

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ**

**GABRIEL DA ROCHA BRAGION**

**MELHORIAS NA ACURÁCIA DO MAPEAMENTO POR NDVI**

**CAMPO MOURÃO**

**2017**

GABRIEL DA ROCHA BRAGION

## **MELHORIAS NA ACURÁCIA DO MAPEAMENTO POR NDVI**

Trabalho de Conclusão de Curso, do curso de Engenharia Ambiental, do Departamento Acadêmico de Ambiental (DAAMB), do Campus Campo Mourão, da Universidade Tecnológica Federal do Paraná (UTFPR), como requisito parcial para obtenção do título de Bacharel em Engenharia Ambiental.

Orientador: Prof. Dr. Edivando Vitor do Couto

CAMPO MOURÃO

2017

*“Der Mensch ist das einzige Geschöpf, das erzogen werden muß. Unter der Erziehung nämlich verstehen wir die Wartung (Verpflegung, Unterhaltung), Disciplin (Zucht) und Unterweisung nebst der Bildung. Demzufolge ist der Mensch Säugling, – Zögling, – und Lehrling”*

(Immanuel Kant)

## **AGRADECIMENTOS**

Agradeço aos meus pais acima de tudo e todos, Roseli Olímpio da Rocha Bragion e Walter Bragion, pelo amor e confiança dedicados a mim, não merecedor.

Ao meu orientador, Prof. Dr. Edivando Vitor do Couto, por se prestar ao árduo trabalho de me guiar.

Ao meu co-orientador Prof. Dr. José Hilário Delconte Ferreira, que idealizou este trabalho.

À amiga, Aruani Letícia Tomoto, e à companheira, Kauanna Uyara Devens, por contribuírem diretamente com a execução deste trabalho.

## RESUMO

Este trabalho propõe um método de classificação supervisionada pela distância de Bhattacharya baseado na utilização do índice de vegetação da diferença normalizada para a classificação supervisionada de lavouras temporárias e remanescentes florestais da mata atlântica e outras classes de uso da terra da bacia hidrográfica do Rio Mourão, Paraná, visando atenuar os efeitos das sazonalidades na classificação. A acurácia global e índice de Kappa do produto gerado pela classificação supervisionada foram de 73,92% e 0,53, respectivamente. Também foram investigadas a acurácia do usuário, a fiabilidade do produtor e o índice de Kappa condicional. Os resultados mostraram que o método apresenta um excelente desempenho para a diferenciação de coberturas florestais ( $k = 76,94$ ), lavouras temporárias ( $k = 0,89$ ) e água ( $k = 0,87$ ).

**PALAVRAS-CHAVE:** NDVI; Sensoriamento remoto; Bhattacharya; Kappa.

## **ABSTRACT**

This work proposes a supervised classification method by the Bhattacharya distance tool using the Normalized Difference Vegetation Index of croplands and forest remnants of the Atlantic forest and other land use classes from the Mourão river watershed, Paraná, aiming to mitigate the effects of seasonality in the classification. The overall accuracy and Kappa index of the product generated by the supervised classification were 73.92% and 0.53, respectively. We also investigated the user's accuracy, the producer's reliability and the conditional Kappa index. The results showed that the method presented an excellent performance for the differentiation of forest cover ( $k = 76.94$ ), temporary crops ( $k = 0.89$ ) and water ( $k = 0.87$ ).

**KEYWORDS:** NDVI; Remote sensing; Bhattacharya; Kappa.

## LISTA DE FIGURAS

Figura 1 - Localização da bacia hidrográfica do rio do Campo, Paraná, Brasil...	9
Figura 2 - Padrões de erros relativos ao processo de construção de mosaico a) e b), e c) mosaico ideal. ....	10
Figura 3 – Mapas de uso do terra da bacia hidrográfica do Rio Mourão, Paraná, relativos aos diferentes métodos de classificação supervisionada. ....	16
Figura 4 - Uso do solo e classes de declividade na bacia hidrográfica do Rio Mourão, Paraná. ....	17
Figura 5 – Proporção das classes de uso da terra na bacia hidrográfica do Rio Mourão, Paraná, relativo aos diferentes métodos de classificação supervisionada. ....	18
Figura 6 – Índice de Kappa (K) e acurácia global (N) dos diferentes produtos da classificação supervisionada. ....	19
Figura 7 – Acurácia da classe Área antropizada não agrícola segundo diferentes métodos de avaliação. ....	21
Figura 8 – Acurácia da classe Pastagem segundo diferentes métodos de avaliação. ....	22
Figura 9 - Acurácia da classe Água segundo diferentes métodos de avaliação. ....	23
Figura 10 – Acurácia da classe Lav. Temporária segundo diferentes métodos de avaliação. ....	24
Figura 11 - Acurácia da classe Florestal segundo diferentes métodos de avaliação. ....	25
Figura 12 - Acurácia da classe Silvicultura segundo diferentes métodos de avaliação. ....	26
Figura 13 - Grau de concordância dos diferentes métodos de classificação segundo o índice de Kappa condicional. ....	27

## LISTA DE TABELAS

Tabela 1 – Representação de uma matriz de confusão. ....	13
Tabela 2 – Grau de concordância segundo o índice de Kappa.....	14
Tabela 3 – Grau de concordância dos diferentes métodos de classificação segundo índice de Kappa. ....	20



## LISTA DE ABREVIATURAS E SIGLAS

IV	Índice de Vegetação
K	Índice de Kappa de Cohen
k	Índice de Kappa condicional
N	Acurácia global
NDVI	Índice de Vegetação da Diferença Normalizada
Np	Acurácia do usuário
Nu	Fiabilidade do produtor
SR	Sensoriamento remoto

## SUMÁRIO

<b>1 INTRODUÇÃO</b> .....	<b>3</b>
<b>2 OBJETIVOS</b> .....	<b>5</b>
2.1 Objetivo geral .....	5
2.2 Objetivos específicos.....	5
<b>3 FUNDAMENTAÇÃO TEÓRICA</b> .....	<b>6</b>
3.1 Índices de Vegetação .....	6
3.2 As questões da sazonalidade .....	7
<b>4 MATERIAL E MÉTODOS</b> .....	<b>9</b>
4.1 Caracterização da área de estudos .....	9
4.2 Aquisição de cenas e pré-processamento.....	10
4.3 Cálculo do índice de vegetação da diferença normalizada médio.....	11
4.4 Segmentação e classificação supervisionada.....	12
4.5 Avaliação da acurácia da classificação supervisionada .....	12
<b>5 RESULTADOS</b> .....	<b>15</b>
5.1 Mapeamento das classes de uso da terra.....	15
5.2 Acurácia dos diferentes métodos de classificação.....	18
5.3 Acurácia das classes segundo diferentes métodos de classificação .....	20
5.3.2 Acurácia da classe Pastagem .....	22
5.3.3 Acurácia da classe Água .....	23
5.3.4 Acurácia da classe Lavoura Temporária .....	24
5.3.5 Acurácia da classe Cobertura Florestal.....	25
5.3.6 Acurácia da classe Silvicultura .....	26
5.3.7 Classificação dos níveis de concordância do índice de Kappa condicional ...	26
<b>6 DISCUSSÃO</b> .....	<b>28</b>
6.1 Sazonalidades no índice de vegetação pela diferença normalizada .....	28
6.2 Índice de Vegetação pela Diferença Normalizada médio.....	30
<b>7 CONCLUSÃO</b> .....	<b>32</b>
<b>REFERÊNCIAS</b> .....	<b>33</b>



## 1 INTRODUÇÃO

No decorrer das últimas décadas, as técnicas de sensoriamento remoto (SR) aplicadas à classificação e monitoramento dos elementos presentes na paisagem foram amplamente exploradas (PELLETIER et al., 2017), já sendo consideradas como parte fundamental nas atividades de planejamento urbano (SOUZA, 2012), monitoramento dos recursos naturais (QAMER et al., 2016), prevenção de desastres naturais (NOLESINI et al., 2016), etc.

Explorar a relação existente entre as grandezas físicas e as formas com que elas interagem com a radiação eletromagnética é um dos principais desafios do SR aplicado aos estudos do ambiente. Variações na quantidade e propriedades da radiação eletromagnética podem fornecer dados valiosos para a interpretação da natureza de um fenômeno ao longo do tempo (JENSEN, 2009). Neste contexto, o imageamento realizado por sensores orbitais possibilitou a geração de dados espectrais que permitiram o desenvolvimento de técnicas para o tratamento dessas informações, e posteriormente a análise da superfície terrestre através de diferentes algoritmos e índices matemáticos (GANDHI et al., 2015).

Em meio às várias metodologias desenvolvidas, uma das mais frequentes é a utilização de índices de vegetação (IV), indicadores numéricos utilizados para estimar variáveis biogeofísicas e também evidenciar a vegetação dentre outros aspectos da paisagem, já que o seu cálculo deriva das principais componentes espectrais de áreas com cobertura vegetal.

Dentre diversos IV, o Índice de Vegetação da Diferença Normalizada (em inglês, *Normalized Difference Vegetation Index*, NDVI, ROUSE et al., 1973) é sem dúvida um dos mais notórios, pois desde a sua descrição na década de 70, continua sendo um dos mais recorrentes parâmetros para a análise da vegetação. Muitos trabalhos já concluíram sobre a correlação entre o NDVI e distribuição da vegetação, no entanto existem limitações atribuídas à forte influência da atmosfera e do substrato no qual a vegetação se encontra (HUETE, 1988).

Tratando-se especificamente sobre a utilização desses índices para detectar e diferenciar áreas agrícolas ociosas, Vaiphasa et al. (2011) demonstram a grande irregularidade dos valores de NDVI de culturas agrícolas ao longo de um ano, o que dificulta a identificação de faixas de valores que melhor representem estas áreas.

Estas variações ocorrem devido às flutuações dos ciclos fenológicos de cultivos temporários. Durante as entressafras, estas áreas têm seu solo exposto e, em pouco tempo apresentam uma vegetação substancialmente mais vigorosa que as áreas florestais, além de serem menos sombreadas e não ocorrerem com frequência em regiões com variações abruptas na topologia, resultando em altos valores de NDVI (SOBRINHO; ALVES, 2012).

Sendo assim, o resultado da classificação da cobertura do solo que utiliza como parâmetro este índice, quando processado em função de apenas uma data, pode confundir os diferentes tipos de cultura, e mais além, atribuir a qualidade de floresta às culturas temporárias, e vice-versa. Assim, na classificação por SR derivada, fica clara a necessidade da adoção de metodologias que levem em consideração a sazonalidade das variáveis que possam afetá-la.

Neste contexto, buscou-se apresentar uma metodologia que explore a aplicabilidade do NDVI no processo de classificação supervisionada da cobertura do solo, buscando minimizar os efeitos da sazonalidade na determinação de classes de uso, utilizando imagens orbitais obtidas ao longo de um ano pelo satélite Landsat-8, permitindo diferenciar com eficiência zonas agrícolas de culturas temporárias e fragmentos florestais remanescentes da mata atlântica.

## **2 OBJETIVOS**

### **2.1 Objetivo geral**

Explorar a aplicabilidade do NDVI no processo de classificação supervisionada da cobertura do solo, buscando minimizar os efeitos da sazonalidade na determinação de classes de uso, permitindo diferenciar com eficiência zonas agrícolas de culturas temporárias e fragmentos florestais remanescentes da mata atlântica.

### **2.2 Objetivos específicos**

- Elaborar um banco de dados espaciais a partir das imagens do sensor OLI a bordo do satélite Landsat-8;
- Calcular o índice de vegetação pela diferença normalizada e seus derivados a partir das imagens selecionadas;
- Elaborar um mapa temático de referência de cobertura do solo a partir da segmentação e classificação supervisionada das imagens do sensor OLI que sobrepõem a bacia hidrográfica do rio Mourão;
- Elaborar diversos mapas temáticos de uso da terra a partir da segmentação e classificação supervisionada dos índices de vegetação da diferença normalizada das datas disponíveis para a bacia hidrográfica do Rio Mourão;
- Elaborar um mapa temático de cobertura do solo a partir da segmentação e classificação supervisionada dos índices de vegetação da diferença normalizada anuais médios da bacia hidrográfica do Rio Mourão;
- Avaliar a acurácia das classificações.

### 3 FUNDAMENTAÇÃO TEÓRICA

#### 3.1 Índices de Vegetação

A obtenção de dados remotos de acordo com a abordagem desse trabalho, enfatiza o processamento de dados radiométricos para aquisição de informações sobre a superfície da terra. Este tipo de variável é caracterizado por Jensen (2009) como uma variável híbrida em escala nominal, já que a intenção é atribuir classes a cobertura do solo de acordo com as configurações espectrais comuns de uma composição de diversas variáveis atribuídas a um ou mais pixels.

Na tentativa de qualificar a intensidade de fenômenos muito complexos para serem atribuídos a parâmetros conhecidos, pesquisadores têm desenvolvido ao longo dos anos índices que se correlacionem a estas variáveis de interesse, neste caso, índices de vegetação (BANNARI et al., 1995).

Desenvolvido por Rouse et al. (1973), o NDVI (Equação 1) é um índice que busca identificar a vegetação e a sua condição a partir de suas componentes espectrais principais. A reflectância foliar de uma vegetação sadia típica apresenta, em teoria, características espectrais bem definidas. A radiação do espectro vermelho é a que melhor responde às variações na concentração de pigmentos fotossintetizantes, pois a maior parte do espectro ótimo de absorção está concentrado nela, diferente da banda do infravermelho próximo, onde grande parte é refletida devido a estrutura foliar adaptada das plantas, que evita o superaquecimento de suas estruturas (FARABEE, 2001).

$$NDVI = \frac{NIR - Red}{NIR + Red} \quad \text{Equação 1}$$

em que:

NDVI = índice de vegetação da diferença normalizada;

NIR = reflectância medida pelo sensor na banda do infravermelho próximo;

RED = reflectância medida pelo sensor na banda do vermelho.

Assim, quando os valores de reflectância da banda NIR são maiores que os da RED, o índice apresentará valores maiores que zero. Em situações onde há uma

menor atividade fotossintética, menos energia da banda RED é absorvida, aproximando os valores das bandas e resultando em valores de NDVI mais próximos de zero, o que pode evidenciar um dossel menos denso, caducidade ou algum tipo de estresse (JENSEN, 2009).

O NDVI revolucionou as aplicações do sensoriamento remoto até então, mas conforme o número de pesquisas aumentava, suas limitações ficavam cada vez mais evidentes. No entanto, Huete (1988) discorre sobre como os IV são afetados pelas configurações do solo de fundo, configurações estas que variam sazonalmente. Delon et al. (2015) constataram também que a umidade e a concentração de matéria orgânica são as que mais variam ao longo do tempo, sendo ainda mais díspares em áreas agrícolas, onde há a intervenção antrópica.

### **3.2 As questões da sazonalidade**

A cobertura terrestre pode ser mais ou menos estável, a depender da matriz de ocupação da região, tendo como exemplo a bacia hidrográfica do rio Mourão, que é uma área com intensa atividade agrícola. Diferenciar e classificar a vegetação e outras feições através de imagens orbitais restritas por uma data, num contexto agrícola como o da bacia hidrográfica do rio Mourão, não deverá apresentar resultados satisfatórios, visto que os ciclos fenológicos dessas culturas são acelerados, e por isso a sua assinatura espectral varia significativamente em poucas semanas.

Além disso, agricultores escolhem iniciar o plantio de determinada cultura em épocas distintas, a depender de certas condições meteorológicas e por vezes adotam técnicas heurísticas de manejo (JENSEN, 2009). Mesmo que estas culturas sejam colhidas em períodos diferentes, a variação de seus IV será praticamente a mesma, já que eles apresentam boa correlação com a produção de biomassa da vegetação, que responde diretamente ao seu ciclo fenológico (LUMBIERRES et al., 2017).

Quanto à discriminação de áreas florestais, uma matriz agrícola pode exercer forte influência no processo de classificação, pois em determinado momento de seu desenvolvimento, culturas temporárias como café, milho, soja e triticale apresentarão um dossel tão denso quanto florestas, podendo superestimar a classificação de áreas florestais.

Na tentativa de apresentar um intervalo de NDVI para a classificação da cobertura vegetal, Lima et al. (2013) tomam como base uma única imagem do sensor



*Thematic Mapper* (TM) e estabelecem um intervalo de classificação fixo do índice, o que pode ter sido a razão da ineficácia da classificação de pastagens degradadas e solos sem cobertura em seu trabalho.

Este tipo de processo deveria levar em consideração a interferência de culturas adjacentes sobre a identificação de uma faixa adequada para a classificação da vegetação. Alguns autores (e.g., VICENTE et al., 2012; SILVA et al., 2015) observaram que culturas agrícolas podem superestimar a ocorrência de dosséis florestais em determinadas épocas devido aos seus ciclos fenológicos, e regularmente apresentam valores de NDVI médios superiores aos de áreas de mata.

