

**LAND COVER MAPPING OF A HYDROELECTRIC DOMAIN
AREA OBTAINED BY SUPPORT VECTOR MACHINES AND
MAXIMUM LIKELIHOOD CLASSIFIERS**

**MAPEADO DE LA COBERTURA DEL SUELO DE LOS
ALREDEDORES DE UNA PRESA HIDROELÉCTRICA
OBTENIDO POR LOS CLASIFICADORES MÁQUINA DE
VECTOR DE SOPORTE Y MÁXIMA VEROSIMILITUD**

**¹Rafael Walter de Albuquerque, ²Maurício George Miguel Jardini,
³Mariana Abrantes Giannotti & ⁴José Alberto Quintanilha**

¹Escola Politécnica da Universidade de São Paulo – Departamento de Engenharia de Transportes - Av. Prof. Almeida Prado, Travessa 2, no. 83 – São Paulo – SP – Brasil
r.w.albuquerque@gmail.com

²FDTE – Fundação para o Desenvolvimento tecnológico da Engenharia, Av. Eusébio Matoso, 1375, 6º Andar, Butantã, São Paulo-SP, CEP: 05423-180
mjardini@fdte.org.br

³Escola Politécnica da Universidade de São Paulo – Geoprocessing Laboratory (LabGeo) - Departamento de Engenharia de Transportes - Av. Prof. Almeida Prado, Travessa 2, no. 83 – São Paulo – SP – Brasil
mariana.giannotti@usp.br

⁴Escola Politécnica da Universidade de São Paulo – Departamento de Engenharia de Transportes - Av. Prof. Almeida Prado, Travessa 2, no. 83 – São Paulo – SP – Brasil
jaquinta@usp.br

Recebido 26 de Maio de 2016, aceito 12 de Setembro de 2017

RESUMEN - Las clasificaciones mediante imágenes de satélite son muy útiles para la identificación de la cobertura del suelo y pueden ser utilizadas para evaluar los dominios terrestres. El propósito principal del artículo es comparar los resultados de mapeado de la cobertura terrestre/uso del suelo - CTUS de dos conocidos algoritmos - la Máquina

de Vector de Soporte (MVS) y la Máxima Verosimilitud (MV) - en las cercanías de una presa hidroeléctrica utilizando imágenes de satélite con alta resolución espacial. Ambos clasificadores presentaron una alta precisión y las diferencias no fueron estadísticamente significativas. Los resultados de la clasificación sugieren que el uso del fuego en la zona representa una amenaza para la buena situación ambiental del embalse. Este hallazgo confirma y enfatiza la importancia de las herramientas analizadas en este artículo, lo cual ayuda en la monitorización ambiental.

Palabras clave: clasificación de la cobertura del suelo, Máquina de Vector de Soporte (MVS), Máxima Verosimilitud (MV), hidroeléctrico, embalse, Teledetección.

ABSTRACT - Satellite Images Classification is very useful for land cover identification and it can be used to evaluate land surface domains. The aim of this study was to compare the land cover mapping (LCLU) generated by Support Vector Machine (SVM) and Maximum Likelihood (ML) classifiers applied to high resolution satellite image. Both SVM and ML classification results presented high quantitative accuracy indexes and were not significantly different. Classification results stated fire usage over the land as a threat to the reservoir's good environmental situation. SVM therefore was confirmed as a good classifier in land cover mapping of hydroelectric power plant reservoir and emphasized the importance of the tools discussed in this paper, which helps the environmental monitoring.

Keywords: satellite images classification, Support Vector Machine (SVM), Maximum Likelihood (ML), hydroelectric, reservoir, Remote Sensing.

1. INTRODUCCIÓN

Las imágenes de satélite ofrecen una vista panorámica de la superficie terrestre y ofrecen varias posibilidades de Teledetección (detección remota—DR) que pueden ser

utilizadas para realizar un seguimiento de áreas ambientales y urbanas (Jensen, 1986; Schowengerdt, 2007). Las imágenes de DR permiten obtener mapas de cobertura terrestre y usos del suelo - CTUS. Los datos de este tipo de mapas proceden de la superficie terrestre, la cual refleja valores del espectro electromagnético que son captados por los sensores a bordo de satélites (Jensen, 1986).

La utilización de imágenes de satélite para obtener información de la cobertura del suelo se basa principalmente en el método de interpretación visual, el cuál es una forma cualitativa de análisis de datos (Lillesand *et al.*, 2008). Un ejemplo de un proyecto de grandes dimensiones que hace uso del análisis cualitativo de datos es el mapeado de grandes áreas del Amazonas (Skole *et al.*, 1993). A pesar de que el análisis cualitativo juega un papel importante en la DR, el análisis cuantitativo obtenido mediante la clasificación digital de imágenes ha ganado importancia a nivel global (Mather & Koch, 2011) y permite mayor precisión a menor coste y con mayor rapidez (Dutta *et al.*, 1994).

De acuerdo con Michalijos & Uboldi (2013), la clasificación digital implica convertir la imagen multibanda en otra imagen donde los niveles de gris de cada pixel no se definen por la radiancia sino por la categoría asignada a ese pixel. Este nivel de referencia permite delimitar sobre la imagen áreas representativas de cada una de las coberturas existentes (definición digital de categorías o fase de entrenamiento), y las que se convertirán en las categorías que componen la leyenda a través del agrupamiento de los píxeles de la imagen en cada una de las categorías (fase de asignación) (Chuvieco, 2008).

