenta os valores referentes às variações de perímetro médio para o mesmo tipo de filtro.



1- Afloramento rochoso 2- Agricultura 3- Água 4- Café 5- Eucalípto 6- Mata 7- Sem classificação 8- Pastagem 9- Solo exposto 10- Sombra

Figura 56. Variação de perímetro médio para filtro retangular


Podemos notar que houve a mesma tendência de queda do perímetro médio, porém, ligeiramente mais suave que o filtro circular

Os valores de desvio-padrão seguiram a queda observada nos filtros circulares e, assim como os valores de perímetro, também foram mais suaves e sem homogeneidade entre as classes.

Em relação ao primeiro cenário, ocorreu maior variação negativa dos valores para todas as tolerâncias e para valores de desvio-padrão também.

4.2.2.3.3 Variação de Kc médio

A Tabela 32 no Anexo 7 apresenta os valores referentes à variação de Kc médio e desvio padrão para filtro circular e a Figura 57 apresenta os valores referentes às variações de Kc médio para o mesmo tipo de filtro.



1- Afloramento rochoso 2- Agricultura 3- Água 4- Café 5- Eucalípto 6- Mata 7- Sem classificação 8- Pastagem 9- Solo exposto 10- Sombra

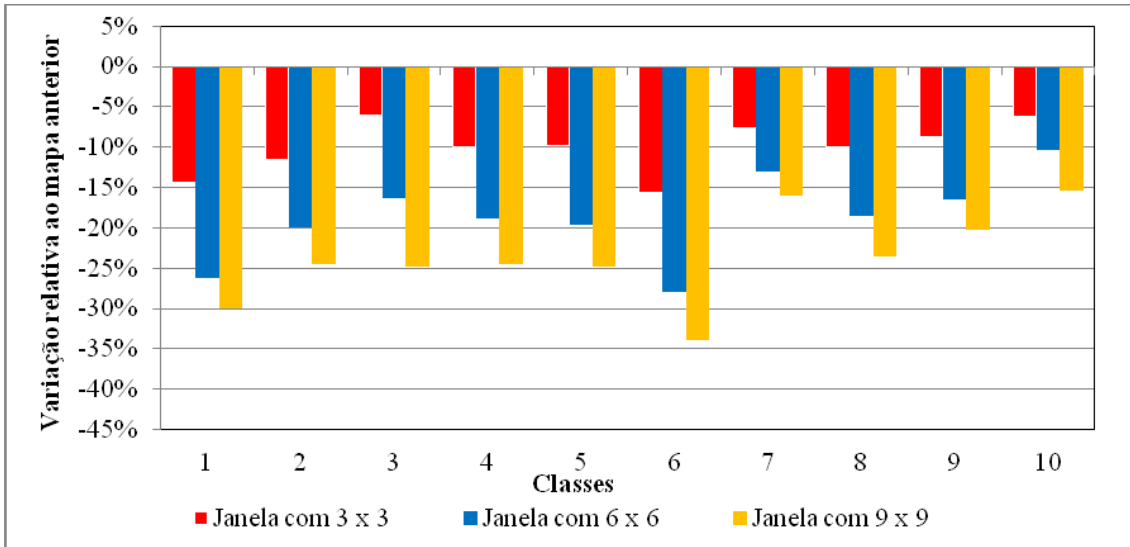
Figura 57. Variação de Kc médio para filtro circular

O comportamento dos valores de Kc são coerentes com a variação observada para o perímetro médio, pois, aqui houve forte tendência ao círculo principalmente para a janela com 9 de raio. Concordando com isto, estes valores são mais expressivos que para o primeiro cenário.

As classes “mata” e “afloramento” rochoso para janela com 9 de raio apresentaram forte declínio para este parâmetro, sendo as mais alteradas na forma final.

Chama atenção a variação de desvio-padrão para classe “sem classificação” para janela com 9 de raio, onde não houve alteração em relação ao mapa anterior, indicando que a atuação do filtro, nesta tolerância para esta classe foi absolutamente idêntica para os dois grupos de *pixels* da classe. A classe “sombra” fugiu ao padrão para janela com 6 de raio, ao apresentar valor de desvio-padrão inferior à janela com 9 de raio. O restante das classes apresentaram variações constantes de acordo com o tamanho de raio.

