



UdelAR / FING / IA
Departamento de Geomática

Prof. Asist. Grdo. 2, Geógrafo Eduardo Vasquez

Captura de Datos por Percepción Remota

5.2 - Clasificación de imágenes e integración de datos. Clasificación digital. Métodos estadísticos. Clasificación supervisada y automática o no supervisada. Proceso de selección de muestras. Procesos para obtención de resultados y determinación de firmas espectrales. Procesos de clasificación. Clasificación de contexto. Clasificación multitemporal. Clasificación por Redes neuronales. Clasificación por clasificadores borrosos.



Clasificación de imágenes e integración de datos.

Procesos de clasificación.

Evaluación de resultados. Matriz de confusión.

MÓDULO V

Sistemas de clasificación de imágenes y evaluación de resultados.

5.2 - Clasificación de imágenes e integración de datos. Clasificación digital. Métodos estadísticos. Clasificación supervisada y automática o no supervisada. Proceso de selección de muestras. Procesos para obtención de resultados y determinación de firmas espectrales. Procesos de clasificación. Clasificación de contexto. Clasificación multitemporal. Clasificación por Redes neuronales. Clasificación por clasificadores borrosos.


5.2 Extracción de información temática. Clasificación.

Clasificación de imágenes e integración de datos. Clasificación digital. Métodos estadísticos. Clasificación supervisada y automática o no supervisada. Proceso de selección de muestras. Procesos para obtención de resultados y determinación de firmas espectrales. Procesos de clasificación. Clasificación de contexto. Clasificación multitemporal. Clasificación por Redes neuronales. Clasificación por clasificadores borrosos.

CLASIFICACIÓN DIGITAL

es un proceso de generalización temática
que,

[http://www.teledet.com.uy/tutorial-
imagenes-satelitales/clasificacion-no-
supervisada.htm](http://www.teledet.com.uy/tutorial-
imagenes-satelitales/clasificacion-no-
supervisada.htm)




mediante **categorización**
convierte

INFORMACIÓN CUANTITATIVA

de una imagen, en

INFORMACIÓN CUALITATIVA

[http://www.teledet.com.uy/tutorial-
imagenes-satelitales/clasificacion-no-
supervisada.htm](http://www.teledet.com.uy/tutorial-
imagenes-satelitales/clasificacion-no-
supervisada.htm)



**generación de información
cuantitativa a partir de una
cualitativa**

DEFINICIONES

la CLASIFICACIÓN MULTIESPECTRAL

es el proceso de ordenar pixeles en una cantidad finita de clases o categorías

SI UN PIXEL SATISFACE
CIERTO CRITERIO, ES
ASIGNADO A LA CLASE
CORRESPONDIENTE A ESE
CRITERIO.

PROCESO QUE A VECES
TAMBIÉN SE LE DENOMINA
"SEGMENTACIÓN"

**clasificación
multiespectral, haciendo
uso del potencial de una XS**

las clases



GENERALIDADES

LA ELABORACIÓN DE UNA CLASIFICACIÓN DEL ÁREA DE ESTUDIO, EN UNA SERIE DE CLASES RELATIVAS A UNA TEMÁTICA ESPECIAL, ES UNO DE LOS

OBJETIVOS FUNDAMENTALES DE LA TELEDETECCIÓN


LA CLASIFICACIÓN EN TELEDETECCIÓN ES, UN CASO PARTICULAR DEL PROBLEMA GENERAL

DE CLASIFICAR N INDIVIDUOS EN UN CONJUNTO DE K CLASES EN FUNCIÓN DE UNA SERIE DE VARIABLES CUANTITATIVAS ($X_1, X_2, X_3, \dots, X_N$)

PARA SU RESOLUCIÓN LO QUE NECESITAMOS ES UNA MEDIDA DE LA SEMEJANZA O DIFERENCIA ENTRE LOS INDIVIDUOS Y ENTRE LOS INDIVIDUOS Y LAS CLASES

como obtener una serie de clases, para una temática definida

<http://edoc.hu-berlin.de/dissertationen/diaz-lacava-amalia-nahir-2003-07-16/HTML/image032.gif>




GENERALIDADES

- LA **MEDIDA** QUE SE UTILIZA EN MAYOR PARTE, ES LA

DISTANCIA EUCLIDIANA

AUNQUE PUEDE UTILIZARSE OTRO TIPO DE DISTANCIAS.



https://es.wikipedia.org/wiki/Distancia_euclidiana

- PARA **ESTIMAR** LOS VALORES DE LAS VARIABLES X_i , PARA LAS DIFERENTES CLASES, SE UTILIZA LA

MEDIA ARITMÉTICA

DE LOS VALORES DE LOS PÍXELES INCLUIDOS EN LA CLASE

**conceptos de medida
y estimaciones**

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n a_i = \frac{a_1 + a_2 + \dots + a_n}{n}$$

https://es.wikipedia.org/wiki/Media_aritm%C3%A9tica

GENERALIDADES

COMO EN LA PRÁCTICA NO PODEMOS SABER CON CERTEZA A QUE CLASE
CORRESPONDE CADA UNO DE LOS PÍXELES

EL **PROBLEMA DE CLASIFICACIÓN** SE CONVIERTE EN UN **PROBLEMA DE
PROBABILIDAD** DE PERTENENCIA A CADA UNA DE LAS CLASES DE UN CONJUNTO

PARA SU RESOLUCIÓN ES QUE SE UTILIZAN EN MAYOR PARTE

MÉTODOS ESTADÍSTICOS

**conceptos de medida
y estimaciones**



<http://aprendiendoadministracion.com/que-es-la-estadistica-definicion-historia-y-metodos-estadisticos/>

FASES EN LA CLASIFICACIÓN

EL PROCEDIMIENTO DE CLASIFICACIÓN SUPONE DOS FASES:

DEFINICIÓN DE LAS CLASES

<http://www.definicionabc.com/historia/sociedad-estamental.php>



ADJUDICACIÓN DE CADA UNO DE LOS PÍXELES

el procedimiento de
clasificación



<https://www.pinterest.com/pin/497225615082798608/>

FASE I – DEFINICIÓN DE CLASES

SUPONIENDO QUE LOS DATOS HAN PASADO YA TODO TIPO DE CORRECCIONES NECESARIAS, **EXISTEN DOS MÉTODOS COMPLEMENTARIOS** PARA AFRONTAR LA DEFINICIÓN DE CLASES, ESTOS SON VÁLIDOS EN IMÁGENES DE SATELITE COMO EN CUALQUIER OTRO CAMPO




CLASIFICACIÓN CON CONTROL

CLASIFICACIÓN SIN CONTROL

<http://noticias.universia.edu.ve/tag/estudiar/>

procedimientos generalizados para toda imagen



<http://aprendiendoadministracion.com/que-es-la-estadistica-definicion-historia-y-metodos-estadisticos/>

PROCESO EN LA CLASIFICACIÓN

a cada pixel de la imagen, se le asigna un valor o clase, según un criterio matemático basado en información estadística la que es derivada de las características espectrales de los píxeles de la imagen

CLASIFICACIÓN SUPERVISADA



EXISTE DOS FORMAS
FRECUENTES DE
CLASIFICACIÓN



CLASIFICACIÓN NO SUPERVISADA (*clustering*)