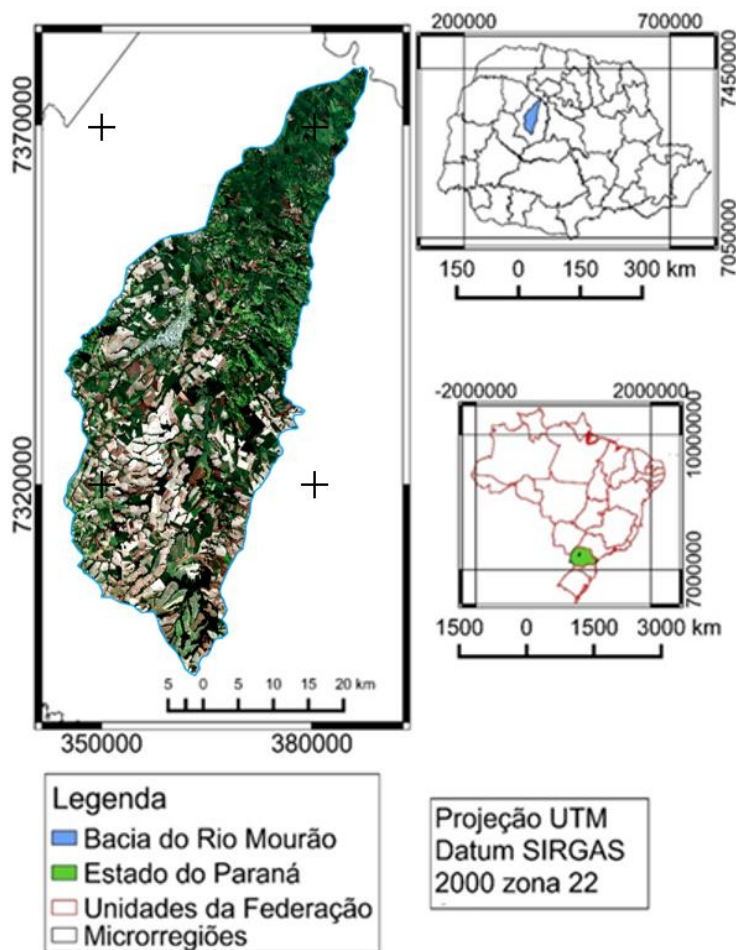
De modo análogo à metodologia proposta por este trabalho, Benedetti et al. (2011) utilizou com sucesso valores multitemporais médios de NDVI para a obtenção de limiares indicativos das classes de vegetação na metade sul do Rio Grande do Sul, muito embora os valores sejam distintos e independentes de acordo com a base temporal.

Assim sendo, a utilização de parâmetros de distribuição temporal de índices de vegetação poderão ajudar a classificar a cobertura do solo de maneira mais eficiente, de modo que os efeitos das sazonalidades sejam minimizados.

## 4 MATERIAL E MÉTODOS

### 4.1 Caracterização da área de estudos

A bacia hidrográfica do Rio Mourão está localizada nos municípios de Campo Mourão, Quinta Do Sol, Engenheiro Beltrão, Peabiru, Luiziana e Mamborê, no Estado do Paraná, Brasil (Figura 1). Sua área é de aproximadamente 1.651 Km<sup>2</sup>, tendo como afluentes principais o Rio do Campo e o Rio Quilômetro 119.



**Figura 1 - Localização da bacia hidrográfica do rio do Campo, Paraná, Brasil.**  
Fonte: Autoria própria.

O uso da terra da bacia é composto principalmente por lavouras temporárias representadas pelos gêneros *Zea*, *Triticum* e *Glycine*, além da presença de silviculturas dos gêneros *Pinus* e *Eucalyptus*. Os principais núcleos populacionais são os centros urbanos de Campo Mourão, Peabiru, parte de Engenheiro Beltrão e Luiziana, e ainda o distrito de Piquirivaí.

## 4.2 Aquisição de cenas e pré-processamento

A bacia hidrográfica do rio Mourão é sobreposta por duas cenas de mesma órbita e pontos distintos do satélite Landsat-8, sensor OLI, sendo elas 223/76 e 223/77. Através da plataforma Earth Explorer (USGS, 2017), foram selecionados os produtos disponíveis para o ano de 2016 com porcentagem de nuvens obstrutoras da superfície terrestre inferior a 10%. As imagens elencadas foram requeridas ao Centro de Ciência de Arquitetura de Processamento EROS (ESPA). Mediante requerimento, o ESPA disponibiliza gratuitamente as cenas já submetidas à conversão de números digitais para reflectância aparente segundo o método *Top of Atmosphere* (ToA) e reflectância efetiva através de um algoritmo interno. Desta forma, as cenas adquiridas correspondem as seguintes datas: 13/03/2016; 30/04/2016; 03/07/2016; 21/09/2016; 23/10/2016. Foram adquiridas 10 cenas no total, sendo duas para cada data.

As cenas de mesma data foram submetidas a um processo de construção de mosaico. O sucesso do processo foi julgado através da análise dos pixels correspondentes à área de sobreposição das cenas (Figura 2). Foi analisada a presença de variações abruptas nos valores de reflectância efetiva de pixels alinhados pelas diagonais referentes à borda inferior das cenas de ponto 76 e à borda superior das cenas de ponto 77 (Figura 2b) e o alinhamento de feições de referência presentes na área de transição. (Figura2a).




Figura 2 - Padrões de erros relativos ao processo de construção de mosaico a) e b), e c) mosaico ideal.

Fonte: Autoria própria.

Após submetidas ao processo de construção de mosaico, extraiu-se apenas as informações de reflectância efetiva das bandas 4 e 5 inseridas nos limites da bacia hidrográfica. As outras bandas foram utilizadas para a classificação de referência, que foi produzida por fotointerpretação através do cruzamento dessas informações com imagens de alta resolução disponibilizadas pela plataforma Bing® (MICROSOFT, 2016). Também foram realizadas visitas à porção nordeste da bacia hidrográfica, afim de aferir a presença de lavouras, pastagens e remanescentes arbóreos que se distribuem de forma irregular devido à complexidade do terreno declivoso.

### 4.3 Cálculo do índice de vegetação da diferença normalizada médio

O cálculo do NDVI foi empregado para cada data separadamente, resultando em cinco imagens com níveis de cinza podendo variar entre -1 e 1. No Spring 5.2.6®, os pixels das imagens têm os seus valores truncados em determinada casa decimal para evitar a sobrecarga de informações em uma matriz. Sendo assim, é necessário a aplicação de um fator aditivo de *offset* (32.768) e outro multiplicativo de ganho (32.767), convertendo então o produto em uma matriz com possíveis valores entre 1 e 65.535, que equivalem aos valores extremos de uma imagem de 16 *bits* ( $2^{16}$ ). Valores nulos são por padrão considerados como *background*.

O NDVI médio foi obtido através da média aritmética entre estes produtos (Equação 2), resultando então em uma única imagem com valores médios do índice. Foram produzidas duas imagens de NDVI médio: a) NDVI médio total: baseada em todas as datas disponíveis e; b) NDVI médio parcial: baseada em datas distribuídas em intervalos semelhantes (30/04/2016, 03/07/2016 e 23/10/2016).

$$\overline{\text{NDVI}} = \frac{1}{n} \sum_{i=1}^n \left\{ 32.767 \times \left( \frac{\text{Banda 5} - \text{Banda 4}}{\text{Banda 5} + \text{Banda 4}} \right) + 32.768 \right\}_i \quad \text{Equação 2}$$

em que:

$\overline{\text{NDVI}}$  = índice de vegetação da diferença normalizada médio;

n = número total de imagens;

Banda 5 = faixa espectral do infravermelho próximo do sensor OLI;

Banda 4 = faixa espectral do vermelho do sensor OLI.

#### **4.4 Segmentação e classificação supervisionada**

O processo de segmentação se deu também pelo programa SPRING 5.2.6®. O algoritmo fragmentador disponibilizado pelo programa utiliza o método binário de segmentação. Este é um método estatístico de segmentação por crescimento de regiões. É preciso determinar limiares de segmentação que serão utilizados para dar início ao teste de hipóteses.

O limiar área corresponde ao número mínimo de pixels que o algoritmo deve considerar como sendo um único objeto. O outro limiar definido é a similaridade, utilizada para restringir a variação necessária para que o algoritmo interprete que dois conjuntos de pixels adjacentes não pertençam à mesma classe. Ambos foram definidos empiricamente, até que houvesse uma distribuição de feições segmentadas que mais se aproximasse do encontrado pela classificação supervisionada de referência, sendo eles 50 e 1.800, respectivamente.

Para a classificação supervisionada, foi utilizado o algoritmo classificador baseado na distância de Bhattacharya. O produto da segmentação foi utilizado para a amostragem necessária para o treinamento da classificação. Foram coletadas 50 amostras das classes Cobertura florestal, Silvicultura, Pastagem, Lavouras Temporárias, Água e Áreas antropizadas não agrícolas. Os polígonos amostrados foram então extraídos e importados para o treinamento do classificador, havendo então uma parametrização do processo amostral.

#### **4.5 Avaliação da acurácia da classificação supervisionada**

A acurácia das classificações supervisionadas provenientes das imagens NDVI de diferentes datas distribuídas ao longo do ano e das imagens NDVI médios foi identificada através da matriz de confusão relativa ao mapeamento de referência. Com base na matriz de confusão, foram adotados os seguintes parâmetros para avaliação e discussão: Acurácia global; índice de Kappa; coeficiente de Kappa condicional; Acurácia do usuário e Fiabilidade do produtor.

A matriz de confusão é uma forma de expressar os resultados de observações lançadas sobre um conjunto de dados por diferentes observadores (Tabela 1). Nas linhas estão representadas as classes de uso do solo do mapeamento que será testado, enquanto nas colunas estão representadas as classes de uso do solo do

mapeamento que será usado como referência. Em sua diagonal principal, é representado o número de concordância entre as classes de acordo com as amostras verificadas ( $X_{ii}$ ). Nas outras células, estão o número de amostras inferidas pelo classificador supervisionado comparado com o determinado pelo mapeamento de referência, expressando então os erros de classificação.

**Tabela 1 – Representação de uma matriz de confusão.**

Classificação supervisionada	Mapeamento de referência			$\sum n_{i+}$
	1	2	c	
1	$X_{11}$	$X_{12}$	$X_{1c}$	$X_{1+}$
2	$X_{21}$	$X_{22}$	$X_{2c}$	$X_{2+}$
c	$X_{c1}$	$X_{c2}$	$X_{cc}$	$X_{c+}$
$\sum n_{+i}$	$X_{+1}$	$X_{+2}$	$X_{+c}$	n

Fonte: Adaptado de Cohen (1960).

A acurácia global  $N$ , corresponde à proporção de *pixels* classificados corretamente em função da área total da bacia hidrográfica (STORY e CONGALTON, 1986), i. e., o produto da soma da diagonal principal ( $X_{ii}$ ) pelo número total de *pixels* da imagem ( $n$ , Equação 3). De forma análoga a acurácia global, é possível calcular a acurácia do usuário ( $Nu$ , Equação 4) e a fiabilidade do produtor ( $Np$ , Equação 5) a partir dos dados da matriz de confusão.

$$N = \frac{\sum_{i=1}^c x_{ii}}{n} \quad \text{Equação 3}$$

$$Nu = \frac{x_{ii}}{n_{i+}} \quad \text{Equação 4}$$

$$Np = \frac{x_{ii}}{n_{+i}} \quad \text{Equação 5}$$

Onde  $n_{+i}$  e  $n_{i+}$  são as somatórias dos valores da coluna e da linha  $i$ , respectivamente.  $Nu$  representa a proporção de *pixels* corretamente classificados em relação a quantidade total de *pixels* dessa classe no mapeamento testado. Dessa forma, é possível identificar a proporção de erros ocorridos por comissão. Se o valor de  $Nu$  se aproxima de 1, significa que todos os *pixels* de determinada classe testada realmente pertencem àquela classe. Ao passo que este valor diminui, mais *pixels* foram indevidamente classificados.

Por outro lado,  $Np$  é a proporção entre o total de *pixels* corretos em relação ao mapeamento de referência. Quanto mais próximo de 1, maior a quantidade de *pixels*

corretamente representados na imagem testada. Conforme este valor diminui, maior é a quantidade de *pixels* que foram omitidos pelo método de classificação testado.

Aplicado ao sensoriamento remoto, o índice de Kappa (COHEN, 1960) expressa a probabilidade de o classificador identificar corretamente um *pixel* sem que tal classificação tenha ocorrido por acaso. Corresponde à razão entre a proporção real de discordâncias entre os mapas e a proporção de discordâncias entre os mapas esperada ao acaso. (Equação 6).

$$K = \frac{n \sum_{i=1}^c x_{ii} - \sum_{i=1}^c x_{i+} x_{+i}}{n^2 - \sum_{i=1}^c x_{i+} x_{+i}} \quad \text{Equação 6}$$

Quanto mais próximo de 1, maior a concordância entre o mapeamento de referência e o produto testado. Se o valor de K for igual a zero, então a concordância se deu puramente ao acaso. Por outro lado, se o seu valor for negativo, então é evidenciada uma discordância que não ocorreu ao acaso.

O índice de Kappa sofreu diversas adaptações ao longo do tempo. Uma delas é o Kappa condicional (*k*; Equação 7; COLEMAN, 1966), que se vale da mesma interpretação que o K, porém o seu cálculo é feito em função das probabilidades marginais específicas de cada classe.

$$k = \frac{Nx_{ii} - x_{i+}x_{+i}}{Nx_{i+} - x_{i+}x_{+i}} \quad \text{Equação 7}$$

Landis e Koch (1977) caracterizaram diferentes intervalos da variação do índice de Kappa, baseados no grau de concordância que eles sugerem (Tabela 2), que foram adotados neste trabalho para a análise dos dados.

**Tabela 2 – Grau de concordância segundo o índice de Kappa.**

Limite inferior	Grau de concordância	Limite superior
< 0,05	Nenhum	0,05
0,05	Muito ruim	0,20
0,20	Ruim	0,40
0,40	Regular	0,55
0,55	Bom	0,70
0,70	Muito bom	0,85
0,85	Excelente	0,99
0,99	Perfeito	1,00

Fonte: Adaptado de Landis e Koch (1977).

## 5 RESULTADOS

### 5.1 Mapeamento das classes de uso da terra

O processo de mapeamento do uso da terra permitiu a quantificação das classes de uso da terra da bacia hidrográfica do Rio Mourão a partir de análise de imagens de alta resolução do ano de 2016, além de evidências coletadas em incursões a campo. O mapa gerado foi tomado como verdade para fins de comparação (Figura 3a).

Além do mapeamento de referência, foram produzidos outros sete mapas através da classificação supervisionada pelo método da distância de Bhattacharya. Dois destes tomam como base a média aritmética do NDVI das datas com cobertura de nuvens inferior a 10% disponíveis para o ano de 2016 (Figura 3b e c), e os outros cinco referem-se ao NDVI específico para cada data, tomadas como base de cálculo dos dois mapas supracitados (Figura 3d até h).

O produto final corresponde a um mapa de referência, que foi a base para aferição da acurácia, dois mapas de NDVI médio, um total e outro parcial, e cinco mapas derivados no NDVI de datas específicas.

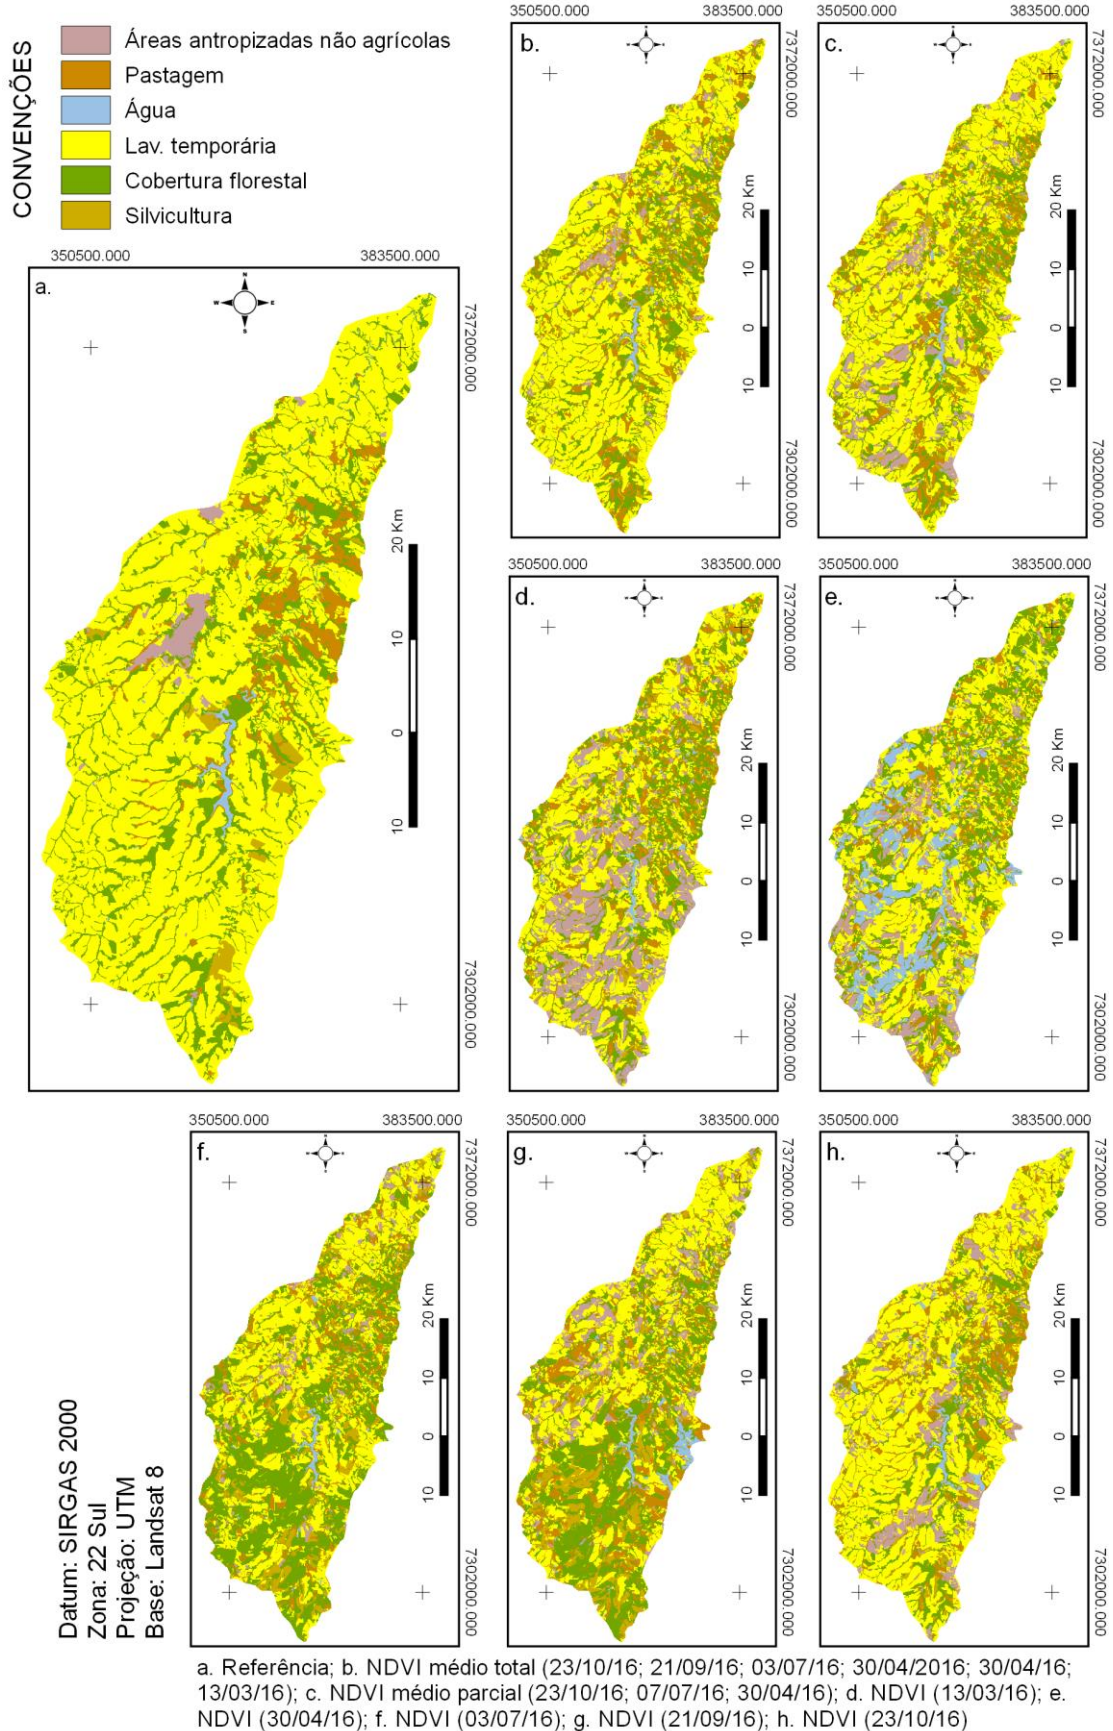
No mapeamento de referência, observa-se que as regiões representadas pela classe Área antropizada não agrícola não são tão bem distribuídas pela bacia hidrográfica quanto as outras classes, pelo contrário, elas tendem a se aglomerar em regiões específicas. Não é difícil concluir que isto ocorre porque esta classe é representada majoritariamente pelos centros urbanos.

