

Universidad Nacional de La
Plata Facultad de Informática



Clasificación de cultivos en imágenes Landsat utilizando algoritmos de Active Learning

Trabajo Final presentado para obtener el grado de
Especialista en Computación Gráfica, Imágenes
y Visión por Computador

Autor: Ing. Lucas Benjamin Cicerchia
Directores: Dra. María José Abasolo y Dra. Claudia
Russo
Septiembre de 2022

Índice general

Clasificación de cultivos en imágenes Landsat utilizando algoritmos de Active

Learning	i
Índice general	ii
Índice de figuras	iv
Índice de tablas.....	vi
Capítulo 1. Introducción	1
1.1. Motivación.....	1
1.2. Definición del problema	2
1.3. Objetivos.....	5
1.4. Estructura del resto del informe	6
Capítulo 2. Remote Sensing	6
2.1. Definición	6
2.2. Espectro electromagnético.....	7
2.3. Firma Espectral	10
2.4. Índices de Vegetación	11
2.4.1. Definición de Índices de Vegetación.....	11
2.4.2. Normalized Difference Vegetal Index (NDVI).....	12
2.4.3. Ratio Vegetation Index (RVI).....	12
2.4.4. Soil Adjusted Vegetation Index (SAVI).....	12
2.4.5. Modified Soil Adjusted Vegetation Index (MSAVI)	12
2.4.6. Enhanced Vegetation Index (EVI)	13
2.4.7. Normalized Difference Moisture Index (NDMI).....	13
2.4.8. Normalized Difference Water Index (NDWI)	13
2.5. Resolución espectral y resolución radiométrica	14
2.6. Resolución espacial.....	16
2.7. Resolución temporal.....	16
Capítulo 3. Machine Learning.....	18
3.1. Definiciones y clasificaciones	18
3.1.1. Grupos de algoritmos de Machine learning	18
3.1.2. Machine Learning aplicado a Remote Sensing	19
3.1.3. Active Learning: una alternativa a Supervised Learning	19
3.2. Máquinas de vectores soporte (Support Vector Machine – SVM)	21

3.2.1. Introducción	21
3.2.2. Partes y definición matemática	24
3.2.3. Frontera de decisión no lineal	32
3.2.4. SVM Kernels.....	34
3.3. Heurísticas	35
3.3.1. Random sampling (AL-RS)	35
3.3.2. Margin sampling (AL-MS).....	35
3.3.3. Multiclass Level Uncertainty (AL-MCLU).....	36
3.3.4. Breaking Ties (AL-BT)	37
3.3.5. Margin Sampling Orthogonal (AL-MSO).....	37
3.4. Métricas de Evaluación	38
3.4.1. Matriz de confusión.....	38
3.4.2. Exactitud o <i>Accuracy</i>	41
3.4.3. Precisión o <i>Precision</i>	42
3.4.4. Exactitud o <i>Recall</i>	42
3.4.5. Medida F o <i>F1-Score</i>	43
Capítulo 4. Pruebas y Resultados	44
4.1. Dataset y estructura de los datos	44
4.2. División del dataset y pruebas	46
4.3. Resultados.....	47
4.4. Discusión	58
Capítulo 5. Conclusiones.....	60
5.1. Conclusiones.....	60
5.2. Trabajo futuro	60
Capítulo 6. Bibliografía.....	61
Capítulo 7. Anexos	67
Anexo 1 - Resultados Estadísticos.....	67
Anexo 2 - Matrices de Confusión.....	73

Índice de figuras

Figura 1 - Gráfico de firma espectral de los cultivos	4
Figura 2 - Lote sembrado con dos híbridos del mismo cultivo de Maíz de Segunda.....	5
Figura 3 - Matriz de confusión de clasificación para el Maíz, Maíz Tardío y Maíz de Segunda utilizando SVM.....	5
Figura 4 - Métodos de sensado con diferentes alturas.....	7
Figura 5 - Onda electromagnética compuesta por una onda eléctrica sinusoidal (E) y una onda magnética similar (M) en ángulo recto, perpendiculares al sentido de propagación. ...	8
Figura 6 - Espectro electromagnético	9
Figura 7 - Elemento que interactúan en el sistema de sensado	9
Figura 8 - Curva espectral sobre varias coberturas terrestres	10
Figura 9 - Firmas espectrales para vegetación sana, vegetación seca o enferma, suelo y agua.....	11
Figura 10 - Proceso de generación de una imagen	15
Figura 11 - Caracterización de una imagen espectral.....	16
Figura 12 - Diagrama de captura o barrido de una escena.....	17
Figura 13 - Diagrama de flujo del funcionamiento general de Active Learning	21
Figura 14 - Gráfico de características Altura y Área promedio de la hoja para los dos cultivos C1 y C2 del ejemplo de juguete.....	22
Figura 15 – Gráfico de una frontera de decisión que separe las características.....	23
Figura 16 - Gráfico de múltiples fronteras de decisión posibles que separe las características.	23
Figura 17 - Frontera de decisión obtenida con SVM, identificando los vectores soporte...	25
Figura 18 – Hiperplano (plano) de frontera de decisión obtenida con SVM, identificando	25
Figura 19 - Frontera de decisión con el vector (w_1, w_2) perpendicular al hiperplano de separación.....	26
Figura 20 - Frontera de decisión obtenida con SVM, con todas sus partes.....	28
Figura 21 - Gráfico de características Altura y Área promedio de la hoja para los dos cultivos C1 y C2 del ejemplo de juguete, en este caso con datos no separables linealmente.	30
Figura 22 – Frontera de decisión obtenida con SVM lineal para un conjunto de datos no separables linealmente.	31
Figura 23 – Hiperplano (plano) frontera de decisión obtenida con SVM lineal para un	

conjunto de datos no separables linealmente.	31
Figura 24 – Frontera de decisión no lineal arbitraria.....	32
Figura 25 - Función de separación con un kernel no lineal	34
Figura 26 - Imagen RGB ecualizada con verdades de campo	45
Figura 27 – Descripción de las partes del conjunto de datos.....	46
Figura 28 - <i>Overall accuracy</i> para cada heurística con (a) (c) (e) 150 iteraciones y 10 nuevos píxeles por iteración (b) (d) (f) 75 iteraciones y 20 nuevos píxeles por iteración. ...	49
Figura 29 - Matriz de confusión para la imagen del 25 de enero de 2020 con un conjunto de entrenamiento inicial de 5 píxeles por clase (30 píxeles en total). (a, c) 150 iteraciones y 10 nuevos píxeles por iteración (b, d) 75 iteraciones y 20 nuevos píxeles por iteración.	55
Figura 30 - Matriz de confusión para la imagen del 10 de febrero de 2020 con un conjunto de entrenamiento inicial de 5 píxeles por clase (30 píxeles en total). (a) 150 iteraciones y 10 nuevos píxeles por iteración (b) 75 iteraciones y 20 nuevos píxeles por iteración.	56
Figura 31 - Matriz de confusión para la imagen del 26 de febrero de 2020 con un conjunto de entrenamiento inicial de 5 píxeles por clase (30 píxeles en total). (a, c) 150 iteraciones y 10 nuevos píxeles por iteración (b, d) 75 iteraciones y 20 nuevos píxeles por iteración. ...	57
Figura 32 – Matrices de confusión para las imágenes de todas las fechas con ambas combinaciones de iteraciones para la heurística AL-BT.....	74
Figura 33 - Matrices de confusión para las imágenes de todas las fechas con ambas combinaciones de iteraciones para la heurística AL-MCLU.....	75
Figura 34 - Matrices de confusión para las imágenes de todas las fechas con ambas combinaciones de iteraciones para la heurística AL-MS.....	76
Figura 35 - Matrices de confusión para las imágenes de todas las fechas con ambas combinaciones de iteraciones para la heurística AL-MSO.....	77
Figura 36 - Matrices de confusión para las imágenes de todas las fechas con ambas combinaciones de iteraciones para la heurística AL-RS.	78
Figura 37 - Matrices de confusión para las imágenes de todas las fechas con ambas combinaciones de iteraciones para la heurística SVM.	79

Índice de tablas

Tabla 1 - Tabla de verdad de ejemplo	39
Tabla 2 - Tabla de verdad de ejemplo con valores porcentuales	39
Tabla 3 - Tabla de verdad indicando cada parte de la misma	40
Tabla 4 - Tabla de verdad indicando cada parte de la misma expresada en valores porcentuales.....	40
Tabla 5 - Tabla de verdad indicando cada parte de la misma para un problema multiclase	40
Tabla 6 – Tabla de verdad resaltando en rojo los elementos utilizados en <i>Precision</i>	42
Tabla 7 - Tabla de verdad resaltando en rojo los elementos utilizados en <i>Recall</i>	43
Tabla 8 - Coberturas, siglas y cantidad de muestras de la verdad de campo	45
Tabla 9 - Media de OA para cada fecha con cada uno de los clasificadores con 150 iteraciones y 10 nuevos píxeles por iteración	49
Tabla 10 - Media de OA para cada fecha con cada uno de los clasificadores con 75 iteraciones y 20 nuevos píxeles por iteración.	50
Tabla 11 - Media de OA para cada fecha con cada uno de los clasificadores. Con 75 iteraciones y 20 nuevos píxeles por iteración	52
Tabla 12 - Media de OA para cada fecha con cada uno de los clasificadores. Con 150 iteraciones y 10 nuevos píxeles por iteración	53
Tabla 13 - Resultados de las métricas con todas las heurísticas, para la imagen del 25 de Enero, con 20 píxeles agregados por iteración.....	67
Tabla 14 - Resultados de las métricas con todas las heurísticas, para la imagen del 25 de Enero, con 10 píxeles agregados por iteración.....	68
Tabla 15 - Resultados de las métricas con todas las heurísticas, para la imagen del 10 de Febrero, con 20 píxeles agregados por iteración.....	69
Tabla 16 - Resultados de las métricas con todas las heurísticas, para la imagen del 10 de Febrero, con 10 píxeles agregados por iteración.....	70
Tabla 17 - Resultados de las métricas con todas las heurísticas, para la imagen del 26 de Febrero, con 20 píxeles agregados por iteración.....	71
Tabla 18 - Resultados de las métricas con todas las heurísticas, para la imagen del 26 de Febrero, con 10 píxeles agregados por iteración.....	72

Capítulo 1. Introducción

1.1. Motivación

El avance de la tecnología en los últimos años ha abarcado diferentes disciplinas, incluida la agricultura. La identificación de coberturas terrestres se ha convertido en un aspecto importante a la hora de realizar monitoreo, además de aportar información a la hora de gestionar recursos y servir de soporte a la toma de decisiones. La Agricultura de Precisión (AP) ha comenzado a aplicar la tecnología de la información y la comunicación en todas las áreas de la disciplina [1]. De este modo, se ha convertido en una herramienta fundamental para lograr un manejo adecuado del suelo y sus cultivos, teniendo en cuenta su variabilidad dentro de un lote [2]. Esto permite adaptarse a las exigencias de la agricultura moderna en el manejo óptimo de grandes superficies [3].

La gran cantidad de datos (Big Data) que este sector genera a través de la tecnología requiere de la introducción de técnicas específicas que permitan operar y obtener de ellos información. Para extraer dicha información a partir de estos datos se requiere de Machine Learning (ML), que engloba un conjunto de técnicas que hacen posible el aprendizaje automático a través del entrenamiento con grandes volúmenes de datos.

El Sensado Remoto (RS) [4], que incluye imágenes de satélite, genera una gran cantidad de datos para la AP. El uso de técnicas de ML puede aplicarse a todo tipo de datos, incluidos los generados por la RS para obtener información [5] [6].

Como se puede ver en Lary et al. [5] la aplicación de las técnicas de ML a la RS es relativamente nueva y limitada, abarcando diferentes campos de aplicación y ejemplos [7]. También, en D. Marcos et al. [8], se puede encontrar la contribución que el procesamiento digital de imágenes puede dar a estos dos tipos de trabajos anteriores. Así es que basándose en técnicas de ML en RS se pueden obtener mapas de clasificación, predicción, selección y extracción de características, entre otras cosas [9]–[11], aportando de este modo a la AP. También, como mencionan A. González-Sánchez et al. [12] y S. Veenadhari et al. [13], se podría implementar el monitoreo del suelo, los cultivos y el clima para proporcionar un sistema de soporte a la toma de decisiones. También podría ser capaz de aprender, entre otras cosas, a predecir el rendimiento de los cultivos o, como indican S. Dimitriadis et al. [14] a determinar tratamientos específicos para los cultivos, como el riego, la aplicación de fertilizantes o pesticidas para diferentes partes del suelo.

Entre las diferentes técnicas de ML que se encuentran en la literatura, aquellas en las que se hará hincapié son las relacionadas con RS. Teniendo en cuenta las más recientes, se destacan algunas de las más utilizadas [15] Semi-Supervised Learning, Deep Learning (DL) y Active Learning (AL). En las técnicas de ML con Aprendizaje Supervisado (LS), como Support Vector Machine (SVM) o Deep Learning (DL), todas las muestras o datos

tienen que estar etiquetadas. Deep Learning (DL) es muy utilizado en la actualidad inclusive en el área de RS y agricultura a distancia [16][17]. La dificultad que presentan este tipo de algoritmos supervisados como SVM o DL es que la gran cantidad de datos generados por los sensores remotos hoy en día, dada la alta resolución espacial y espectral, hace que el etiquetado de datos para los algoritmos sea una tarea difícil y que consume muchas horas de trabajo. Además se le agrega que en el caso concreto de la agricultura, se requiere que dicho etiquetado sea realizado por expertos en la materia. El DL, como mencionan Kamilaris & Prenafeta-Boldú [16], requiere en muchos casos grandes conjuntos de datos etiquetados o cientos de imágenes. Este problema hace que a menudo estos algoritmos pueden aplicarse a un conjunto de datos pequeño. En contraparte a estas técnicas existen alternativas como el Active Learning (AL) [18], que es una técnica de Semi-Supervised Learning (SSL) que pretende obtener un rendimiento de clasificación satisfactorio con un menor número de muestras etiquetadas y que además explota la interacción continua con el clasificador [7][19]. Este construye conjuntos de datos de entrenamiento eficientes, mejorando iterativamente el rendimiento del modelo permitiendo obtener resultados similares a los de una técnica de SL con un menor costo de etiquetado. Esto permite un reentrenamiento constante del algoritmo, la explotación de los datos y reduce el coste del etiquetado. Las muestras a etiquetar se seleccionan mediante una heurística para que sean lo suficientemente representativas como para mejorar el modelo y luego serán etiquetadas por un experto [18].

1.2. Definición del problema

El presente trabajo surge como una búsqueda de desarrollo de una herramienta que permita a instituciones o entidades ligadas a la actividad agronómica obtener una clasificación de cultivos dentro de la región del noroeste de la provincia de Buenos Aires de manera simple y rápida. En base al estudio de cómo trabajaban entidades como el Instituto Nacional de Tecnología Agropecuaria Estación Experimental Agropecuaria Pergamino (INTA EEA Pergamino) en relación al relevamiento de cultivos que se sembraban en la región es que surge la idea de abordar esta temática, buscando por un lado objetivar el trabajo realizado, mejorar los resultados que estos obtienen, simplificar la tarea lo que permite un ahorro de tiempo y por último comenzar a incorporar otros cultivos que en el relevamiento que estos realizan no se identifican. Sumado a ello, al no contar con una descripción de los lotes de la región hace que la separación entre cultivos sea dificultosa para las técnicas de clasificación que utilizan, lo que lleva en muchas ocasiones a confusiones por parte del algoritmo.