**tipos o formas de
clasificación**

MI UNIVERSO DE DATOS




<http://www.quierodibujos.com/Dibujos-para-Colorear-de-Monstruos/590>

CLASIFICACIÓN SUPERVISADA



selección de la muestra



signatures o firma espectral

$$ax^2 + bx + c = 0$$
$$-b \pm \sqrt{b^2 - 4ac}$$

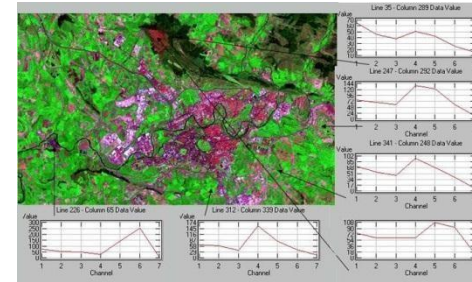
clasificación



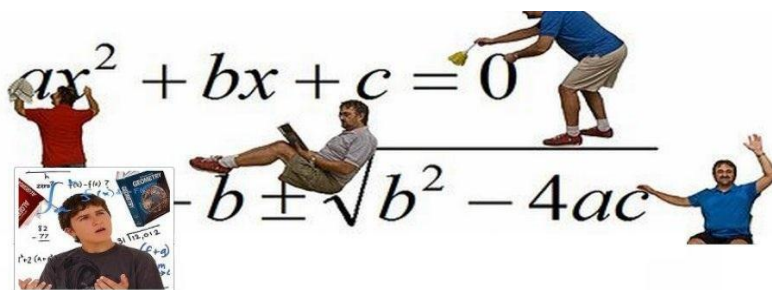
CLASIFICACIÓN NO SUPERVISADA



generación de clusters



signatures o firma espectral



clasificación



CLASIFICACIÓN SUPERVISADA

SE BASA EN LA **DISPONIBILIDAD DE ÁREAS DE ENTRENAMIENTO**

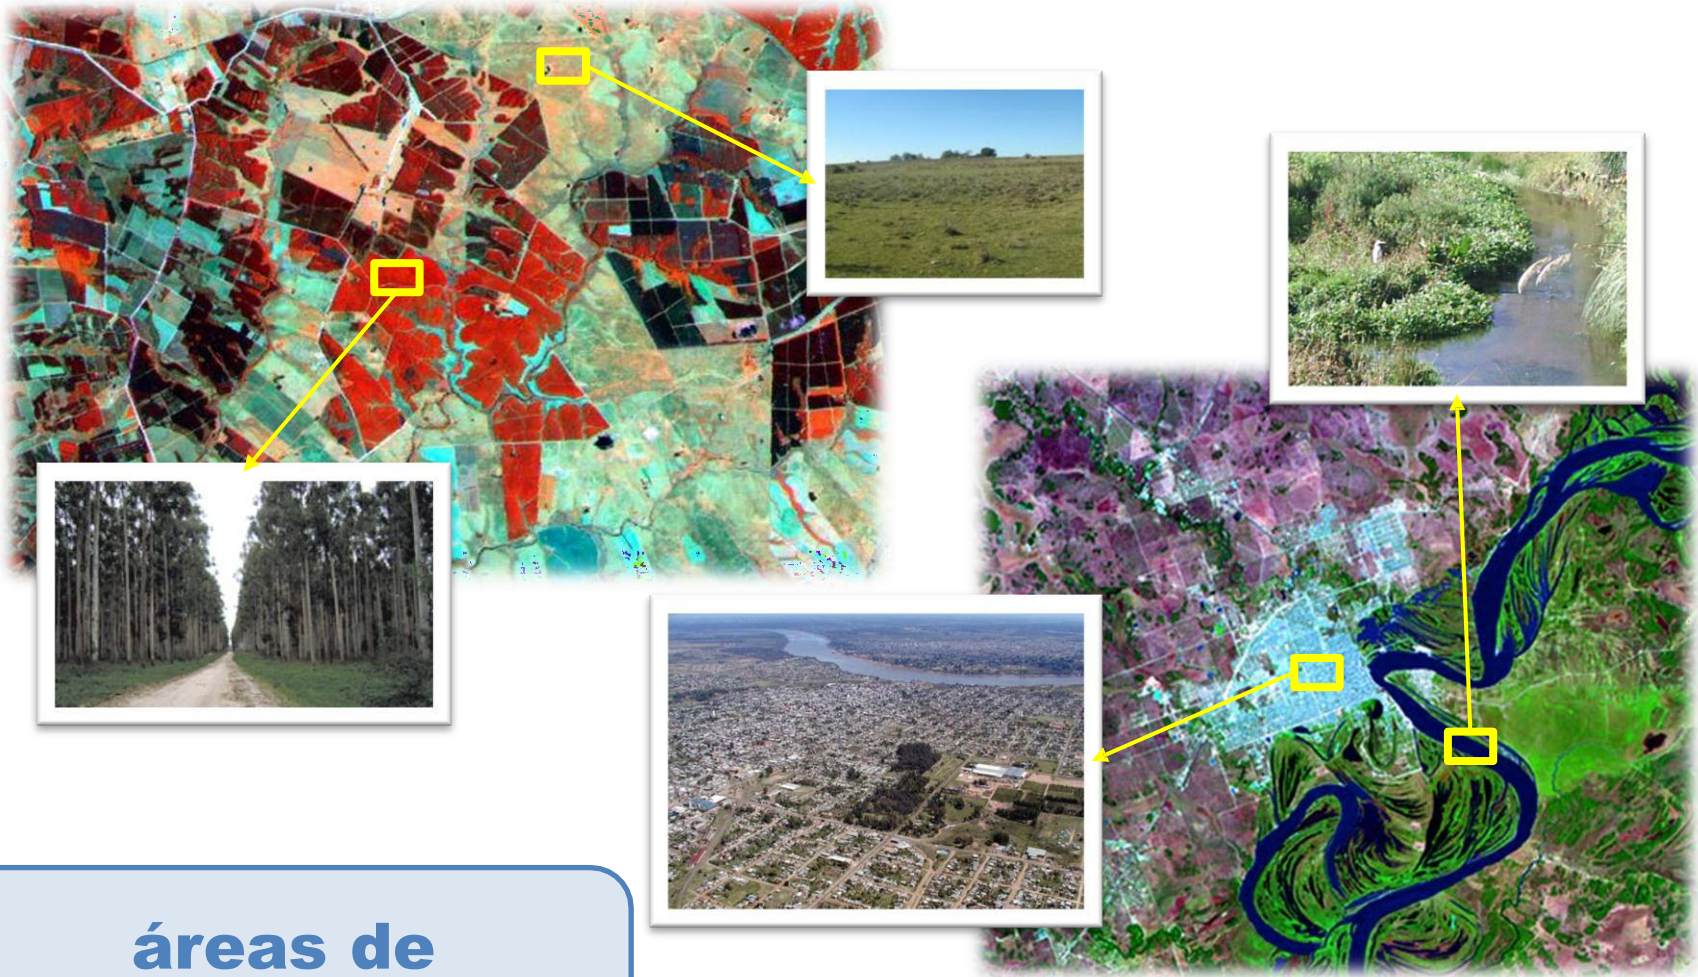
SE TRATA DE ÁREAS DE LAS QUE **SE CONOCE A PRIORI LA CLASE A LA QUE PERTENECEN** Y QUE SERVIRÁN PARA **GENERAR UNA SIGNATURA ESPECTRAL CARACTERÍSTICA DE CADA UNA DE LAS CLASES**

SE DENOMINAN **CLASES INFORMACIONALES**. ESTAS DEBEN SER ÁREAS LO MÁS **HOMOGÉNEAS** POSIBLES Y EN LAS QUE **SEAMOS LO QUE HABÍA EL DÍA QUE SE TOMÓ LA IMAGEN**.