O mesmo ocorreu no mapeamento da classe Água, já que esta é representada principalmente pela área referente ao lago formado pela Usina Hidrelétrica Mourão. O espelho d'água tem uma extensão de aproximadamente 10,15 Km<sup>2</sup>, que equivale a 61% da área total da classe identificada no mapeamento de referência.

As áreas florestais ocorrem na região marginal dos cursos d'água, dado a existência de áreas de preservação permanente. Excetuam-se os fragmentos nas áreas de maior declividade, que impedem o avanço da agricultura ou também compõe APP's. As feições mais representativas da classe são as associadas ao Parque Nacional Lago Azul, no centro da área e estudos, e às silviculturas, distribuídas em grandes fragmentos na região central e sul da bacia hidrográfica.



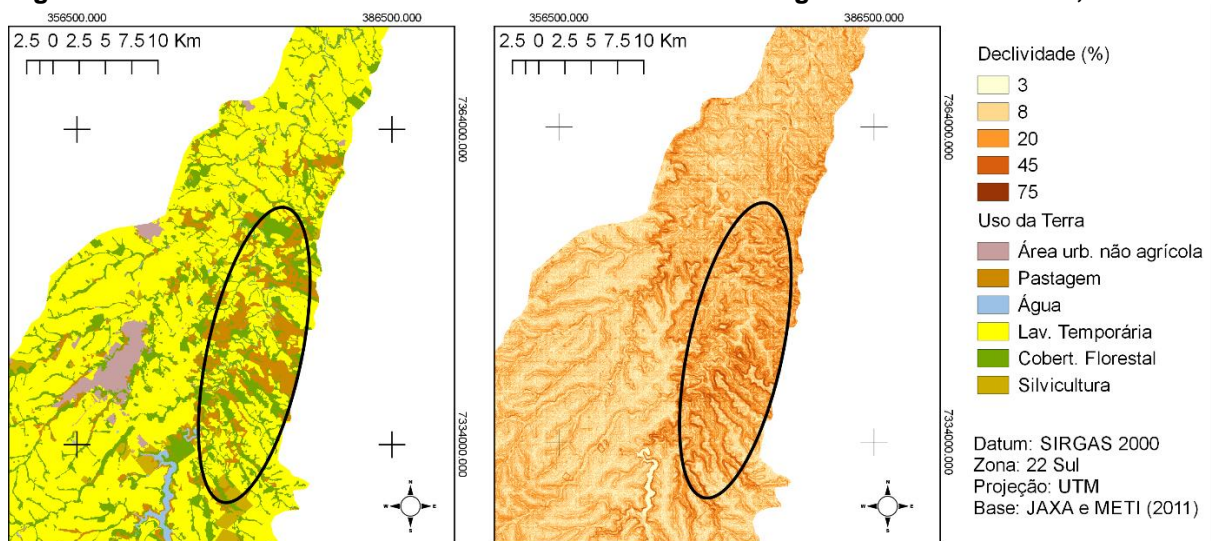
**Figura 3 – Mapas de uso do terra da bacia hidrográfica do Rio Mourão, Paraná, relativos aos diferentes métodos de classificação supervisionada. Nota: Os mapas em tamanho A4 se encontram no Apêndice B.**



**Fonte: Autoria própria.**

As áreas de pasto encontradas ocorrem principalmente na região nordeste e leste da bacia hidrográfica, próximas às regiões onde há uma maior densidade de fragmentos florestais. A presença da classe também está associada às declividades mais altas, assim como fragmentos florestais. (Figura 4). Outras feições menores de pastos e campos sujos foram identificadas também junto às áreas florestais próximas aos cursos d'água.

**Figura 4 - Uso do solo e classes de declividade na bacia hidrográfica do Rio Mourão, Paraná.**



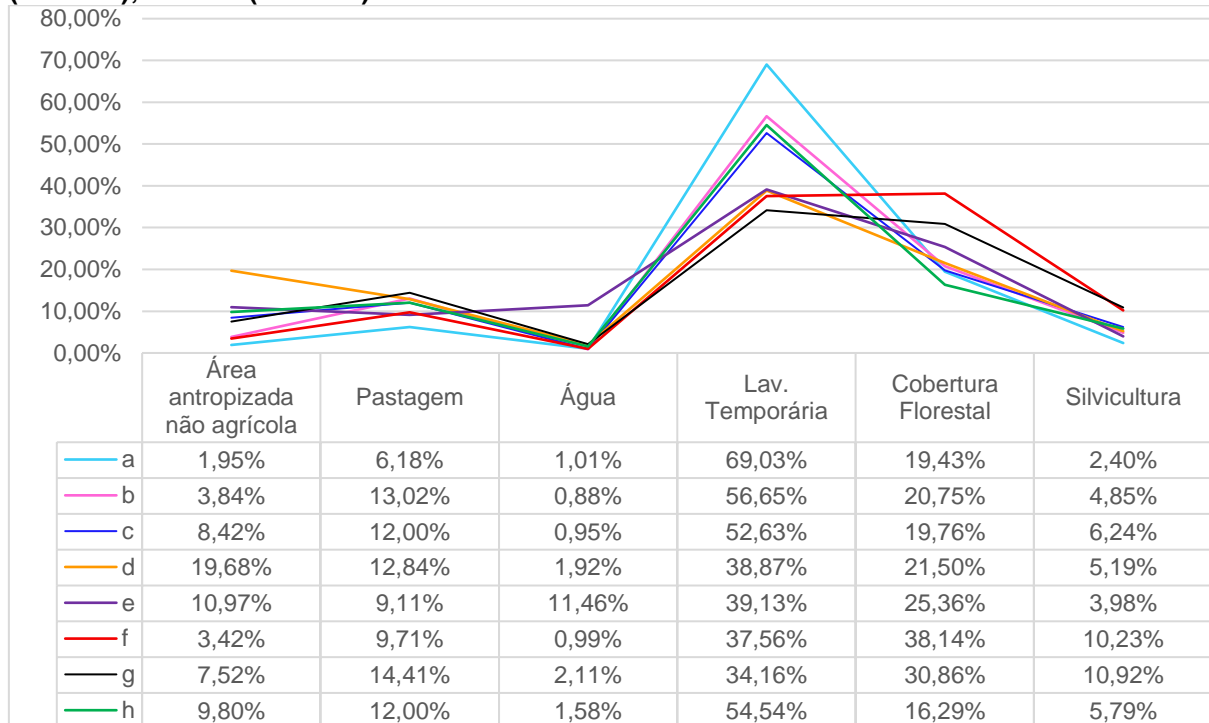
**Fonte: Autoria própria.**

A partir do mapeamento de referência das classes de uso da terra, foi possível determinar a proporção de cada classe relativa a área total da bacia hidrográfica, expressa em porcentagem. Os mapas gerados a partir das classificações supervisionadas do NDVI médio total, NDVI médio parcial e das datas específicas também foram submetidos a este processo, possibilitando então a comparação dessas proporções (Figura 5).

Na distribuição relativa à referência, houve a predominância de lavouras temporárias (69,03%), seguida da classe Florestal (19,43%) e pastagem (6,18%). As demais classes representam apenas 5,36% da área total.

As curvas evidenciam uma concordância da distribuição de classes relativamente boa entre o mapeamento de referência (Figura 5a) e os NDVI médios total e parcial (Figura 5b e c). Destaca-se também o mapeamento relativo à data 23 de outubro (Figura 5h.), com distribuição de frequência de classes também similar à de referência.

**Figura 5 – Proporção das classes de uso da terra na bacia hidrográfica do Rio Mourão, Paraná, relativo aos diferentes métodos de classificação supervisionada. Nota: a. Referência; b. NDVI médio total (23/10/16; 21/09/16; 03/07/16; 30/04/2016; 30/04/16; 13/03/16); c. NDVI médio parcial (23/10/16; 07/07/16; 30/04/16); d. NDVI (13/03/16); e. NDVI (30/04/16); f. NDVI (03/07/16); g. NDVI (21/09/16); h. NDVI (23/10/16).**



Fonte: Autoria própria.

Mesmo sem considerar a proporção de acertos na classificação, é possível observar que as classes com menor frequência tendem a ser superestimadas na classificação supervisionada, como é o caso das classes Área antropizada não agrícola, Pastagem, Silvicultura e Cobertura florestal, exceto a data 23/10/16, enquanto a com maior frequência, i.e., Lavoura temporária, foi subestimada em todos os casos.

A única classe que obteve um comportamento distinto em relação a sua distribuição foi a classe Água, com frequência coincidente em todos os períodos amostrados, salvo a data 30/04/16 (Figura 5e.).

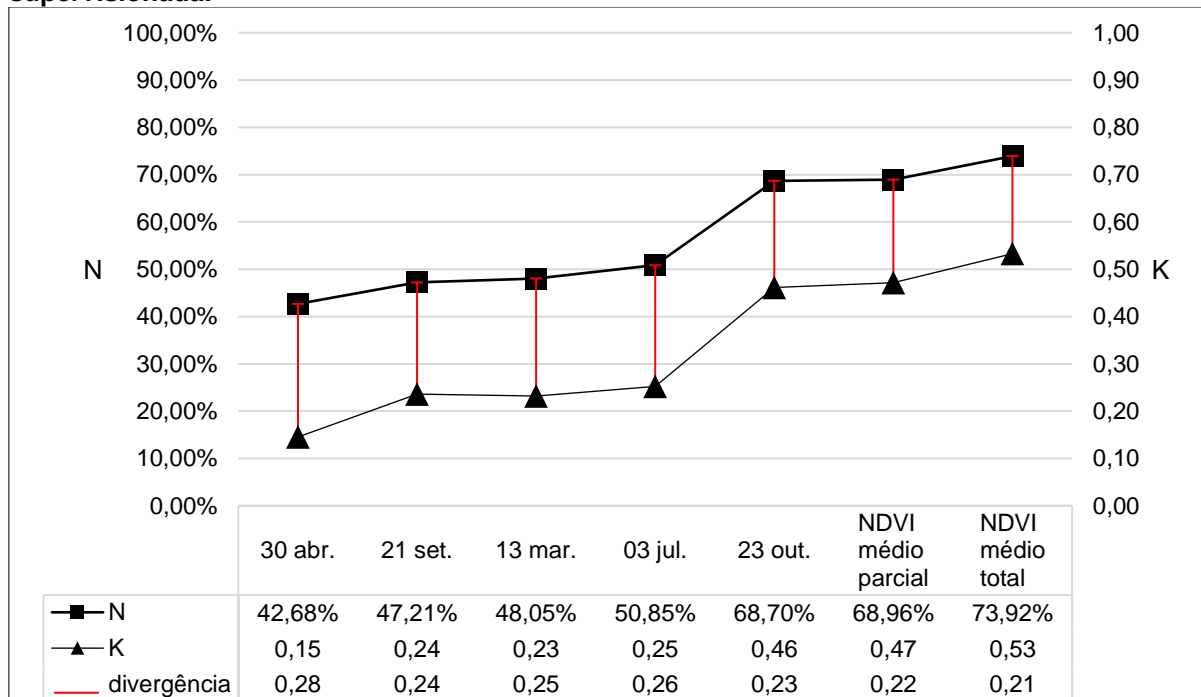
## 5.2 Acurácia dos diferentes métodos de classificação

Com os produtos gerados da classificação supervisionada derivada dos NDVI's médios e das datas específicas, foi possível comparar de forma quantitativa a acurácia dos métodos de classificação, isto é, julgar o quão acurado foi a classificação, com base na porcentagem de acerto (Acurácia global, expressa como N) e o índice de Kappa (K). Os cálculos desses índices se baseiam nos resultados obtidos pelas

matrizes de confusão geradas entre o cruzamento das informações de cada método de classificação (Apêndice A) e o mapa de referência (Apêndice B).

Quando comparada ao mapeamento de referência, a classificação baseada na média de todas as datas disponíveis foi a que obteve o maior valor de N e K, (73,92% e 0,53), seguida da baseada no NDVI médio parcial (68,96% e 0,47) e do NDVI relativo à data 23/10/2016 (68,70% e 0,46) (Figura 6). No entanto, o índice de Kappa apresentou desempenho inferior à acurácia global, o que já seria esperado, tendo em vista que este método leva em consideração os acertos que possam ter ocorrido de forma aleatória.

**Figura 6 – Índice de Kappa (K) e acurácia global (N) dos diferentes produtos da classificação supervisionada.**



**Fonte: Autoria própria.**

O coeficiente de correlação linear de Pearson ( $r$ ) entre os valores de N e K foi de 0,9969, o que indica um alto grau de correlação. O desvio padrão das divergências encontradas entre os indicadores de acurácia dos diferentes métodos de classificação foi de 0,0255.

Deve-se salientar que, enquanto N é simplesmente a proporção de acertos da classificação automática em função do número total de amostras, K é a razão entre a proporção real de discordâncias entre os mapas e a proporção de discordâncias entre os mapas esperada ao acaso, expressando então a proporção de acertos que não tenha sido ao acaso (ROSSITER, 2014). No entanto, os diferentes indicadores de

acurácia se mostraram redundantes, se considerados o valor de  $r$  e do desvio padrão da divergência entre eles.

A qualidade do mapeamento baseada no índice de Kappa depende do intervalo no qual ele está inserido, que pode variar entre -1, para um nível de discordância alto, e 1, para um nível de concordância perfeito. Existe, portanto, a possibilidade de atribuir caráter qualitativo para os mapas gerados a partir dos diferentes métodos de classificação testados (Tabela 3).

**Tabela 3 – Grau de concordância dos diferentes métodos de classificação segundo índice de Kappa.**

<b>NDVI</b>	<b>Kappa</b>	<b>Grau de Concordância</b>
Médio total	0,53	Regular
Médio parcial	0,47	Regular
23 out.	0,46	Regular
03 jul.	0,25	Ruim
13 mar.	0,23	Ruim
21 set.	0,24	Ruim
30 abr.	0,15	Muito Ruim

**Fonte: Autoria própria.**

Observa-se que em termos de grau de concordância, as classificações baseadas no NDVI médio total, NDVI médio parcial e no NDVI de 23/10/16 são classificadas como regular.

As proporções de erro no cálculo do índice de Kappa têm todas o mesmo peso. Isto quer dizer que os erros cometidos na classificação da classe Lavoura Temporária influenciam a variação do valor de K tanto quanto os erros cometidos na classificação da classe Água. Em termos práticos, a utilização do índice K para avaliar a acurácia do mapeamento permitiu inferir sobre o desempenho de cada um dos métodos de forma generalizada, mostrando que o NDVI médio total foi o método que mais se aproximou do mapeamento de referência, porém é necessário a observação da acurácia das classes em específico.