El mapeado de CTUS es muy útil en las políticas de mantenimiento de presas hidroeléctricas, ya que se pueden localizar las áreas afectadas y se pueden planificar las intervenciones. Este tipo de mapeado ayuda en el seguimiento de los alrededores de la presa hidroeléctrica mediante la identificación de nuevos asentamientos humanos en la zona, (Jardini *et al.*, 2011), evitando así problemas

ambientales y sociales causados por asentamientos irregulares y/o ilegales.

La realización de este trabajo fue inicialmente motivada por el deseo de comprender y evaluar los diferentes dominios de la superficie terrestre de los alrededores de una presa hidroeléctrica, lo cual puede ayudar en el establecimiento de políticas de conservación en relación a la expansión de los asentamientos en la presa. Con los resultados se espera poder evitar la contaminación del lago y otros problemas ambientales, disminuyendo así el coste de mantenimiento del equipamiento hidroeléctrico, y proporcionar herramientas para una mejor utilización de las tierras alrededor de la presa.

El propósito principal del artículo es comparar los resultados de mapeado de CTUS de dos conocidos algoritmos - la Máquina de Vector de Soporte (MVS) y la Máxima Verosimilitud (MV) - en las cercanías de una presa hidroeléctrica utilizando imágenes de satélite con alta resolución espacial. La metodología se aplica a una imagen de satélite de la planta hidroeléctrica Luis Eduardo Magalhães la cual está localizada en el municipio de Lajeado (estado de Tocantins, Brasil).

El artículo se estructura de la siguiente manera: la sección Área de Estudio que contiene la descripción del área estudiada; la sección de Métodos donde se describe la metodología científica usada en el artículo; la sección de Resultados y Discusión donde se muestran los resultados obtenidos así como también un análisis de la información adquirida; y finalmente el apartado de Conclusiones donde se describen las contribuciones y conclusiones del trabajo.

2. MATERIALES Y MÉTODOS

2.1 Área de estudio

La planta hidroeléctrica Luis Eduardo Magalhães suministra energía eléctrica al estado de Tocantins y otros estados brasileños. Esta planta y sus alrededores

están localizados ~~está localizada~~ en el municipio de Lajeado, Estado de Tocantins, Brasil (Figura 1). Esta planta suministra energía eléctrica al estado de Tocantins y otros estados brasileños. Solo una parte de los alrededores del área donde la presa hidroeléctrica está localizada fue utilizada en éste estudio (Figura 2), ya que el área de la presa de Lajeado es muy extensa, lo cual requeriría mucho tiempo y una elevada capacidad de computación.

La Área de estudio (Figura N°2) está ubicada en la Cuenca Tocantins y el principal río de la presa Luis Eduardo Magalhães es justamente el Río Tocantins. La presa pertenece a la subcuenca Tocantins y está ubicada entre los ríos Paraná y do Sono. La ciudad Lajeado, presente en la área de estudio, está ubicada a 47 kilómetros al norte de la capital del Estado Tocantins, Palmas. No hay una gran economía en la Área de Estudio y las principales actividades son 61,27% de servicios (principalmente actividades de administración pública), 32,06% de industrias (principalmente la construcción civil) y 6,67% de agropecuaria (IBGE, 2010).





Figura 1 - La localización del municipio de Lajeado. Fuente: Elaboración propia.

2.2 Materiales

El software ENVI 4.8 fue utilizado para el preprocesamiento y clasificación de la imagen y varios diseños gráficos de mapas fueron obtenidos con ArcGis 10.

Se utilizó una imagen georeferenciada obtenida del sistema de satélite GEOEYE (GeoEye, 2010), con fecha de Septiembre de 2010, que utiliza cuatro canales espectrales (rojo, verde, azul e infrarrojo) y se utilizaron resoluciones espaciales y radiométricas de 0.5 metros y 16 bits respectivamente. La Figura N° 2 muestra la imagen obtenida en la banda del rojo, donde es posible identificar la ciudad de Lajeado (en la parte superior izquierda de la imagen), así como la presa y parte del embalse.



*Figura 2 - Imagen del área de estudio obtenida por GEOEYE en la banda del rojo.
Fuente: Elaboración propia.*

2.3 Métodos

El preprocesamiento consistió únicamente en el georreferenciamiento basado en un mosaico ya realizado por la empresa proveedora de la imagen Geoeeye.

Las categorías de la cobertura del suelo elegidas para este trabajo siguen la terminología propuesta por el Instituto Nacional de Geografía e Estadística (organismo nacional brasileño de Geografía y Estadística) (IBGE, 2006), con algunos ajustes, incluyendo las categorías definidas por la Coordinación de la Información del Medioambiente (CORINE, por sus siglas en inglés) (Bossard *et al.*, 2000) para completar la jerarquía de categorías, tal como se muestra en la Figura N° 3.