LA RESPUESTA ESPECTRAL DE UNA **CLASE**, SERÁ LA **RESPUESTA ESPECTRAL MEDIA DE SUS PÍXELES**,

**lineamientos
básicos**

CLASIFICACIÓN SUPERVISADA



**áreas de
entrenamiento**

SELECCIÓN DE MUESTRAS

PASO 1

se seleccionan en la imagen, zonas o áreas con pixeles pertenecientes a un elemento conocido

INFORMACIÓN RESULTADO DE UN RELEVAMIENTO DE CAMPO
CONOCIMIENTO DEL TERRITORIO
..... DIVERSAS FUENTES

PASO 2


cada una de las muestras

DEBEN ABARCAR UN NÚMERO DE PIXELS, REPRESENTATIVOS DE LA CLASE
CANTIDAD DE MUESTRAS TAL QUE ABARQUE LAS DIFERENTES SITUACIONES PARA EL ELEMENTO EN CUESTIÓN

PASO 3

se debe de evaluar cada muestra, para confirmar su inclusión o no a la misma

HISTOGRAMA POR BANDA CON DISTRIBUCIÓN NORMAL
GRÁFICOS DE BANDA CONTRA BANDA



**procedimiento
y fases**

<http://www.quierodibujos.com/Dibujos-para-Colorear-de-Monstruos/590>

SIGNATURA O FIRMA ESPECTRAL

NOTA 1

las muestras seleccionadas están confirmadas

PROCESO VALIDADO EN EL MOMENTO DE ASIGNACIÓN DE MUESTRAS

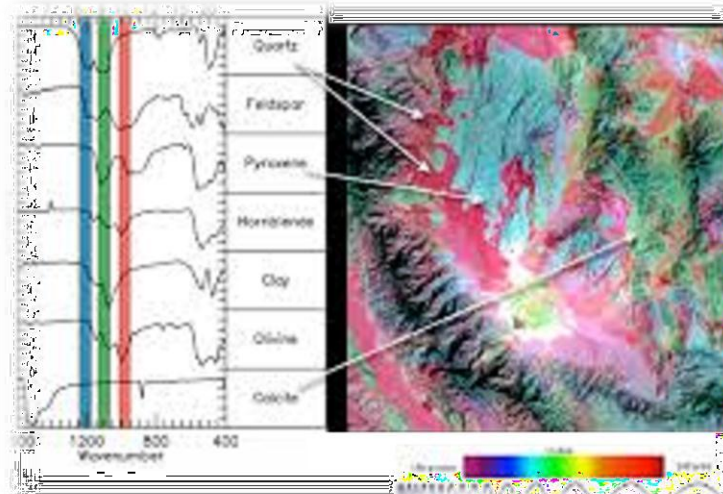
NOTA 2

aportan información estadística para la clasificación

SON LOS VALORES SOBRE LOS QUE SE BASARÁ EL PROCESO ESTADÍSTICO, PARA LA INCLUSIÓN DEL RESTO DE LOS PÍXELES A CADA UNA DE LAS CLASES

<http://www.ufrgs.br/enqcart/PDASR/hist.html>

**es lo esencial en la
clasificación
supervisada**



SIGNATURA O FIRMA ESPECTRAL

NOTA 3

es un ejemplo de la respuesta espectral en cada banda, del elemento que representa

REPRESENTARÁ A COMO RESPONDE ESPECTRALMENTE CADA ELEMENTO EN CADA UNA DE LAS BANDAS, ES LO QUE SE LLAMA FIRMA ESPECTRAL


NOTA 4

son usadas como reglas de decisión para la asignación de pixeles a las clases

SON LA ESENCIA DE LA CLASIFICACIÓN SUPERVISADA

<http://www.ufrgs.br/enqcart/PDASR/hist.html>

es lo esencial en la clasificación supervisada



PROCESOS PARA OBTENER RESULTADOS

OBSERVACIÓN 1

objetivo fundamental, asignar cada pixel del área en estudio, a una clase conocida

OBSERVACIÓN 2

el resultado, una IMAGEN con el área de estudio subdividida en clases conocidas (derivadas de las muestras)

OBSERVACIÓN 3

son varios los algoritmos a aplicar en los procesos de clasificación (*válidos también para la clasificación no supervisada*), **comúnmente se utilizan dos:**

MAXIMUM LIKELIHOOD

ESTIMACIÓN DE MÁXIMA VEROSIMILITUD - **ML**

CLASS PROBABILITY

CLASIFICADOR PROBABILÍSTICO CON PREDICCIÓN - **CP**

objetivos y procedimientos existentes, ML y CP

PROCEDIMIENTOS Y PROCESOS EN CLASIFICACIÓN

maximum likelihood / ML

ESTIMACIÓN DE MÁXIMA VEROSIMILITUD

class probability / CP

*CLASIFICADOR PROBABILÍSTICO CON
PREDICCIÓN*

**algoritmos utilizados en la
etapa de asignación de
clases, durante el proceso
de clasificación**


MAXIMUM LIKELIHOOD / ML *ESTADÍSTICO*

1. por cada clase calcula la probabilidad de que un punto, pertenezca a ella en función de sus características espectrales.

2. el punto es asignado a la clase con mayor probabilidad.

<http://www.geo-informatie.nl/courses/qrs20306/lectures/>

ML
es un método totalmente
probabilístico



© Wageningen UR 1997

CONSIDERACIONES SOBRE EL MÉTODO

HIPÓTESIS

- *los datos en cada banda deben de tener una distribución normal*
- *cada clase debe tener distribución normal en el espacio dado por las bandas*
 - *todas las clases deben ser igualmente probables*

VENTAJAS

- *método potente desde el punto de vista matemático, estima muy bien la varianza*
- *para grandes muestras, resulta preciso y puede ser usado cuando se trabaja en modelos y determinación de parámetros*

DEBILIDADES

- *muy sensible a las fallas, con pocos yerros puede tener un resultado muy sesgado*
- *calculo muy complejo, por lo que está sujeto a procesos importantes (tiempo y recursos de equipamiento).*

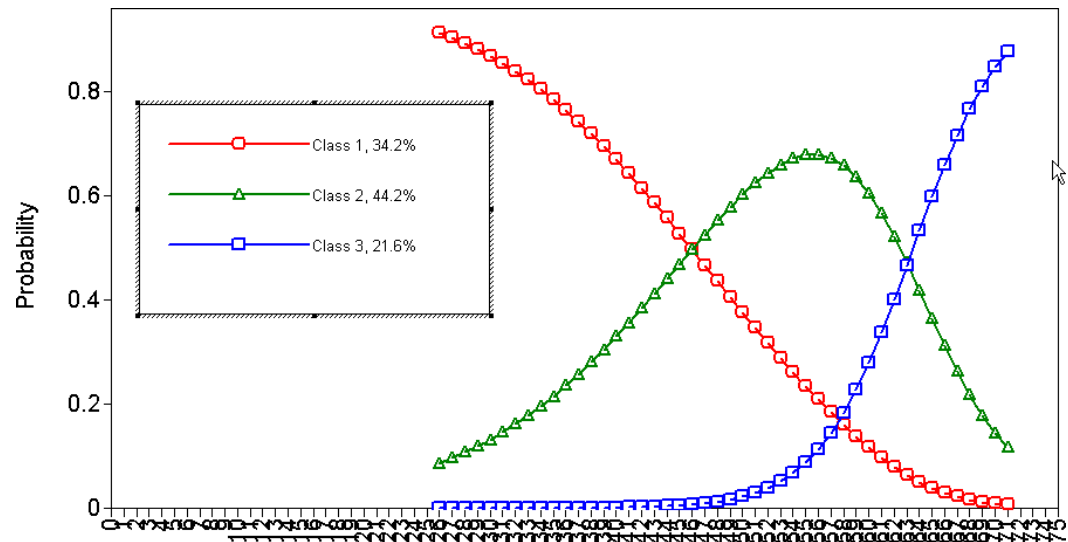
**maximum
likelihood**

<http://ignaciosantiago.com/blog/beneficios-redes-sociales/>

CLASS PROBABILITY / CP *ESTADÍSTICO CON INFO CONTEXTUAL*

1. genera una imagen por cada clase, la que contiene la probabilidad de cada pixel de pertenecer a esa clase.