### **5.3 Acurácia das classes segundo diferentes métodos de classificação**

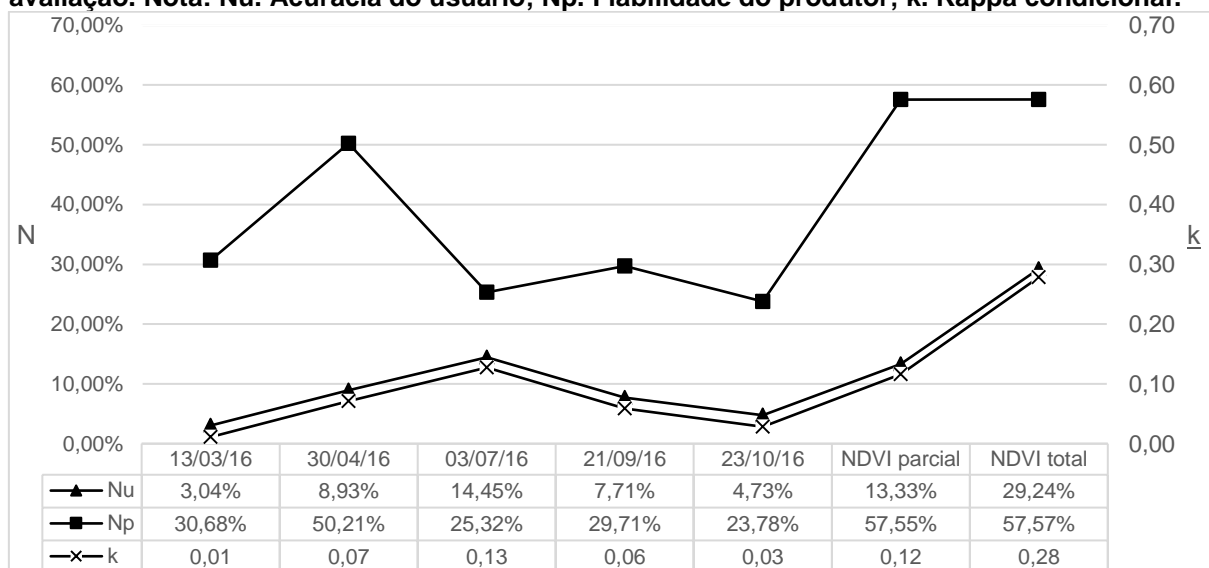
A acurácia global e o índice de Kappa não representam informações relevantes sobre a acurácia de cada classe em específico. Deste modo, optou-se pela análise da acurácia do usuário, da fiabilidade do produtor e do índice de Kappa condicional para proceder com a avaliação dos resultados, de modo a apresentar conclusões sobre a qualidade dos métodos de classificação para as classes específicas.

### 5.3.1 Acurácia da classe Área antropizada não agrícola

Como demonstrado pela distribuição da classe Área antropizada não agrícola, os produtos gerados pela classificação com base nos NDVI's médios foram os que obtiveram melhores resultados na identificação desta classe. A Fiabilidade do produtor destas classificações (Figura 7f. e g.) mostra que cerca de 60% da classe foi corretamente identificada em relação ao mapeamento de referência.

No entanto, deve-se levar em consideração também a quantidade de casos comissos, i. e., *pixels* que foram indevidamente classificados como a classe em questão. Esta proporção de erros de comissão é expressa pela acurácia do usuário, que demonstra que, do total de *pixels* classificados através do NDVI médio total como Área antropizada não agrícola, apenas 29,24% destes realmente correspondem à classe, contra 13,33% do NDVI parcial.

**Figura 7 – Acurácia da classe Área antropizada não agrícola segundo diferentes métodos de avaliação. Nota: Nu. Acurácia do usuário; Np. Fiabilidade do produtor; k. Kappa condicional.**




Fonte: Autoria própria.

A diferença entre os erros de comissão, expressos por Nu, e dos erros de omissão, expressos por Np, influenciam o valor do Kappa condicionado ao mapeamento do usuário, de forma que o valor em si expressa a probabilidade de um *pixel* da classe em específico ter sido corretamente classificado, levando em consideração a chance de o acerto ter sido ao acaso, de forma análoga ao Kappa apresentado anteriormente a toda a classificação.

### 5.3.2 Acurácia da classe Pastagem

Assim como a classe anterior, nenhum método de classificação obteve resultados relevantes (Figura 8). De modo relativo, há uma distinção entre a classificação baseada no NDVI da data 23/10/16 e os outros métodos, porém o seu Kappa condicional não é alto o suficiente para demonstrar resultados expressivos. Isto ocorre pois mesmo que 45% do total de *pixels* do mapeamento de referência tenha sido identificado, 80% dos *pixels* presentes no produto gerado representam erros de comissão, tornando a probabilidade de classificação por acaso muito elevada, representada pelo valor de k inexpressivo (0,18).

**Figura 8 – Acurácia da classe Pastagem segundo diferentes métodos de avaliação. Nota: Nu. Acurácia do usuário; Np. Fiabilidade do produtor; k. Kappa condicional.**



Fonte: Autoria própria.

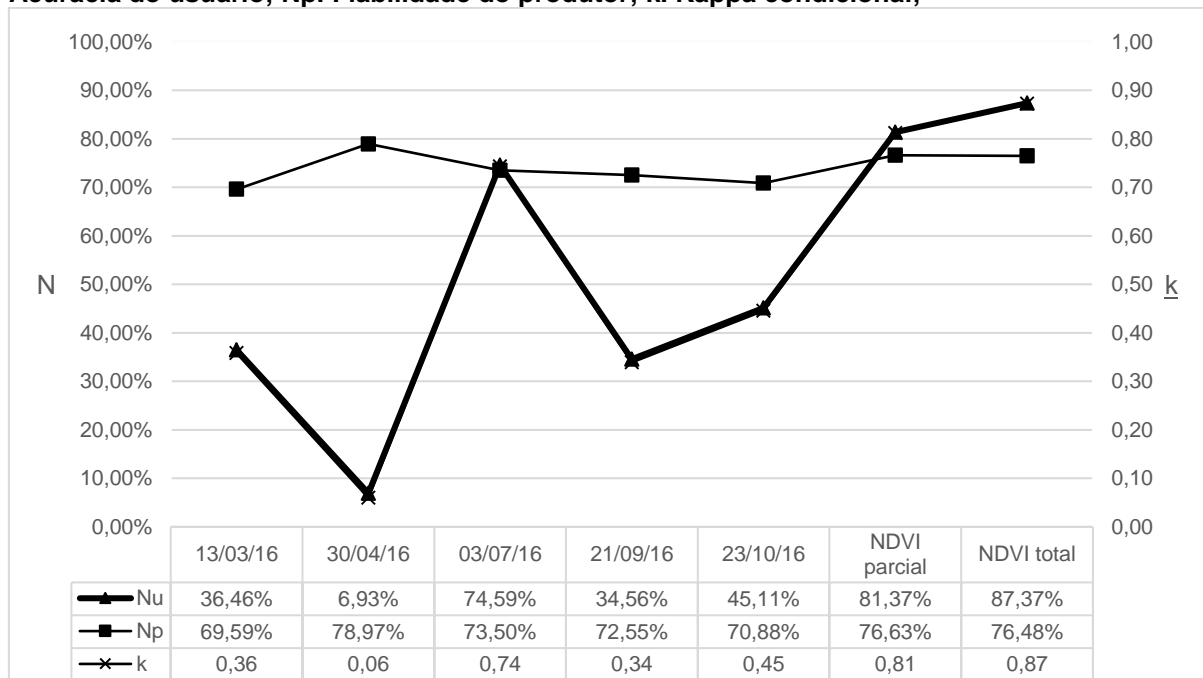
Apesar de as classificações baseadas nos NDVI's médios não terem tido um bom desempenho nesta classe, ambas obtiveram uma proporção similar de erros de comissão, omissão e Kappa condicional, indicando que a identificação desta classe nos diferentes métodos foi afetada pela mesma disfunção de classificação.

Para os outros métodos baseados em datas específicas, não foi identificado o mesmo comportamento, permitindo inferir que os erros de classificação são específicos de cada imagem.

### 5.3.3 Acurácia da classe Água

A classe Água obteve desempenho substancialmente superior as outras duas apresentadas. Todos os métodos de classificação obtiveram bons resultados se considerado as proporções de cada Np isolado (Figura 9). Este comportamento demonstra que em todos os casos, houve a identificação de 69,59% a 78,97% das feições desta classe. Todavia, deve-se atentar para o fato de que na maioria das datas específicas ocorreram muitos erros de comissão, resultando em valores baixos de Nu e, conseqüentemente, na superestimação da área total da classe água.

**Figura 9 - Acurácia da classe Água segundo diferentes métodos de avaliação. Nota: Nu. Acurácia do usuário; Np. Fiabilidade do produtor; k. Kappa condicional;**



Fonte: Autoria própria.

Tendo isto em vista, os NDVI's médios se mostraram superiores aos demais, com proporção de erros de omissões e comissões de aproximadamente 23% e 12%, respectivamente. Estas proporções resultam em valores de k de 0,81 para o NDVI médio parcial e 0,87 para o NDVI médio total, ou seja, há baixa probabilidade de que a concordância entre as classificações e a referência foi ocasionada por acaso.


Destaca-se também a classificação baseada na data 03/07/16, com altos valores de Nu, Np e k (74,59, 73,50 e 0,74).



### 5.3.4 Acurácia da classe Lavoura Temporária

Os métodos de classificação propostos apresentaram resultados visivelmente positivos para esta classe. O NDVI médio total é o mais significativo, com valores de Nu e Np de 96,63% e 79,30% (Figura 10), resultando em um k de 0,89, também superior a todos os outros observados. O NDVI parcial e o NDVI da data 23/10/16 também obtiveram um bom desempenho, demonstrando que, nestes três casos, poucas feições foram omitidas da classificação e menos ainda foram classificadas de forma equivocada.

**Figura 10 – Acurácia da classe Lav. Temporária segundo diferentes métodos de avaliação.**  
**Nota: Nu. Acurácia do usuário; Np. Fiabilidade do produtor; k. Kappa condicional;**



Fonte: Autoria própria.

Apenas a classificação do NDVI da data 30/04/16 apresentou valor de k inferior a 0,5, resultado do seu número elevado de omissão de *pixels*. A queda abrupta do valor de k ocorre devido a proporção da classe Lav. Temporária. Quanto mais representativa é a classe, maior serão os efeitos do ajuste proposto pelo índice de Kappa condicional, fator que atribui um peso maior para relação omissão-comissão (ROSSITER, 2014).

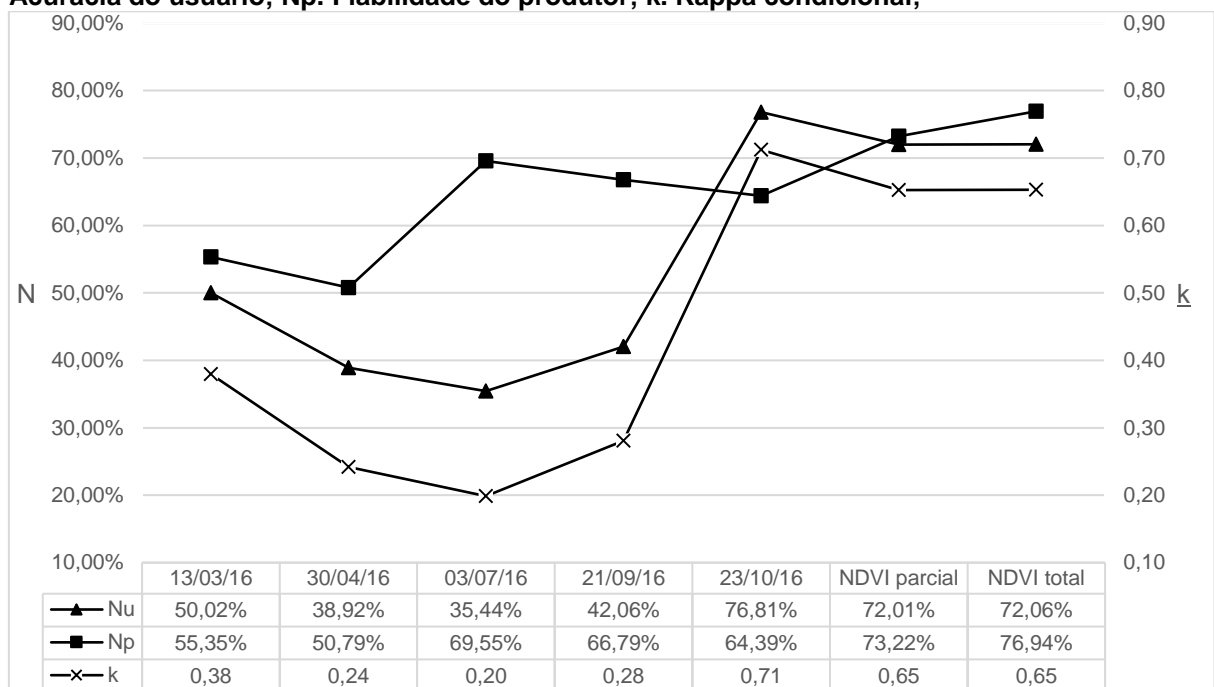
A classe compõe 69,03% da área total da bacia hidrográfica, portanto é a maior responsável pela definição da acurácia global e do nível de concordância de Kappa.

### 5.3.5 Acurácia da classe Cobertura Florestal

Os desempenhos mais significativos quanto aos valores Nu foram dos dois NDVI's médios e o NDVI da data 23/10/16 (Figura 11). Nestes casos, a proporção de *pixels* classificados como área florestal e os que realmente pertencem a esta classe se manteve acima de 70%. Nos casos dos NDVI's médios, os valores de Np são menos significativos, porém se mantêm em uma faixa aceitável de concordância.

A data 23/10/16 tem valor de Np superior a todos os outros, o que indica que houve uma menor omissão de *pixels* em relação ao mapeamento de referência. Como consequência, o valor de k para esta data se manteve acima dos outros dois métodos, apesar da pouca diferença.

**Figura 11 - Acurácia da classe Florestal segundo diferentes métodos de avaliação. Nota: Nu. Acurácia do usuário; Np. Fiabilidade do produtor; k. Kappa condicional;**



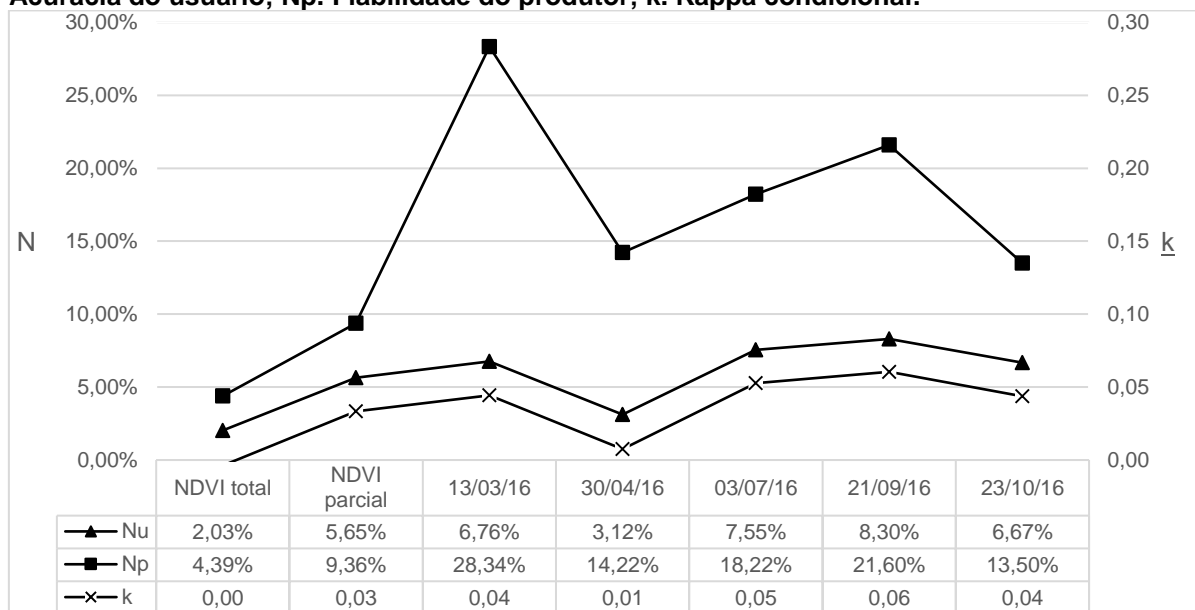
Fonte: Autoria própria.

As datas isoladas obtiveram um desempenho relevante na identificação das áreas florestais relativas à referência, no entanto apresentam valores de Np baixos, o que torna a eficiência questionável, já que uma quantidade significativa de *pixels* foi acometida por erros de comissão, tornando a classificação dessas áreas mais propensa a ter ocorrido pelo acaso. Isto se reflete nos valores inferiores de k, sempre inferiores a 0,4 nestes métodos.

### 5.3.6 Acurácia da classe Silvicultura

A classe Silvicultura não obteve um bom desempenho em nenhum dos métodos utilizados para a classificação do uso da terra. Os valores de Nu e Np indicam a ocorrência de muitos erros de omissão e de comissão, i. e., os métodos não conseguiram identificar as áreas correspondentes à classe, e os *pixels* que foram identificados como silviculturas, não representam tal classe na referência (Figura 12).

**Figura 12 - Acurácia da classe Silvicultura segundo diferentes métodos de avaliação. Nota: Nu. Acurácia do usuário; Np. Fiabilidade do produtor; k. Kappa condicional.**



Fonte: Autoria própria.

Os valores do índice k, muito próximos a zero, demonstram que os *pixels* identificados como silviculturas ocorrem puramente ao acaso. Já os valores de Np das datas 30/07/16 e 23/10/16, demonstram que, nestes casos, houveram proporções maiores de acertos relativos ao mapeamento de referência, porém não muito significativas.