Es decir que esta investigación surge a partir de la dificultad que estos tienen para poder realizar un relevamiento de los cultivos, y el área cultivada dentro de la región, donde las herramientas y técnicas utilizadas insumen mucho tiempo, en muchos casos tienen dificultades, y además emplean muchas imágenes a lo largo de la evolución del cultivo y requiere de la utilización de imágenes con índices de vegetación. Donde para el abordaje del trabajo se utilizaron algunas de las tecnologías y técnicas mencionadas en el

apartado anterior.

La particularidad de este desarrollo radica en cuatro aspectos fundamentales; en primer lugar, se trabaja con imágenes Landsat cuando muchos trabajos se realizan con imágenes hiperespectrales, multitemporales o multifuentes [20][21]. Al trabajar con imágenes de este satélite, se dispone de una menor cantidad de datos que en otros casos como por ejemplo en [22], que utiliza imágenes hiperespectrales donde dispone de una resolución de 200 bandas espectrales que aportan información. Esta última tiene una mayor resolución espectral si se compara con Landsat 8, que sólo dispone de una resolución de 11 bandas de las cuales 6 son las bandas que aportan información relevante para los cultivos. En segundo lugar, para las pruebas de clasificación se utiliza una imagen de una sola fecha pero dentro de un rango de fechas determinado, que son las que los especialistas consideran que allí se pueden distinguir los cultivos a evaluar. La decisión de no utilizar imágenes multitemporales radica en que se busca verificar que se puede obtener un buen clasificador para estos cultivos con una sola imagen con el objetivo final de intentar simplificar la posterior utilización del clasificador por parte del usuario final. El tercer aspecto a destacar es que se aplica a una región donde este tipo de algoritmos no ha sido muy estudiado hasta la actualidad. Existen algunos trabajos sobre la cobertura en nuestro país, pero se aplican en otras regiones, a diferentes coberturas, utilizando imágenes multitemporales y con diferentes índices de vegetación [23]. Y el último aspecto a tener en cuenta es que entre los cultivos a clasificar hay variedades de dos de los cultivos a clasificar. Es decir, se pretende discriminar el maíz en tres clases: Maíz de Primera, Maíz Tardío y Maíz de Segunda (de Doble Cultivo), y la soja en dos clases: Soja de Primera y Soja de Doble Cultivo (de Segunda), además de Sorgo y Agua. El principal reto es que son variantes de los mismos cultivos y tienen la misma firma espectral.

En la Figura 1 que se muestra a continuación se pueden observar las firmas espectrales que se obtuvieron de una de las imágenes donde en la línea de color se graficó la mediana para dicho cultivo y con el sombreado del color se graficó el desvío estándar. Así se puede destacar que hay poca diferencia entre las firmas de variantes entre un mismo cultivo.




Figura 1 - Gráfico de firma espectral de los cultivos

Es importante señalar que, en el caso del maíz, la única diferencia entre el Maíz de Primera y el Maíz Tardío es la fecha de siembra, donde el Maíz Tardío se siembra más tarde que el Maíz de primera. En el caso del Maíz de Segunda, se trata de un maíz que, al igual que el Maíz Tardío, fue plantado en una fecha posterior al Maíz de Primera y además fue sembrado después de la cosecha de un cultivo de invierno. Es decir, previamente el mismo año en el mismo lote hubo un cultivo de invierno, en contraste con el Maíz de Primera y el Maíz Tardío, donde durante el año no hubo cultivo de invierno y en su lugar hubo suelo desnudo. En cuanto a la soja, la Soja de Primera y la Soja de Segunda al igual que el maíz, las fechas de siembra difieren, la Soja de Segunda se plantó en una fecha posterior a la Soja de Primera y además se plantó después de un cultivo de invierno.

Durante las primeras pruebas, se detectó la dificultad de distinguir el Maíz Tardío del Maíz de Segunda. Debido a que, por un lado son el mismo cultivo y por el otro también pueden ser sembrados en las mismas fechas. Sumado a esto, las empresas cerealeras que venden granos realizan modificaciones genéticas en sus semillas (híbridos) con el objetivo de obtener más y mejores rindes, lo que provoca que el mismo tipo de cultivo plantado en la misma fecha responda, crezca y se desarrolle de manera diferente. En la Figura 2 utilizando un esquema de falso color, donde las bandas de color RGB están representadas por R=Banda 4, G=Banda 5 y B=Banda 3, se puede observar, dentro del recuadro amarillo, que un lote con dos híbridos de Maíz de Segunda diferentes, plantados en la misma fecha se reflejan (observan) de forma diferente.




Figura 2 - Lote sembrado con dos híbridos del mismo cultivo de Maíz de Segunda

De las pruebas preliminares utilizando el mismo clasificador que se utilizaron en las pruebas que se describen posteriormente, se obtuvo la matriz de confusión de la Figura 3. Que muestra la dificultad para diferenciar ambas clases, Maíz Tardío y Maíz de Segunda. Debido a esta dificultad para separar ambas clases, se ha decidido que estos cultivos, durante las pruebas realizadas hasta el momento, aparecen unificados como un único tipo de cultivo (cobertura).




Figura 3 - Matriz de confusión de clasificación para el Maíz, Maíz Tardío y Maíz de Segunda utilizando SVM

1.3. Objetivos

El presente trabajo tiene como objetivo explorar diferentes técnicas de AL aplicadas a RS en comparación con SVM para lograr un clasificador de diferentes cultivos de verano

en el Noroeste de la provincia de Buenos Aires, Argentina. Más específicamente, la región de estudio que se ha utilizado comprende campos de los partidos de Junín, Rojas y Chacabuco, que forman parte de la llamada "Pampa Húmeda", una de las regiones más relevantes en la producción agrícola y menos estudiada con este tipo de técnicas.

Lo que se considera relevante del objetivo, es por una parte la aplicación de este tipo de técnicas sobre una única imagen satelital del sensor Landsat. Por otra parte los tipos de cultivos que se estudian (Maíz, Soja y Sorgo) incluyendo además variaciones de un mismo cultivo.

1.4. Estructura del resto del informe

En el capítulo 2 se realiza un marco teórico respecto a Remote Sensing, desarrollando qué es, cómo se realizan las capturas de las imágenes y qué es lo que éstas capturan. Se define qué es un espectro electromagnético, qué es la resolución espectral, los índices de vegetación, la resolución radiométrica, la resolución espacial, y la resolución temporal.

En el capítulo 3 se realiza una revisión de cuáles son las diferentes técnicas de ML existentes y se realiza un resumen de cuáles son las técnicas de ML que en la bibliografía consultada se destacan en la aplicación en imágenes de RS. Además se presenta la técnica (active learning) que se aplicará en el presente trabajo, la técnica Support Vector Machine hasta las diferentes heurísticas que se utilizan y cuáles son las métricas de evaluación que se utilizan para evaluar el desempeño.

A partir de la problemática a abordar, del marco teórico, y las técnicas a utilizar descriptos en el capítulo 1, 2 y 3, es que en el capítulo 4 se define, en primera instancia, con qué dataset se trabajará y de qué modo fue preparado para ser utilizado en los algoritmos. Se describe además con qué clasificador y qué heurísticas de decisión del algoritmo se trabajará en el algoritmo de active learning descrito en el capítulo 3. A continuación se presentan todas las pruebas realizadas con dicho dataset y los resultados obtenidos de la aplicación de los algoritmos.

En el capítulo 5 se presentan las conclusiones del trabajo realizado y cuáles son las expectativas a futuro con el presente trabajo.

Finalmente, se listan las referencias bibliográficas. También se incluyen dos anexos, respectivamente con los Resultados Estadísticos y Matrices de Confusión, con el fin de detallar todos los resultados de las pruebas realizadas.

Capítulo 2. Remote Sensing

2.1. Definición

Remote Sensing (RS) es el campo de la ciencia que estudia y modela los procesos que ocurren en la superficie de la tierra y su interacción con la atmósfera [4]. RS refiere al proceso de relevamiento a distancia de características físicas de una zona de interés mediante la medición de la radiación que los objetos reflejan. Donde este relevamiento se realiza con cámaras especiales que pueden capturar dicha energía y que pueden estar montadas sobre un satélite, un avión, un drone o una plataforma terrestre. Dependiendo de la información que se desea obtener de los datos sensados va a ser la plataforma y el sensor que se utilice para realizar el relevamiento. Donde existen muchas aplicaciones donde estas plataformas y sensores se combinan para obtener una información más detallada de lo que se desea observar [24] [25].

No es lo mismo la utilización de una plataforma terrestre, un drone, un avión y un satélite por dos aspectos diferentes. Por un lado la altura a la que se realiza la observación, como se puede ver en la Figura 4, es claro que utilizar una plataforma terrestre permite tener una mayor cercanía de lo que se quiere capturar. Y el otro aspecto a tener en cuenta es el sensor que se utilice para realizar la observación, ya que estos poseen diferentes características como: una resolución espectral, una resolución radiométrica, una resolución espacial y una resolución temporal.




Figura 4 - Métodos de sensado con diferentes alturas

2.2. Espectro electromagnético

Antes de entrar en los detalles de las características de los sensores se debe describir qué es lo que se captura en los sensores y para ello se hace una analogía con qué es lo que

observan a diario con nuestros ojos. Así es que lo que ven no es más que lo que reflejan los objetos dentro de la luz visible, la cual es una de las tantas formas de energía electromagnética que existen sobre la tierra. Dentro de las más conocidas se encuentran la luz ultravioleta, los rayos X y las ondas de radio entre otras. Dichas energías, como se representa en la Figura 5, se propagan en forma de ondas electromagnéticas, es decir que viajan a la velocidad de la luz con una forma sinusoidal y armónica. Cumpliendo con la ecuación básica de onda:

$$c = v \lambda \quad (1)$$

donde c es la constante de la velocidad de la luz (3×10^8 m/s), v es la frecuencia y λ es la longitud de onda.

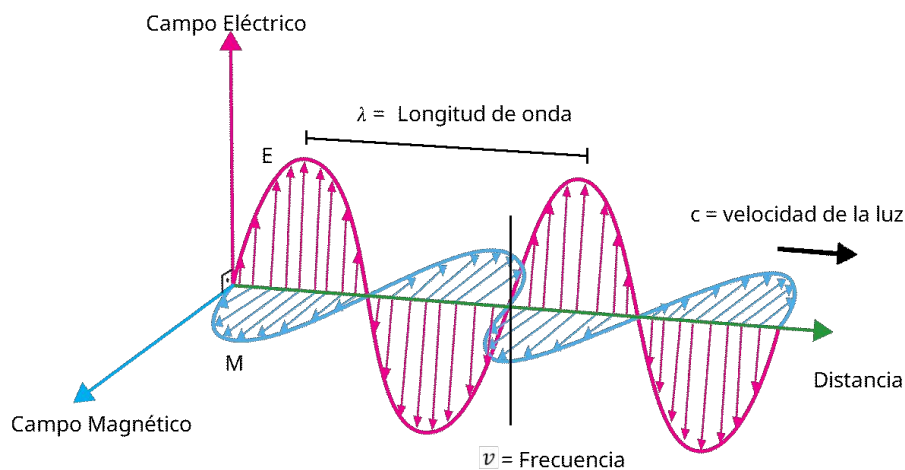


Figura 5 - Onda electromagnética compuesta por una onda eléctrica sinusoidal (E) y una onda magnética similar (M) en ángulo recto, perpendiculares al sentido de propagación.

En base a estas características es que existe un rango o espectro de ondas electromagnéticas, las cuales podemos agruparlas por su longitud de onda medidas en micrómetros (μm).

Dentro del espectro y las que se utilizan en RS se encuentran, por una parte la porción que es visible por el ojo humano el cual se extiende de $0.4 \mu\text{m}$ a $0.7 \mu\text{m}$ donde es dividido en 3 partes los cuales representan de $0.4 \mu\text{m}$ a $0.5 \mu\text{m}$ los colores azules (BLUE), de $0.5 \mu\text{m}$ a $0.6 \mu\text{m}$ los colores verdes (GREEN) y de $0.6 \mu\text{m}$ a $0.7 \mu\text{m}$ al rojo (RED). Luego a ambos lados del rango se encuentran rangos electromagnéticos de interés, la zona ultravioleta (UV) al lado del azul y el rango del infrarrojo (IR) al lado del rojo. Además el rango del IR también es dividido en 3 partes donde de $0.7 \mu\text{m}$ a $1.3 \mu\text{m}$ se encuentra el IR cercano (NIR), de $1.3 \mu\text{m}$ a $3 \mu\text{m}$ el IR medio (shortwave IR o SWIR) y de $3 \mu\text{m}$ a $14 \mu\text{m}$ el IR térmico (longwave IR o LWIR). En la Figura 6 se ilustra lo mencionado anteriormente:




Figura 6 - Espectro electromagnético

Se conoce que el sol es la fuente de radiación electromagnética más conocida, sin embargo, toda materia a temperaturas superiores al cero absoluto (0 K, o -273 C) emite continuamente radiación electromagnética. Debido a que los materiales en una escena reflejan, absorben y emiten dicha radiación electromagnética de una manera diferente en función de su composición y forma molecular, es que se puede realizar la adquisición de información acerca de una escena (o un objeto específico) a una corta, media o larga distancia [6]. Es por esto que se considera que los objetos terrestres son fuentes de radiación donde la cantidad de energía que irradian depende, entre otras cosas, de la temperatura de su superficie. Donde dicha radiación es capturada por un sensor, como por ejemplo un satélite y enviado a una estación de recepción.




Figura 7 - Elemento que interactúan en el sistema de sensado

Como se puede observar en la Figura 7, un sistema de RS necesita de 3 componentes, una fuente de energía, una superficie terrestre (cobertura) y un sensor que sea capaz de

captar las diferentes ondas electromagnéticas que refleja la superficie.

De la captura dicha radiación es que resulta una imagen multispectral, la cual consiste en una adquisición simultánea de imágenes espacialmente co-registradas, en varias bandas del espectro electromagnético contiguos de una plataforma operada remotamente [4], [26].

2.3. Firma Espectral

Dependiendo del objeto que se está observando y la longitud de onda con la que se incide sobre la superficie del mismo va a ser el modo en que se refleje en el satélite. Para el análisis de las coberturas terrestres es relevante analizar cómo reflejan las superficies en diferentes longitudes de onda.

Dentro de las longitudes de ondas, se encuentra el espectro visible que incluye las ondas (bandas) denominadas de color, la banda del azul, verde y roja, que son las que, combinadas, nos permiten formar el color que el ojo percibe de los objetos. Si se toma como ejemplo un objeto como una vegetación verde, tendrá más intensidad de color en la banda del verde por sobre las bandas del azul y rojo.

Se conoce así que las coberturas terrestres cuentan diferentes reflectancias espectrales, las cuales si se las analiza para todas las longitudes de onda conforman una curva espectral denominada firma espectral. Así, como se muestra en la Figura 8, se tienen diferentes firmas espectrales si por ejemplo, lo que se observa es una vegetación vigorosa, una vegetación seca, un suelo sin cultivos, asfalto, construcciones o agua. En las siguientes figuras podemos observar diferentes firmas espectrales dependiendo de la cobertura.