A Tabela 33 no Anexo 7 apresenta os valores referentes à variação de Kc médio e desvio padrão para filtro retangular e a Figura 58 apresenta a variação de Kc médio para o mesmo tipo de filtro



1- Afloramento rochoso 2- Agricultura 3- Água 4- Café 5- Eucalípto 6- Mata 7- Sem classificação 8- Pastagem 9- Solo exposto 10- Sombra

Figura 58. Variação de Kc médio para filtro retangular

Os resultados aqui são coerentes com o que já foi discutido, tendo para filtro retangular valores mais brandos de variação negativa para Kc médio. Em relação ao primeiro cenário também houve maior queda nos valores.

Para valores de desvio-padrão não foi observado nenhum valor anômalo, seguindo a tendência de queda de acordo com o raio da janela.

Na análise do conjunto das variáveis, podemos notar que a mudança do algoritmo para o operador *amalgamação* resultou em valores negativos mais acentuados para o parâmetro perímetro médio e Kc médio, em relação a variação de área média não houve grandes diferenças. Indicando que o algoritmo utilizado aqui causa mais alterações na forma e não na área dos grupos de *pixels*. A própria análise do Índice Kappa também nos revela este fato, pois, os valores entre os cenários foram próximos.

4.2.2.4. Grau de pureza das classes

A próxima análise demonstra o grau de pureza de cada classe final em relação à original, indicando quais classes foram mais preservadas em termos de área após a aplicação dos operadores. A Tabela 34 no Anexo 8 apresenta os valores, expressos em porcentagem, para os filtros circulares com 3 de raio.

Os números destacados em vermelho significam a porcentagem de área da classe original que foi preservada na classe final.

Cabe ressaltar que este resultado é fruto de todos os operadores, diferenciando apenas no tipo de filtro e a tolerância especificada, neste caso, 3 de raio.

Podemos notar que as classes foram alteradas sensivelmente, pois, a maioria delas não apresentou valores acima de 80% de sua classe original, apenas a classe “água”. A classe “sombra” foi a mais alterada, com 51,45% de pureza, a classe mais conservada foi “água” com 87,69% de pureza.

Em relação ao primeiro cenário para o mesmo filtro, usando a mesma tolerância, os resultados variaram pouco, apenas a “classe” água obteve uma pureza bem superior.

A Tabela 35 no Anexo 8 apresenta o mesmo índice para o filtro circular com 6 de raio.

De acordo com os resultados expostos nesta tabela, pode-se notar que houve ligeira queda dos valores de grau de pureza em relação a primeira tolerância. Novamente a classe “sombra” apresentou menor grau de pureza com 51,13% e a classe “água” 76,26% com maior pureza na classe final.

Em relação ao primeiro cenário também houve uma modificação inexpressiva, com a maioria das classes neste cenário apresentando pequeno aumento no grau de pureza.

A Tabela 36 Anexo 8 apresenta o mesmo índice para o filtro circular com 9 de raio.

Acompanhando o resultado anterior, e mantendo a coerência, observa-se novamente tendência de ligeira queda nos valores de pureza. A classe “sombra” com menor valor, 50,95% e a classe “água” com o maior, 81,66%.

Em relação ao primeiro cenário também houve aqui melhora pouco significativa no grau de pureza.

Apesar do filtro com 9 de raio ser o filtro que mais modifica os valores das variáveis estabelecidas anteriormente, em relação ao grau de pureza das classes não o modifica de forma acentuada, houve neste cenário, como no primeiro, pequenas variações entre as tolerâncias, tendendo a diminuir com o aumento da tolerância.

Para os filtros circulares, na comparação entre os dois cenários, a variação para o grau de pureza também foi insignificante.

A Tabela 37 no Anexo 8 apresenta os valores, expressos em porcentagem, para os filtros retangulares de janela 3x3

Os resultados continuam demonstrando estabilidade, apesar de ter havido um pequeno acréscimo no grau de pureza em relação ao primeiro cenário e em relação ao filtro circular de janela com 3 de raio. Parece que este índice neste cenário também não depende da atuação dos filtros.