### 5.3.7 Classificação dos níveis de concordância do índice de Kappa condicional

Da mesma forma que foi apresentado para os níveis de concordância a partir do índice de Kappa aplicado a toda a matriz de confusão, a classificação do desempenho do mapeamento pode ser utilizada para distinguir o nível de concordância entre cada classe nos diferentes mapeamentos, a partir do índice de Kappa condicionado ao mapeamento feito pelo usuário (Figura 13).

**Figura 13 - Grau de concordância dos diferentes métodos de classificação segundo o índice de Kappa condicional. Nota: (-)  $k < 0,05$ .**

Método de classificação	Classe					
	Área antrop.	Pastagem	Água	Lav. Temporária	Cobert. Florestal	Silvic.
13/03/16	-	Muito Ruim	Ruim	Bom	Ruim	-
30/04/16	Muito ruim	Muito Ruim	Muito Ruim	Ruim	Ruim	-
03/07/16	Muito ruim	Muito ruim	Muito bom	Bom	Ruim	-
21/09/16	Muito ruim	Muito ruim	Ruim	Muito bom	Ruim	-
23/10/16	-	Muito ruim	Regular	Muito bom	Muito bom	Muito ruim
NDVI Total	Muito ruim	Muito Ruim	Muito bom	Excelente	Bom	-
NDVI Parcial	Ruim	Ruim	Excelente	Excelente	Bom	-

**Fonte: Autoria própria.**

Os melhores resultados foram obtidos pela classificação baseada no NDVI médio gerado a partir de todas as imagens disponíveis de boa qualidade. Deste método, as classes Área antropizada não agrícola e Pastagem não obtiveram um bom desempenho, porém, comparado aos outros métodos, obteve valor de k superior. As classes Água e Lav. Temporária apresentaram níveis excepcionais de concordância. A classe Cobertura Florestal também obteve desempenho satisfatório, embora inferior as anteriores.

A única classe que não obteve valor significativo de k é a Silvicultura. O valor tão próximo a zero indica que as áreas classificadas por este método como áreas de silviculturas foram classificadas como tal simplesmente ao acaso.

As classificações baseadas em NDVI's de datas isoladas não apresentaram bons resultados, visto que apenas a classe Lav. Temporária foi classificada de modo satisfatório pela maioria destes métodos. O produto da classificação baseada na data 23/10/16 foi o único que apresentou resultados significativos, com apenas as classes Cobertura florestal e Silvicultura superiores, sendo que esta última apenas se destaca por apresentar um valor de k minimamente superior aos demais.

## 6 DISCUSSÃO

### 6.1 Sazonalidades no índice de vegetação pela diferença normalizada

Os resultados obtidos entre a comparação dos mapas gerados a partir dos NDVI's de datas distribuídas ao longo do ano de 2016 e o mapa de referência de uso da terra evidenciam a inconstância do NDVI quando submetido aos efeitos sazonais relacionados a diferentes processos naturais e antrópicos. Os índices utilizados para avaliar o grau de concordância entre estes mapeamentos (K, N, k, Nu e Np) demonstram que, em alguns casos, existem problemas comuns a todos os mapas, e, em outros, os erros de classificação devem ser explicados por fenômenos específicos de cada data.

Por exemplo, no mapeamento baseado no NDVI da data 13/03/16, diversas feições de lavouras temporárias foram confundidas pelo classificador como Área antropizada não agrícola (27,32%). Alguns autores já constataram que áreas urbanas apresentam valores de NDVI próximos aos dos solos em diferentes proporções de exposição (e. g. DEMARCHI, PIROLI e ZIMBACK, 2011), o que torna a distinção entre essas classes problemática.

As áreas urbanas, principais representantes da classe Área antropizada não agrícola, apresentam uma grande amplitude de NDVI, ocasionada pela complexidade dos alvos que ocorrem nestes espaços (JENSEN, 2009). Em uma área de 90 m<sup>2</sup> dentro de um perímetro urbano, que corresponde à resolução espacial do sensor OLI, espera-se a presença de córregos, áreas impermeabilizadas por materiais distintos, asfalto, árvores, automóveis, além da ausência de um padrão de dispersão desses elementos da paisagem urbana, que pudesse caracterizar uma faixa de NDVI adequada para classe.

Ainda na data 13/03/16, a exposição parcial do solo é causada pelas colheitas de culturas temporárias que atingiram o estágio final de seu ciclo fenológico. No caso da soja, principal cultivo da região, este período equivale aos meses de janeiro até março, já que o plantio é feito em meados de outubro e o grão leva cerca de 150 dias para maturar e ser colhido (CONAB, 2017).

A prática mais comum na região é o plantio direto, que consiste na introdução da próxima cultura logo após a colheita da anterior. Dessa forma, os meses de fevereiro a março são caracterizados pela presença de culturas de milho e soja em

diferentes estágios de seu ciclo fenológico, com sojas dessecadas, sojas colhidas, solo coberto pela palha da soja e milho em desenvolvimento (CRUZ et al., 2006).

Com a presença simultânea desses elementos, ocorre uma variação muito grande nos valores de NDVI dos *pixels* que deveriam ser classificados como Lavoura temporária. A diferença nos valores de NDVI durante o desenvolvimento dessas culturas é tão significativa, que a própria produção média de grãos é estimada a partir dessa variação (CONAB, 2017). Csillik e Belgiu, (2017) também exploraram essa variação, utilizando-a para caracterizar diferentes tipos de culturas agrícolas a partir do comportamento do NDVI e do NDWI.

Nos mapas das datas 03/07/16 e 21/09/16, os erros de comissão ilustram bem a premissa deste trabalho. Em ambos os casos, cerca de 20% das áreas que deveriam ter sido classificadas como lavoura temporária, foram classificadas como cobertura florestal. É justamente neste período que o milho começa a sua fase de maturação, já que após o plantio, ele leva cerca de 120 dias para amadurecer e ser colhido (RITCHIE, HANWAY e BENSON, 2003).

As áreas que foram erroneamente classificadas como Cobertura florestal nas datas 03/07/16 e 21/09/16 coincidem. Isto mostra que, cerca de 90 dias após o plantio, o milho já apresentava valores de NDVI substancialmente elevados, podendo ser confundido com coberturas florestais. Viña et al. (2004), além de demonstrarem o comportamento espectral do NDVI de culturas de *Zea mays L.*, que pode variar entre 0,2 e 0,98 no decorrer de seus ciclos, também identificaram um período no qual o NDVI do milho interrompe a sua ascensão e se mantém estável por determinado período, o que resulta na equiparação identificada entre as datas 03/07/16 e 21/09/16.

O milho, diferente da soja, pode ser colhido em diversos estágios, a depender do produto que será vendido. A escolha do momento da colheita depende exclusivamente do agricultor, que pode considerar oscilações no preço do mercado, planejamento prévio da safra, ou regras heurísticas de manejo (JENSEN, 2009). Isto torna ainda mais severa a variância dos valores de NDVI nessas áreas.

A data que obteve o melhor desempenho foi a de 23/10/16. Os seus valores de *k* foram bastante próximos aos dos NDVI's médios, principalmente nas classes Cobertura florestal (0,71) e Lav. Temporária (0,84). Ocorre que, no ano de 2015, a Agência de Defesa da Agropecuária do Paraná decretou que o período de semeadura deveria ser compreendido entre os dias 16 de setembro e 31 de dezembro, não podendo haver plantas ainda não colhidas ou dessecadas após o dia 15 de maio. Este

procedimento é intitulado vazio sanitário, uma medida criada para conter o desenvolvimento do fungo *Phakopsora pachyrhizi* (PARANÁ, 2015). O mapa do NDVI da data 23/10/2016 se encontra justamente na fase de semeadura da soja da safra de 2016/2017, fator que certamente contribuiu para uma variância menor do NDVI de áreas agrícolas, permitindo o estabelecimento de um intervalo de classificação menos abrangente e, por isso, menos suscetível a ser confundido com outras classes.

## 6.2 Índice de Vegetação pela Diferença Normalizada médio

Os resultados demonstraram que a utilização do NDVI médio total para a classificação supervisionada através da distância de Bhattacharya é um método eficiente para a identificação de lavouras temporárias ( $k=0,89$ ), coberturas florestais ( $k=0,65$ ) e água ( $k=0,87$ ), se comparado à utilização de NDVI's de datas isoladas. O NDVI médio parcial também apresentou resultados semelhantes, com valores de  $K$  (0,46) e  $k$  para as classes supracitadas pouco inferiores ao NDVI total (0,86, 0,65 e 0,81).

A classe Florestal do NDVI médio total apresentou erros de comissão mais significativos do que de omissão, sendo que estes erros são representados principalmente pela classe Pastagem (12%) e Silvicultura (9%). Wagtendonk e Root (2003), reportaram representantes de espécies perenes com NDVI variando entre 0,5 e 1, valores também encontrados por outros autores em diferentes florestas decíduas e semidecíduas (BHAVSAR, KUMAR e ROY, 2017), o que dificulta a identificação dessas áreas pelo método proposto.

Dahigamuwa, Qiuyane e Gunaratne (2016) também testaram a acurácia de classificadores supervisionados, porém a partir dos sensores TM e AVHRR. Apesar de apresentarem uma acurácia global razoável, os métodos não obtiveram um desempenho tão bom quanto o método do NDVI médio na identificação de áreas agrícolas e água, mesmo considerando as variações do índice ao longo do ano.

Outras metodologias foram testadas especificamente para a detecção de áreas de cultivo agrícola, também baseadas em índices de vegetação, porém com resoluções espaciais variadas. Os índices de Kappa obtidos variam de 0,29 a 0,95, sendo mais significativos conforme o aumento da resolução temporal disponível (VALERO et al., 2016), fenômeno similar ao observado entre os NDVI's médios parcial e total adotados neste trabalho.

O método do NDVI médio também se destaca pela baixa demanda de recursos computacionais para sua execução diferente de outros trabalhos como o de Epiphonio et al. (2010) e Victoria et al. (2012), que utilizam metodologias também baseadas em séries temporais de sensores orbitais, porém destacam a necessidade de avaliar individualmente os produtos das séries e de dispor de máquinas com alta capacidade de processamento.

O NDVI também foi utilizado para diferenciar culturas agrícolas, como trigo, arroz, girassol e milho (CSILLIK e BELGIU, 2017). Neste caso, o método apresentado pelo autor se beneficia da maior frequência de visitaç o do Sentinel-2 e de sua resoluç o espacial, que permitem caracterizar as diferentes culturas a partir da variaç o do NDVI m dio no decorrer de seus ciclos fenol gicos e capturar mais detalhes em *pixels* onde h  a mistura de objetos (ALSHEHRI, 2017).

O m todo do NDVI m dio tamb m obteve melhor desempenho em funç o da maior disponibilidade de imagens, por m foram observadas limitaç es em relaç o   resoluç o temporal do sensor. Brow et al. (2006) apresentam um estudo do NDVI derivado de diferentes sensores orbitais em s ries temporais longas, no qual foi constatado a consist ncia significativa do  ndice, especialmente para regi es tropicais onde n o h  a incid ncia de fatores que possam causar anomalias e ru dos nas imagens, como neve e gelo associadas   superf cie ou   atmosfera.

Estas evid ncias indicam que NDVI's derivados de diferentes sensores podem ser utilizados em conjunto, ou ainda formar uma base de  ndices parametrizados, para ent o suprir lacunas nas s ries temporais de certos sensores, como   o caso do Landsat-8, que em 2016 disp e de apenas cinco produtos com porcentagem de nuvens obstrutoras da superf cie terrestre inferior a 10% para as cenas amostradas.



## 7 CONCLUSÃO

O mapeamento do uso da terra através de classificadores supervisionados ainda é um desafio, pois busca representar graficamente variáveis que são mutáveis e não podem ser integralmente representadas em apenas um momento do tempo. Na bacia hidrográfica do Rio Mourão, este problema é evidenciado principalmente pela presença majoritária de lavouras temporárias e pelo método de cultivo atualmente empregado. Das datas analisadas, o mês de outubro foi o que obteve o melhor desempenho, porém depende da disponibilidade de imagens livres de nuvens.

Através da utilização do NDVI médio para a classificação supervisionada pelo método da distância Bhattacharya, foi possível diferenciar com eficácia as áreas de lavouras temporárias, água e coberturas florestais, com coeficientes de kappa condicionais que variam de bom a excelente. O método não consegue distinguir bem áreas de silviculturas, pastagens e coberturas florestais, que é um problema ainda comum na literatura, porém os resultados sugerem que o desempenho do classificador é melhor à medida que mais imagens são integradas ao cálculo, o que pode ser alcançado com a utilização de produtos de outros sensores.

A aplicação do método deve ser considerada para áreas onde deseja-se identificar as áreas de lavoura temporária e coberturas florestais, diminuindo o tempo despendido para as análises de datas individuais e reduzindo consideravelmente o tempo e esforço necessários para a geração desses produtos.

## REFERÊNCIAS

- ALSHEHRI, Mushabab. **The Effect of Spatial Resolution on Classification Accuracy of Marine and Coastal Areas**. 2010. Disponível em: <<https://www.geospatialworld.net/article/the-effect-of-spatial-resolution-on-classification-accuracy-of-marine-and-coastal-areas/>>. Acesso em: 10 nov. 2017.
- BANNARI, A; MORIN, D; BONN, F; HUETE, A. R. A Review of Vegetation Indices. **Remote Sensing Reviews**, v. 13, n. 1-2, p. 95-120, 1995.
- BENEDETTI, A. C. P.; PEREIRA, R. S.; ALMEIDA, C. D. V; HENDGES, E. R.; LIPPERT, D. B.; Índice de Vegetação por Diferença Normalizada (NDVI) do sensor Modis: aplicações para estudos de uso e cobertura da terra na Metade Sul do Rio Grande do Sul. In: **Simpósio Brasileiro de Sensoriamento Remoto**, 15, p.6.144, Curitiba, PR, 2011.
- BHAVSAR, Dhruval; KUMAR, Anil; ROY, Arijit. Applicability of NDVI temporal database for western Himalaya forest mapping using Fuzzy-based PCM classifier. **European Journal Of Remote Sensing**, [s.l.], v. 50, n. 1, p.614-624, jan. 2017. Informa UK Limited.
- BROWN, M. E.; PINZÓN, J. E.; DIDAN, K.; MORISETTE, J. T.; TUCKER, C. J. Evaluation of the consistency of long-term NDVI time series derived from AVHRR, SPOT-vegetation, SeaWiFS, MODIS, and Landsat ETM+ sensors. **IEEE Transactions on Geoscience and Remote Sensing**, v. 44, n. 7, p. 1787-1793, 2006.
- COHEN, Jacob. A coefficient of agreement for nominal scales. **Educational and psychological measurement**, v. 20, n. 1, p. 37-46, 1960.
- COLEMAN, J. S. Measuring Concordance in attitudes, unpublished manual script. Department of Social Relations, Johns Hopkins University, 1966
- CONAB, Companhia Nacional de Abastecimento. Acompanhamento da Safra Brasileira: Grãos. Observatório agrícola, v. 4, n. 12, 2017.
- CRUZ, J. C.; PEREIRA FILHO, I. A.; ALVARENGA, R. C.; GONTIJO NETO, M. M.; VIANA, J. H. M.; OLIVEIRA, M. F.; SANTANA, D. P. Manejo da cultura do milho. **Embrapa Milho e Sorgo - Circular Técnica**. Circular Técnica, 87, v1, 2006.
- CSILLIK, Ovidiu; BELGIU, Mariana. Cropland mapping from Sentinel-2 time series data using object-based image analysis. **AGILE**. Wageningen, May 9-12, 2017.
- DAHIGAMUWA, Thilanki; YU, Qiuyan; GUNARATNE, Manjriker. Feasibility study of land cover classification based on normalized difference vegetation index for landslide risk assessment. **Geosciences**, v. 6, n. 4, p. 45, 2016.
- DELON, C; MOUGIN, E; SERÇA, D; GRIPPA, M; HIERNAUX, P; DIAWARA, M; GALY-LACAUX, C; KERGOAT, L. Modelling the effect of soil moisture and organic

matter degradation on biogenic NO emissions from soils in Sahel rangeland (MALI). **Biogeosciences**, v. 12, p. 325 – 3272, 2015.

DEMARCHI, Julio C.; PIROLI, Edson L.; ZIMBACK, Célia R. L. Análise temporal do uso do solo e comparação entre os índices de vegetação NDVI e SAVI no município de Santa Cruz do Rio Pardo–SP usando imagens LANDSAT-5. **Raega**, v. 21, p. 234-271, 2011.

EPIPHANIO, R. Dalla V.; FORMAGGIO, A.R.; RUDORFF, B.F.T.; MAEDA, E.E.; LUIZ, A.J.B. Estimating soybean crop areas using spectral-temporal surfaces derived from MODIS images in Mato Grosso, Brazil. *Pesquisa Agropecuária Brasileira*, v.45, p.72-80, 2010.

FARABEE, M. J. **Photosynthesis**. 2001. Disponível em: <<http://www2.estrellamountain.edu/faculty/farabee/biobk/BioBookPS.html>> Acesso em: 17 mai. 2017.

GANDHI, G; PARTHIBAN, S; NAGARAJ, T; CHRISTY, A. **Ndvi: Vegetation change detection using remote sensing and gis – A case study of Vellore District**. 3rd International Conference on Recent Trends in Computing, 2015.

HUETE, A.R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v.25, p.295-308, 1988.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente: Uma Perspectiva em Recursos Terrestres**. Tradução da Segunda Edição. São José dos Campos, SP: Parêntese editora, 2009.