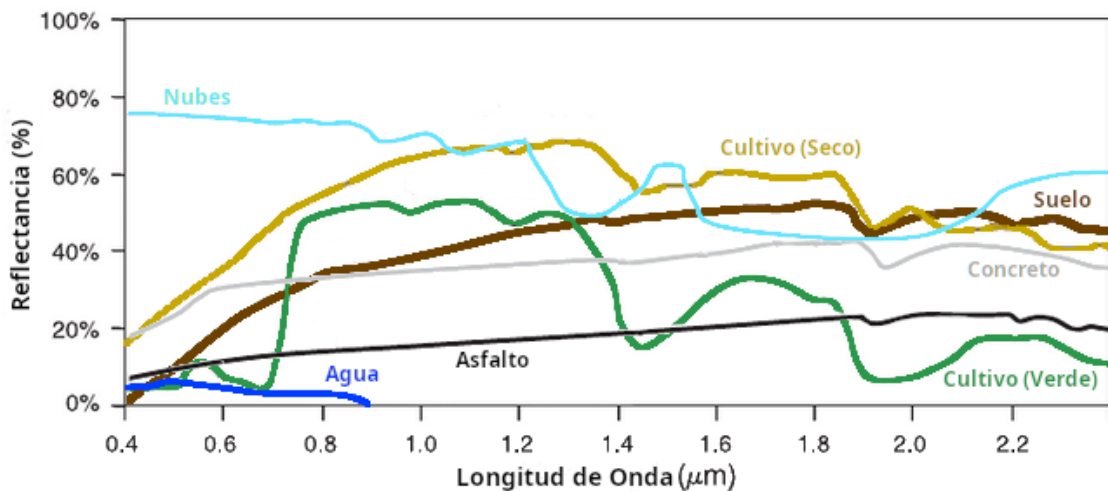


Figura 8 - Curva espectral sobre varias coberturas terrestres

Al analizar la cobertura de vegetación que es la que se investiga en el presente trabajo, se observa que en el caso de la vegetación vigorosa (sana) la parte visible del espectro se percibe un valle el cual es determinado por los pigmentos de las hojas de las plantas. La clorofila, por ejemplo, absorbe fuertemente la energía en las bandas de longitud

de onda centradas en unos 0,45 μm y 0,67 μm . Es por ello que la vegetación sana se percibe de color verde debido a la gran absorción de energía azul y roja por parte de las hojas de las plantas y a la reflexión relativamente alta de la energía verde. Si una planta sufre algún tipo de estrés puede cambiar la postura de sus ojos para disminuir la incidencia del sol o disminuir la producción de clorofila. Lo cual redundará en una menor absorción de clorofila en las bandas azul y roja. En el caso de la banda del NIR la vegetación sana aumenta drásticamente su reflectancia respecto a la banda roja. Este rasgo espectral, conocido como el borde rojo, suele producirse entre 0,68 μm y 0,75 μm , donde la posición exacta depende de la especie y el estado.

2.4. Índices de Vegetación

2.4.1. Definición de Índices de Vegetación

A partir de los valores de reflectancia en diferentes bandas es posible caracterizar el tipo, la cantidad y el estado de la vegetación presente en una escena. Debido a que la cantidad de luz reflejada viene determinada por las propiedades de reflectancia de la misma y a que la irradiación solar varía con el tiempo y las condiciones atmosféricas, una simple medida de reflectancia no es suficiente para caracterizar la superficie de forma repetible. Para ello existen los denominados índices de vegetación [27] que combina los datos de dos o más bandas espectrales y brinda una medida que puede ser comparable a lo largo del tiempo.

Como la reflectancia varía con la longitud de onda de la luz se tiene que si del suelo se trata, la mayor parte de la luz que incide se refleja o se absorbe, dicho de otro modo, cambia relativamente poco con la longitud de onda. En el caso de la vegetación, la mayor parte de la luz en las longitudes de onda del NIR se transmite y se refleja, con poca absorción, algo que no sucede con las longitudes de onda visibles, donde predomina la poca reflectividad [28]. En la Figura 9, se ilustra lo anteriormente mencionado:




Figura 9 - Firmas espectrales para vegetación sana, vegetación seca o enferma, suelo y agua

Existen diferentes índices de vegetación destacados en la bibliografía [29] de los cuales se destacan aquellos que se utilizan para destacar aspectos referidos a los cultivos que se encuentran en la argentina, más específicamente dentro de la provincia de buenos aires [23].

2.4.2. Normalized Difference Vegetal Index (NDVI)

El índice de vegetación de diferencia normalizada (NDVI) propuesto por [30] es uno de los más utilizados debido a que permite obtener una medida de la densidad de la vegetación. Este índice se basa en la curva espectral que posee una vegetación sana calculando la diferencia entre la banda del rojo visible y la del infrarrojo cercano. Los valores que arroja el índice varían entre -1 y 1, teniendo al cero como valor aproximado de donde empieza la ausencia de vegetación y los valores negativos representan una superficie que no posee vegetación. La fórmula del índice queda expresada del siguiente modo:

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad (2)$$

2.4.3. Ratio Vegetation Index (RVI)

El índice de relación de vegetación (RVI) desarrollado por [31] brinda una relación entre las bandas NIR y RED que son aquellas que brindan información acerca de la salud de la vegetación. El índice queda representado con la siguiente fórmula:

$$RVI = \frac{NIR}{RED} \quad (3)$$

2.4.4. Soil Adjusted Vegetation Index (SAVI)

El índice de vegetación ajustado al suelo (SAVI) propuesto por [32] es una variación del NDVI donde incorpora una constante L relacionada con el suelo, con el objetivo de minimizar las influencias de las condiciones de ruido que este pueda proporcionar por su condición de color, humedad, tipo, etc.. Este índice posee buenos resultados para determinar suelos con vegetación de baja, intermedia o alta densidad. Quedando representado por la siguiente fórmula:

$$SAVI = \frac{(NIR - RED)(1 + L)}{NIR + RED + L} \quad (4)$$

2.4.5. Modified Soil Adjusted Vegetation Index (MSAVI)

Este índice propuesto por [33] es una modificación del SAVI, que busca mejorar la precisión de su antecesor. El cual queda expresado con la siguiente fórmula:

$$SAVI = \frac{2 * (NIR + 1) - \sqrt{(2 * NIR + 1)^2 - 8 * (NIR + RED)}}{2} \quad (5)$$

2.4.6. Enhanced Vegetation Index (EVI)

El índice de vegetación mejorado (EVI) [34] es un índice que permite tener un indicador de biomasa en la vegetación. Separando la señal proveniente de la vegetación de la influencia atmosférica. Tiene además coeficientes que permiten realizar dicha separación donde dichos coeficientes dependen del sensor que se esté utilizando. La fórmula queda expresada del siguiente modo:

$$EVI = G * \frac{NIR - RED}{NIR + C_1 * RED - C_2 * BLUE + L} \quad (6)$$

Donde G es el factor de ganancia propio del sensor, L un factor de ajuste o corrección del suelo y tanto C_1 como C_2 son dos coeficientes que permiten realizar una corrección de los efectos que producen la dispersión atmosférica.

2.4.7. Normalized Difference Moisture Index (NDMI)

El índice de diferencia de humedad normalizada (NDMI) [35] es un índice que permite resaltar los niveles de humedad que posee la vegetación, permitiendo reflejar entre otras cosas el estrés hídrico de los cultivos. Para ello, a diferencia del NDVI utilizar las bandas espectrales del NIR y el SWIR, quedando del siguiente modo:

$$NDMI = \frac{NIR - SWIR}{NIR + SWIR} \quad (7)$$

2.4.8. Normalized Difference Water Index (NDWI)

El índice de diferencia de agua normalizada (NDWI) [36] tiene como objetivo poder resaltar las masas de agua, reflejando en menor medida el suelo y la vegetación. Donde este utiliza GREEN y NIR permitiendo resaltar la presencia de agua solamente, a diferencia del NDMI que utiliza NIR y SWIR resaltando la presencia de agua pero en la vegetación. La representación del índice queda representada del siguiente modo:

$$NDWI = \frac{GREEN - NIR}{GREEN + NIR} \quad (8)$$

2.5. Resolución espectral y resolución radiométrica

En el apartado anterior se expuso que se tiene un espectro electromagnético muy amplio y que el ojo humano solamente puede percibir una parte de este. Para poder observar el resto del espectro se necesita de sensores especiales que sean capaces de detectar dicho espectro y convertirlo en una imagen que sea plausible de ser observada e interpretada. Esa capacidad que tienen los sensores de capturar un rango del espectro electromagnético es la que se denomina Resolución Espectral, es decir, cuánto del espectro total es capaz de capturar el sensor. Sumado a ello, aparece además con qué sensibilidad detecta dicho rango del espectro el sensor, dicho de otro modo, en cuantos fragmentos es capaz de dividir y distinguir ese espectro, y transformarlo en una imagen que pueda ser interpretada. A esa cualidad se la denomina Resolución Radiométrica, es decir la capacidad de distinguir diferentes rangos y cada rango representarlo en una imagen.

En la actualidad existen satélites que poseen sensores que tienen diferentes resoluciones espectrales y radiométricas, así es que tenemos satélite Aviris [37] con un sensor que es capaz de detectar desde los 0.4 a 2.5 micrómetros (μm) pudiendo detectarlo en 224 rangos o bandas espectrales. O el satélite Landsat 8 [38], que es el que se utiliza en el presente trabajo, que posee un sensor capaz de detectar desde los 0.43 a 12.5 micrómetros (μm) en 11 bandas. Estos sensores capturan esos diferentes rangos del espectro y los representan en una imagen, en otras palabras, cada uno de esas bandas están representados en una imagen, entonces si se utiliza el satélite Landsat 8 el satélite entregará 11 imágenes, o dicho de otro modo, entregará una imagen con 11 bandas. Si se utilizara el satélite Aviris entregaría 224 imágenes, es decir, una imagen con 224 bandas.

Todas las imágenes cuentan con una resolución que es expresada en píxeles, donde si una imagen captura un área determinada, estos píxeles representan esa área en forma de matriz de filas y columnas donde en cada posición (píxel) de la matriz se le asigna un valor numérico que representa un valor dentro del rango del espectro capturado. Así el sensor recibe una energía incidente que es cuantificada en diferentes niveles de voltajes asociados los que en forma discreta serán almacenados independientemente en dichos píxeles. Cada píxel tendrá un valor numérico asociado al nivel de intensidad, donde esta intensidad se obtiene como el producto de una componente de iluminación y una componente de reflectancia. La primera consecuencia de las fuentes de iluminación existentes en la escena en el momento de la captura. La segunda asociada a las propiedades físico químicas intrínsecas del objeto. En la Figura 10 a continuación se ilustra el proceso de generación de una imagen:




Figura 10 - Proceso de generación de una imagen

La cuantificación de esos valores incidentes en el sensor es otra de las características a tener en cuenta. Esta cuantificación indica la cantidad de valores distintos que puede detectar el sensor, cuanto mayor cuantificación tenga el sensor, mayor detalle para detectar con más sensibilidad la energía incidente y por consiguiente una mejor representación de los valores de la escena. Esto comúnmente se lo denomina “profundidad de color” o “resolución en niveles de gris” y como estamos trabajando con elementos digitales es expresada en cantidad de bits. Por ejemplo un sensor que trabaja en 8 bits, puede representar $2^8 = 256$ tonos de grises diferentes, así a mayor cantidad de bits mayor nivel de detalle tendrá para representar lo que recibe el sensor. En el caso del satélite Landsat 8 trabaja con 16 bits en cada una de sus 11 bandas.

Como los sensores capturan más de una banda, se puede interpretar como se mencionó anteriormente como una imagen con la cantidad de bandas que el sensor tenga. Es decir que se podría interpretar como un cubo de imágenes, donde tenemos una imagen con “x” filas, “y” columnas y “z” bandas como se puede observar en la Figura 11.

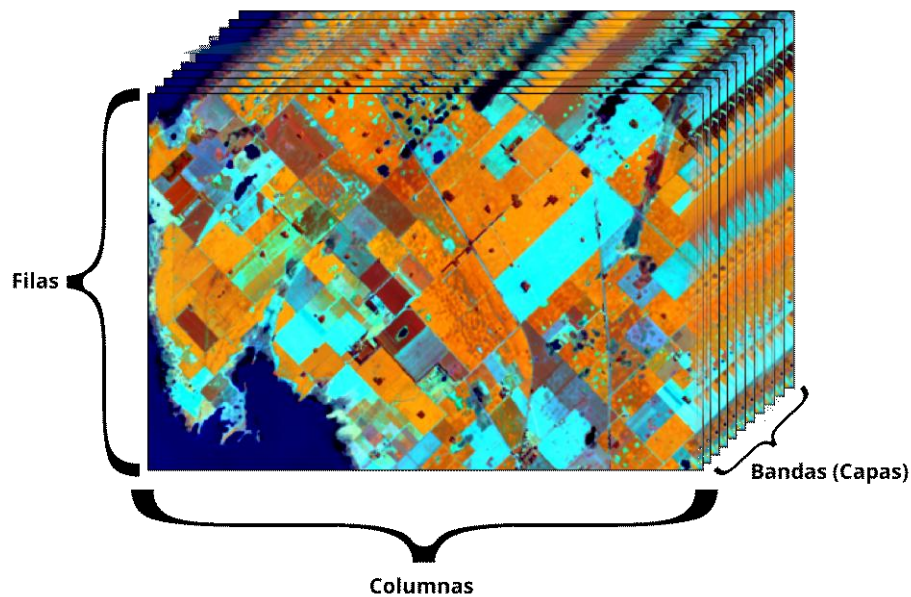


Figura 11 - Caracterización de una imagen espectral

2.6. Resolución espacial

Hasta el momento mencionamos que estos píxeles representan (capturan) una escena y se les asigna un valor numérico. Pero existe otra característica de los sensores relacionada a los píxeles que es, cuánto de la escena que se desea capturar representa espacialmente ese píxel, es decir, un píxel qué área representa de la escena real. Dicho de otro modo, qué Resolución Espacial tiene el sensor. Así dependiendo del sensor estos indican cuál es su resolución espacial a una cierta distancia estandarizada. De ese modo, si se cambia la distancia a la que se realiza la captura de la escena mediante un simple cálculo matemático se podría saber qué área real representa cada píxel de la imagen y por ende cuál es el área total capturada en una imagen.

En el caso de los sensores de las imágenes satelitales estos se encuentran a una distancia fija por lo que siempre cuentan con la misma resolución espacial y en algunos casos dependiendo del rango del espectro que capturen puede cambiar su resolución de una banda a otra. En el caso del satélite Landsat 8, este posee 1 banda con una resolución espacial de 15 m, 8 bandas con una resolución de 30 m y 2 bandas con resolución de 100 m.

2.7. Resolución temporal

El último aspecto a desarrollar sobre los sensores es la Resolución Temporal, esto es, con qué periodicidad de tiempo el sensor es capaz de captar la misma escena una o n veces. En este proceso de barrido de una escena (ver Figura 12), en el caso de los satélites, lo que define la temporalidad es el ciclo de repetición orbital que este tenga definido, en referencia a cada cuanto tiempo vuelve a pasar por el mismo lugar o capturar en una imagen una zona determinada.




Figura 12 - Diagrama de captura o barrido de una escena.

En el caso del satélite Landsat 8, la resolución temporal es de 15 días, y nuevamente dependiendo de lo que se busque obtener con estas imágenes se determinará qué satélite utilizar y con qué resolución temporal.

Capítulo 3. Machine Learning

3.1. Definiciones y clasificaciones

3.1.1. Grupos de algoritmos de Machine learning

Dentro de lo que a la IA concierne, se encuentra el *Machine Learning* (ML), área que engloba un conjunto de técnicas que hacen posible el aprendizaje automático a través del entrenamiento con grandes volúmenes de datos. Es decir, ML trata acerca de computadoras que puedan, mediante diferentes operaciones, aprender y adaptarse en base a la precisión de sus resultados.