De acuerdo con Büttner (2014), la Cobertura del Suelo de CORINE (CORINE Land Cover - CLC, por sus siglas en inglés) se usa para estandarizar conjuntos de datos de terrenos en Europa y respaldar el desarrollo de políticas ambientales. La CLC es ampliamente utilizada como indicador de desarrollo en modelado ambiental y en el análisis de los cambios en la cobertura del suelo en Europa. Los parámetros técnicos básicos de la CLC (i.e. la nomenclatura, las 25 ha de unidad mínima de mapeado y los 100 m de anchura mínima de mapeado) no han cambiado desde el inicio del proyecto; de esta manera, los resultados de los diferentes inventarios son comparables.

Los niveles iniciales (en negro en la Figura N° 3) del árbol jerárquico se definen de acuerdo con el modelo propuesto por el IBGE y los niveles finales (en gris) proceden de CORINE. Las categorías de la cobertura del suelo elegidas y validadas por el índice Jeffries-Matusita (Richards & Jia, 1999) son: Agua (A), Rocas (R), Campos (C), Bosque (B), Quemado (Q), Edificios (E), Hormigón (H) y Sin Vegetación (S). Los principales aspectos considerados fueron la localización y extensión de las áreas quemadas, sin vegetación y construidas, las cuales corresponden a lugares influenciados antropogénicamente.




Figura 3 - Jerarquía de categorías propuesta por el IBGE junto con los niveles de categorías de cobertura del suelo obtenidos del CORINE. Fuente: Elaboración propia.

Para llevar a cabo clasificaciones basadas en imágenes se han desarrollado varios algoritmos, siendo los más comunes los de Máxima Verosimilitud - MV (Jensen, 1986; Richards & Jia, 1999; Warner *et al.*, 2009). Este clasificador considera que los niveles de gris de las diferentes categorías siguen una distribución normal y que los píxeles se identifican de acuerdo con la probabilidad más alta de estos de pertenecer a una determinada categoría (Mather, 2004).

Recientemente, el algoritmo de Máquina de Vector de Soporte – MVS (Gigandet *et al.*, 2005) ha sido adoptado por la comunidad científica. Varios estudios han mostrado que este clasificador puede alcanzar un gran rendimiento, a menudo con resultados incluso más significativos que los obtenidos mediante MV (Song & Civco 2004; Gualtieri & Crompt, 1999; Pal & Mather, 2004, 2005), lo cual hace del MVS un clasificador que puede ser potencialmente utilizado para el mapeado de la cobertura del suelo.

De acuerdo con Lu & Wong (2007), el clasificador MVS es no paramétrico (no se requiere asunción alguna sobre la distribución de datos y no emplea parámetros estadísticos para calcular la separación entre categorías). A diferencia de otros clasificadores no paramétricos (red artificial neural, clasificador de árbol de decisión, razonamiento evidencial y sistema experto, por ejemplo), el MVS es fácil de utilizar y muchas de sus implementaciones están disponibles en diferentes softwares.

De la misma manera que el clasificador MV, el MVS es un clasificador por pixel y, a pesar de que el MVS también puede implementarse como clasificador de objetos (Tzotsos & Argialas, 2008). Sin embargo, se debe resaltar que la clasificación basada en objetos (Object-Based Image Analysis – OBIA) no se aborda en este trabajo. Logo, en el clasificador MVS por pixel, la señal resultante contiene las contribuciones de todos los materiales presentes en los pixeles de datos de entrenamiento para encontrar los mejores Vectores Soporte - VS (Burges, 1998). Los VS permiten obtener una decisión definitiva sobre el tipo de cobertura del suelo en la cual cada pixel está dentro de una única categoría (Lu & Wong, 2007). Para más detalles sobre el proceso de identificación por MVS consultar Burges (1998).

Sobre el proceso de clasificación, las muestras de entrenamiento y de prueba se obtuvieron por fotointerpretación y fueron confirmadas en trabajo de campo. La adquisición de muestras de entrenamiento es llevada a cabo según las recomendaciones propuestas por Campbell (2008), Mather & Koch (2011) y Foody & Mathur (2004). Estas recomendaciones buscan alcanzar un proceso de identificación preciso. En ese caso, las muestras de prueba se validan también de acuerdo con los requisitos de Congalton (2005) para cuantificar la exactitud de la clasificación. Así, para cada clase de cobertura del suelo, las muestras totalizaron por lo menos trescientos ochenta y ocho pixeles para entrenamiento y por lo menos dos mil trescientos pixeles para prueba.

Para abordar la clasificación mediante MVS, Hsu *et al.* (2010) sugiere utilizar la función Radial Basis Function (RBF) Kernel en el proceso de clasificación usando los parámetros de calibración determinados mediante el método de validación cruzada. Los parámetros de calibración están presentes en la ecuación de MVS (Burges, 1998) y sus valores son definidos por el usuario. Para más información acerca del método de validación cruzada consultar Hsu *et al.* (2010).

La validación de la clasificación se lleva a cabo considerando el valor más alto del índice de Kappa (Cong & Howarth, 1990; Iwai & Quintanilha, 2005) que se obtiene mediante los resultados de la validación cruzada. Para la clasificación resultante, se obtiene y analiza apropiadamente la matriz de errores.

La matriz de errores muestra el porcentaje de clasificación correcta e incorrecta de los resultados de algoritmos aplicados, en relación con alguna otra clasificación tomada como verdadera (Jensen, 1986; Mather & Koch, 2011). En este caso, se obtuvo la verdad por análisis visuales de la imagen y visitas de campo.