As classes “sombra” e “água”, novamente apresentaram os valores mais baixos e altos, com 51,48% e 90,53% respectivamente.

A Tabela 38 no Anexo 8 apresenta o mesmo índice para o filtro retangular de janela 6x6.

De forma semelhante à tabela anterior, os resultados para esta tolerância são coerentes entre si. Apresentando ligeira tendencia de queda para as classes, continuando com a classe “sombra” com 51,40% e a classe “água” 87,37% com os menores e maiores valores respectivamente.

A Tabela 39 no Anexo 8 apresenta o mesmo índice para o filtro retangular de janela 9x9.

Estes resultados também são coerentes, porque preservam a característica que foi observada ao longo das outras variáveis, que foi a pequena variação dos valores. Com as mesmas classes apresentando menor e maior grau de pureza, “sombra” com 51,07% e “água” com 84,61% respectivamente.

Realizada a análise numérica, a Figura 70 no Anexo 9 demonstra o mapa original, que foi o mapa após a aplicação do operador *eliminação* e os mapas resultantes dos filtros circulares em escala original, porém, devido a área de apresentação, optou-se por capturar apenas uma área da bacia.

É clara a diferença entre as tolerâncias, a janela com 3 de raio suaviza as bordas de maneira pouco perceptível em certas áreas, causando pouca modificação em relação ao mapa anterior.

Com 6 de raio as mudanças começam a ficar mais notáveis, as sinuosidades das áreas são mais preenchidas, com menos ângulos agudos.

Já com 9 de raio, a diferença é abrupta em relação ao mapa original, as áreas são alteradas a ponto de eliminar alguns pequenos grupos de *pixels*, arredondar por completo alguns outro e também agregar grupos de *pixels* antes separados.

Em relação ao primeiro cenário as diferenças visuais são poucas, apesar da conhecida mudança de valores das variáveis.

A Figura 71 no Anexo 9 apresenta o mesmo modelo para as tolerâncias com o filtro retangular.

Nas tolerâncias para filtro retangular, nota-se pouca diferença entre a janela 3x3 e o mapa original, assim como a diferença entre a janela 6x6 para a primeira não é tão drástica como para o filtro circular, para janela 9x9 a diferença em relação aos demais e ao mapa original é grande, os objetos se apresentam mais suaves, porém, a diferença não foi tão expressiva quanto constatada no filtro circular. Da mesma maneira que no primeiro cenário.

De acordo com as análises numéricas, este resultado era esperado, pois, podemos notar de acordo com as alterações das variáveis que o filtro retangular sempre apresentou menores variações, tanto neste cenário quanto no primeiro. As diferenças visuais também não se fazem notar com muita clareza em relação ao primeiro cenário.

Para tamanho de janela 6x6 notou-se alguns ruídos no mapa, *pixels* que foram erroneamente eliminados e estão sem atributo.

4.2.3. 3º Cenário

A diferença básica neste cenário dos anteriores é que aqui não foi aplicado o operador *amalgamação*, procurando determinar se para nosso caso houve a necessidade de uso deste operador. Para os demais operadores foram utilizados os mesmos algoritmos e tolerâncias.

4.2.3.1. Operador Eliminação

O primeiro operador utilizado foi categorização, da mesma maneira que os anteriores, não sendo necessário exibir novamente, adiante aplicou-se o operador *eliminação*. Neste resultado que exibiremos é que será possível determinar o uso ou não do operador *amalgamação*, de acordo com o número de grupo de *pixels*, se houver mais grupos de *pixels* ou número igual, entende-se que, para nosso caso, não houve a necessidade de utilizar tal operador.

A Tabela 10 apresenta os valores relativos ao mapa categorizado e eliminado.