Esto requiere definir claramente qué se busca con este tipo de técnicas, así tenemos algoritmos que nos permiten hacer una predicción, es decir entreno un algoritmo para que aprenda de un conjunto de datos y cuando le llegue un dato nuevo pueda predecir qué es. O si se busca que un algoritmo aprenda a encontrar, reconocer patrones o extraer información a partir de ciertos datos con el fin de encontrar algo que un humano no podría realizar o demandaría demasiado tiempo.

Esto es traducido en diferentes tipos de algoritmos, los cuales pueden agruparse en 3 grandes grupos [39]:

- *Supervised Learning* o Aprendizaje supervisado donde los algoritmos necesitan de que todos los datos con los que trabajará se encuentren etiquetados, a partir de los cuales se entrena, y son la base para la realización de predicciones o clasificaciones.

- *Unsupervised Learning* o Aprendizaje No Supervisado, el cual varía respecto al anterior en que el conjunto de datos que utiliza no se encuentran etiquetados, a partir de lo cual estos algoritmos no brindan posibles respuestas correctas sino que busca similitudes entre las características de los datos y en base a ello los agrupa.

- *Semi-Supervised Learning* o Aprendizaje Semi-Supervisado, donde aquí sólo una parte del conjunto de datos se encuentra etiquetada y para obtener un resultado del conjunto no etiquetado, el modelo debe aprender las estructuras para organizar los datos, así como a hacer predicciones.

Estas técnicas pueden ser aplicadas a todo tipo de datos, entre los cuales podrían ser los generados por las tecnologías utilizadas en la AP. Una de las tecnologías relacionadas a la misma es el Sensado Remoto o *Remote Sensing* (RS), dentro del cual se encuentran las imágenes satelitales.

Un aspecto importante a tener en cuenta es que estos algoritmos trabajan sobre un conjunto de datos, donde estos poseen una gran relevancia, si el conjunto de datos no es representativo del problema que se desea abordar mediante estas técnicas, los resultados

obtenidos no serán los esperados. Se desarrollará con mayor profundidad este aspecto en el próximo capítulo.

3.1.2. Machine Learning aplicado a Remote Sensing

Dentro de las diferentes técnicas de ML que se encuentran, aquellas en las que se hará hincapié son las relacionadas con RS. Teniendo en cuenta las más recientes, se destacan las cinco más utilizadas [6], entre las cuales se encuentra la ya mencionada *Semi-Supervised Learning*. Las restantes técnicas son:

- *Manifold Learning* o Aprendizaje Colector, encargada de buscar la visualización y comprensión de datos de alta dimensión de un modo viable a través del mapeo de datos de alta dimensión a otro de una menor.

- *Transfer Learning* o Aprendizaje de Transferencia, que permite que los dominios, tareas y distribuciones de datos utilizados en el entrenamiento y en el test sean diferentes. A veces existe una tarea de clasificación en un dominio de interés, pero sólo se dispone de datos suficientes de formación en otro dominio, donde los últimos datos pueden estar en un espacio de características diferentes o poseer una distribución de datos diferente. En tales casos, la transferencia de conocimientos, si se hace correctamente, mejoraría en gran medida el rendimiento del aprendizaje, evitando costosos esfuerzos de etiquetado de datos [40].

- *Structured Learning* o Aprendizaje Estructurado, que pertenece a un tipo de *Supervised Learning* y estudia los casos donde los espacios de salida son estructuras complejas, como por ejemplo, la predicción de múltiples etiquetas (uso y cobertura del suelo a la vez), o secuencias de imágenes multitemporales [6].

- *Active Learning* o Aprendizaje Activo (AL), técnica que constituye un caso especial de *Semi-Supervised Learning* y tiene como objetivo la construcción de conjuntos de entrenamiento eficientes, mejorando de manera iterativa el rendimiento del modelo. AL parte de un conjunto de datos etiquetados para el entrenamiento y luego mediante una heurística determinada va definiendo la incertidumbre de algunos datos para lo cual necesita de la interacción de un experto haciendo que éste determine la etiqueta que le corresponde. A partir de la repetición de dicho procedimiento es que se obtienen resultados deseados con una cantidad de datos etiquetados menor que si se utilizara una técnica de *Supervised Learning*. Es decir, AL explota la interacción con el usuario, disminuyendo al mismo tiempo el error.

3.1.3. Active Learning: una alternativa a Supervised Learning

La gran cantidad de datos que generan los sensores remotos en la actualidad, debido a la alta resolución tanto espacial como espectral, hacen que el etiquetado de dichos datos para los algoritmos, por ejemplo de *Supervised Learning*, sea muy difícil de realizar y que

demande demasiado tiempo. Sumado a ello, en el caso específico del agro, se requiere que dicho etiquetado sea realizado por expertos en la temática, lo que hace que la obtención de dicha cantidad de datos etiquetados, para el entrenamiento de las técnicas, represente todo un desafío. Debido a esta problemática, en muchas ocasiones, dichos algoritmos terminan aplicándose solamente sobre un conjunto reducido de datos. En este contexto, AL, representa una solución al tipo de inconvenientes mencionados anteriormente.

El objetivo de AL es obtener un rendimiento satisfactorio de clasificación con un menor número de muestras etiquetadas que las que se utilizan con Supervised Learning, donde el conjunto de entrenamiento, a menudo, se selecciona al azar o de forma manual y sin interacción con el clasificador [18]. Esto permite un reentrenamiento constante del algoritmo, lo cual posibilita una explotación de los datos y una reducción del costo de etiquetado.

Las técnicas AL requieren un conjunto de datos de 3 partes, el Conjunto de Entrenamiento o Training Set (CE), el Conjunto de Prueba o Test Set (CP) y el Conjunto de Candidatos o Candidate Set (CC). Donde algunos datos de este último conjunto, tras la aplicación de una heurística o criterio de selección, pasarán a formar parte del conjunto de entrenamiento [41].

Se toma como punto de partida un conjunto de Datos Etiquetados "L" los cuales se utilizarán para entrenar el Clasificador supervisado "C", que genera Datos Clasificados a partir de ese entrenamiento. La técnica continúa con el conjunto de Candidatos No Etiquetados "U", que son los datos de entrada para el Criterio de Selección "Q" (heurístico) el cual determina cuáles serán los Posibles Candidatos de los cuales determinará los Candidatos Seleccionados. Los que fueron seleccionados por la heurística deben ser etiquetados por el usuario experto para añadirlos al conjunto de Datos Etiquetados y comenzar de nuevo el proceso. El conjunto de datos no etiquetados que no hayan sido seleccionados serán considerados como Posibles Candidatos a ser seleccionados por el Criterio de Selección en la nueva iteración, repitiendo el procedimiento hasta alcanzar los resultados esperados. El conjunto de Datos No Etiquetados que no fueron seleccionados, serán considerados como candidatos a ser seleccionados por el Criterio de Selección en la nueva iteración. En otras palabras, AL aprovecha la interacción con el usuario y de ese modo intenta disminuir el error. En la Figura 13 continuación se expone un diagrama representativo del funcionamiento mencionado anteriormente.

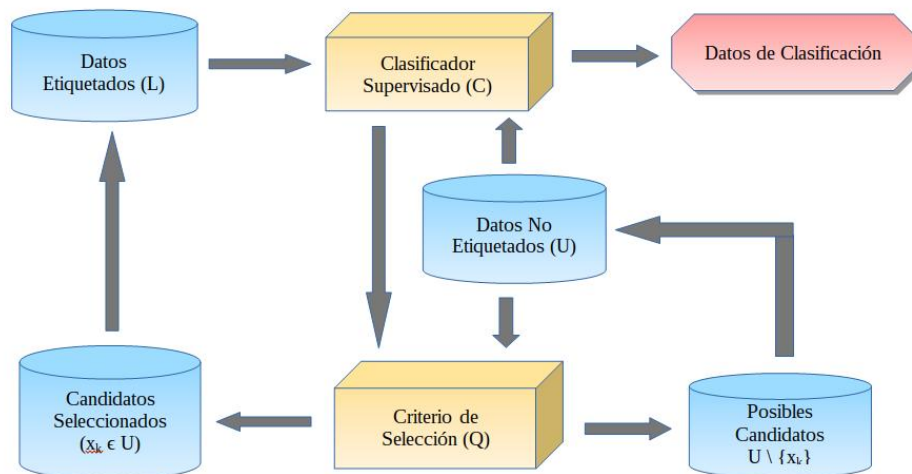


Figura 13 - Diagrama de flujo del funcionamiento general de Active Learning

A continuación se presenta un diagrama representativo del funcionamiento de la técnica en cuestión:

Algorithm 1: GENERAL PROCEDURE FOR ACTIVE LEARNING
ALGORITHM

Input: Initial labeled training set L
 Pool of training samples candidates U

- 1 **repeat**
- 2 With a Classifier C train a model with current training set L
- 3 **for each candidate from the pool U do**
- 4 Evaluate the score with a defined Selection Criteria Q *(Heuristic)*
- 5 **end**
- 6 Rank the candidates in U according to the score of the heuristic.
- 7 Select the X most interesting samples.
- 8 The user assigns a label ω to the selected samples.
- 9 Add these samples to the training set L .
- 10 Remove the samples from the pool of candidates U .
- 11 **until stop criteria are reached;**

3.2. Máquinas de vectores soporte (Support Vector Machine – SVM)

3.2.1. Introducción

Para el entrenamiento en cada iteración pueden ser utilizados varios clasificadores supervisados. En base a la literatura consultada, se decidió utilizar Máquinas de vectores soporte o Support Vector Machine (SVM) porque se aplica ampliamente en la clasificación de la cobertura del suelo [42], tiene mejores resultados que otras técnicas [43], y no requiere tantos datos etiquetados como las técnicas de redes neuronales [44].

Los algoritmos de AL que se han implementado utilizan SVM como clasificador, que fue popularizado por Vladimir Vapnik en 1992 [45] y luego en 1995 actualizado por el mismo autor [46]. Se utilizan principalmente para construir clasificadores, que a través del aprendizaje supervisado, distinguen entre diferentes muestras o clases.

Para comprender el funcionamiento de SVM se desarrollará un ejemplo de juguete en

el que se supondrá que se quiere separar dos clases, Cultivo 1 (C_1) y Cultivo 2 (C_2), donde además se cuenta con dos características que permitirán desarrollar un clasificador. Por un lado se tiene la Altura del Cultivo (x_1) y por el otro el Área Promedio de la Hoja (x_2), en el que se asumirán valores numéricos totalmente arbitrarios. Asumiendo los valores representados en la Figura 14 para cada una de las clases, donde en color rojo se representa C_1 y en color verde se representa C_2 , se debe determinar un modo de separar estas dos clases para que cuando se quiera evaluar una nueva planta se pueda determinar si pertenece a C_1 o C_2 .

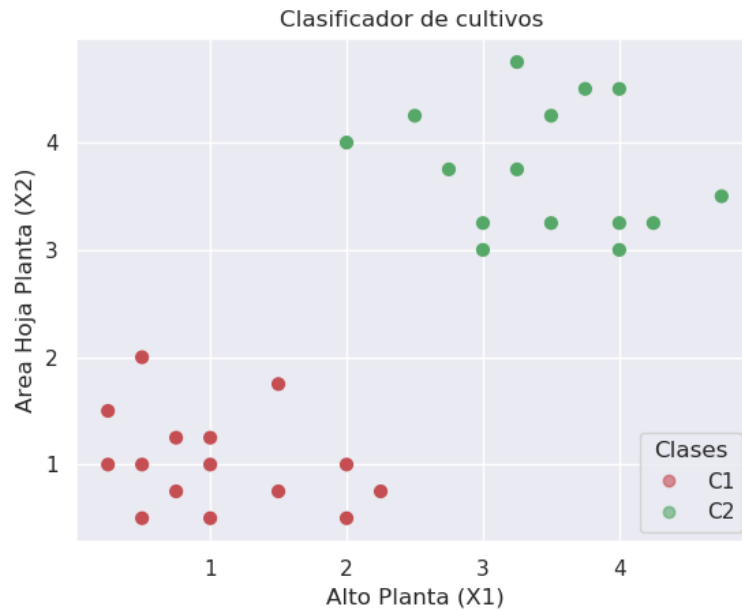


Figura 14 - Gráfico de características Altura y Área promedio de la hoja para los dos cultivos C_1 y C_2 del ejemplo de juguete.

Para ello se utilizan las matemáticas, ya que se podría definir una frontera de decisión que permita separar estas dos clases a partir de sus dos características. Así se podría determinar una línea recta que separe ambos conjuntos de puntos, donde una vez determinada la recta (frontera de decisión), cuando aparezca una nueva planta, se evalúen sus características en la función establecida y esta nos determine a qué tipo de planta pertenece.




Figura 15 – Gráfico de una frontera de decisión que separe las características.

Si se analiza la Figura 15 se puede observar que podría haber otras rectas que también separen ambas clases de manera correcta, de las cuales se desea determinar aquella que mejor separe las clases. En la Figura 16 se pueden observar algunas rectas alternativas que permitan separar las clases.




Figura 16 - Gráfico de múltiples fronteras de decisión posibles que separe las características.

Se sabe que la determinación de la mejor frontera de decisión depende de los datos con los que se cuenta a partir de los cuales se determinará la recta, es decir del conjunto de datos de entrenamiento, si estos son escasos, se encuentran desbalanceados (mayor cantidad de una clase que de otra) o las características utilizadas no son representativas de

las clases, hará que el clasificador (recta determinada) no sea del todo bueno. Aun teniendo características representativas de las clases existen infinitas rectas para separarlas.

3.2.2. Partes y definición matemática

Lo que en las figuras se observa como una recta en realidad es un hiperplano. Esto se debe a que en realidad se busca una frontera de decisión pero esta depende de las dos características, es decir que tanto x_1 como x_2 pueden variar sus valores. En el caso de la ecuación matemática de una recta se tiene:

$$f(x) = mx + b \quad (9)$$

Donde el valor de $f(x)$ depende del valor que toma la variable x , en el caso de la frontera de decisión no tenemos una relación lineal entre ambas sino que ambas, x_1 y x_2 varían, por lo que se debe encontrar una frontera de decisión que se encuentre en una dimensión mayor a R^2 , en este caso R^3 , donde se podría ver la clase como esa tercera dimensión a determinar. Formalizando lo mencionado sea x y w vectores N dimensionales $x = (x_1, x_2, \dots, x_n) \in R^n$ y $w = (w_1, w_2, \dots, w_n) \in R^n$ es posible determinar un hiperplano de decisión representado por:

$$F(x) = w \cdot x + b \quad (10)$$

$$w \cdot x + b = 0$$

Se conoce que, así como la modificación del valor de m y b en la ecuación de la recta se logra modificar la pendiente y ordenada al origen de la misma, lo mismo sucede con el hiperplano.

Como se observa en la Figura 16 para realizar la clasificación existen múltiples fronteras de decisión que permiten separar las diferentes muestras. Ahora para definir el criterio con el cual se selecciona ese hiperplano de separación existen diversos criterios, como pueden ser el caso de un regresor lineal que se utilizan en las redes neuronales [47] o las Support Vector Machine (SVM). En el caso de las primeras éstas definen un primer hiperplano aleatorio buscan definir el hiperplano de separación en base a la minimización del error que dicho comete a la hora de clasificar con datos conocidos (etiquetados). En el caso de SVM define un hiperplano de separación con la diferencia que luego busca ajustar esa frontera de separación (decisión) con el objetivo de que esta sea equidistante de las muestras a clasificar. En otras palabras, busca la frontera de separación que es equidistante a los ejemplos más cercanos de las clases en estudio y de este modo minimizar el error de clasificación.