En la metodología utilizada para la interpretación de los datos, los dos posibles tipos de errores - el valor de las omisiones (el píxel es de una clase se erróneamente asignado a otra clase) y comisiones (píxeles de otras clases se atribuyen erróneamente a una clase) (Campbell, 2008) - fueron considerados para la gestión ambiental. Adicionalmente a los resultados de la matriz de errores, se realizó un análisis cualitativo de la precisión de la clasificación mediante fotointerpretación. Los errores identificados cualitativamente también fueron evaluados por trabajo de campo.

Finalmente, los resultados de la MVS se comparan con los obtenidos mediante la MV. Esta comparación confirma los resultados de los algoritmos de clasificación utilizados para el mapeo de la cobertura del suelo de los alrededores de la planta hidroeléctrica en la presa. Para validar estadísticamente si los resultados de las clasificaciones obtenidas mediante MVS y MV son

significativamente diferentes, se aplica el test de McNemar, descrito en Agresti (2007) y recomendado en Foody (2004).

3. RESULTADOS Y DISCUSIÓN

Las áreas resultantes de la clasificación (en km²) y el porcentaje de cada categoría considerada se muestran en el Cuadro N° 1. Ya los valores de las clases de cobertura del suelo en porcentaje se muestran gráficamente en la Figura N° 4

Cuadro 1 - Extensión de las categorías de cobertura del suelo obtenidas con los clasificadores MVS y MV. Fuente: Elaboración propia.

Categorías	Píxeles (%)	Área (km²)	Píxeles (%)	Área (km²)
	MVS	MVS	MV	MV
Agua	23,54	23,06	23,04	22,58
Bosque	25,94	25,41	32,93	32,27
Campos	32,49	31,83	23,99	23,52
Rocas	2,57	2,52	2,03	1,99
Edificios	1,12	1,10	2,46	2,41
Sin Vegetación	5,49	5,38	10,77	10,55
Quemado	7,99	7,83	4,47	4,38
Hormigón	0,86	0,84	0,3	0,29




Figura 4 - Extensión en porcentaje de las categorías de cobertura del suelo obtenidas con los clasificadores MVS y MV. Fuente: Elaboración propia.

El mapeado de las clases de cobertura del suelo obtenidas por los clasificadores MVS y MV son ilustrados en la Figura N° 5.




Figura 5 - Mapa de la cobertura del suelo obtenido por el clasificador MVS (a) y MV (b). Fuente: Elaboración propia.

El rendimiento de los algoritmos MVS y MV es evaluado por la matriz de errores, como se muestra en el Cuadro N° 2. Esta matriz presenta valores altos en los índices de precisión de acuerdo con Congalton & Green (1999): generalmente, el índice de precisión y el índice de Kappa son iguales a 86,11% y 0,84 respectivamente.

En el Cuadro N° 2 los resultados de las clasificaciones se establecen utilizando los dos métodos (MVS y MV). En las columnas de este matriz son las clases asumidos para ser Verdad y en las líneas, las clases resultantes de clasificadores. Por ejemplo, la categoría de agua (A) para el segundo método (MV), 95% de agua fueron correctamente clasificados como (A), mientras que un 13% como hormigón (H). Similar lectura se puede hacer para las otras columnas. Para facilitar la lectura, utilizaremos la siguiente notación en adelante: H|A

significa que se clasificó como H cuando debe ser A. En el ejemplo, clasificó como hormigón cuando debería ser agua (H|A). La diagonal principal de esta matriz (resaltado en negrita) tiene los porcentajes de clasificación correcta de cada categoría.

Cuadro 2 - Matrices de errores obtenidas de las clasificaciones mediante MVS y MV. Los valores están en porcentajes. Leyenda: A=Agua; R=Rocas; C=Campos; B=Bosque; Q=Quemado; E= Edificios; H=Hormigón; S=Sin Vegetación. Fuente: Elaboración propia.

Resultados de los algoritmos	Verdad Assumida							
	A	R	C	B	Q	E	H	S
A (MVS)	85.9	0.0	0.0	0.0	2.7	0.4	0.1	0.0
A (MV)	94.6	0.0	0.0	0.0	0.4	0.0	0.2	0.0
R (MVS)	0.0	75.6	0.0	0.0	0.0	1.1	4.5	12.3
R (MV)	0.5	77.0	0.0	0.0	0.1	0.7	8.3	18.5
C (MVS)	0.2	2.2	78.2	0.0	10.7	3.7	0.0	0.0
C (MV)	2.3	6.6	96.6	0.0	16.8	0.5	1.5	0.0
B (MVS)	0.0	0.0	0.0	100	0.0	0.0	0.0	0.0
B (MV)	0.0	0.0	0.3	100	0.3	0.3	0.0	0.0
Q (MVS)	0.7	9.2	21.8	0.0	86.6	0.0	0.0	0.0
Q (MV)	2.2	7.3	0.5	0.0	82.4	0.0	0.0	0.0
E (MVS)	0.0	0.0	0.0	0.0	0.0	82.8	0.0	4.9
E (MV)	0.0	0.0	0.0	0.0	0.0	91.5	0.2	9.9
H (MVS)	13.2	12.9	0.0	0.0	0.0	1.3	95.4	0.0
H (MV)	0.5	9.0	0.0	0.0	0.0	0.0	89.8	0.0
S (MVS)	0.0	0.0	0.0	0.0	0.0	10.8	0.0	82.7
S (MV)	0.0	0.0	2.7	0.0	0.0	7.3	0.0	71.6
Total (MVS)	100	100	100	100	100	100	100	100
Total (MV)	100	100	100	100	100	100	100	100