Tabela 10. Tabela resultante do operador eliminação

CLASSE	Área total (ha)	Área relativa (%)	Grupos de <i>pixels</i>	CLASSE	Área total (ha)	Área relativa (%)	Diferença de área (%)	Grupos de <i>pixels</i>	Redução de grupos de <i>pixels</i> (%)
Mata	76	7	171	Mata	49	4,52	-35,52	16	-90,64
Café	325	30,00	281	Café	400	36,95	23,07	59	-79,00
Eucalipto	81	7,50	225	Eucalipto	37	3,43	-54,32	15	-93,33
Solo exposto	24	2,21	70	Solo exposto	12	1,10	-50,00	6	-91,42
Agricultura	55	5,10	119	Agricultura	30	2,77	-45,45	9	-92,43
Água	7	0,64	23	Água	2	0,18	-71,42	1	-95,65
Pastagem	416	38,42	155	Pastagem	496	45,80	19,23	32	-79,35
Aflor.rochoso	75	6,93	176	Aflor.rochoso	42	3,87	-44,00	12	-93,18
Sombra	12	1,10	35	Sombra	9	0,83	-25,00	3	-91,42
S/Classificação	12	1,10	41	S/classificação	6	0,55	-50,00	2	-95,12
TOTAL	1.083	100	1.296		1.083	100		155	-88,04

Semelhante aos dois primeiros cenários, este operador foi o que mais causou alteração nas áreas e nos grupos de *pixels*, provocando grande alteração estética no mapa. A classe que mais perdeu áreas foi “água” e a classe “café” foi a que mais obteve ganhos, com 23,07%.

Novamente a classe “água” e “sem classificação” perderam mais representatividade no mapa, com 95,65% e 95,12% respectivamente. Seguindo a mesma tendência, todas as classes tiveram perdas expressivas em seus grupos de *pixels*.

De acordo com o exposto houve, ao contrário do que era esperado, aumento no grupo de *pixels*, de um grupo de *pixel* a mais em relação ao primeiro cenário e dois grupos em relação ao segundo cenário, indicando que não houve a necessidade do uso do operador *amalgamação*.

A Figura 59 apresenta o mapa após aplicação deste operador.