2. según el caso, permite manualmente, crear nuevas clases teniendo en cuenta las probabilidades de cada clase.



<http://www.geo-informatie.nl/courses/grs20306/lectures/>

CP
es un método que utiliza
otra información

CONSIDERACIONES SOBRE EL MÉTODO

HIPÓTESIS

- **Permite trabajar sin considerar una distribución normal de los datos**
 - **La probabilidad define las clases**

VENTAJAS

- **Permite adaptar las clases a clases mixtas y así poder interrelacionar con estándares de clasificación en lo que respecta a coberturas**
 - **Se aplica muy bien a los procesos de segmentación**

DEBILIDADES

- **Generalmente no hay que trabajar solo con ellos, su aplicabilidad se potencia con el uso de otras herramientas y tecnologías**
 - **No todos los software tienen estos algoritmos**

**Class
Probability**

<http://ignaciosantiago.com/blog/beneficios-redes-sociales/>

CLASIFICACIÓN NO SUPERVISADA

NO SE ESTABLECE A PRIORI, NINGUNA CLASE

ES NECESARIO DETERMINAR EL NÚMERO DE CLASES QUE QUEREMOS ESTABLECER Y SE APLICAN ALGORITMOS MATEMÁTICOS DE CLASIFICACIÓN AUTOMÁTICA

POR EJEMPLO, ALGORITMO DE CLUSTERING, QUE DIVIDE EL ESPACIO DE LAS VARIABLES EN UNA SERIE DE REGIONES, DE MANERA QUE SE MINIMICE LA VARIABILIDAD INTERNA DE LOS PÍXELES INCLUIDOS EN CADA REGIÓN.

DEFINE UNA CLASE ESPECTRAL

**lineamientos
básicos**

PROCESOS Y PROCEDIMIENTOS DE CLASIFICACIÓN

TRATA DE COMPRENDER E IDENTIFICAR LOS CLUSTERS DETERMINADOS EN LA IMAGEN

se basa en un algoritmo

ITERATIVE SELF ORGANIZING – ISO

los clusters son calculados usando un subconjunto de pixeles del área de estudio

todos los cálculos son realizados sobre los valores de los pixeles basado en las características espectrales de cada banda y no las espaciales.

utiliza la media derivada de los distintos valores almacenados en las bandas

la varianza y covarianza son calculadas a partir de la variación dentro y entre las bandas

generación de clusters

FASE II – ADJUDICACIÓN DE PÍXELES

AL DISPONER DE UN CONJUNTO DE CLASES Y DE SUS SIGNATURAS ESPECTRALES CARACTERÍSTICAS EXISTEN PROCEDIMIENTOS PARA ADJUDICAR CADA UNO DE LOS PÍXELES A UNA CLASE

ALGORITMOS NO ESTADÍSTICOS – ÁRBOLES DE DECISIÓN, MÍNIMA DISTANCIA, PARALEPÍEDOS

ALGORITMOS ESTADÍSTICOS CLÁSICOS – MÁXIMA PROBABILIDAD

ALGORITMOS CON INTELIGENCIA ARTIFICIAL – LÓGICA BORROSA, REDES NEURONALES, MACHINE LEARNING.

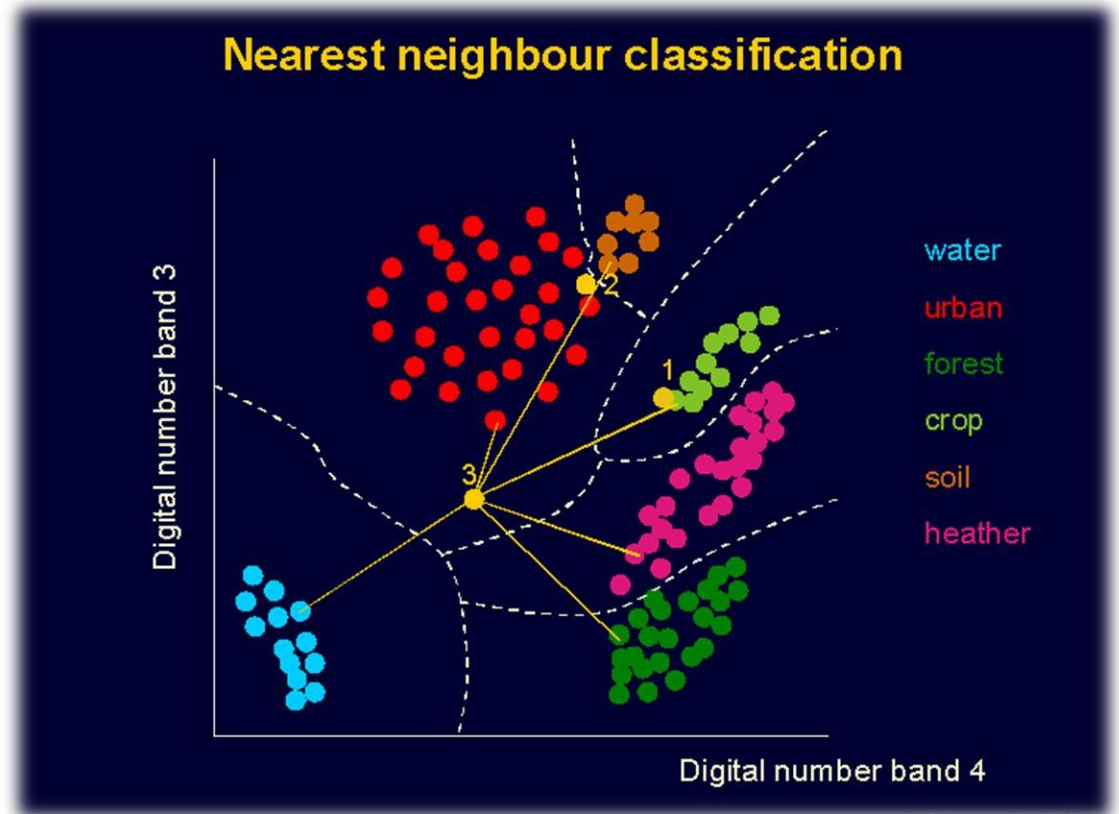
ALGORITMOS QUE UTILIZAN INFORMACIÓN CONTEXTUAL – INFORMACIÓN VECINA

**cada clase generada,
será formada por un
conjunto de píxeles
asignados**

ÁRBOLES DE CLASIFICACIÓN

AJUSTES MUY BUENOS
EN LAS ÁREAS DE
ENTRENAMIENTO

LOS ALGORITMOS SE
ADECUAN SOLO A LOS
PROBLEMAS EN QUE
SE HAN OBTENIDO




**método no
estadístico**

ÁRBOLES DE CLASIFICACIÓN

TÉCNICAS NO ESTADÍSTICAS

ÁRBOLES DE CLASIFICACIÓN



SE PLANTEA UNA SERIE DE CUESTIONES RESPECTO AL PIXEL.