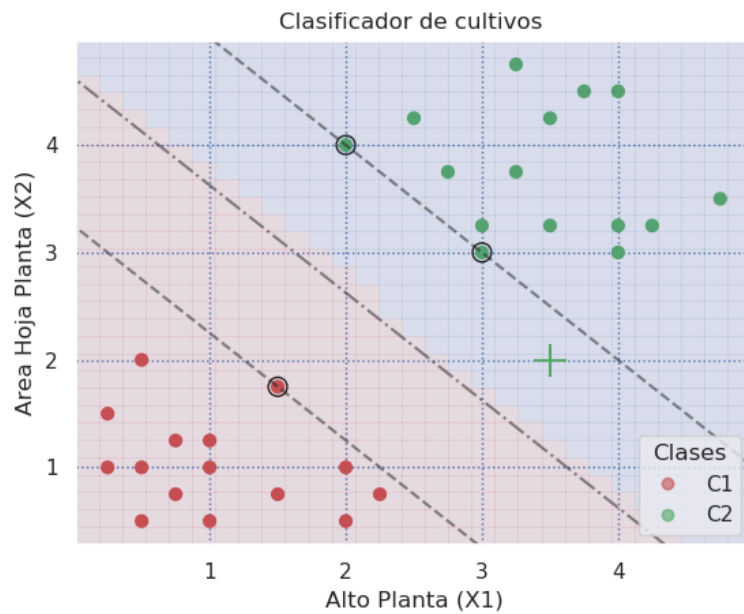


Figura 17 - Frontera de decisión obtenida con SVM, identificando los vectores soporte




Figura 18 – Hiperplano (plano) de frontera de decisión obtenida con SVM, identificando

Siguiendo con el mismo conjunto de datos, en la Figura 18 se puede observar el hiperplano de separación para ambas clases que logra realizar separar de manera equidistante ambas clases en base a sus características. En la Figura 17 se puede observar la proyección de ese hiperplano en 2 dimensiones, donde además se proyectan los márgenes de separación.

Si se tiene la ecuación del hiperplano como:

$$w \cdot x + b = 0 \quad (11)$$

siendo esta la frontera de decisión, siguiendo con el ejemplo se puede determinar que:

$$w_1 \cdot x_1 + w_2 \cdot x_2 + b = 0 \quad (12)$$

Donde w_1 y w_2 son las coordenadas del vector perpendicular al hiperplano como se puede apreciar en la Figura 19.




Figura 19 - Frontera de decisión con el vector (w_1, w_2) perpendicular al hiperplano de separación

La frontera de decisión nos determina:

$$w \cdot x + b < 0 \quad (13)$$

para aquellos elementos que se encuentren a la izquierda de la frontera, en este caso, para aquellos que pertenecen a C_1 . Y determina:

$$w \cdot x + b > 0 \quad (14)$$

para aquellos elementos que se encuentren a la derecha de la frontera, en este caso, para aquellos que pertenecen a C_2 .

Se puede observar además que los márgenes pasan por puntos pertenecientes a las clases, donde dichos puntos se los denomina Vectores Soporte. Así, se podría escribir la frontera de decisión teniendo en cuenta los vectores soporte x_+ y x_- , donde si denominamos a la clase C_1 con -1 y C_2 con 1 se tiene:

$$w \cdot x_- + b \leq -1 \quad (15)$$

como la ecuación para determinar los elementos de C_1 y

$$w \cdot x_+ + b \geq 1 \quad (16)$$

como la ecuación para determinar los elementos de C_2 .

Formalizando la ecuación se tiene que:

$$y_i(w \cdot x + b) \geq 1 \begin{cases} y_i = 1 & x_+ \\ y_i = -1 & x_- \end{cases} \quad (17)$$

Quedando la ecuación de los vectores soportes como:

$$y_i(w \cdot x + b) - 1 = 0 \quad (18)$$

ya que estos al estar sobre los planos de los márgenes se cumple con la igualdad.

Como se mencionó anteriormente, el objetivo de SVM es maximizar la distancia entre el hiperplano de separación y los valores de entrenamiento de las clases, dicho de otro modo, intenta que los Vectores Soporte estén lo más alejados entre sí posible ya que esto ampliará el margen de separación d . En la Figura 20 se muestra la frontera de decisión detallando el margen d y cada una de las partes que se involucran en el cálculo de la misma.

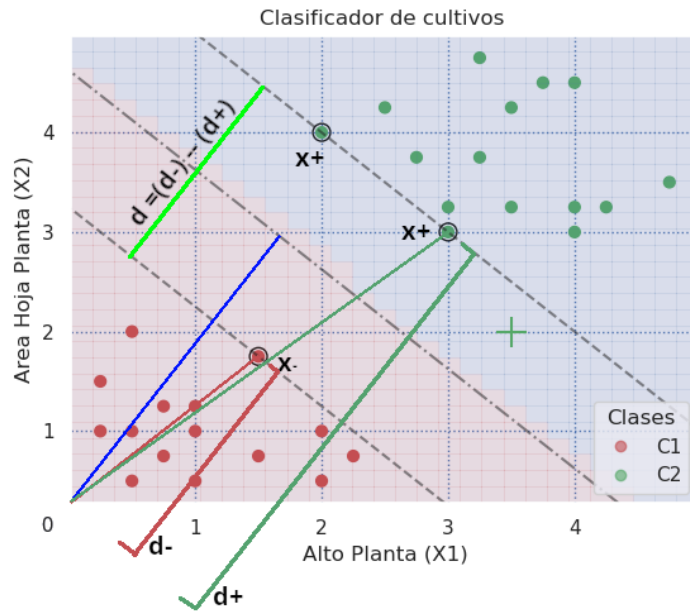


Figura 20 - Frontera de decisión obtenida con SVM, con todas sus partes.

Analizando la figura tenemos que la distancia del margen es:

$$d = d_+ - d_- \quad (19)$$

dónde:

$$d_- = \frac{x_- \cdot w}{\|w\|} \text{ y } d_+ = \frac{x_+ \cdot w}{\|w\|} \quad (20)$$

de este modo:

$$d = d_+ - d_- = \frac{x_+ \cdot w}{\|w\|} - \frac{x_- \cdot w}{\|w\|} = \frac{1}{\|w\|} (x_+ \cdot w - x_- \cdot w) \quad (21)$$

Reemplazando la ecuación 10 en la ecuación 14 se obtiene:

$$d = \frac{1}{\|w\|} (1 - b + 1 + b) = \frac{2}{\|w\|} \quad (22)$$

Maximizar la ecuación anterior es lo mismo que minimizar su inversa:

$$\operatorname{argmax} \frac{2}{\|w\|} = \operatorname{argmin} \frac{\|w\|}{2} \quad (23)$$

Ahora este problema de optimización es abordado con multiplicadores de Lagrange [48], ya que este permite que a partir de una función y sus restricciones de igualdad obtener

un nuevo problema de optimización pero sin las restricciones. Definiendo el Lagrangiano $L(w, b, \alpha)$:

$$L(w, b, \alpha) = f(w) + \alpha g(w, b) \quad (24)$$

En este caso, el problema de minimización con restricciones lo convierte en un nuevo de minimización pero sin restricciones. Tomando la ecuación 15 como objetivo $f(w)$ y la función 11 como restricción $g(w, b)$ se obtiene:

$$f(w) = \frac{1}{2} \|w\|^2 = \frac{1}{2} w^t w \quad (25)$$

$$g(w, b) = y_i(w \cdot x + b) - 1 = 0 \quad (26)$$

$$L(w, b, \alpha) = \frac{1}{2} w \cdot w - \sum_{i=1}^l \alpha_i [y_i(w \cdot x_i + b) - 1] \quad (27)$$

Donde operando y distribuyendo α_i se obtiene:

$$L(w, b, \alpha) = \frac{1}{2} w \cdot w - \sum_{i=1}^l \alpha_i y_i (w \cdot x_i + b) - \alpha_i \quad (28)$$

donde $(x_1, y_1), \dots, (x_l, y_l)$ es el conjunto de datos de entrenamiento que se quiere separar, l es el número de vectores soportes y $\alpha = (\alpha_1, \dots, \alpha_l)$ es el vector de multiplicadores de Lagrange asociado a las restricciones.

De este modo se obtiene un Lagrangiano el cual se debe optimizar, para lo cual derivando respecto de w y respecto de b , e igualando a 0 se puede obtener un mínimo:

$$\frac{\partial L}{\partial w} = w - \sum_{i=1}^l \alpha_i y_i x_i = 0 \quad \therefore w = \sum_{i=1}^l \alpha_i y_i x_i \quad (29)$$

$$\frac{\partial L}{\partial b} = \sum_{i=1}^l \alpha_i y_i = 0 \quad (30)$$

Reemplazando la ecuación 21 y 22 en la ecuación 20 se obtiene

$$L(\alpha) = -\frac{1}{2} \sum_{i=1}^l \alpha_i y_i x_i \cdot \sum_{j=1}^l \alpha_j y_j x_j + \sum_{i=1}^l \alpha_i \quad (31)$$

$$L(\alpha) = -\frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i y_i x_i \alpha_j y_j x_j + \sum_{i=1}^l \alpha_i$$

$$L(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j x_i \cdot x_j$$

Así se obtiene una función objetivo de minimización que solamente depende de los multiplicadores de lagrange α_i . Esto se cumple en los casos en los que los datos pueden ser separados de forma lineal como se ha mostrado en el caso de juguete.

Si ahora se tiene un conjunto de datos como los que muestra la Figura 21, ya no se puede utilizar un plano recto para poder separarlos.

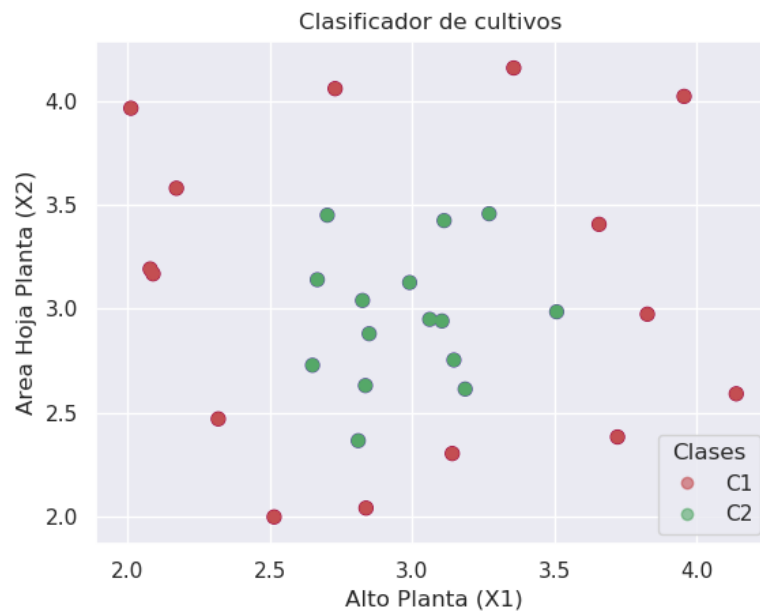


Figura 21 - Gráfico de características Altura y Área promedio de la hoja para los dos cultivos C_1 y C_2 del ejemplo de juguete, en este caso con datos no separables linealmente.

En ese caso, si se utilizaran las fórmulas desarrolladas anteriormente para SVM se obtendría una frontera de decisión como la que se muestra en la Figura 22 y Figura 23, donde se observa que no se obtiene una separación óptima de las clases.




Figura 22 – Frontera de decisión obtenida con SVM lineal para un conjunto de datos no separables linealmente.

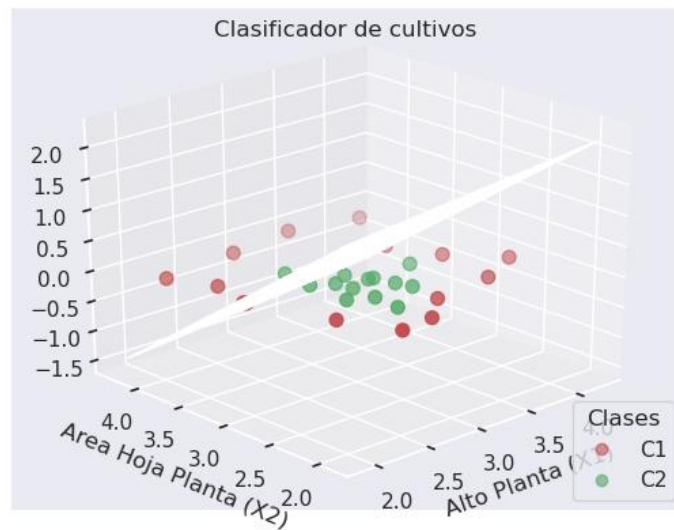


Figura 23 – Hiperplano (plano) frontera de decisión obtenida con SVM lineal para un conjunto de datos no separables linealmente.

Por ese motivo es que, cuando los datos no pueden ser separados de forma lineal, es necesario que la frontera de decisión tenga otra forma que pueda adaptarse a los datos, para lo cual se necesita utilizar funciones especiales llamadas kernels [49]. En la Figura 24 se muestra una posible frontera de decisión no lineal.




Figura 24 – Frontera de decisión no lineal arbitraria

3.2.3. Frontera de decisión no lineal

Para determinar cuál es la frontera no lineal a utilizar y además que esta sea óptima se necesitan hacer algunas modificaciones a las definiciones establecidas en las ecuaciones anteriores.

Se conoce que, basado en el producto escalar (punto) del espacio de Hilbert [50], es posible transformar el vector de entrada n -dimensional x en un vector de características N -dimensional a través de la elección de una función vectorial N -dimensional.

$$\phi(u) \cdot \phi(v) \equiv K(u, v) \quad (32)$$

$$\phi: R^n \rightarrow R^N$$

A partir de lo cual se puede construir un separador lineal de N dimensiones w y b para el conjunto de vectores transformados:

$$\phi(x_i) = \phi_1(x_i), \phi_2(x_i), \dots, \phi_N(x_i), \quad i = 1, \dots, l \quad (33)$$

Es decir, en lugar de tener directamente el vector de características, se tiene una función vectorial ϕ aplicada sobre el vector de características:

$$f(x) = w \cdot \phi(x) + b \quad (34)$$

De este modo, se puede convertir la función que originalmente era lineal en otro tipo de funciones. Ahora si se realiza el mismo cálculo aplicando el Lagrangiano de la ecuación 21 reemplazando x por $\phi(x)$ en el cálculo de la ecuación 22 se obtiene lo siguiente:

$$w = \sum_{i=1}^l \alpha_i y_i \phi(x_i) \quad (35)$$

Reemplazando la ecuación 28 en la ecuación 27:

$$f(x) = \sum_{i=1}^l \alpha_i y_i \phi(x_i) \cdot \phi(x) + b \quad (36)$$

Si se hace una analogía con la ecuación 25 de Gilbert, se tiene:

$$K(x_i, x) = \phi(x_i) \cdot \phi(x) \quad (37)$$

Así, se puede observar que en K se puede utilizar una función no lineal y de este modo salvar la ecuación para que la frontera de decisión pueda adaptarse a las características de los datos. A partir de esto, el Lagrangiano de la ecuación 24, quedaría del siguiente modo:

$$L(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j \phi_i \cdot \phi_j = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (38)$$

Siguiendo el ejemplo anterior, se podría obtener una frontera de decisión como se puede observar en la Figura 25, donde ésta es más óptima que la definida de manera arbitraria en la figura anterior.