Los errores relacionados con la categoría Rocas, la cual presenta una parte de su área incorrectamente incluida dentro de la categoría Hormigón (H|R = 12.9 para MVS y 9.0 para MV), son fácilmente identificados mediante el contexto especial ya que el hormigón no se distribuye aleatoriamente en pequeños trozos a diferencia de las rocas. La Figura N° 7 (a) muestra un ejemplo de este hecho. La situación inversa; falso positivo de la categoría Roca y negativa de Hormigón, es también fácilmente detectado a lo largo del contexto especial ya

que las carreteras pavimentadas presentan forma regular como se muestra en la Figura N° 7 (b). Para el caso de estas dos categorías, la similitud espectral que presentan ya fue indicada por Van der Meer & Gort (1999): la similitud de su marca espectral es debida a la existencia de minerales en los afloramientos rocosos que son usados en la manufacturación de cemento.






Figura 6 - Errores entre las categorías Edificios y Sin vegetación. Fuente: Elaboración propia. Ejemplo del mapeo correcto de la categoría Edificios falsos positivos para la categoría Edificios (a) y falsos negativos para la categoría Sin Vegetación (b).

Los errores cometidos entre las categorías Sin Vegetación y Rocas ($R|S = 12.3$ y 18.5) se pueden determinar mediante la matriz de errores ya que no pudieron ser fácilmente discriminados mediante inspección visual. De esta forma, es necesario localizar las muestras de prueba para la categoría Sin Vegetación y verificar que se solapan con pequeñas áreas clasificadas como rocas. Estos errores son rápidamente identificables y su ocurrencia local se determina analíticamente

como Sin Vegetación mediante el contexto espacial a medida que aparecen. En ése caso, el gestor de la presa no dispone de una desventaja significativa ya que estos errores sutiles son analíticamente e intuitivamente detectados.



(a)



(b)

Figura 7 - Confusión de las categorías Rocas y Hormigón. Falsos negativos de la categoría Rocas y falsos positivos de la categoría Hormigón (a) falso negativo de la categoría Hormigón y falso positivo de Rocas (b). Fuente: Elaboración propia.


En la Figura N° 8 se muestran mismos tipos de errores los cuales aparecen en la matriz de errores en varios pares de categorías: $A|H$ (13.22%), $R|Q$ (9.24%) y $Q|A$ (2.66%). Para estos pares de categorías, los errores de clasificación pueden ser detectados solo mediante la localización de las muestras de ensayo que incluyan clasificaciones erróneas.



Figura 8 - Ejemplo de una muestra de ensayo de la categoría Sin Vegetación que solapa con pequeñas áreas clasificadas en la categoría Rocas. Fuente: Elaboración propia.

En la categoría Campos se puede observar que una cantidad significativa de los errores totales están asociados a la categoría Quemado ($C|Q = 10.7$ y 16.8). En este caso, el gestor de la presa debe ser consciente ya que la confusión se produce entre áreas naturales y antropogénicas (que no son fácilmente detectadas analíticamente). Los errores asociados a la categoría Quemado son alarmantes ya que la ocurrencia de esta categoría no está definida espacialmente. Puede darse en cualquier parte ya que la población local no utiliza ningún tipo de criterio a la hora de elegir las áreas a ser quemadas.

El uso del fuego en el terreno se determina mediante clasificación por imagen y trabajo de campo. Este uso representa una amenaza para la buena situación medioambiental del embalse. Las imágenes procedentes de GEOEYE muestran que el área fue quemada en 2010 y la visita a la zona llevada a cabo en 2011 permitió determinar que los residentes locales quemaron la tierra con el propósito de realizar pasto en un área cercada por una valla.



(a)



(b)

Figura 9 - Presencia de áreas quemadas mostradas en una imagen de GEOEYE 2010 (a) y mismo lugar durante la visita realizada para llevar a cabo los trabajos de campo en 2011, donde se observaron actividades de pasto (b). Fuente: Elaboración propia.

El MVS tuvo más sobreestimación de Quemado que el MV ($Q|C = 21,8$ y $0,5$). La sobreestimación de la categoría Quemado se podría considerar menos problemática para la monitorización ambiental que la subestimación causada en la clasificación mediante MVS ya que estas áreas se consideran afectadas. Se prefiere la sobreestimación de las zonas afectadas por actividad antropogénica ya que estas se pueden determinar por análisis cualitativo, lo que contribuye a la gestión medioambiental. De esta forma, los errores de este tipo en las áreas afectadas se consideran más deseables que los falsos negativos.

La comparación entre los resultados de la MVS y la MV muestra que ambos presentaron similares índices de precisión. Los valores obtenidos para la clasificación mediante la MV son virtualmente idénticos a los del clasificador MVS, ya que en general los valores de precisión y del índice de Kappa son, 86.01% y 0.84 respectivamente. El Cuadro N° 2 en pagina 9 muestra la matriz de errores de los resultados obtenidos para la clasificación por MV.