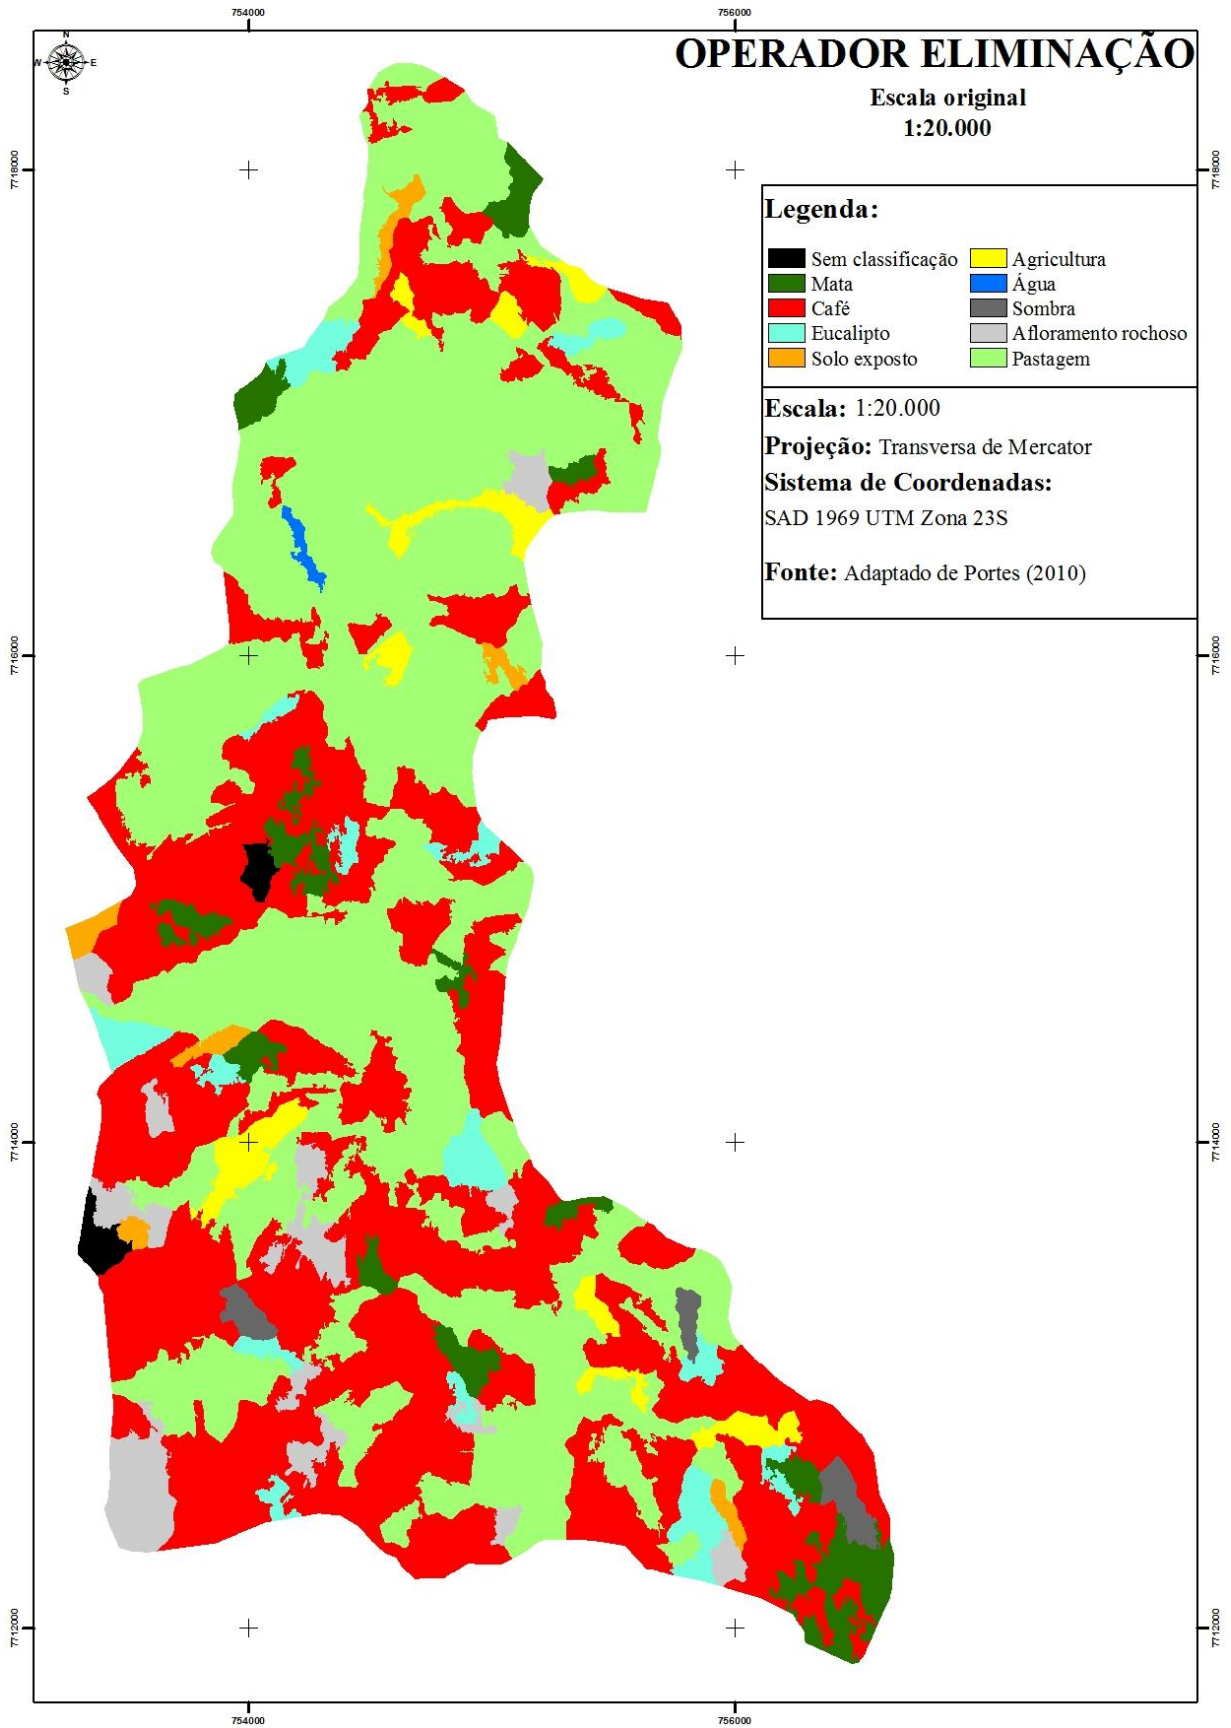



Figura 59. Mapa resultante do operador eliminação

4.2.3.2. Operador Numérico

Foram aplicados dois tipos de filtros e para cada um foram utilizadas três tolerâncias. Para avaliar a atuação de cada um foram utilizados as mesmas variáveis que nos dados vetoriais: variação de área média; variação de perímetro médio; variação de Kc médio e a variação do desvio-padrão para cada um, como dado auxiliar. Idêntico aos dois cenários anteriores.

4.2.3.2.1 Variação de área média

A Tabela 40 no Anexo 10 apresenta a variação de área média e desvio-padrão e a Figura 60




1- Afloramento rochoso 2- Agricultura 3- Água 4- Café 5- Eucalipto 6- Mata 7- Sem classificação 8- Pastagem 9- Solo exposto 10- Sombra

Figura 60. Variação de área média para filtro circular

Os dados revelam que houve predominância de valores positivos, exceto para as classes “água” e “sombra”. Os valores são muito parecidos com os dois cenários anteriores. Onde para um pouco mais da metade houve leve aumento de área média para todos os filtros e um pequeno declínio para as outras classes. Indicando que para este parâmetro os valores, para os três filtros são relativamente estáveis.

Os valores de desvio-padrão variaram pouco entre as classes e de forma gradativa, tendendo a um suave acréscimo de acordo com o aumento das tolerâncias. Em relação aos cenários anteriores, os valores foram consideravelmente mais baixos.

A Tabela 41 no Anexo 10 e a Figura 61 apresentam as variações de área referentes aos filtros retangulares.



1- Afloramento rochoso 2- Agricultura 3- Água 4- Café 5- Eucalípto 6- Mata 7- Sem classificação 8- Pastagem 9- Solo exposto 10- Sombra

Figura 61. Variação de área média para filtro retangular