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

LIMA, G. C.; SILVA, M. L. N; CURI, N.; SILVA, M. A. da S.; OLIVEIRA, A. H.; AVANZI, J. C.; UMUUS, M. E. Avaliação da cobertura vegetal pelo índice de vegetação por diferença normalizada (IVDN). **Revista Ambiente & Água**. vol. 8, n.2, p. 204 – 214, 2013.

LUMBIERRES, M; MÉNDEZ, P. F; BUSTAMANTE, J; SORIGUER, R; SANTAMARÍA, L. Modeling Biomass Production in Seasonal Wetlands Using MODIS NDVI Land Surface Phenology. **Remote sensing**, v. 9, n. 392, p. 1-18, 2017.

MICROSOFT. Bing Maps. Version 2017. Rio mourão, 2016, z. 19x. Disponível em: <<https://www.bing.com/maps>>. Acesso em: Julho de 2016.

NOLESINI, T; FRODELLA, W; BIANCHINI, S; CASAGLI, N. Detecting Slope and Urban Potential Unstable Areas by Means of Multi-Platform Remote Sensing Techniques: The Voltera (Italy) Case Study. **Remote Sensing**, v. 8, n. 746, p.1-18, 2016.

PARANÁ, Portaria nº 193, de 6 de outubro de 2015. Estabelece o período de semeadura e colheita de soja no Estado do Paraná e dá outras providências. **Agência de Defesa Agropecuária do Paraná (ADAPAR)**, 06 de outubro de 2015.

PELLETIER, C; VALERO, S; INGLADA, J; CHAMPION, N; SICRE, C. M; DEDIEU, G. Effect os Training Class Label Noise on Classification Performances for Land Cover Mapping with Satellite Image Time Series. **Remote Sensing**, v. 9, n.173, p.1-24, 2017.

QAMER, F. M; SHEHZAD, K; ABBAS, S; MURTY, M. S. R; XI, C; GILANI, H; BAJRACHARYA, B. Mapping Deforestation and Forest Degradation Patterns in Western Himalaya, Pakistan. **Remote Sensing**, v. 8, n. 385, p.1-17, 2016.

RITCHIE, Steven W.; HANWAY, John J.; BENSON, Garren O. Como a planta de milho se desenvolve. **Informações agronômicas**, v. 103, p. 1-19, 2003.

ROSSITER, D. G. Technical Note: Statistical methods for accuracy assesment of classified thematic maps. Enschede, the Netherlands. 2004.

ROUSE J. W; HAAS R. H; SCHELL J. A; DEERING D.W. **Monitoring vegetation systems in the great plains with ERTS**. In: Third ERTS Symposium, NASA SP-351 I, p. 309-317, 1973.

SILVA, L. C. de A.; GRZEGOZEWSKI, D. M.; JOHANN, J. A; PALOSCHI, R. A; JUNIOR, C. C. Estimativa da área plantada com soja e milho, safra 2014/2014, no Oeste paranaense utilizando um mapa de alvos permanentes. In: **Simpósio Brasileiro de Sensoriamento Remoto**, 17, João Pessoa, PB, p. 4270-4277, 2015.

SOBRINHO, A. F. S; ALVES, M. de C. **Sensoriamento Remoto Multiespectral da Soja (Flycine Max L.) e sua Relação com a Produtividade de Sementes em Mato Grosso**. In: Simpósio Brasileiro de Ciências Geodésicas e Tecnologias da Geoinformação, 4, p.1-9, Recife, PE, 2012.

SOUZA, I. de M. **Sensoriamento Remoto Orbital Aplicado a Estudos Urbanos**. Instituto Nacional de Pesquisas Espaciais. São José dos Campos, 2012.

STORY, M.; CONGALTON, R. G. Accuracy assessment: A user's perspective. *Photogrammetric Engineering and Remote Sensing*, v.52, p.397-399. 1986.

UNITED STATES GEOLOGICAL SURVEY (USGS). Landsat-8 Images. Path: 223. Row: 76, 77. Disponível em: <<http://landsat.usgs.gov/>> Acesso em: Março de 2017.

VAIPHASA, C; PIAMDUAYTHAM, S; VAIPHASA, T; SKIDMORE, A. K. A normalized Difference Vegetation Index (NDVI) Time-Series of Idle Agriculture Lands: A Preliminar Study. **Engineering Journal**, v. 15, n. 1, 2011.

VALERO, S.; MORIN, D.; INGLADA, J.; SEPULCRE, G.; ARIAS, M.; HAGOLLE, O.; KOETZ, B. Production of a dynamic cropland mask by processing remote sensing image series at high temporal and spatial resolutions. **Remote Sensing**, v. 8, n. 1, p. 55, 2016.

VICENTE, L. E; GOMES, D; VICTORIA, D. de C; GARÇON, E. A. M; BOLFE, É. L; ANDRADE, R. G; SILVA, G. B. S. da. Séries temporais de NDVI do sensor SPOT Vegetaion e algoritmo SAM aplicados ao mapeamento de cana-de-açúcar. **Pesquisa Agropecuária Brasileira online**, EMBRAPA, v. 47, n. 9, p. 1337-1345, set. 2012.

VICTORIA, Daniel de Castro et al. Cropland area estimates using Modis NDVI time series in the state of Mato Grosso, Brazil. **Pesquisa Agropecuária Brasileira**, [s.l.], v. 47, n. 9, p.1270-1278, set. 2012. FapUNIFESP (SciELO).

VINA, A.; GITELSON, A. A.; RUNDQUIST, D. C.; KEYDAN, G.; LEAVITT, B.; SCHEPERS, J. Monitoring maize (L.) phenology with remote sensing. **Agronomy Journal**, v. 96, n. 4, p. 1139-1147, 2004.

WAGTENDONK, J. W. Van; ROOT, R. R. Root. The use of multi-temporal Landsat Normalized Difference Vegetation Index (NDVI) data for mapping fuel models in Yosemite National Park, USA, **International Journal of Remote Sensing**, v. 24, n. 8, p. 1639-1651, 2003.

## APÊNDICE A – Matrizes de Confusão

Matriz de confusão NDVI médio total. Nota: 1- Área antropizada não agrícola; 2 – Pastagem; 3 – Água; 4 – Lavoura temporária; 5 – Cobertura florestal; 6 – Silvicultura.

		Referência							
Teste	1	2	3	4	5	6	Total	Nu	
1	<b>20596</b>	1289	637	46253	915	746	70436	29,24%	
2	4555	<b>36770</b>	1776	145879	41235	8656	238871	15,39%	
3	546	307	<b>14099</b>	815	369	2	16138	87,37%	
4	7067	16443	1055	<b>1004072</b>	8814	1627	1039078	96,63%	
5	836	42342	323	35815	<b>274218</b>	27031	380565	72,06%	
6	2175	16251	546	33276	30844	<b>5938</b>	89030	6,67%	
<b>Total</b>	35775	113402	18436	1266110	356395	44000	<b>1355693</b>		
<b>Np</b>	0,57571	0,32424	0,764754	0,793037	0,769422	0,134955			
	<b>k1</b>	<b>k2</b>	<b>k3</b>	<b>k4</b>	<b>k5</b>	<b>k6</b>	<b>N</b>	<b>K</b>	
	0,28	0,10	0,87	0,89	0,65	0,04	73,92%	0,533	
	Ruim	Ruim	Excelente	Excelente	Bom	Nulo			

Matriz de confusão NDVI médio parcial. Nota: 1- Área antropizada não agrícola; 2 – Pastagem; 3 – Água; 4 – Lavoura temporária; 5 – Cobertura florestal; 6 – Silvicultura.

		Referência							
Teste	1	2	3	4	5	6	Total	Nu	
1	<b>20589</b>	2623	592	128851	1043	749	154447	13,33%	
2	2008	<b>35841</b>	1038	126803	44876	9601	220167	16,28%	
3	338	390	<b>14127</b>	1686	821	0	17362	81,37%	
4	10227	17874	1767	<b>923884</b>	10126	1391	965269	95,71%	
5	1254	39973	435	37004	<b>260935</b>	22755	362356	72,01%	
6	1359	16701	477	47882	38594	<b>9504</b>	114517	8,30%	
<b>Total</b>	35775	113402	18436	1266110	356395	44000	<b>1264880</b>		
<b>Np</b>	0,575514	0,316053	0,766273	0,729703	0,732151	0,216			
	<b>k1</b>	<b>k2</b>	<b>k3</b>	<b>k4</b>	<b>k5</b>	<b>k6</b>	<b>N</b>	<b>K</b>	
	0,12	0,11	0,81	0,86	0,65	0,06	68,96%	0,471864	
	Muito Ruim	Muito ruim	Muito bom	Excelente	Bom	Nulo			

Matriz de confusão 13. março de 2016. Nota: 1- Área antropizada não agrícola; 2 – Pastagem; 3 – Água; 4 – Lavoura temporária; 5 – Cobertura florestal; 6 – Silvicultura. (CONTÍNUA)

		Referência							
Teste	1	2	3	4	5	6	Total	Nu	
1	<b>10975</b>	2208	145	345910	1265	383	360886	3,04%	
2	3457	<b>26756</b>	493	118326	73398	13150	235580	11,36%	
3	115	1533	<b>12830</b>	7184	12766	761	35189	36,46%	
4	17052	19589	2609	<b>631519</b>	33689	8425	712883	88,59%	

Matriz de confusão 13. março de 2016. Nota: 1- Área antropizada não agrícola; 2 – Pastagem; 3 – Água; 4 – Lavoura temporária; 5 – Cobertura florestal; 6 – Silvicultura. (CONCLUSÃO)

		Referência							
Teste	1	2	3	4	5	6	Total	Nu	
5	3339	49247	1809	123342	<b>197265</b>	19350	394352	50,02%	
6	837	14069	550	39829	38012	<b>1931</b>	95228	2,03%	
<b>Total</b>	35775	113402	18436	1266110	356395	44000	<b>881276</b>		
<b>Np</b>	0,306778	0,235939	0,695921	0,498787	0,553501	0,043886			
	<b>k1</b>	<b>k2</b>	<b>k3</b>	<b>k4</b>	<b>k5</b>	<b>k6</b>	<b>N</b>	<b>K</b>	
	0,0111	0,0552	0,3582	0,6315	0,3797	-0,0038	48,05%	0,232283	
	Nulo	Muito ruim	Ruim	Bom	Ruim	Nulo			

Matriz de confusão 30. de abril de 2016. Nota: 1- Área antropizada não agrícola; 2 – Pastagem; 3 – Água; 4 – Lavoura temporária; 5 – Cobertura florestal; 6 – Silvicultura.

		Referência							
Teste	1	2	3	4	5	6	Total	Nu	
1	<b>17963</b>	3976	443	176351	1661	841	201235	8,93%	
2	3981	<b>19914</b>	590	104879	33768	3942	167074	11,92%	
3	1193	2004	<b>14558</b>	190238	1801	329	210123	6,93%	
4	10012	27637	1672	<b>545181</b>	114187	19019	717708	75,96%	
5	1736	50144	861	215554	<b>181017</b>	15749	465061	38,92%	
6	890	9727	312	33907	23961	<b>4120</b>	72917	5,65%	
<b>Total</b>	35775	113402	18436	1266110	356395	44000	<b>782753</b>		
<b>Np</b>	0,50211	0,175605	0,789651	0,430595	0,507911	0,093636			
	<b>k1</b>	<b>k2</b>	<b>k3</b>	<b>k4</b>	<b>k5</b>	<b>k6</b>	<b>N</b>	<b>K</b>	
	0,07	0,06	0,06	0,22	0,24	0,03	42,68%	0,145365	
	Muito ruim	Muito ruim	muito ruim	Ruim	Ruim	Nulo			

Matriz de confusão 03. de julho de 2016. Nota: 1- Área antropizada não agrícola; 2 – Pastagem; 3 – Água; 4 – Lavoura temporária; 5 – Cobertura florestal; 6 – Silvicultura.

		Referência							
Teste	1	2	3	4	5	6	Total	Nu	
1	<b>9059</b>	1799	250	50161	657	746	62672	14,45%	
2	2234	<b>30025</b>	991	96260	42739	5755	178004	16,87%	
3	71	178	<b>13551</b>	3984	325	59	18168	74,59%	
4	19026	20677	2629	<b>619467</b>	21206	5887	688892	89,92%	
5	2228	50139	778	378880	<b>247889</b>	19607	699521	35,44%	
6	3157	10584	237	117358	43579	<b>12674</b>	187589	6,76%	
<b>Total</b>	35775	113402	18436	126611	356395	44728	<b>932665</b>		
<b>Np</b>	0,253	0,264	0,735	0,48926	0,69554	0,283			
	<b>k1</b>	<b>k2</b>	<b>k3</b>	<b>k4</b>	<b>k5</b>	<b>k6</b>	<b>N</b>	<b>K</b>	
	0,13	0,11	0,74	0,67	0,20	0,04	50,85%	0,252314	
	Muito ruim	Muito ruim	Muito bom	Bom	Ruim	Nulo			

**Matriz de confusão 21. de setembro de 2016. Nota: 1- Área antropizada não agrícola; 2 – Pastagem; 3 – Água; 4 – Lavoura temporária; 5 – Cobertura florestal; 6 – Silvicultura.**

		Referência							
Teste	1	2	3	4	5	6	Total	Nu	
1	<b>10630</b>	3052	596	121589	1741	350	137958	7,71%	
2	3206	<b>27895</b>	1598	154383	68960	8175	264217	10,56%	
3	261	378	<b>13376</b>	23901	793	0	38709	34,56%	
4	18163	22843	1574	<b>569681</b>	10613	3614	626488	90,93%	
5	2330	44196	774	254988	<b>238045</b>	25605	565938	42,06%	
6	1185	15038	518	141089	36243	<b>6256</b>	200329	3,12%	
<b>Total</b>	35775	113402	18436	1265631	356395	44000	<b>865883</b>		
<b>Np</b>	0,29713	0,24598	0,72553	0,45011	0,66792	0,142182			
	<b>k1</b>	<b>k2</b>	<b>k3</b>	<b>k4</b>	<b>k5</b>	<b>k6</b>	<b>N</b>	<b>K</b>	
	0,06	0,05	0,34	0,71	0,28	0,01	47,21%	0,236172	

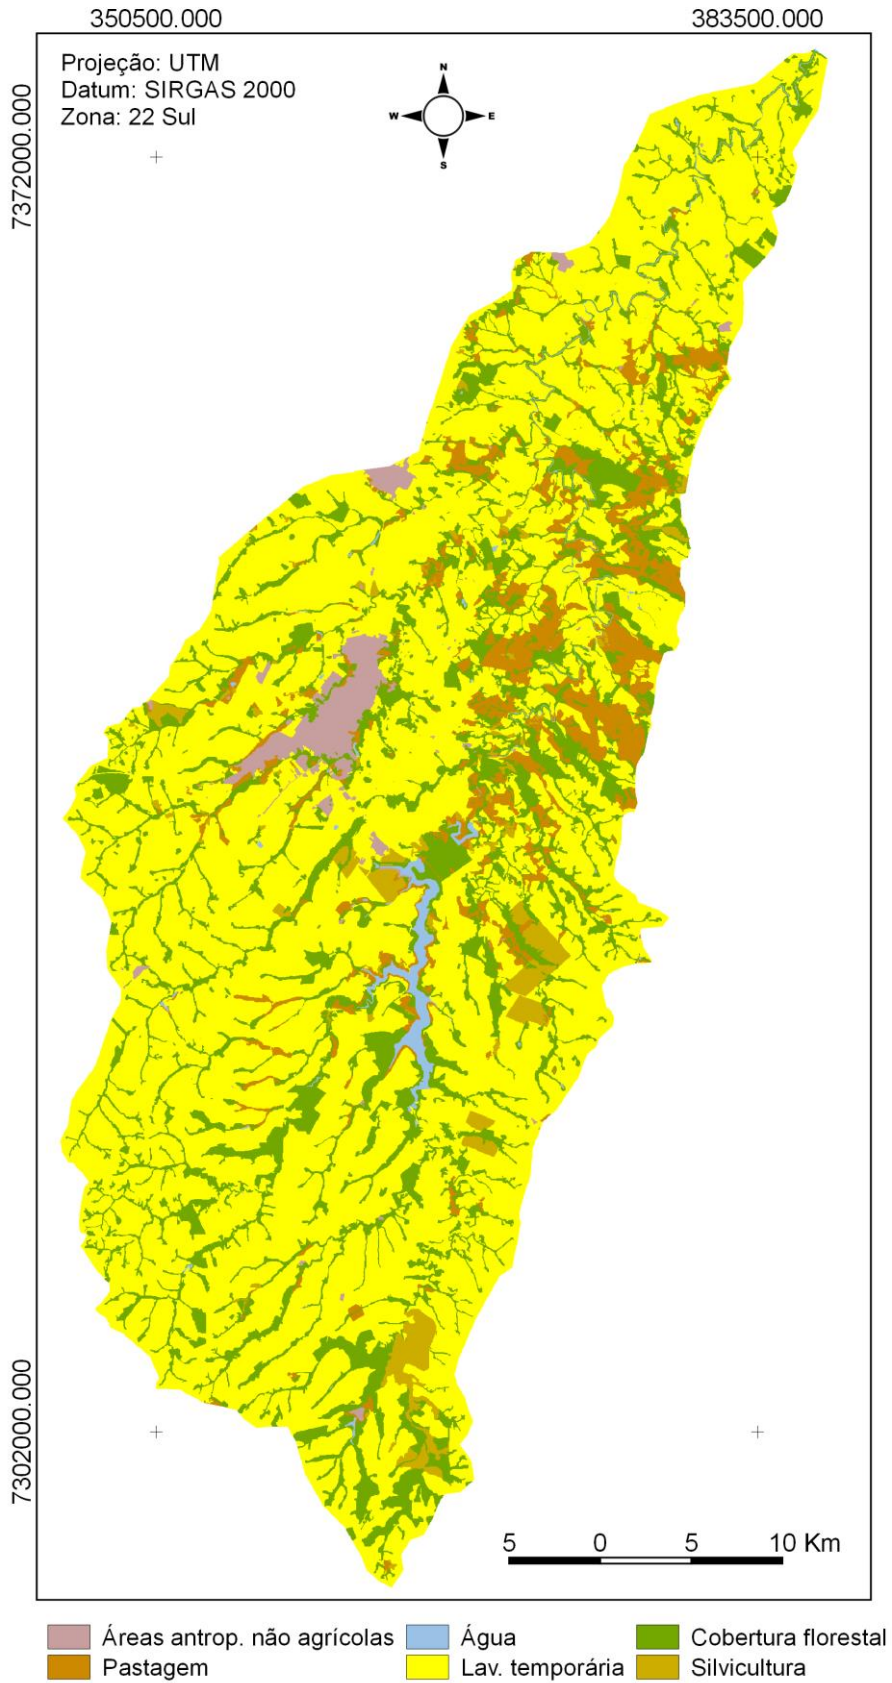
**Matriz de confusão 23. de outubro de 2016. Nota: 1- Área antropizada não agrícola; 2 – Pastagem; 3 – Água; 4 – Lavoura temporária; 5 – Cobertura florestal; 6 – Silvicultura.**