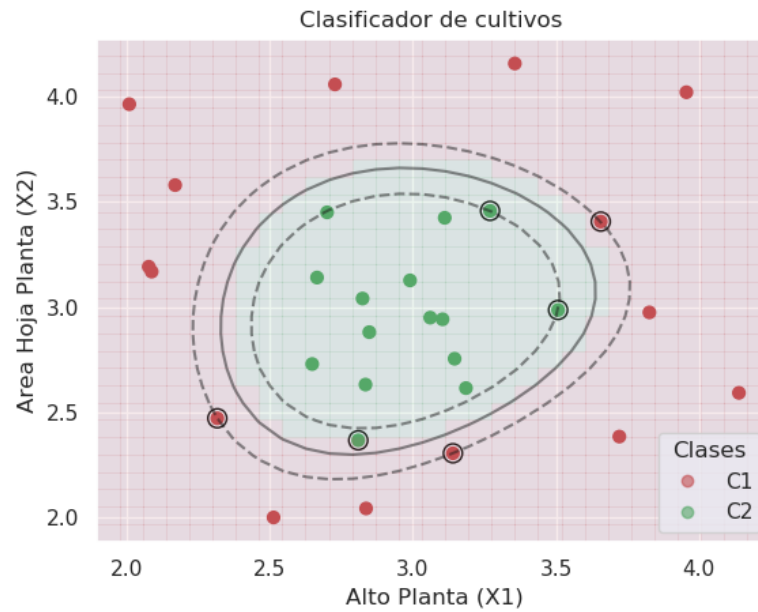


Figura 25 - Función de separación con un kernel no lineal

De este modo, con dicha función K , denominada kernel, se puede transformar la SVM lineal en una SVM donde su frontera de decisión se pueda adaptar a los datos si estos no fueran lineales. Existen diversas funciones kernel muy utilizadas en la bibliografía [51].

3.2.4. SVM Kernels

Dentro de la bibliografía consultada se encuentran diferentes kernel, el más básico y el que primero se ha definido es el Kernel Lineal:

$$K(x_i, x_j) = x_i \cdot x_j + c \quad (39)$$

Para cuando los datos no pueden ser separados linealmente como se ha mencionado anteriormente se necesita utilizar otro tipo de kernel. A partir de esto es que surge el Kernel Polinómico, donde se puede especificar el grado d del polinomio que se quiere utilizar, siendo $d > 1$:

$$K(x_i, x_j) = (x_i \cdot x_j + c)^d \quad (40)$$

Se puede utilizar una función exponencial como lo hace el Kernel Radial Basis Function (RBF) el cual es uno de los más populares y utilizados debido a su capacidad de parametrización y ajuste de las curvas que se quieren utilizar:

$$K(x_i, x_j) = e^{-\gamma \|x_i - x_j\|^2} \quad (41)$$

siendo $\gamma > 0$.

Otro que utiliza una función exponencial es el Kernel Gaussiano:

$$K(x_i, x_j) = e^{\frac{-\|x_i - x_j\|^2}{2\sigma^2}} \quad (42)$$

Por último, un kernel que es utilizado en las redes neuronales como función de activación es el Kernel Sigmoideo:

$$K(x_i, x_j) = \tanh(x_i \cdot x_j + c) \quad (43)$$

3.3. Heurísticas

Como se mencionó anteriormente, el algoritmo de AL requiere de heurísticas o criterios de selección de nuevos candidatos a ser incorporados en el conjunto de entrenamiento, es decir, pasan de estar en el conjunto de Posibles Candidatos a ser incorporados al conjunto de Candidatos Seleccionados. Luego de esta selección el especialista en la temática debe etiquetar dichos candidatos que pasan a ser parte de los Datos Etiquetados. A continuación se presentan diferentes criterios de selección Q (heurísticas) de candidatos que se implementaron. La determinación de las heurísticas se realizó en base a la literatura consultada [22] [52] [53].

3.3.1. Random sampling (AL-RS)

Se considera que una buena medida de comparación que permita evaluar el rendimiento de las demás heurísticas es que la selección de dichos candidatos a ser etiquetados se seleccionen al azar. Es decir que AL-RS, como su nombre indica, selecciona los candidatos sin utilizar ningún criterio particular es decir toma del conjunto de candidatos ciertos datos totalmente al azar. Tiene la ventaja de que al no utilizar criterio alguno el costo de realizar la selección es mucho menor que el de las demás heurísticas.

3.3.2. Margin sampling (AL-MS)

También encontrado en la literatura como *Most Ambiguous, Binary Level Uncertainty* o SVM_{SIMPLE} , es una heurística de selección de candidatos perteneciente a la familia de *large margin based heuristics*, que trata de incorporar al conjunto de entrenamiento las muestras más susceptibles de cometer errores de clasificación por parte de una SVM ya entrenada. Esta selecciona los candidatos en base a la minimización de la siguiente fórmula:

$$\hat{X}_{MS} = \arg \min_{x_i \in U} \{ \min_{\omega} |f(x_i, \omega)| \} \quad (44)$$

donde $f(x_i, \omega)$ es la distancia de la muestra al hiperplano definido para la clase ω .

Para establecer qué elementos deben incorporarse al conjunto de entrenamiento, se mide la distancia entre todas las muestras del conjunto candidato y los hiperplanos de la

SVM que determinan dónde se encuentran los individuos de cada una de las clases ω . Las muestras más cercanas a los límites de decisión (hiperplanos) de la SVM serán las más propensas a ser clasificadas erróneamente. Por ello, la heurística las seleccionará para que sean clasificadas por un experto y pasen a formar parte del conjunto de entrenamiento.

La heurística parte de asumir que el espacio de muestras es lo suficientemente simétrico o balanceado, característica que no siempre cuenta el conjunto de datos. La heurística prevé que si se tiene dentro del conjunto de candidatos una clase que es la que más dificultades tiene el modelo para distinguir va a tender a incorporar dichos elementos. En el caso de que haya una o más clases con dificultades puede llevar a que una predomine en detrimento de la otra, sobre entrenando una dejando de lado las demás.

En el caso de este trabajo, se utiliza una configuración *one-vs-one*, a diferencia de la fuente referenciada que utiliza *one-against-all*. Ambas difieren en que la primera requiere un clasificador binario para cada par de clases posible, por lo cual el número de pares totales es $\frac{n(n-1)}{2}$ para un problema de clase n . En contraste, la segunda utiliza un clasificador binario que separe cada clase de las restantes, teniendo n clasificadores, siendo n el número de clases. Según las pruebas experimentales realizadas por [54], *one-vs-one* es superior a *one-against-all* e incluso a *all-at-once*.

3.3.3. Multiclass Level Uncertainty (AL-MCLU)

MCLU también pertenece a la familia de *large margin based heuristics* y utiliza las dos clases más probables o mayor confianza. Este selecciona los candidatos en base a la diferencia entre la distancia al margen para las dos clases más probables:

$$\hat{X}_{MCLU} = \arg \min_{x_i \in U} \{f(x_i)^{MC}\} \quad (45)$$

donde

$$f(x_i)^{MC} = \max_{\omega \in N} f(x_i, \omega) - \max_{\omega \in N \setminus \omega^+} f(x_i, \omega)$$

siendo ω^+ la clase más probable o que posee mayor confianza. Para establecer los elementos que se incorporan al conjunto de entrenamiento, mide la distancia entre todas las muestras del conjunto candidato y los hiperplanos de la SVM que determinan dónde se encuentran los individuos de cada una de las clases ω . Para cada muestra calcula la diferencia entre las distancias de las dos clases más probables, que son las dos distancias mayores, tomando las de menor diferencia para incorporarlas al conjunto de entrenamiento. Cuando la distancia entre estas dos clases es menor, indican que estas muestras están cerca de la frontera de decisión que las separa y por ende allí la incertidumbre es mayor, lo que indicaría que existe una mayor probabilidad de que se tengan errores de clasificación.

3.3.4. Breaking Ties (AL-BT)

BT pertenece a la familia de algoritmos *Posterior Probability Based* que utiliza la estimación de la probabilidad posterior para seleccionar un nuevo candidato. Dado que la probabilidad posterior brinda una referencia de la confianza de la asignación de la clase. Se trata de utilizar la probabilidad condicional $p(y_i^* = \omega | x_i)$ para predecir una determinada clase para cada candidato $x_i \in U$, y $y_i^* = \max_{\omega \in N} f(x_i, \omega)$. En la literatura [22] se propone la estimación de Platt [55]:

$$p(y_i^* = \omega | x_i) = \frac{1}{1 + e^{(Af(x_i, \omega) + B)}} \quad (46)$$

pero en el presente desarrollo se utilizará la estimación de para multiclase de Wo [56], donde siendo $(p_1, \dots, p_n) = (P_Y(y_1|x), \dots, P_Y(y_n|x))$ define que la probabilidad p_i se deriva de:

$$p_{ij} = P_Y(y_i | \{y_i, y_j\}) = \frac{p_i}{p_i + p_j} \quad (47)$$

A continuación, para establecer qué elementos deben incorporarse al conjunto de entrenamiento, calcula, para todas las muestras del conjunto de candidatos, la probabilidad de pertenecer a cada una de las clases. Para cada muestra, calcula la diferencia entre las dos mayores probabilidades y luego toma aquellas en las que la diferencia es menor. Una diferencia menor indica que la incertidumbre de la clasificación es mayor y por lo tanto es más propensa al error.

$$\hat{X}_{MCLU} = \arg \min_{x_i \in U} \{ \max_{\omega \in N} \{p(y_i^* = \omega | x_i)\} - \max_{\omega \in N \setminus \omega^+} \{p(y_i^* = \omega | x_i)\} \} \quad (48)$$

3.3.5. Margin Sampling Orthogonal (AL-MSO)

Las anteriores heurísticas no tienen en consideración que las muestras que se incorporen al conjunto de entrenamiento no sean demasiados similares, dicho de otro modo no consideran que las muestras incorporadas sean lo más diversas posible. Contar con diversidad en las muestras que pertenecen a la misma clase a la otra de entrenar un modelo puede llegar a aportar valor, siempre dependiendo de cómo sea la distribución de las muestras pertenecientes a cada clase. La heurística AL-MSO tiene por objetivo lo mencionado anteriormente, donde para elegir la nueva muestra a incorporar utiliza una medida que le indique dicha diversidad. Mejorando en cierto modo la dificultad que contaba AL-MS de sobre entrenar con una misma clase y que el entrenamiento se realice de un modo desbalanceado. La heurística parte de que una medida de diversidad se maximiza cuando los hiperplanos asociados a las muestras son ortogonales. Si como se

menciona en el apartado 3.2.1, se tiene que x_i y x_j son las representaciones del espacio de entrada de dos muestras candidatas, entonces requerimos un valor bajo para $K(x_i, x_j)$, que es el valor que toma el kernel SVM para este par de datos. Como por Hilbert se mencionó que se tiene que $\phi(x_i), \phi(x_j)$ son los vectores de características de x_i, x_j y si todos los datos de los vectores en el espacio de entrada son perpendiculares al hiperplano, entonces esta condición adicional corresponde a un requisito de (cuasi) ortogonalidad entre $\phi(x_i)$ y $\phi(x_j)$ (ya que $K(x_i, x_j) = \phi(x_i) \cdot \phi(x_j)$).

Para medir dicha heurística debería calcular una medida del ángulo entre los candidatos en el espacio de características, lo cual lo hace computacionalmente costoso es por eso que se utiliza lo anteriormente mencionado. La fórmula puede describirse del siguiente modo:

$$\hat{X}_{MAO} = \arg \min_{x_i \in U^{AL-MS}} \{ \max_{x_j \in S} K(x_i, x_j) \} \quad (49)$$

siendo S el subconjunto de datos seleccionados por AL-MS.

3.4. Métricas de Evaluación

Las técnicas de ML que fueron mencionadas anteriormente requieren de alguna métrica que proporcione una medida para determinar qué tan buenas estas son, y que además puedan ser comparadas entre sí cuando se aplican a un mismo conjunto de datos. Estas métricas permiten, a la hora de aplicar de este tipo de algoritmos de ML, no solo tener una medida de qué tan buenos son las diferentes técnicas aplicadas sobre los datos que se están evaluando sino que permiten además analizar el modelo utilizado con el fin de ajustar los parámetros que este tenga.

En todos los casos, como se trata de una técnica supervisada se necesita contar con lo que se denomina Verdades de Campo o Ground Truth (GT) que son las que luego permitirán cotejar si el valor al que está arribando el algoritmo es correcto o no. Es decir que por un lado se tendrán los datos y asociado a esos datos cuál es el valor correcto que se espera obtener luego de que esos datos pasen por el algoritmo lo que se denomina el dato etiquetado.

Existen diferentes tipos de métricas para los distintos tipos de algoritmos de ML existentes, en el caso del presente trabajo se mencionan las que aplican a las técnicas supervisadas y más utilizadas en la literatura consultada [57]. A continuación se describen las métricas que se consideraron en el presente trabajo orientando el desarrollo de las mismas a problemas de clasificación con múltiples clases.

3.4.1. Matriz de confusión

La matriz de confusión es una tabla que muestra el resultado de la clasificación de un

conjunto de datos, mostrando por un lado la clasificación obtenida y contrastándola con la clasificación que debía obtener según la verdad de campo. Es decir, muestra la cantidad de datos que fueron precedidos correctamente y la cantidad que lo ha hecho de manera errónea, mostrando además en aquellas que se equivocó con qué otra etiqueta la confundió. De este modo aporta un valor significativo ya que nos permite ajustar el modelo con el que estemos trabajando o en su defecto operar con los datos de entrada en pos de ayudar a la técnica a que logre diferenciarlas de manera correcta. Así, en las filas de la tabla se indican los valores Predichos por el algoritmo y en las columnas los verdades de campo, teniendo en la diagonal los valores que coinciden entre la predicción y el valor esperado (la etiqueta de los datos). Estas cantidades pueden ser indicadas con la cantidad de valores reales, es decir si se utilizaron 100 datos de una clase C_1 , en la columna si se suman todas las clasificaciones se encuentra un total de 100 elementos clasificados. Cabe destacar que en la literatura puede que se encuentren los valores de las filas y columnas invertidas, encontrando en las columnas las verdades de campo y en las filas los valores de la clasificación. A continuación se muestra en la **Tabla 1** una matriz de confusión para el caso de la utilización de dos clases.

Tabla 1 - Tabla de verdad de ejemplo

		Valor Real	
		C_1	C_2
Valores Predichos	C_1	69	12
	C_2	6	3

Asimismo esta cantidad puede verse reflejada en modo de porcentaje como en la Tabla 2, donde cada celda contiene el porcentaje referido a las cantidades predichas para esa clase. Dicho de otro modo, en la celda se encuentra el porcentaje en referencia al total de elementos de esa clase es decir al total de esa columna.

Tabla 2 - Tabla de verdad de ejemplo con valores porcentuales

		Valor Real	
		C_1	C_2
Valores Predichos	C_1	$69 / 72 = 0.92$	$12 / 15 = 0.8$
	C_2	$6 / 72 = 0.08$	$3 / 15 = 0.2$

Ahora se debe establecer qué es cada una de las partes de esta tabla de verdad ya que los valores reflejados en esta matriz de confusión son los que se utilizan luego en las

siguientes métricas.