Para este filtro, também houve leve acréscimo na área média, mais tênue que no filtro circular. Este comportamento é coerente com os dois cenários anteriores, e os valores para este filtro em relação aos outros cenários também são muito próximos.

Houve para a classe “sem classificação” comportamento parecido como nos cenários anteriores, com um acréscimo superior a média dos demais para janela 9x9.

Para as janelas 3x3 a variação foi em certos casos praticamente nula.

4.2.3.2.2 Variação de perímetro médio

A Tabela 42 no Anexo 10 apresenta os valores referentes a variação de perímetro médio e desvio padrão para filtro circular e a Figura 62 apresentam os valores referentes as variações de perímetro médio para o mesmo tipo de filtro.



1- Afloramento rochoso 2- Agricultura 3- Água 4- Café 5- Eucalípto 6- Mata 7- Sem classificação 8- Pastagem 9- Solo exposto 10- Sombra


Figura 62. Variação de perímetro médio para filtro circular

Para este parâmetro todos os valores de raio de janela apresentaram valores negativos, indicando que este filtro tendeu à homogeneização as formas dos grupos de *pixels*.

Como era de esperar, houve redução maior na janela com 9 de raio. Ao contrário do desvio-padrão relativo à área, aqui houve uma maioria negativa, com anomalias na classe “sem classificação” com forte variação positiva para todas as tolerâncias.

Em relação aos cenários anteriores, aqui os valores foram muito mais expressivos em relação ao primeiro cenário, inclusive de desvio-padrão, e em relação ao segundo cenário, houve uma leve redução na queda dos valores, inclusive de desvio-padrão.

A Tabela 43 no Anexo 10 apresenta os valores referentes à variação de perímetro médio e desvio-padrão para filtro retangular e a Figura 63 apresenta os valores referentes às variações de perímetro médio para o mesmo tipo de filtro.