		Referência							
Teste	1	2	3	4	5	6	Total	Nu	
1	<b>8508</b>	3034	711	165209	1663	561	179686	4,73%	
2	4044	<b>50395</b>	1188	77637	67509	19382	220155	22,89%	
3	88	617	<b>13068</b>	13513	1684	0	28970	45,11%	
4	20749	14088	2322	<b>950675</b>	10248	2256	1000338	95,04%	
5	770	27583	631	26510	<b>229466</b>	13786	298746	76,81%	
6	1616	17685	516	32566	45825	<b>8015</b>	106223	7,55%	
<b>Total</b>	35775	113402	18436	1266110	356395	44000	<b>1260127</b>		
<b>Np</b>	0,237	0,44439	0,70883	0,75	0,6438	0,1821			
	<b>k1</b>	<b>k2</b>	<b>k3</b>	<b>k4</b>	<b>k5</b>	<b>k6</b>	<b>N</b>	<b>K</b>	
	0,03	0,18	0,45	0,84	0,71	0,05	68,70%	0,46	
	Nulo	Muito ruim	Regular	Muito bom	Muito bom	Muito ruim			

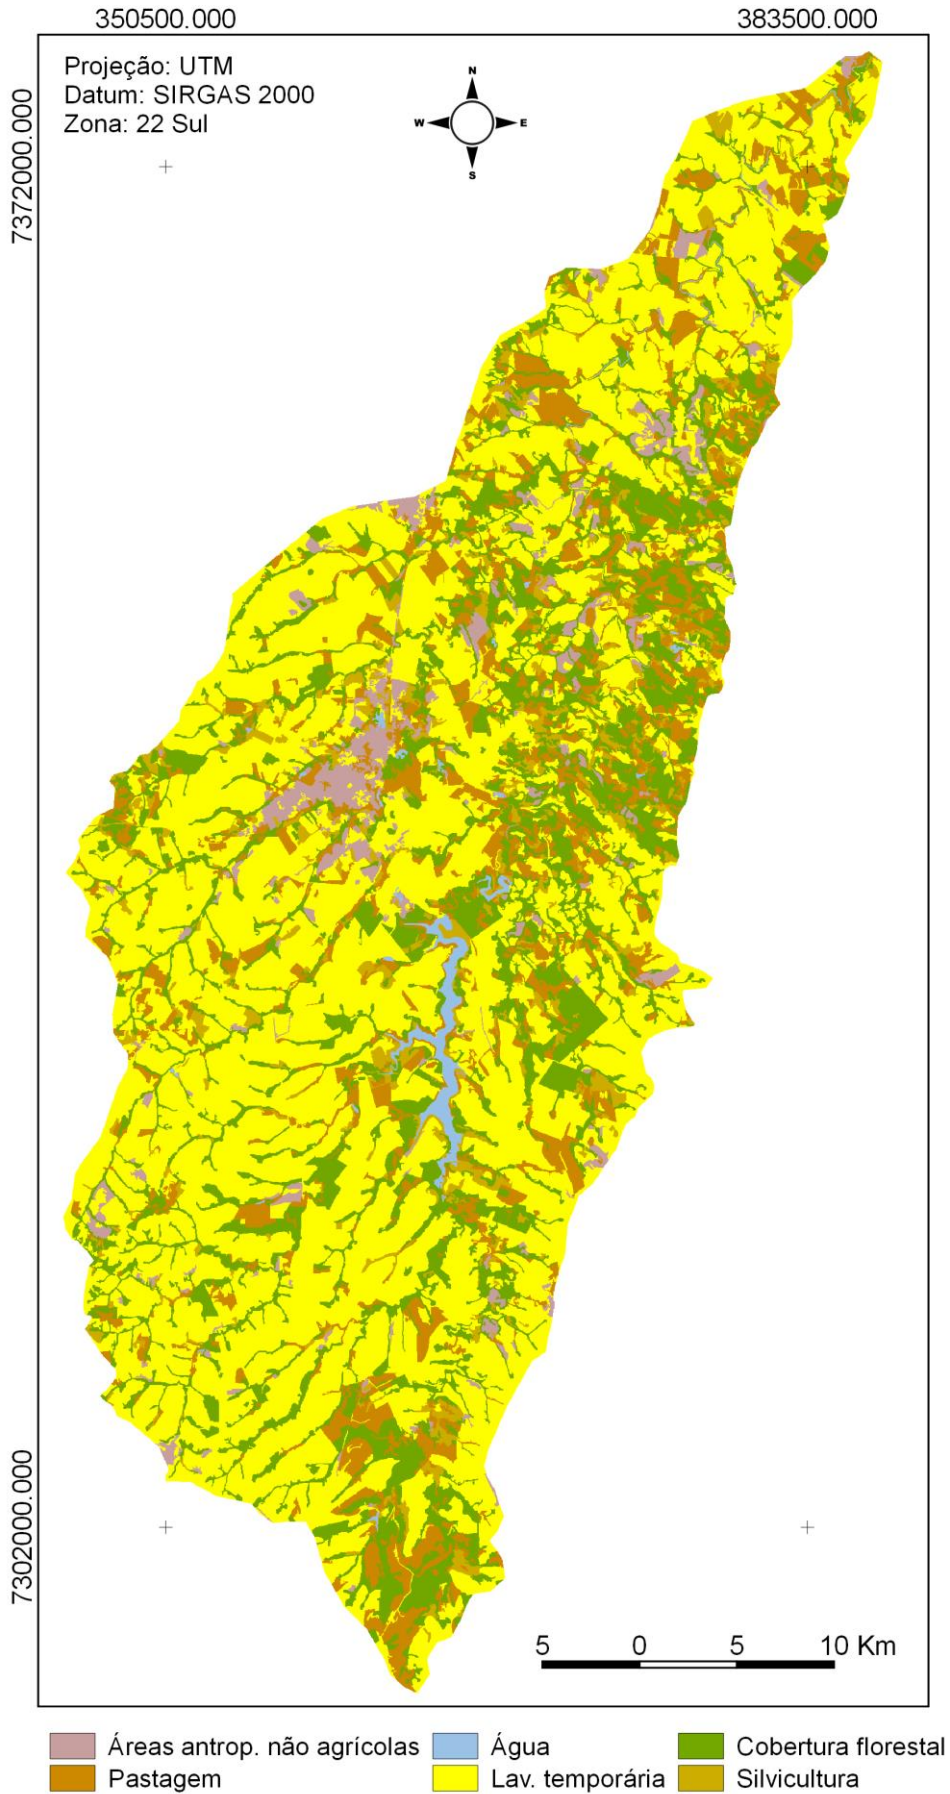


## APÊNDICE B – Mapas de Uso da Terra

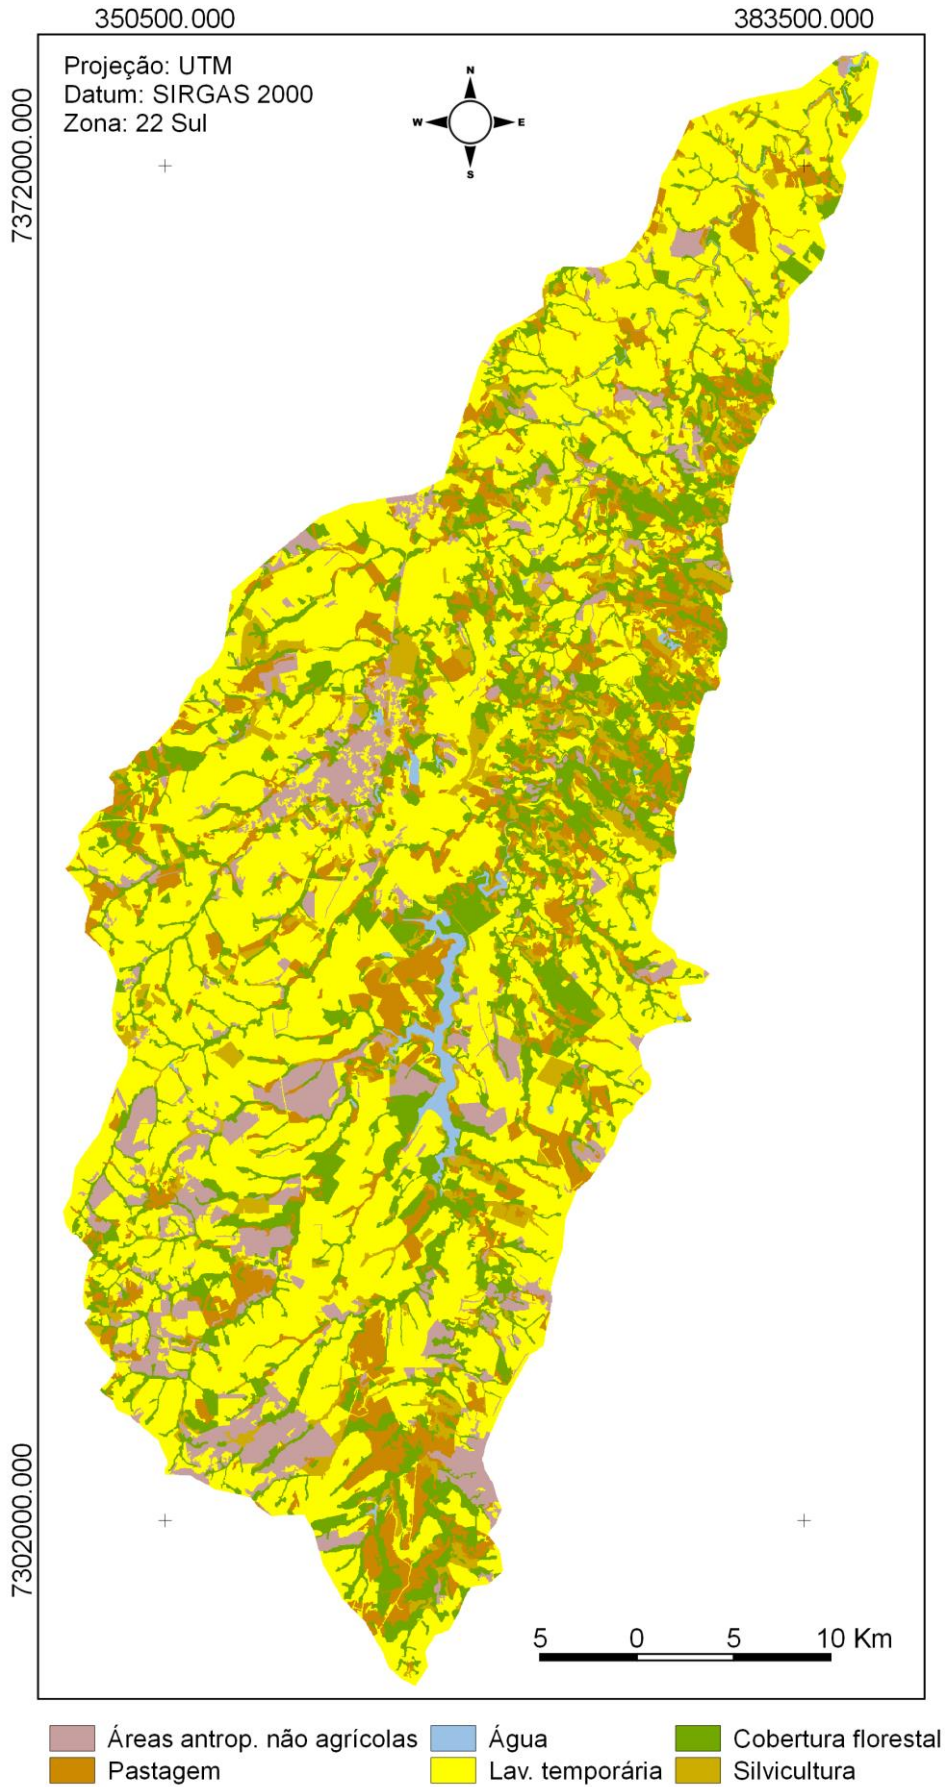
### Uso da terra da bacia hidrográfica do Rio Mourão.