Si se observa la matriz en la diagonal encontraremos los valores que coinciden el valor real con el valor Predicho. Si lo que se está analizando es qué tan bien funciona el algoritmo para la predicción de la clase C_1 , la celda de la diagonal en la que coinciden los dos C_1 se lo considera como Verdadero Positivo o *True Positive* (TP). Ahora la otra celda de la diagonal en el que coinciden C_2 como el valor predicho es correcto pero se está analizando C_1 se la considera Verdadero Negativo o *True Negative* (TN). Luego, los valores que fueron predichos como C_2 pero en realidad eran de la clase C_1 , se lo considera como Falso Negativo o *False Negative* (FN). Por último los valores predichos como C_1 que en realidad eran C_2 se los considera como Falso Positivo o *False Positive* (FP). Esto se puede observar en la **Tabla 3**.

Tabla 3 - Tabla de verdad indicando cada parte de la misma

		Valor Real	
		C_1 (<i>Positive</i>)	C_2 (<i>Negative</i>)
Clases		C_1 (<i>Positive</i>)	C_2 (<i>Negative</i>)
Valores Predichos	C_1 (<i>Positive</i>)	TP	FP
	C_2 (<i>Negative</i>)	FN	TN

Si expresamos esta misma tabla pero con los porcentajes tenemos la **Tabla 4**:

Tabla 4 - Tabla de verdad indicando cada parte de la misma expresada en valores porcentuales

		Valor Real	
		C_1 (<i>Positive</i>)	C_2 (<i>Negative</i>)
Clases		C_1 (<i>Positive</i>)	C_2 (<i>Negative</i>)
Valores Predichos	C_1 (<i>Positive</i>)	$\frac{TP}{TP + FP}$	$\frac{FP}{FP + TP}$
	C_2 (<i>Negative</i>)	$\frac{FN}{FN + TN}$	$\frac{TN}{TN + FN}$

Ahora si se tienen más de dos clases se debe reconsiderar esta tabla teniendo en cuenta una redistribución de los valores definidos anteriormente, teniendo en estos casos más de un valor para el TN, FP y FN. Si se quiere evaluar la clase C_k , se tendría algo expresado como en la **Tabla 5**.

Tabla 5 - Tabla de verdad indicando cada parte de la misma para un problema multiclase

		Valor Real					
		Clases	C_1	C_2	...	C_k	C_{n-1}
Valores Predichos	C_1	TN	TN	TN	FN	TN	TN
	C_2	TN	TN	TN	FN	TN	TN
	...	TN	TN	TN	FN	TN	TN
	C_k	FP	FP	FP	TP	FP	FP
	C_{n-1}	TN	TN	TN	FN	TN	TN
	C_n	TN	TN	TN	FN	TN	TN

3.4.2. Exactitud o Accuracy

El *Accuracy* es una de las métricas más comunes y utilizadas de todas, la cual mide la cantidad de casos que el modelo predijo correctamente y lo expresa como un porcentaje.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (50)$$

Uno de los factores que se debe tener en cuenta con esta métrica es que puede llevar a resultados que no reflejen lo que está sucediendo con el modelo que se está evaluando.

Si se toma el ejemplo que se ha mostrado en la Tabla 1 el resultado que se obtiene es:

$$accuracy = \frac{69 + 3}{69 + 3 + 6 + 12} = 0.8 \quad (51)$$

En este caso se puede observar que el accuracy tiene un valor alto, pero oculta que su funcionamiento no es bueno para clasificar la clase C_2 . Sumado a esto el desbalance en la cantidad de muestras entre las clases, donde se tiene más cantidad de muestras evaluadas para la clase C_1 que la clase C_2 hace que pueda llevar a errores de interpretación del modelo.

Una alternativa a esto es, en lugar de utilizar la matriz con las cantidades de muestras, utilizar la matriz con los porcentajes Tabla 4, de este modo la fórmula quedaría:

$$Balanced Accuracy = \frac{\frac{TP}{TP + FP} + \frac{TN}{TN + FN}}{2} \quad (52)$$

siguiendo el ejemplo:

$$Balanced Accuracy = \frac{\frac{69}{69+6} + \frac{3}{3+12}}{2} = \frac{0.92 + 0.2}{2} = \frac{1.12}{2} = 0.56 \quad (53)$$

Como se observa del resultado, éste refleja un poco mejor qué tan bien está funcionando el modelo pero nuevamente nada nos dice acerca de qué sucede con cada una de las clases intervinientes.

3.4.3. Precisión o *Precision*

Una métrica que permite observar qué sucede con cada una de las clases es la precisión, que brinda un valor de referencia teniendo en cuenta los valores de los FP. Dicho de otro modo, permite destacar cuando el costo de los FP es alto, utilizando los valores que el modelo predijo como esa clase que se está evaluando. La métrica permite para una clase predicha determinar cuántas de los valores predichos como esas clases son correctas y cuántas no. A continuación se detalla la fórmula y en la Tabla 6 los atributos que interactúan en la fórmula:

$$Precision = \frac{TP}{TP + FP} \quad (54)$$

Tabla 6 – Tabla de verdad resaltando en rojo los elementos utilizados en *Precision*

		Valor Real	
		C_1 (Positive)	C_2 (Negative)
Valores Predichos	C_1 (Positive)	TP	FP
	C_2 (Negative)	FN	TN

3.4.4. Exactitud o *Recall*

Otra métrica que considera las clases es el *Recall* que tiene en cuenta los FN, es decir esta métrica permite ver para un valor de verdad qué cantidad de valores fueron predichos de manera correcta y cuántos no. Permite determinar del total de elementos de una clase, cuántos de estos clasificó de manera correcta y cuántos no. A continuación se detalla la fórmula y en la Tabla 7 los atributos que interactúan en la fórmula:

$$Recall = \frac{TP}{TP + FN} \quad (55)$$

Tabla 7 - Tabla de verdad resaltando en rojo los elementos utilizados en *Recall*

		Valor Real	
		C_1 (Positive)	C_2 (Negative)
Valores Predichos	C_1 (Positive)	TP	FP
	C_2 (Negative)	FN	TN

Se puede observar que el *Recall* es lo que se utiliza en la fórmula del *Balanced Accuracy* con el TP y el TN, o de otro modo el *Recall* para C_1 y el *Recall* para C_2 , la cual podría ser reescrita del siguiente modo:

$$Balanced Accuracy = \frac{Recall_{C_1} + Recall_{C_2}}{2} \quad (56)$$

3.4.5. Medida F o *F1-Score*

Esta métrica brinda una media armónica entre *Precision* y *Recall*, lo que brinda una buena medida de referencia cuando se tienen desbalance entre las clases.

$$F1 - Score = \frac{2}{Precision^{-1} + Recall^{-1}} = 2 \cdot \left(\frac{Precision \cdot Recall}{Precision + Recall} \right) \quad (57)$$

Capítulo 4. Pruebas y Resultados

4.1. Dataset y estructura de los datos

El objetivo del presente trabajo es la aplicación de algoritmos AL para la clasificación de cultivos de verano en el noroeste de la provincia de Buenos Aires mediante el uso de imágenes del satélite Landsat 8. Los cultivos de verano que se siembran en la región son el maíz, la soja y el sorgo, siendo los dos primeros los principales y más extendidos. La región también cuenta con grandes lagunas y ríos que la atraviesan, por lo que algunas parcelas son adyacentes a estas grandes concentraciones de agua y muchas de ellas contienen tierras bajas donde el agua de lluvia suele acumularse.

Las imágenes utilizadas en el trabajo se han descargado del sitio web del Servicio Geológico de los Estados Unidos [38] las cuales se tomaron del sensor Landsat 8 en la ruta 226 y la fila 084, zona que abarca el área de estudio, comprendiendo el distrito de Junín, Rojas y Chacabuco, dentro de la provincia de Buenos Aires.

La imagen espectral que cubre parte del noroeste de la provincia de Buenos Aires tiene 2615 por 2519 píxeles y de las 11 bandas espectrales que cuenta Landsat solamente se utilizaron 6 bandas de reflectancia (azul, verde, rojo, infrarrojo cercano, infrarrojo de onda corta 1, e infrarrojo de onda corta 2) con 30 metros de resolución espacial. Luego, se analizaron algunos índices de vegetación para destacar aspectos de las diferentes coberturas teniendo en cuenta la región [23], con el objetivo de aportar datos que sirvan de ayuda al algoritmo. A partir de allí, se determinó el uso de cuatro índices de vegetación Índice de Vegetación de Diferencia Normalizada (NDVI), Índice de Vegetación Ajustado al Suelo (SAVI), Índice de Vegetación Mejorado (EVI), e Índice de Humedad de Diferencia Normalizada (NDMI), que se añadieron como bandas a la imagen Landsat.

El estudio se basó en los cultivos de verano sembrados durante el año 2019; se trata de cultivos para la temporada 2019-2020. Consultando con los expertos se determinó que el rango de fechas óptimas para la detección de cultivos de verano en esta región es desde mediados de enero hasta finales de febrero, ya que en esas fechas algunos cultivos están pasando de la floración a la senescencia. Dado que las imágenes Landsat tienen una frecuencia de 16 días entre imágenes del mismo sitio, se han obtenido 3 imágenes en ese periodo. Una imagen es del 25 de enero de 2020, la otra es del 10 de febrero de 2020 y la última del 26 de febrero de 2020. Para la verdad de campo, se consultó a 6 productores locales y se realizó un recorrido por los diferentes campos tomando nota del cultivo plantado.

Las imágenes contienen diferentes coberturas terrestres, lagunas, bajos y edificios. En esta primera instancia, estas edificaciones fueron excluidas de la clasificación e identificadas como fondo por estar compuestas por diferentes elementos, no respondiendo a un patrón específico, lo que dificulta su clasificación.

Para la verdad de campo, se consultó a los productores locales y se realizó un recorrido por diferentes campos tomando nota del cultivo plantado. La Tabla 8 muestra las 6 clases de cobertura del suelo utilizadas en la verdad de campo y el número de muestras

de cada una de ellas. Allí se puede observar que la cantidad de cultivos de Sorgo que se identificó es menor que el resto de las coberturas del suelo porque el Sorgo es menos frecuente que el resto de los cultivos en esta región.

Dado que las imágenes Landsat tienen una frecuencia de 16 días entre las imágenes del mismo sitio, se han obtenido 3 imágenes en ese período. Y las imágenes contienen diferentes coberturas terrestres, lagunas, tierras bajas y edificios. En este primer caso, estos edificios fueron excluidos de la clasificación e identificados como fondo. En la Figura 26 se muestra un recorte de una de las imágenes landsat utilizadas con un esquema de color RGB y con algunas de las verdades de campo dibujadas en forma de polígonos.



Figura 26 - Imagen RGB ecualizada con verdades de campo

Tabla 8 - Coberturas, siglas y cantidad de muestras de la verdad de campo

Cobertura	Sigla	Número de Muestras
Background	BG (No Clase)	6.492.999
Maíz	MZ	10.088
Soja	SB	16.731
Soja de Segunda	DS	13.187
Maíz de Segunda y Maíz Tardío	DM	33.108
Sorgo	SG	1.758
Agua	WT	19.314

El armado del conjunto de datos para su utilización en el algoritmo consta de dos partes, la imagen espectral y una imagen del mismo tamaño, pero con las Verdades de

Campo o Ground Truth (GT) o etiquetas como se ilustra en la Figura 27. Dicho de otro modo, la imagen espectral puede ser vista como un cubo de imagen donde las filas y las columnas son las dimensiones de la imagen y la profundidad son cada una de las bandas espectrales (imágenes de las bandas espectrales). Y una imagen con la misma cantidad de filas y columnas donde se encuentran las verdades de campo. Cada píxel de la imagen espectral con los valores de cada sus bandas conformará el vector de características sobre el cual los algoritmos de ML intentarán encontrar patrones.

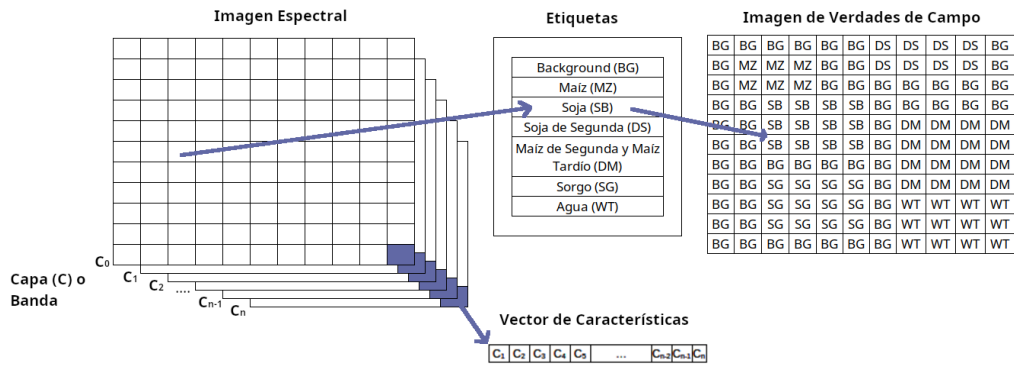


Figura 27 – Descripción de las partes del conjunto de datos.

Para la construcción de dicho dataset se ha utilizado la herramienta QGIS [58] donde se ha procesado la imagen descargada, llevándola a las dimensiones establecidas y se ha realizado el etiquetado de la imagen que luego ha derivado en una nueva imagen de las mismas dimensiones que la Landsat. El agregado de las bandas con los índices de vegetación se ha realizado posteriormente durante el desarrollo, realizando el cálculo y agregando las nuevas bandas a la imagen.

4.2. División del dataset y pruebas

La imagen espectral utilizada en el presente trabajo es un cubo de dimensiones 2519 píxeles (fila) por 2615 píxeles (columna) por 10 bandas que se ha redimensionado a una matriz, convirtiendo las filas por columnas en 6.587.185 píxeles (fila) y manteniendo las 10 bandas (columnas). De los 6.587.185 píxeles del conjunto de datos, se descartaron los que estaban etiquetados como fondo, debido a que como no poseen una clase específica de cobertura contienen una firma espectral que puede ser muy variada, lo que hace muy difícil su clasificación. En total 6.492.999 píxeles pertenecientes al fondo se han quitado, quedando un conjunto de datos de 94.186 píxeles a utilizar.

El criterio para la selección del conjunto de entrenamiento inicial ha sido tomar una determinada cantidad de píxeles de cada una de las clases para equilibrar el clasificador inicial. Para ello se han realizado diferentes pruebas, llegando a un mínimo de 5 píxeles por clase (unos 30 píxeles de entrenamiento) para construir el conjunto de entrenamiento. La cantidad se ha determinado teniendo en cuenta el objetivo de la técnica, que es tener que etiquetar la menor cantidad de píxeles para obtener un resultado óptimo. Posteriormente, se ha definido que el 30% del total de píxeles del conjunto de datos se utiliza en el conjunto de entrenamiento y el 70% restante de píxeles para el conjunto de entrenamiento y los

candidatos.

A lo largo del trabajo se realizaron diferentes pruebas, donde se utilizaron los algoritmos mencionados anteriormente, SVM y algoritmos AL como AL-RS, AL-MS, AL-MSO, AL-BT y AL-MCLU, aplicados a imágenes Landsat de 3 fechas diferentes. En primer lugar, se definió el tamaño del conjunto de entrenamiento inicial que necesitan los algoritmos AL que luego se ha ido incrementando utilizando algún criterio particular (heurística). Después de diferentes pruebas, se determinó que se obtenía un buen clasificador de partida utilizando un mínimo de 5 píxeles etiquetados por clase. Es decir, con $n=5$ se ha obtenido un clasificador que con un *Overall Accuracy* (OA) entre el 65% y el 80% dependiendo de la heurística.