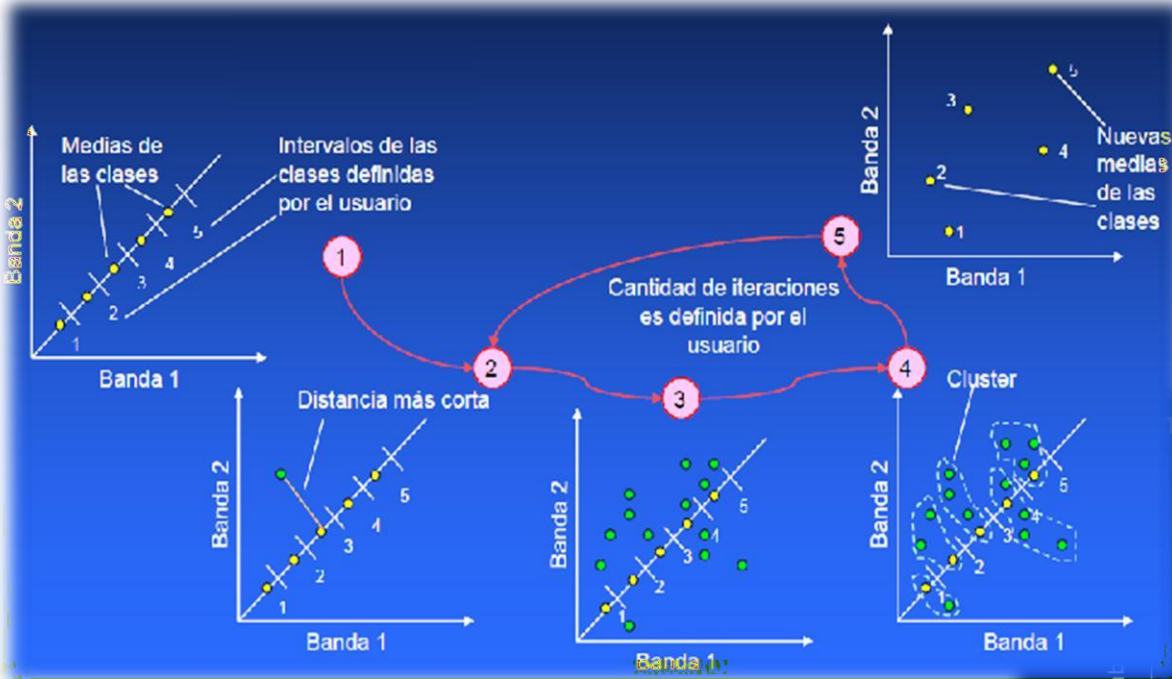
EN FUNCIÓN DE LA RESPUESTA SE HACEN OTRAS PREGUNTAS.

LAS PREGUNTAS SE RELACIONAN CON LOS VALORES DE REFLECTIVIDAD EN LAS DIFERENTES BANDAS.

SE TRATA QUE GEOMÉTRICAMENTE SE DEFINAN FRONTERAS ENTRE CLASES. LA DEFINICIÓN DE LOS CUESTIONAMIENTOS SON UN TANTO SUBJETIVA.

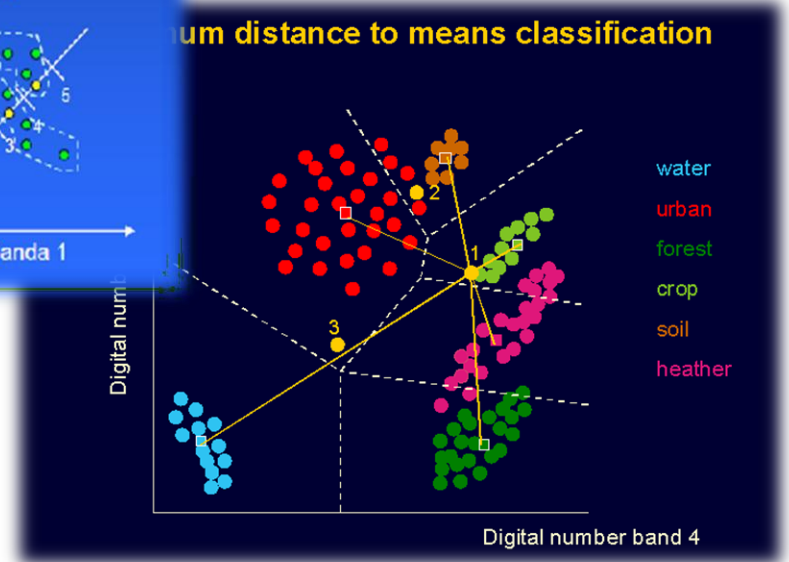
método no estadístico

CLASIFICACIÓN POR MÍNIMAS DISTANCIAS



SOBRE CLASIFICA LA IMAGEN
NINGÚN PIXEL QUEDA SIN CLASIFICAR
GENERALMENTE LOS PÍXELES SITUADOS EN FRONTERAS ENTRE CLASES

OTRO PROBLEMA, ES NO TOMAR EN CUENTA CIERTA CLASE




método no estadístico

CLASIFICACIÓN POR MÍNIMAS DISTANCIAS

TÉCNICAS NO ESTADÍSTICAS

CLASIFICACIÓN POR MÍNIMA DISTANCIA



SE DISPONE PARA CADA CLASE, UNA REFLECTIVIDAD MEDIA PARA CADA BANDA.

SE CALCULA LA DISTANCIA DE LOS PÍXELES A LAS CLASES.

CADA PÍXEL SE ASIGNA A LA CLASE MAS CERCANA.

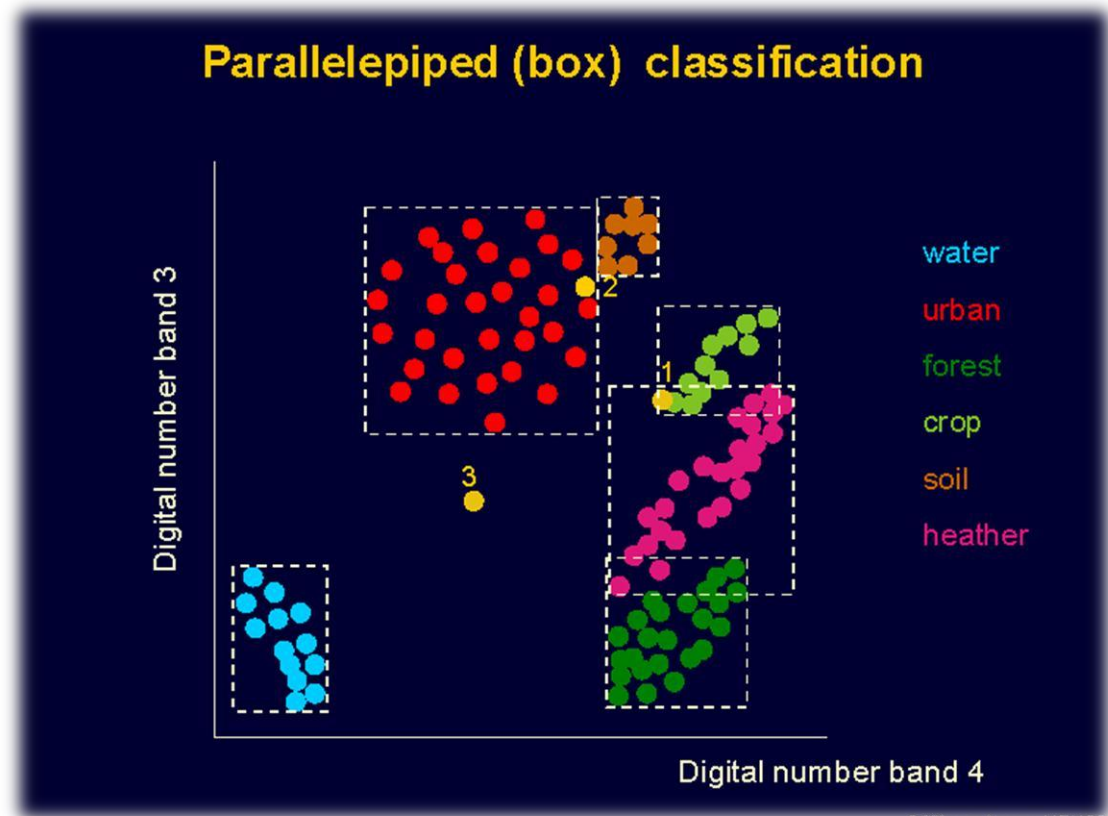
SOBRECLASIFICA LA IMAGEN, NO DEJA PÍXEL SIN CLASIFICAR

NO CONSIDERAN LAS DESVIACIONES TÍPICAS DE CADA UNA DE LAS BANDAS.