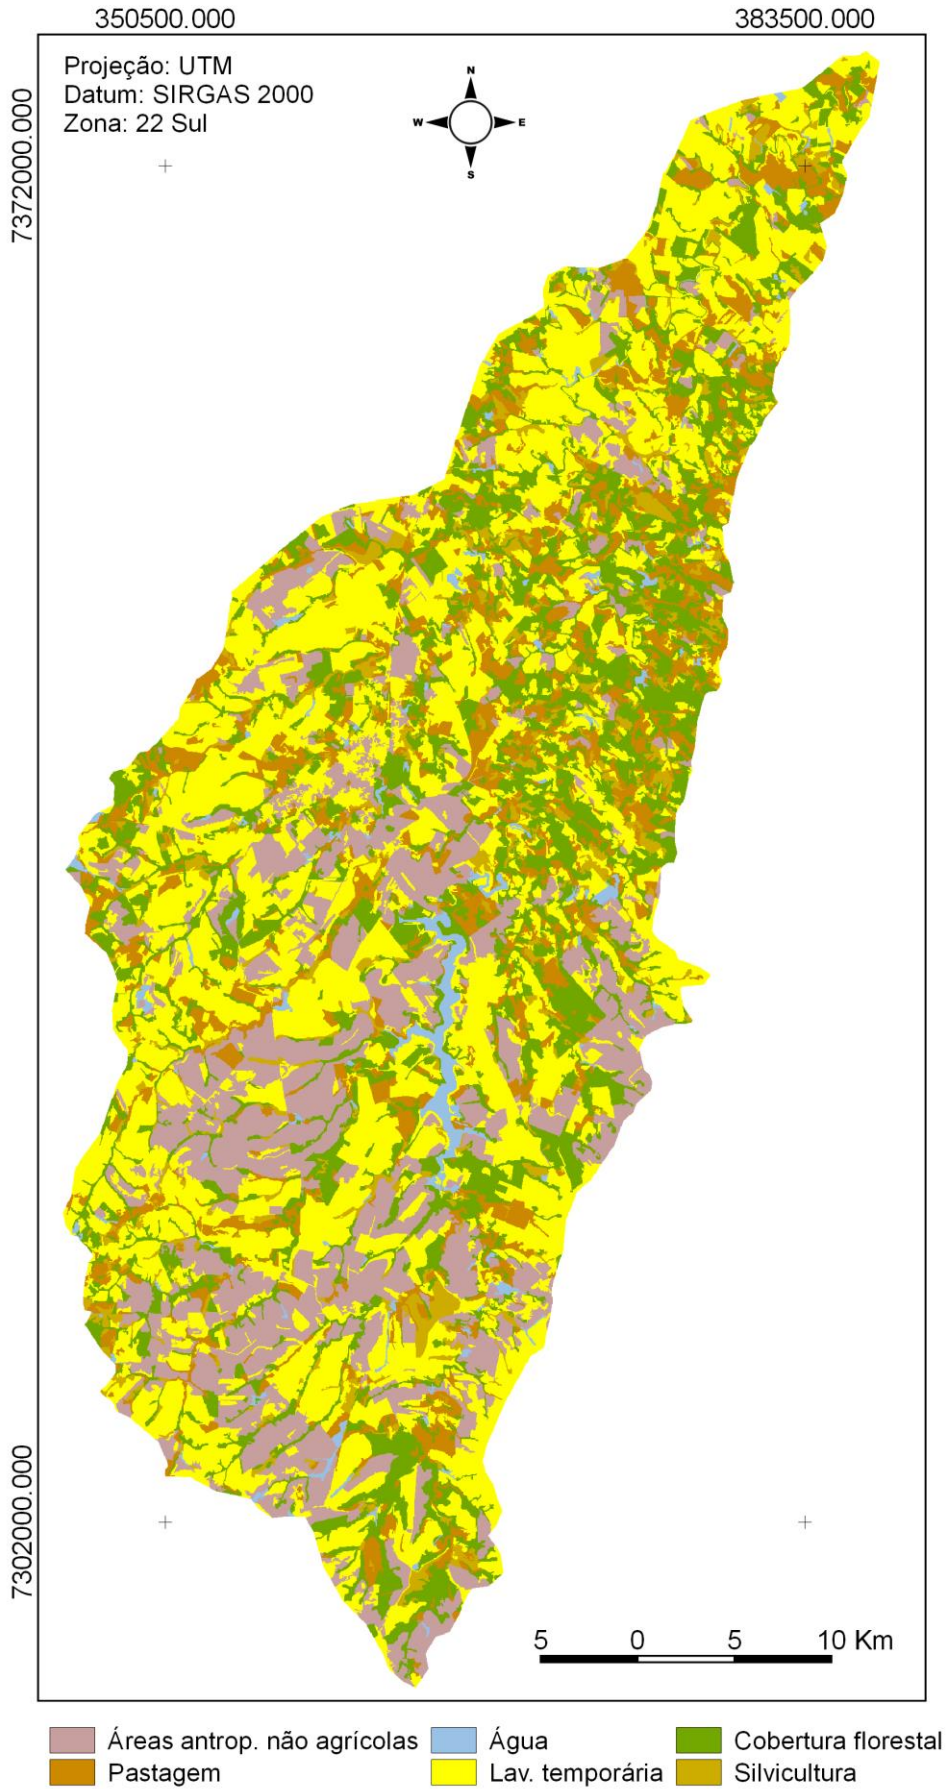


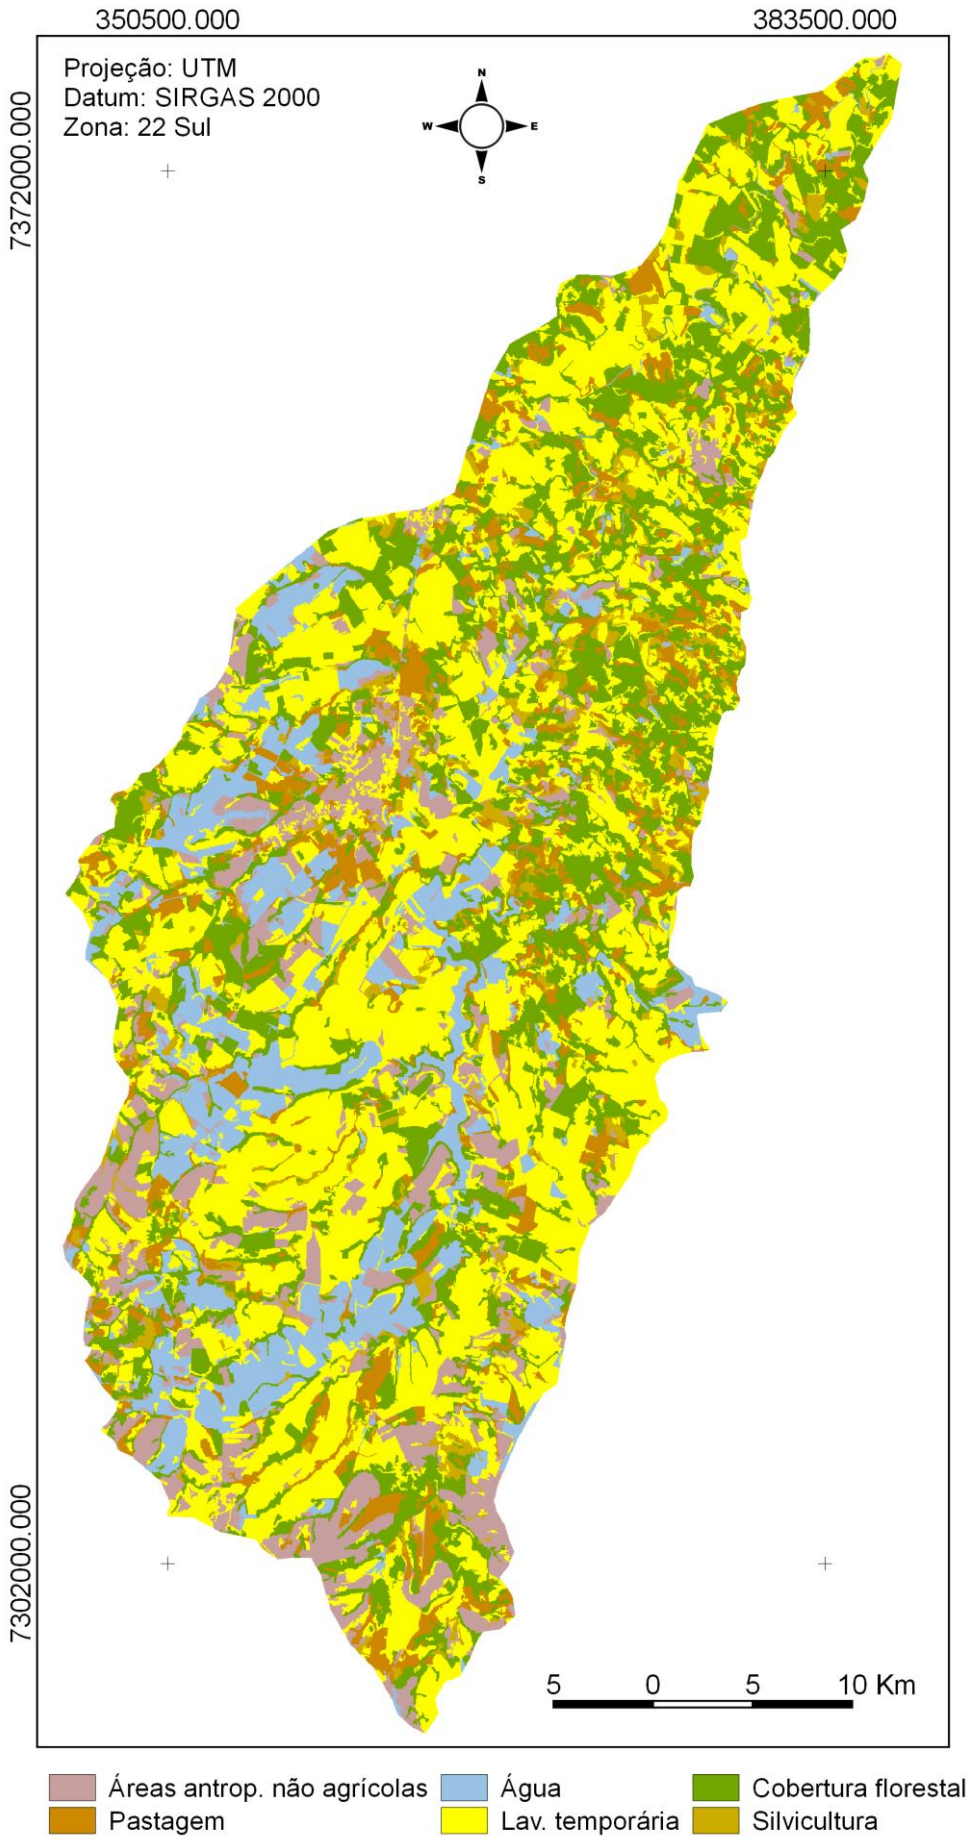
### Uso da terra segundo a classificação supervisionada baseada no NDVI médio total



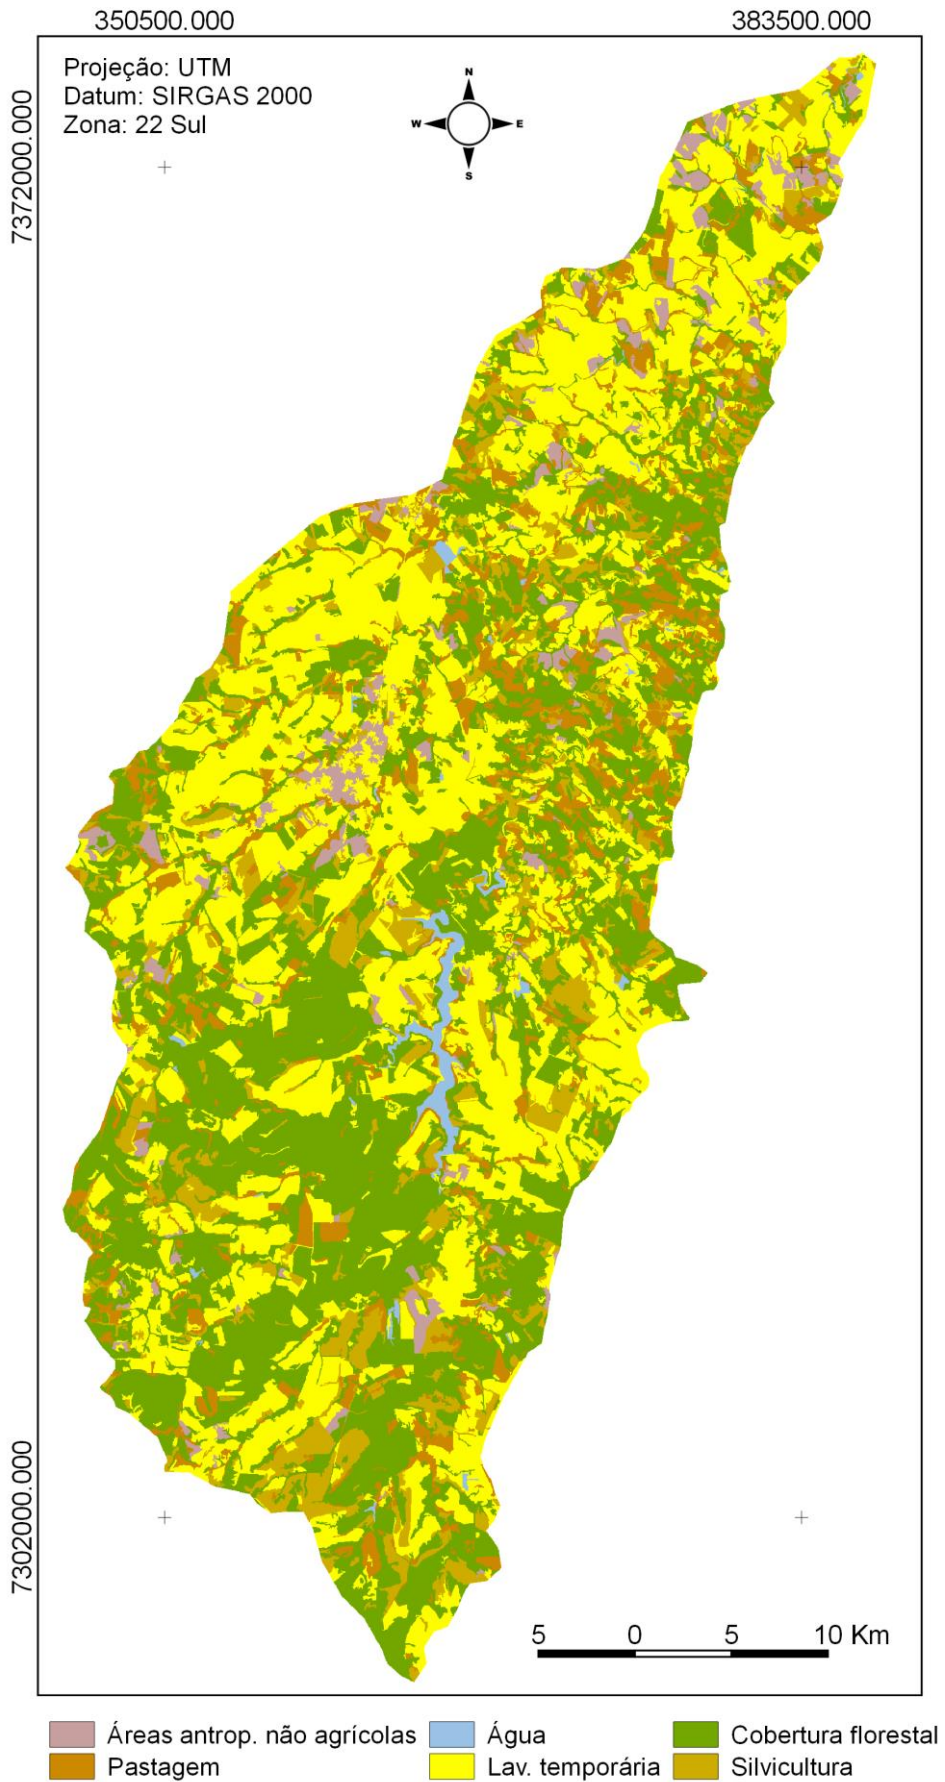
### Uso da terra segundo a classificação supervisionada baseada no NDVI médio parcial

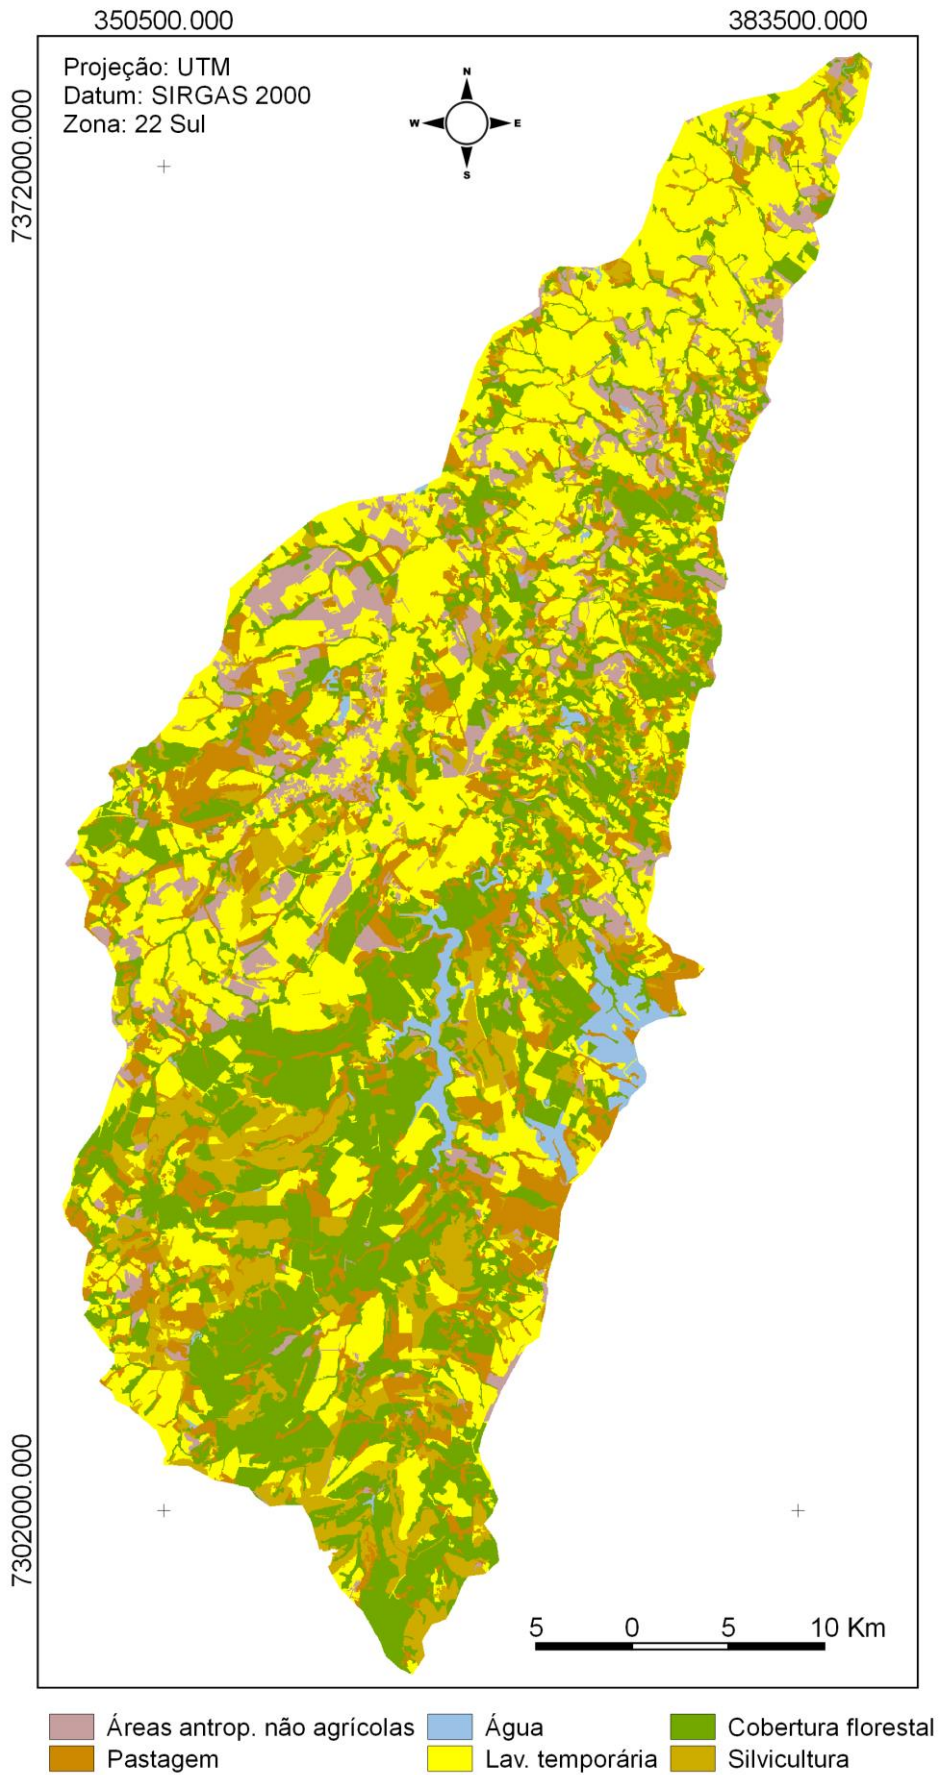


**Uso da terra segundo a classificação supervisionada baseada no NDVI da data 13/03/2016**



Uso da terra segundo a classificação supervisionada baseada no NDVI da data 03/07/2016



**Uso da terra segundo a classificação supervisionada baseada no NDVI da data 21/09/2016**

**Uso da terra segundo a classificação supervisionada baseada no NDVI da data 23/10/2016**