De acuerdo con la matriz de errores (Cuadro N° 2) obtenida mediante la MV, las categorías para las que se obtienen una menor precisión son Rocas, Sin Vegetación y Quemado. Tales errores son parecidos a los resultantes de la clasificación por MVS, los cuales han sido ya presentados en este artículo. Además, los resultados para las categorías Agua, Campos, Rocas y Edificios obtenidos mediante MV son más precisos de acuerdo con la matriz de errores. Para confirmar la similitud entre los resultados de estos dos algoritmos se aplicó el test estadístico de McNemar, cuyo resultado fue $X^2 = 0,66$. Como $X_{tab} = 6,64$ y $X^2 < X_{tab}$, las diferencias entre la MVS y la MP no son significativamente diferentes en un porcentaje de 99% de confianza.

Mediante la comparación cualitativa de los resultados de la MVS y la MV, se puede determinar que, en términos generales, las dos clasificaciones son muy parecidas, lo cual queda confirmado por el test estadístico. La MVS, sin embargo, proporciona una localización y distribución de las diferentes categorías ligeramente mejor de acuerdo

con el análisis cualitativo. Las Figuras N° 10 a 12 muestran las pequeñas diferencias entre algunas de las distribuciones espaciales de categorías del suelo obtenidas.




Figura 10 - Comparación entre la distribución espacial de las categorías Campos y Sin Vegetación. Fuente: Elaboración propia.




Figura 11 - Comparación de la distribución espacial de la categoría Hormigón. Fuente: Elaboración propia.




Figura 12 - Comparación entre la distribución espacial de las categorías Campos y Rocas. Fuente: Elaboración propia.

Los resultados obtenidos con ambos clasificadores son parecidos en términos cuantitativos de manera que los resultados de la MVS no difieren significativamente de los del clasificador MV. Foody & Marthur (2006) determinaron que la principal ventaja de la MVS es que permite obtener buenos y precisos resultados a partir de muestras de pequeño tamaño, así en este caso, el algoritmo se focaliza en la separación de categorías y no en la descripción de las mismas. Además, los métodos de muestreo empleados en este trabajo siguen los requisitos para obtener un buen rendimiento del algoritmo de MV. Pal & Mather (2005) hallaron que los resultados obtenidos por la MVS presentan una precisión significativamente más alta que los obtenidos por MV cuando la dimensionalidad del espacio de características de las imágenes es extensa, ya que los resultados de la MV quedan limitados por el Efecto de Hughes (Hughes, 1968). La observación de dicho efecto sobre la clasificación obtenida por MV fue también determinada por Oommen *et al.* (2008). Sin embargo, cómo las imágenes de satélite usadas en este estudio han sido obtenidas utilizando solo cuatro canales, el efecto de Hughes no está presente ya que la dimensionalidad considerada no es lo suficientemente grande.

De esta forma, el uso de la MVS previo al de la MV solo está justificado cuando se requiere mayor robustez. La MVS no presenta importantes restricciones en el proceso de muestreo, ya que muestras pequeñas generan buenos resultados (Mather & Koch, 2011) y la MVS presenta un buen rendimiento en la clasificación de imágenes multiespectrales (Oommen *et al.*, 2008; Pal & Mather, 2005).

Se debe considerar que, a pesar de que los altos valores de precisión obtenidos en este estudio para el algoritmo MV son similares a los obtenidos para el MVS, el primero tiene la ventaja de presentar un menor requerimiento computacional. Este resultado hace que el algoritmo de MV sea una buena opción cuando el

analista dispone de muestras representativas.

El estudio realizado se podría mejorar probablemente si se utilizara más de una imagen para verificar la consistencia de los resultados obtenidos, por ejemplo imágenes de diferentes embalses con distintos tipos de cobertura vegetal y/o características geográficas. Sin embargo, en este estudio se utiliza solo una imagen debido a limitaciones en la financiación y fecha de entrega del proyecto, por lo que se sugiere que la misma investigación se lleve a cabo en diferentes áreas en trabajos futuros.

Además, se sugiere que se valide en futuros trabajos el rendimiento de la MVS con respecto a la dinámica de los cambios en la cobertura del suelo. En este caso, una imagen obtenida con el mismo sensor del satélite, de la misma área pero en una fecha diferente debería ser utilizada para evaluar el rendimiento de la MVS con respecto a la dinámica de los cambios en los usos del suelo en los alrededores de la presa hidroeléctrica.

4. CONCLUSIONES

La realización de este trabajo fue inicialmente motivada por el deseo de comprender y evaluar los diferentes dominios de la superficie terrestre de los alrededores de una presa hidroeléctrica, lo cual puede ayudar en el establecimiento de políticas de conservación en relación a la expansión de los asentamientos en la presa. Con los resultados se espera poder evitar la contaminación del lago y otros problemas ambientales, disminuyendo así el coste de mantenimiento del equipamiento hidroeléctrico, y proporcionar herramientas para una mejor utilización de las tierras alrededor de la presa.

El propósito principal del artículo fué mostrar una comparación de los resultados de mapeado de CTUS de los algoritmos MVS y MV en las cercanías

de una presa hidroeléctrica utilizando imágenes de satélite con alta resolución espacial. Las clasificaciones fueron aplicadas a una imagen de satélite de la planta hidroeléctrica Luis Eduardo Magalhães la cual está localizada en el municipio de Lajeado (estado de Tocantins, Brasil).