método no estadístico

CLASIFICACIÓN POR PARALEPÍPEDOS

EL PROBLEMA ES QUE UN PARALEPIPEDO NO ES LA MEJOR FORMA DE MODELIZAR LA DISPERSIÓN DE LA ÁREAS DE ENTRENAMIENTO Y PUEDE PASAR QUE SE DE SUPERPOSICIÓN




© Wengen et al. 1995

método no estadístico

CLASIFICACIÓN POR PARALEPÍEDOS

TÉCNICAS NO ESTADÍSTICAS

CLASIFICACIÓN POR PARALEPÍEDOS



SE DEFINEN UNA SERIE DE RECTÁNGULOS QUE DEFINEN LAS FRONTERAS DE CADA CLASE


LA DEFINICIÓN ES EN BASE A LOS VALORES MÁXIMOS Y MÍNIMOS DE REFLECTIVIDAD PARA CADA UNA DE LAS BANDAS

PUEDEN APARECER PÍXELES SIN ASIGNAR O PÍXELES ASIGNADOS A VARIAS CLASES

método no estadístico

CLASIFICACIÓN POR MÁXIMA VEROSIMILITUD

LA HIPOTESIS DE QUE
LOS DATOS DE
REFLECTIVIDAD (ND)
SIGUEN UNA
DISTRIBUCIÓN NORMAL,
NO SIEMPRE SE CUMPLE
Y DEBERÍA DE
VERIFICARSE




© Wapeninger, IIR, 1995

**método
estadístico
clásico**

CLASIFICACIÓN POR MÁXIMA VEROSIMILITUD

TÉCNICAS ESTADÍSTICAS



DADO QUE SE TIENE LA MEDIA Y LA DESVIACIÓN TÍPICA DE CADA UNA DE LAS CLASES, SE PUEDE MODELAR LA DISTRIBUCIÓN DE LA PROBABILIDAD.

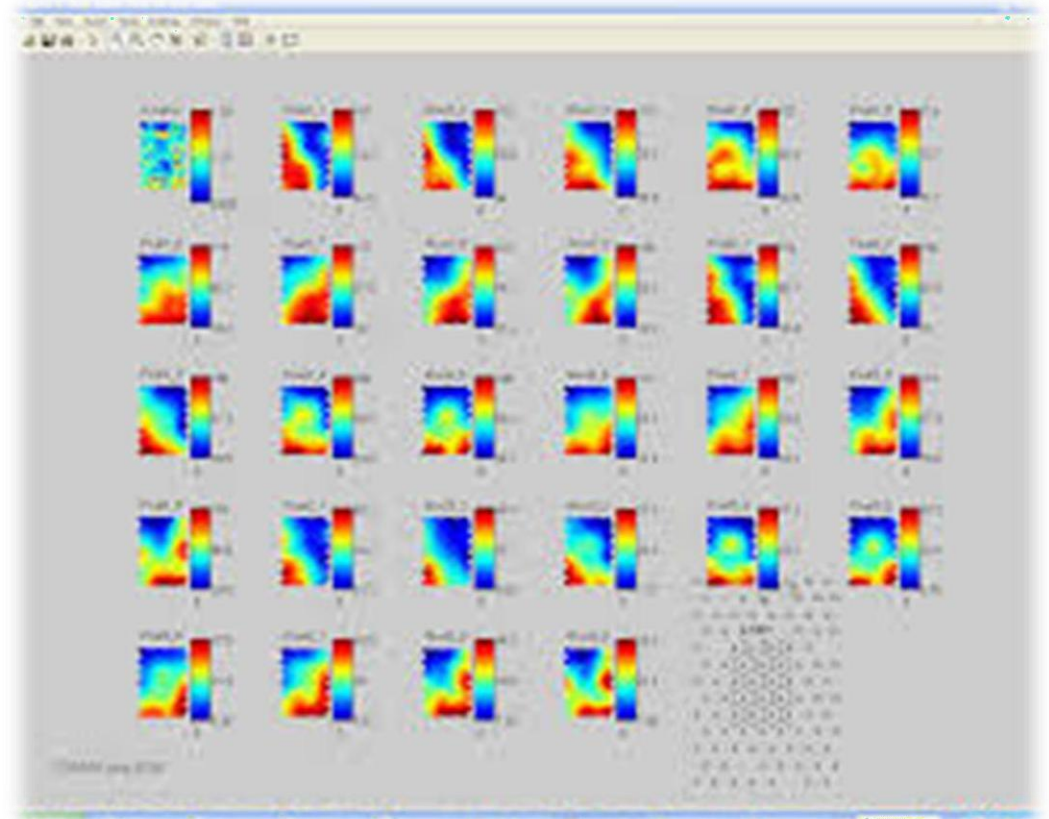
ASUME QUE LOS DATOS SIGUEN UNA FUNCIÓN DE DISTRIBUCIÓN NORMAL.
EL PIXEL SE ASIGNA A LA CLASE MAS PROBABLE.

PERMITE DEFINIR POR ALGÚN CRITERIO LA CALIDAD DE LA ASIGNACIÓN, POR EJEMPLO LA DIFERENCIA ENTRE LA MÁXIMA PROBABILIDAD Y LA SIGUIENTE.

**método
estadístico
clásico**

CLASIFICACIÓN DE CONTEXTO

LA DIFICULTAD LA ENCONTRAMOS EN AQUELLOS CRITERIOS O LA INFORMACIÓN DE BASE PARA DEFINIR LOS CRITERIOS



uso de información adicional, de contexto

CLASIFICACIÓN DE CONTEXTO

TÉCNICAS AVANZADAS CON INFORMACIÓN CONTEXTUAL


CLASIFICACIÓN DE CONTEXTO

CAMBIA EL CONCEPTO, SOBRE LA BASE DE QUE UTILIZAR SOLO LOS VALORES DE REFLECTANCIA NO ES PROBLEMA SI EL ELEMENTO ES MAS CHICO QUE EL TAMAÑO DEL PIXEL, PERO SI EL PIXEL ES MAS PEQUEÑO PODRÍA UTILIZARSE LA INFORMACIÓN DE LOS PÍXELES VECINOS.

ES BUENO UTILIZARLO EN COMBINACIÓN CON EL DE MÁXIMA PROBABILIDAD. POR EJEMPLO PARA DECIDIR EN AQUELLOS CASOS DE PROBABILIDADES DE DOS CLASES SIMILARES O QUE NO EXISTA UNA CLASE CON PROBABILIDAD DE PERTENENCIA CON VALOR ALTO.

TRATA DE INCOORPORAR OTRAS FUENTES DISTINTAS. ALTITUD, PENDIENTE, ETC. Y DICHA INFORMACIÓN LA COMBINA CON LA DE LAS BANDAS.