1- Afloramento rochoso 2- Agricultura 3- Água 4- Café 5- Eucalípto 6- Mata 7- Sem classificação 8- Pastagem 9- Solo exposto 10- Sombra

Figura 63. Variação de perímetro médio para filtro retangular

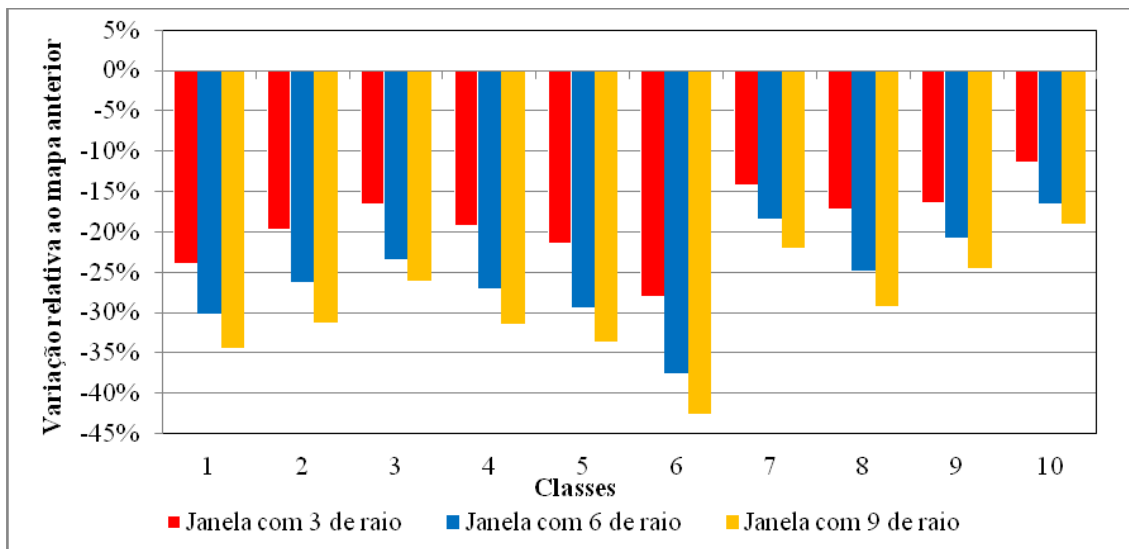
O comportamento observado é coerente, mantendo a tendência de queda do perímetro médio, porém, mais suave que o filtro anterior, apresentando certa constância de valores entre as as tolerâncias e as classes.

Em relação ao primeiro cenário houve também maior redução, e em relação ao segundo os valores não variaram muito, aqui apresentando valores um pouco mais brandos. Isto sinaliza que o comportamento para este cenário tende a gerar resultados mais próximos do segundo cenário.

Os valores de desvio-padrão também são coerentes entre si, mantendo o mesmo comportamento analisado no filtro circular, com valores menos expressivos, e mais semelhantes ao segundo cenário.

4.2.3.2.3 Variação de Kc médio

A Tabela 44 no Anexo 10 apresenta os valores referentes à variação de Kc médio e desvio padrão para filtro circular e a Figura 64 apresenta os valores referentes às variações de Kc médio para o mesmo tipo de filtro.



1- Afloramento rochoso 2- Agricultura 3- Água 4- Café 5- Eucalípto 6- Mata 7- Sem classificação 8- Pastagem 9- Solo exposto 10- Sombra

Figura 64. Variação de Kc médio para filtro circular

O comportamento dos valores de Kc são coerentes com a variação observada para o perímetro médio, pois, aqui houve forte tendência ao círculo principalmente para a janela com 9 de raio. As classes “mata” e “afloramento” rochoso para janela com 9 de raio apresentaram forte declínio para este parâmetro, sendo as mais alteradas na forma final.

Concordando com os valores apresentados no perímetro médio, em relação aos cenários anteriores, a variação de Kc médio aqui foi muito superior ao primeiro cenário e praticamente idêntico ao segundo.

A classe “sombra” fugiu ao padrão para janela com 6 de raio, ao apresentar valor de desvio-padrão inferior à janela com 9 de raio. O restante das classes apresentaram variações constantes de acordo com o tamanho de raio. Guardando as mesmas disparidades entre o primeiro cenário e semelhanças com o segundo.

A Tabela 45 no Anexo 10 apresenta os valores referentes à variação de Kc médio e desvio padrão para filtro retangular e a Figura 65 apresenta os valores referentes às variações de Kc médio para o mesmo tipo de filtro.