LAS PRINCIPALES CONCLUSIONES DEL PRESENTE ESTUDIO SON:

La MVS y la MV así como las categorías adaptadas del sistema Corine, complementando las adoptadas por el IBGE, son adecuadas para la clasificación de CTUS mediante imágenes de satélites de alta resolución espacial y el índice Jeffries-Matusita;

En los dominios correspondientes a las áreas de presas hidroeléctricas donde, como en este caso, se carece de información previa disponible, la metodología desarrollada es crucial para la monitorización medioambiental. A final, el trabajo identificó que el gestor de la presa debe atender para el uso del fuego en la región;

Una evaluación de la matriz de error permite análisis que pueden apoyar la toma de decisiones sobre los aspectos ambientales de interés para el gestor de presa de generación de energía.

En imagen multiespectral y con muestras representativas, los algoritmos MV y MVS presentaron resultados similares. En general, la literatura recomienda el algoritmo MVS cuando las muestras no son representativas para todo el espacio de atributos. Cuando las muestras son significativas, la ventaja del algoritmo MV es un menor requerimiento computacional.

La totalidad de resultados son precisos, por tanto la gestión de las presas hidroeléctricas puede ser mejorada. Los resultados de la clasificación y del trabajo de campo muestran que el gestor debe prestar especial atención, en este caso, a las zonas correspondientes a la categoría Quemado. El analista debe

evaluar dichas regiones ya que la población local no tiene mucho conocimiento sobre el uso adecuado de la tierra. En neste caso, la ocurrencia de fuegos fue confirmada por visitas a la zona, sin embargo hay un problema en la identificación de dichas áreas mediante las clasificaciones: un número de pixeles dentro de la categoría Campos (en algunos casos correspondientes a pastos) son erróneamente incluidos en la categoría Quemado. Esto podría ser peligroso, ya que tanto en los campos de pastos como en cualquier tipo de agricultura se pueden realizar en algún momento actividades de quema, por tanto no podemos determinar los futuros usos del suelo. Sin embargo, estos errores de clasificación estimulan el gestor a comprobar lo que ocurre en las zonas incluidas en la categoría Quemado.

AGRADECIMENTOS

Los autores del presente estudio desean agradecer al Conselho Nacional de Pesquisa (CNPq) por la beca concedida a los investigadores; a la Escuela Politécnica de la Universidad de Sao Paulo y al Programa de Postgrado de Ingeniería de Transportes por apoyar la investigación; también a la Profa. Linda Lee Ho por sus sugerencias durante la edición final y al personal de la Planta Hidroeléctrica Luiz Eduardo, en Lajeado, por facilitar la imagen de satélite y el soporte logístico durante el trabajo de campo.

REFERENCIAS

- AGRESTI, A. (1996) **An Introduction to Categorical Data Analysis**. Wiley, New York, N.Y.: 312 p.
- BOSSARD, M.; FERANEC, J.; OTAHEL, J. CORINE (2000) **Land cover technical guide – Addendum 2000**. Technical Report - European Environment Agency, n. 40.
- BURGES, C. (1998) **A tutorial on support vector machines for pattern recognition**.

- Data Mining and Knowledge Discovery, v.2, n.2, p. 121-167.
- BÜTTNER, G. CORINE (2014) Land Cover and Land Cover Change Products. En: Land Use and Land Cover Mapping in Europe. **Springer Netherlands**. pp. 55-74.
- CAMPBELL, J. B. (2008) **Introduction to Remote Sensing**. New York: Guildford Press, 626 p.
- CONG, P.; HOWART, P. J. (1990) An assessment of some factors influencing multispectral land-cover classification. *Photogrammetric Engineering and Remote Sensing*. **Bethesda**, v. 56, n. 5, p. 597-603.
- CONGALTON, R. G., and GREEN, K. (1999) **Assessing the Accuracy of Remotely Sensed Data: Principles and Practices**. Lewis Publishers, New York: 137p.
- CONGALTON, R. G. (2005) Thematic and Positional Accuracy Assessment of Digital Remotely Sensed Data. En: Proceedings of the Seventh Annual Forest Inventory and Analysis Symposium, 2005. **USDA Forest Service**, 2005, p. 149-154.
- DUTTA, S.; SHARMA, S.A.; KHERA, A.P.; AJAI, YADAV, M.; HOODA, R.S.; MOTHIKUMAR, K.E.; MANCHANDA, M.L. (1994) Accuracy assessment in cotton acreage estimation using Indian remote sensing satellite data. **Journal of Photogrammetry and Remote Sensing**, v.49, n.6, p. 21-26.
- FOODY, G. M. (2004) Thematic Map Comparison: Evaluating the Statistical Significance of Differences in Classification Accuracy. **Photogrammetric Engineering & Remote Sensing**, Vol. 70, No. 5, p. 627–633.
- FOODY, G. M.; MATHUR, A. (2004) Toward Intelligent Training of Supervised Image Classifications: Directing Training Data Acquisition for SVM Classification. **Remote Sensing of Environment**, v. 93, p. 107-117.
- GEOEYE (2010) **GeoEye Product Guide**. Dulles – Virginia - United States of America: Printed by GeoEye. Version 2.
- GIGANDET, X.; CUADRA, M. B.; POINTET, A.; CAMMOUN, L.; CALOZ, R.;