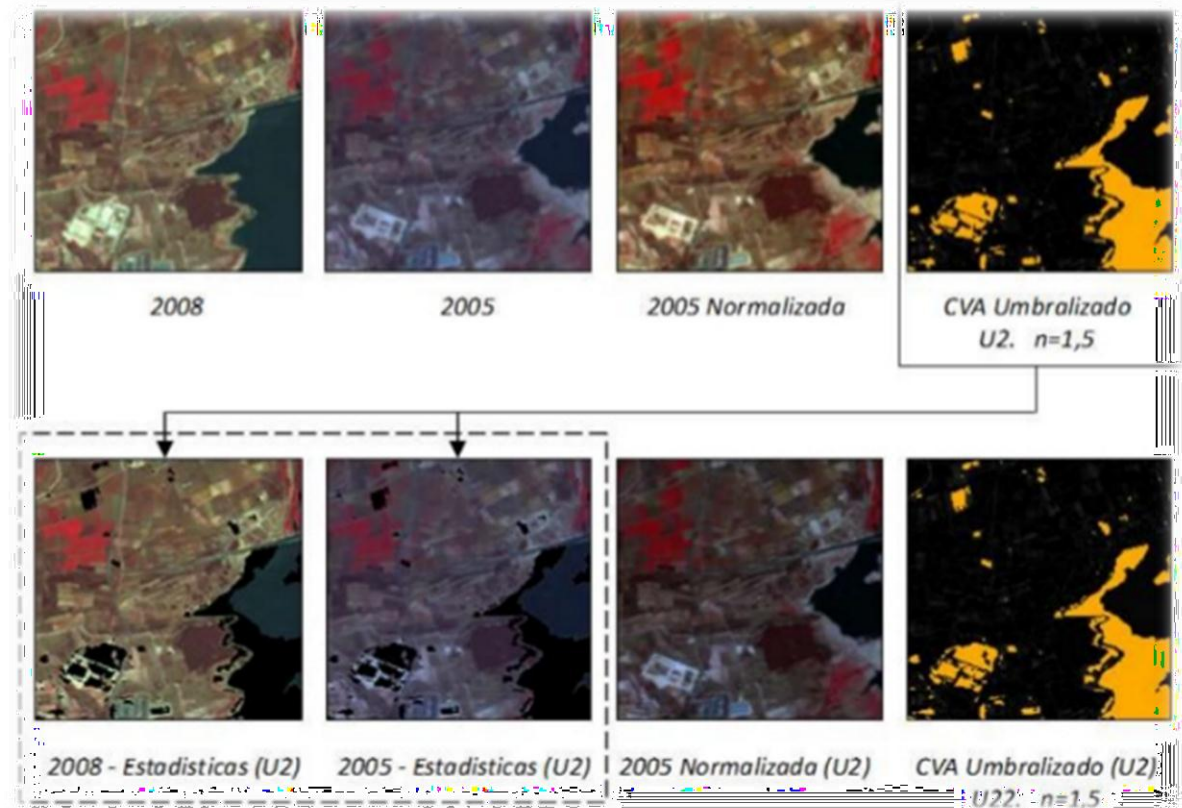
**uso de información
adicional, de contexto**



CLASIFICACIÓN MULTITEMPORAL

POR EJ. IMÁGENES DE PRIMAVERA Y OTOÑO TIENEN UN GRAN VALOR DISCRIMINATORIO EN LO QUE A LAS SUPERFICIES VEGETALES SE REFIERE.

ESPECIALMENTE PARA LA APLICACIÓN EN CULTIVOS



tomando en consideración la variabilidad de la cubierta en el tiempo

CLASIFICACIÓN MULTITEMPORAL


TÉCNICAS AVANZADAS QUE INCLUYEN LA VARIACIÓN TEMPORAL

CLASIFICACIÓN MULTITEMPORAL

DE APLICACIÓN CUANDO EL ELEMENTO A DISTINGUIR TIENE UNA RESPUESTA ESPECTRAL QUE VARÍA CON EL TIEMPO.

ACÁ ES MUY IMPORTANTE UNA MUY BUENA CORRECCIÓN ATMOSFÉRICA, DADO QUE LAS IMÁGENES VAN A SER DE PERÍODOS DIFERENTES Y LA ATMÓSFERA PUEDE ENMASCARAR Y DISTORSIONAR LOS CAMBIOS EN LA RESPUESTA ESPECTRAL, Y TAMBIEN EL AJUSTE GEOMÉTRICO-

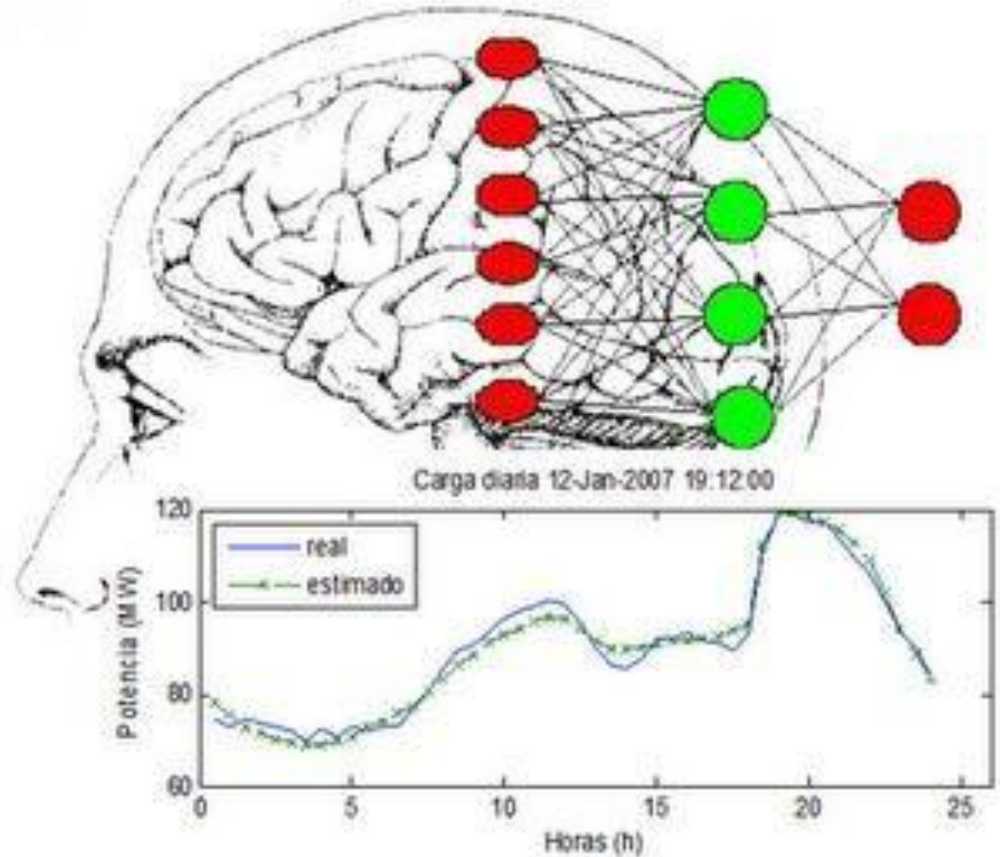
**tomando en consideración
la variabilidad de la
cubierta en el tiempo**



CLASIFICACIÓN POR REDES NEURONALES

INCREMENTAR EL NÚMERO DE CAPAS Y NEURONAS POR CAPAS, MEJORA LA CLASIFICACIÓN, PERO EL MODELO SERÁ CADA VEZ MÁS PARTICULAR Y TENDRÁ MENOR CAPACIDAD DE GENERALIZACIÓN

inteligencia artificial



CLASIFICACIÓN POR REDES NEURONALES

TÉCNICAS DE INTELIGENCIA ARTIFICIAL

CLASIFICACIÓN POR REDES NEURONALES


SE BASA EN EL USO DE REDES ARTIFICIALES CON UN COMPORTAMIENTO COMO LAS REDES NEURONALES REALES EN EL DESARROLLO DE TAREAS DE APRENDIZAJE.