- THIRAN, J. (2005) Region-based satellite image classification: method and validation. **Image Processing**, v. 3. p. 832-835.
- GUALTIERI, J. and CROMP, R. (1998) Support vector machines for hyperspectral remote sensing classification. En: AIPR WORKSHOP, 27, 1998, Washington, D. C. Proceedings of SPIE... Washington D. C.: **The International Society for Optical Engineering** 3584, October 14 to 16 in 1998, p. 221–232.
- HSU, C.W.; CHANG, C.C; LIN, C.J. (2010) **A Practical Guide to Support Vector Classification**. Department of Computer Science, National Taiwan University. (Technical report).
- HUGHES, G. F. (1968) On the mean accuracy of statistical pattern recognizers, IEEE Trans. Inform. **Theory**, vol. 14, no. 1, pp.55–63.
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (2006) Manual Técnico de Uso da Terra. Rio de Janeiro: Manuais Técnicos em Geociências, n.7. 91p.
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA – IBGE. (2010). Censo Demográfico - 2010. In: <http://ibge.gov.br/cidadesat/painel/economia.php?lang=&codmun=171200&search=tocantins|lajeado|infograficos:-despesas-e-receitas-orcamentarias-e-pib>
- IWAI, O. K.; QUINTANILHA, J. A. (2005) Utilização de imagens de satélite como ferramenta de auxílio ao planejamento urbano. **Revista de Geografia Norte Grande**, v. 34, p. 65-82.
- JARDINI, M. G. M.; JARDINI, J. A.; MAGRINI, L. C.; CRISPINO, F.; QUINTANILHA, J. A.; PINFARE, J. C.; SILVA, L. R. (2011) **Monitoring system for hydroelectric reservoir using high resolution satellite images**. En: IEEE Trondheim PowerTech 2011, Trondheim. Proceedings... Norway: IEEE Trondheim PowerTech, 2011.
- JENSEN, J. R. (1986) **Introductory Digital Image Processing**. United States of America: Prentice-Hall, 379p.

- LILLESAND, T. M.; KEIFER, R. W.; CHIPMAN, J. W. (2008) **Remote Sensing and Image Interpretation**. Hoboken, NJ John Wiley & Sons, New York, 756 p.
- MATHER, P.; KOCH, M. (2011) **Computer Processing of Remotely Sensed Images: an Introduction**. 4^a ed. England: John Wiley & Sons, Chichester, 434p.
- MICHALIJOS, M. P.; UBOLDI, J. (2013) Propuesta metodológica para la evaluación de áreas afectadas por incendios mediante el uso de imágenes satelitales (Sierra de la Ventana, Argentina). **Revista de Geografía Norte Grande**, v. 56, p. 223-234.
- OOMMEN, T.; MISRA, D.; TWARAKAVI, N. K. C.; PRAKASH, A.; SAHOO, B.; BANDOPADHYAY, S. (2008) An Objective Analysis of Support Vector Machine Based Classification for Remote Sensing. **Math Geosci**, v. 40, p. 409-424.
- PAL, M.; MATHER, P. (2004) Assessment of the effectiveness of support vector machines for hyperspectral data. **Future Generation Computer Systems**, v. 20, n. 7, p. 1215–1225.
- PAL, M. & MATHER, P.M. (2005) Support vector machines for classification in remote sensing. *International Journal of Remote Sensing*, v. 26, n. 5, p. 1007–1011.
- RICHARDS, J.A.; JIA, X. (1999) **Remote Sensing Digital Image Analysis: An Introduction**, 3rd ed. Ed. Springer-Verlag, New York: p. 273-274
- SCHOWENGERDT, R. A. (2007) *Remote Sensing – Models and Methods for Image Processing*, 3rd ed. United States of America: Academic Press, 515p.
- SKOLE, D.L., CHOMENTOWSKI, W.H., SALAS, W.A., NOBRE, A.D. (1994) Physical and Human Dimensions of Deforestation in Amazonia. **Bioscience**, v. 44, n. 5, p. 314-322.
- SONG, M.; CIVCO, D. (2004) Road Extraction Using SVM and Image Segmentation. *Photogrammetric Engineering & Remote Sensing*, v. 70, n. 12, p. 1365–1371.
- STEIN, A.; VAN DER MEER, F.; GORTE, B. (1999) **Spatial Statistics for Remote Sensing**. Netherlands: Kluwer Academic Publishers, 284p.

- TZOTSOS A.; ARGIALAS D. (2008) Support Vector Machine Classification for Object-Based Image Analysis. In: BLASCHKE T., LANG S., HAY G.J. (org.) Object-Based Image Analysis. **Lecture Notes in Geoinformation and Cartography**. Ed. Springer, Berlin, Heidelberg: p. 663-677. Disponível em: < https://link.springer.com/chapter/10.1007/978-3-540-77058-9_36 > Acesso em 04 de setembro de 2017.
- WARNER, T. A.; FOODY, G. M.; NELLIS, M. D. (2009) **The SAGE Handbook of Remote Sensing**. London: SAGE Publications Ltd, 504p.