CONSTA DE UNA CAPA DE ENTRADA CON TANTAS NEURONAS COMO VARIABLES DE ENTRADA (UNA POR CADA BANDA) Y UNA CAPA DE SALIDA CON TANTAS NEURONAS COMO POSIBLES CLASES CON VALORES ENTRE 0 Y 1 PARA CADA CLASE.

PARA ESTO SE NECESITAN VARIAS FASES
ENTRENAMIENTO, ESTABILIZACIÓN Y CLASIFICACIÓN

LA CLAVE ESTÁ EN LOS COEFICIENTES DE PONDERACIÓN QUE EN DEFINITIVA SON PARÁMETROS QUE SE DEBEN AJUSTAR A DATOS DE ENTRADA Y DE SALIDA, MODO SIMILAR A LA REGRESIÓN.

**inteligencia
artificial**





CLASIFICACIÓN POR MAQUINA DE VECTORES DE SOPORTE:

- Las máquinas de soporte vectorial, máquinas de vectores de soporte o máquinas de vector soporte (Support Vector Machines, SVMs) son un conjunto de algoritmos de aprendizaje supervisado desarrollados por Vladimir Vapnik y su equipo en los laboratorios AT&T.
- una SVM construye un hiperplano o conjunto de hiperplanos en un espacio de dimensionalidad muy alta (o incluso infinita) que puede ser utilizado en problemas de clasificación o regresión. Una buena separación entre las clases permitirá una clasificación correcta.

Machine Learning

H_1 no separa las clases.
 H_2 las separa, pero solo con un margen pequeño. H_3 las separa con el margen máximo.




CLASIFICACIÓN POR MAQUINA DE VECTORES DE SOPORTE:

- El clasificador de SVM proporciona un método de clasificación supervisado potente y moderno que permite manejar una entrada de ráster segmentado o una imagen estándar. Se trata de un método de clasificación relativamente nuevo cuyo uso está muy extendido entre los investigadores.
- Para las entradas de imagen estándar, la herramienta acepta imágenes de varias bandas con cualquier profundidad de bit y realiza la clasificación de SVM por píxel, según el archivo de entidades de formación de entrada.
- La herramienta de clasificador de SVM ofrece varias ventajas, en comparación con los métodos de clasificación tradicionales:
 - El clasificador de SVM permite manejar imágenes segmentadas muy grandes cuya tabla de atributos puede llegar a ser bastante grande, algo que resulta especialmente útil en imágenes de alta resolución.
 - Es menos susceptible al ruido, a las bandas correlacionadas y al desequilibrio entre la cantidad o el tamaño de los sitios de formación dentro de cada clase.

**Machine
Learning**

CLASIFICACIÓN POR CLASIFICADORES BORROSOS




A VECES TIENE MÁS SENTIDO, NO CLASIFICAR PÍXELES EN FORMA BIUNÍVOCA, SINO ESTABLECER 'POSIBILIDAD' DE PERTENENCIA A CADA UNA DE LAS CLASES Y TOMAR LA DECISIÓN CON ALGÚN OTRO MÉTODO INTELIGENTE

inteligencia artificial

CLASIFICACIÓN POR CLASIFICADORES BORROSOS

TÉCNICAS DE INTELIGENCIA ARTIFICIAL

CLASIFICACIÓN POR CLASIFICADORES BORROSOS



SEA CUAL SEA EL MÉTODO, SIEMPRE HABRÁN PÍXELES QUE RESULTAN IMPOSIBLES DE CLASIFICAR.

ACÁ LO QUE TIENE MAS SENTIDO ES NO CLASIFICAR AL PÍXEL EN FUNCIÓN DE LOS CRITERIOS DE PERTENENCIA A CADA UNA DE LAS CLASES, SINO CLASIFICARLO SEGÚN EL CRITERIO DE POSIBILIDAD.

PARA ELLO, SE UTILIZAN MODELOS DE INTELIGENCIA ARTIFICIAL.

**inteligencia
artificial**

CLASIFICACIÓN FINAL Y CLASES OBTENIDAS

CONJUNTO DE CLASES OBTENIDAS POR UNA CLASIFICACIÓN SUPERVISADA

CLASES INFORMACIONALES

Responde a lo que el usuario quiere encontrar. A veces, muy subjetivo.

CONJUNTO DE CLASES OBTENIDAS POR UNA CLASIFICACIÓN NO SUPERVISADA


CLASES ESPECTRALES

Responde al conjunto de clases que realmente aparece en la imagen. No necesariamente tiene un significado para el usuario.

Debemos de considerar o tratar, todas las clases existentes en una imagen

UTILIZACIÓN DE LOS PROCEDIMIENTOS DE CLASIFICACIÓN

NOTA IMPORTANTE



es posible combinar
una clasificación *supervisada*
con una *no supervisada*

usando máscaras para extraer información en cada paso y simplificar la imagen

MÓDULO V

Extracción de información temática. Validación y error.

5.3 - Error y validación de una clasificación. Matriz de confusión.

.

5.3 Extracción de información temática. Validación y error.

Error y validación de una clasificación. Matriz de confusión.

ERROR DE CLASIFICACIÓN

posibilidades de estudio del error:

- 1. estimar teóricamente en función del algoritmo de clasificación**
- 2. analizar una serie de áreas test obtenidas del mismo modo que las área de entrenamiento**

EL SEGUNDO CASO PERMITE OBTENER UNA ESTIMACIÓN MÁS REALISTA DE LOS ERRORES. SE REQUIERE DE UNA MUESTRA GRANDE Y REPRESENTATIVA.

SE OBTIENE:

**MEDICIÓN DEL ERROR COMETIDO
MEDIDA DE LA ADECUACIÓN DE LA CLASIFICACIÓN**

**que posibilidades
tengo para estudiar el
error**

MATRIZ DE CONFUSION

COLUMNAS – representan las clases reales

FILAS – clases obtenidas tras la clasificación

VALOR – número de píxeles perteneciendo a la clase fila, fueron adjudicados a la clase columna

ERROR DE OMISIÓN (indicated by a blue arrow pointing to the 'total' column)

ERROR DE COMISIÓN (indicated by a blue arrow pointing to the 'total' row)

Clasificados	Clases verdaderas			total
	urbano	agua	vegetación	
urbano	103	13	224	340
agua	16	930	148	1094
vegetación	49	1	4543	4593
total	168	944	4915	6027
precisión (%)	61.3	98.5	92.4	92.5

descripción del contenido

Figura – matriz de confusiones

MATRIZ DE CONFUSION, ejemplo

		CATEGORÍAS VERIFICADAS										SUMA	Error absoluto de comisión	Riesgo del usuario (%)	
		1	2	3	4	5	6	7	8	9	10				
		Agua	Suelos desnudos	Coníferas	Fronosas	Herbáceos extensivos	Regadío	Pradera	Monte bajo	Urbano cerrado	Urbano abierto				
CATEGORÍAS EN LA IMAGEN CLASIFICADA	Agua 1	3										3	0	0	
	Suelos desnudos 2		2						1			3	1	33	
	Coníferas 3			27				3	2			32	5	16	
	Fronosas 4			1	7	1	2					11	4	36	
	Herbáceos extensivos 5					86		1	4			91	5	5	
	Regadío 6				3		19					22	3	15	
	Pradera 7					1		9	1			11	2	18	
	Monte bajo 8		2			1		2	31			36	5	24	
	Urbano cerrado 9										9	9	0	0	
	Urbano abierto 10										1	2	3	1	33
	SUMA		3	4	28	10	89	21	15	39	10	2	221	26	
Error absoluto de omisión		0	2	1	3	3	2	6	8	1	0	26			
Riesgo del productor (%)		0	50	4	30	3	10	40	21	10	0				

Carlos Pimilla Ruiz, Curso de Teledetección / Depto. de Cartografía

Prof. Asistente Gdo. 2. Eduardo Vásquez.