Cuando se evaluó el rendimiento de los algoritmos a partir de este n , se ejecutaron $i=150$ iteraciones del algoritmo AL, incorporando a través de la heurística primero 10 píxeles en cada iteración, y luego, $i=75$ iteraciones pero con 20 píxeles en cada iteración. Con cada una de estas combinaciones se ejecutaron un total de 3 instancias para cada algoritmo AL con sus diferentes heurísticas AL-RS, AL-MS, AL-MSO, AL-BT y AL-MCLU. Todo esto hace un total de 50 ejecuciones, 10 para AL-RS, 10 para AL-MS, 10 para AL-MSO, 10 para AL-BT, 10 para AL-MCLU y 10 para SVM. Como el conjunto de datos tenía 3 imágenes de diferentes fechas, se realizaron un total de 150 ejecuciones.

Otro aspecto a determinar fue si se utiliza un conjunto de datos balanceado o no, es decir, si los algoritmos eran entrenados con la misma cantidad de etiquetas para cada clase o si se utilizaron las clases con el número de etiquetas que se obtuvieron. Esto no solamente para el conjunto de entrenamiento sino también para el conjunto de test.

En la prueba realizada, al haber una cantidad significativamente menor de etiquetas del cultivo de sorgo, se decidió balancear el número de muestras de cada clase del conjunto de datos. Así, en la división del conjunto de datos que quedó establecida, el 30% del conjunto de prueba tenía la misma cantidad de etiquetas para todas las clases. Y lo mismo se hizo con el 70% que incluía el conjunto de entrenamiento y el conjunto de posibles candidatos a elegir por la heurística. Esto redujo el número total de 94.186 píxeles etiquetados a 10.548 píxeles (1.758 píxeles, que es el número que tiene Sorgo, para las 6 clases), dejando 7.383 píxeles para el entrenamiento y los candidatos, y unos 3.165 píxeles para la prueba.

El software desarrollado para los algoritmos fue escrito para python 3.7 [59] y utilizando bibliotecas como Scikit-Learn [60] para probar los algoritmos de machine learning.


4.3. Resultados

El resultado de la clasificación de cada una de las imágenes Landsat de las tres fechas seleccionadas a lo largo de todas las iteraciones puede verse en la Figura 28. En ella se muestran las pruebas realizadas para cada fecha con un conjunto de entrenamiento inicial de 5 píxeles por clase. Donde, en el eje x, se muestra la cantidad de muestras etiquetadas en cada iteración y, en el eje y, el porcentaje de precisión obtenido para cada una de estas cantidades de muestras. El gráfico muestra todas las variantes probadas,

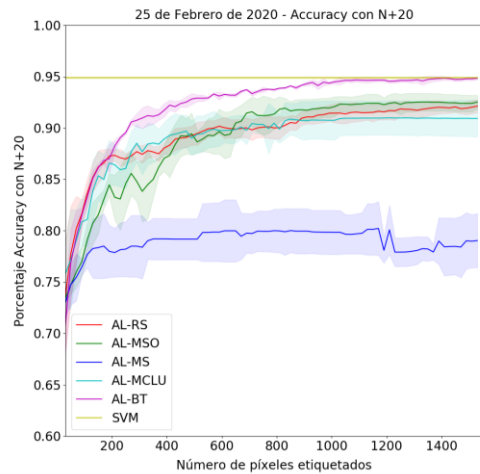
mirando lo que ocurrió en los extremos del número de iteraciones, es decir cuando $i=75$ y cuando $i=150$.

En los gráficos se puede ver que para esta cantidad de iteraciones (estos valores de i) el resultado ha convergido. También puede observarse que AL-BT es la que mejor funciona en comparación con el resto de las heurísticas. Del resto de las heurísticas se destaca que AL-RS es la segunda que mejor funciona y en algunos casos, dependiendo de la fecha y el tamaño de muestras que se agregan en cada iteración no presenta diferencias significativas con AL-MSO y AL-MCLU. La heurística AL-MS, al contrario de lo observado en la bibliografía [23], es la que peor funciona para este conjunto de datos.

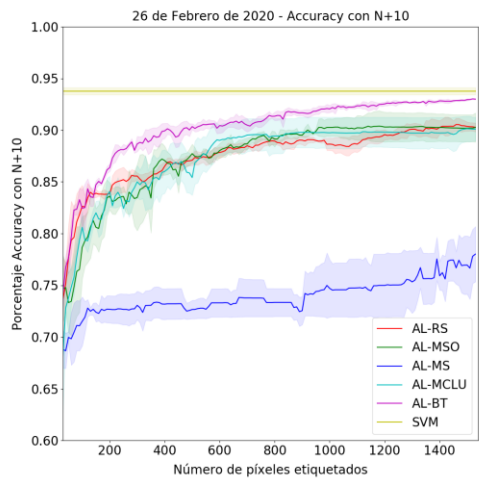
La Tabla 9 y la Tabla 10 muestran el OA de cada clasificador en las 3 imágenes para las diferentes fechas con 150 iteraciones y 10 nuevos píxeles por iteración, y 75 iteraciones y 20 nuevos píxeles por iteración respectivamente. Se puede observar que AL-RS y AL-BT muestran los mejores resultados. Además, a continuación se muestran los resultados obtenidos de la matriz de confusión al aplicar SVM, AL-RS, AL-BT, AL-MCLU, AL-MS y AL-MSO a cada una de las imágenes. En ella se puede observar la precisión para cada una de las clases y ver el buen funcionamiento de los clasificadores para estas clases.




(a)




(b)




(c)



(d)



(e)



(f)

Figura 28 - Overall accuracy para cada heurística con (a) (c) (e) 150 iteraciones y 10 nuevos píxeles por iteración (b) (d) (f) 75 iteraciones y 20 nuevos píxeles por iteración.

Tabla 9 - Media de OA para cada fecha con cada uno de los clasificadores con 150

iteraciones y 10 nuevos píxeles por iteración

Classifier	25 January 2020 Instancias (i)			10 February 2020 Instancias (i)			26 February 2020 Instancias (i)		
	<i>i1</i>	<i>i2</i>	<i>i3</i>	<i>i1</i>	<i>i2</i>	<i>i3</i>	<i>i1</i>	<i>i2</i>	<i>i3</i>
SVM	94.76 %	94.41 %	94.06 %	93.43 %	93.62 %	94.25 %	94.44 %	93.68 %	94.15 %
AL-RS	91.44 %	92.64 %	90.27 %	89.79 %	90.17 %	90.84 %	91.66 %	92.51 %	90.87 %
AL-BT	95.73 %	95.36 %	94.82 %	93.02 %	92.92 %	93.05 %	94.28 %	94.00 %	93.65 %
AL-MCLU	92.73 %	90.14 %	91.34 %	89.07 %	91.72 %	89.51 %	89.32 %	88.47 %	89.35 %
AL-MS	85.28 %	81.07 %	83.7 %	74.47 %	78.64 %	80.92 %	83.70 %	73.78 %	76.56 %
AL-MSO	89.19 %	89.0 %	91.66 %	89.7 %	92.29 %	90.21 %	88.97 %	85.34 %	87.93 %

Tabla 10 - Media de OA para cada fecha con cada uno de los clasificadores con 75 iteraciones y 20 nuevos píxeles por iteración.

Classifier	25 January 2020 Instancias (i)			10 February 2020 Instancias (i)			26 February 2020 Instancias (i)		
	<i>i1</i>	<i>i2</i>	<i>i3</i>	<i>i1</i>	<i>i2</i>	<i>i3</i>	<i>i1</i>	<i>i2</i>	<i>i3</i>
SVM	94.88 %	94.79 %	94.98 %	93.71 %	93.78 %	94.31 %	94.79 %	94.57 %	94.00 %
AL-RS	91.28 %	92.39 %	92.70 %	89.42 %	90.08 %	89.98 %	91.18 %	90.68 %	90.84 %
AL-BT	94.98 %	94.66 %	94.85 %	93.84 %	93.27 %	93.84 %	93.36 %	92.83 %	93.43 %
AL-MCLU	88.47 %	91.63 %	92.67 %	92.51 %	91.03 %	89.86 %	92.1 %	84.08 %	92.86 %
AL-MS	82.46 %	78.55 %	76.08 %	76.27 %	79.87 %	79.81 %	83.73 %	76.56 %	85.81 %
AL-MSO	92.89 %	93.24 %	91.91 %	92.8 %	90.68 %	89.38 %	83.57 %	88.88 %	87.87 %

Si se analizan las tablas anteriores parece indicar que los mejores resultados se encuentran en la imagen del 25 de Enero de 2020, donde se encuentran los valores de OA

mayores. En base a las métricas establecidas anteriormente, se evalúa si estos valores de OA son significativos si se analiza cómo funciona el clasificador para cada una de las clases que se quiere representar. Para ello se evalúan las métricas Precision, Recall y F1-Score para cada una de las clases, con cada una de las heurísticas, en cada una de las imágenes, en las 2 diferentes tipos de iteraciones y en las 3 corridas de cada algoritmo. Estas métricas se han resumido en diversas tablas y debido a que la cantidad de datos a mostrar es significativa se muestran solamente las dos mejores corridas. Estas se ven reflejadas en la Tabla 11 y en la Tabla 12, y el resto de los resultados se encuentran en el Anexo 1 - Resultados Estadísticos. De aquí en adelante los resultados de la heurística AL-MS no se han de mostrar debido a que el desempeño está muy alejado del resto, aunque el resultado de las evaluaciones de esta se pueden observar en los anexos.

Tabla 11 - Media de OA para cada fecha con cada uno de los clasificadores. Con 75 iteraciones y 20 nuevos píxeles por iteración

Etiqueta	25 January 2020 SVM			25 January 2020 AL-RS			25 January 2020 AL-BT			25 January 2020 AL-MCLU			25 January 2020 AL-MSO		
	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
MZ	89.39 %	94.13 %	91.7 %	90.34 %	90.51 %	90.43 %	89.01 %	93.56 %	91.23 %	82.89 %	89.02 %	85.84 %	85.4 %	88.64 %	86.99 %
SB	94.98 %	93.36 %	94.16 %	87.2 %	95.45 %	91.14 %	94.48 %	94.12 %	94.3 %	94.59 %	92.8 %	93.69 %	95.3 %	96.2 %	95.75 %
DS	95.67 %	96.21 %	95.94 %	96.98 %	91.29 %	94.05 %	97.71 %	96.96 %	97.33 %	96.24 %	96.97 %	96.6 %	96.14 %	94.50 %	95.31 %
SG	96.76 %	96.39 %	96.58 %	95.12 %	92.41 %	93.74 %	96.56 %	96.02 %	96.29 %	97.86 %	95.26 %	96.54 %	97.51 %	96.77 %	97.14 %
WT	99.05 %	99.43 %	99.24 %	98.28 %	97.72 %	98.0 %	99.43 %	99.62 %	99.53 %	99.05 %	99.24 %	99.15 %	99.62 %	99.43 %	99.53 %
DLM	94.27 %	90.34 %	92.26 %	89.16 %	88.83 %	88.99 %	92.93 %	89.58 %	91.22 %	86.0 %	82.73 %	84.33 %	85.69 %	83.9 %	84.78 %
Accuracy	94.98 %			92.70 %			94.98 %			92.67 %			93.24 %		

Tabla 12 - Media de OA para cada fecha con cada uno de los clasificadores. Con 150 iteraciones y 10 nuevos píxeles por iteración


Etiqueta	25 January 2020 SVM			25 January 2020 AL-RS			25 January 2020 AL-BT			25 January 2020 AL-MCLU			25 January 2020 AL-MSO		
	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
MZ	87.78 %	95.27 %	91.37 %	85.36 %	90.53 %	87.87 %	92.74 %	94.5 %	93.61 %	86.59 %	83.3 %	84.91 %	87.21 %	72.35 %	79.09 %
SB	94.39 %	95.83 %	95.1 %	96.4 %	91.29 %	93.77 %	95.07 %	95.07 %	95.07 %	95.29 %	95.83 %	95.56 %	95.83 %	95.83 %	95.83 %
DS	95.64 %	95.64 %	95.64 %	93.52 %	95.83 %	94.66 %	95.29 %	96.02 %	95.65 %	94.61 %	96.4 %	95.5 %	96.23 %	96.77 %	96.5 %
SG	98.05 %	95.45 %	96.74 %	94.39 %	95.83 %	95.1 %	98.1 %	97.54 %	97.82 %	98.07 %	96.21 %	97.13 %	95.9 %	97.72 %	96.8 %
WT	99.24 %	99.43 %	99.34 %	97.21 %	99.05 %	98.12 %	99.06 %	99.43 %	99.24 %	98.68 %	99.24 %	98.96 %	99.81 %	99.24 %	99.53 %
DLM	94.05 %	86.91 %	90.34 %	89.23 %	83.3 %	86.16 %	94.17 %	91.86 %	93.0 %	83.18 %	85.39 %	84.27 %	76.44 %	88.05 %	81.83 %
Accuracy	94.76 %			92.64 %			95.73 %			92.73 %			91.66 %		

En las tablas anteriores se puede determinar qué clases etiqueta mejor el clasificador, pudiendo observar con el Recall cuántos píxeles de cada clase etiquetó correctamente. De ahí se observa por ejemplo que en la imagen del 25 de Enero con la configuración de 150 iteraciones sumando de a 10 píxeles con la heurística AL-BT posee un OA de 94.98%, sin embargo el Precision que indica que en la clase MZ es de 89.01%. Indicando que de todos los píxeles que se han clasificado como MZ el 89.01% estaban etiquetados correctamente. Y además que el Recall o Balanced Accuracy para la clase DLM es 89.58%, es decir que de todas los píxeles que eran de la clase DLM el 89.58% estaban bien clasificados.


Dentro de las métricas queda establecer las matrices de confusión, las cuales permiten determinar, no solamente cuál es el Accuracy para cada una de las clases sino además nos brinda información acerca de qué clases el clasificador es propenso a confundir con que otra. En las matrices de confusión de las Figura 29, Figura 30 y Figura 31 muestran qué tan bueno es el clasificador para cada una de las clases, donde la columna muestra el Valor Real o Verdad de Campo y la fila las Valores Predichos o Etiquetas Predichas. Aunque los clasificadores tienen un OA aceptable, aquí se puede observar para qué clases el clasificador funciona mejor, en qué clases no funciona tan bien, e incluso analizarlo por fechas. En este caso se muestran las matrices de confusión de SVM y AL-BT que es la heurística que mejor funciona en base a los resultados mostrados anteriormente. De estas se reflejan las dos mejores corridas con las dos configuraciones, para todas las fechas y el resto de las matrices de confusión se encuentran en el Anexo 2 - Matrices de Confusión.




(a)



(b)




(c)



(d)


Figura 29 - Matriz de confusión para la imagen del 25 de enero de 2020 con un conjunto de entrenamiento inicial de 5 píxeles por clase (30 píxeles en total). (a, c) 150 iteraciones y 10 nuevos píxeles por iteración (b, d) 75 iteraciones y 20 nuevos píxeles por iteración.




(a)



(b)



(c)



(d)

Figura 30 - Matriz de confusión para la imagen del 10 de febrero de 2020 con un conjunto de entrenamiento inicial de 5 píxeles por clase (30 píxeles en total). (a) 150 iteraciones y 10 nuevos píxeles por iteración (b) 75 iteraciones y 20 nuevos píxeles por iteración.

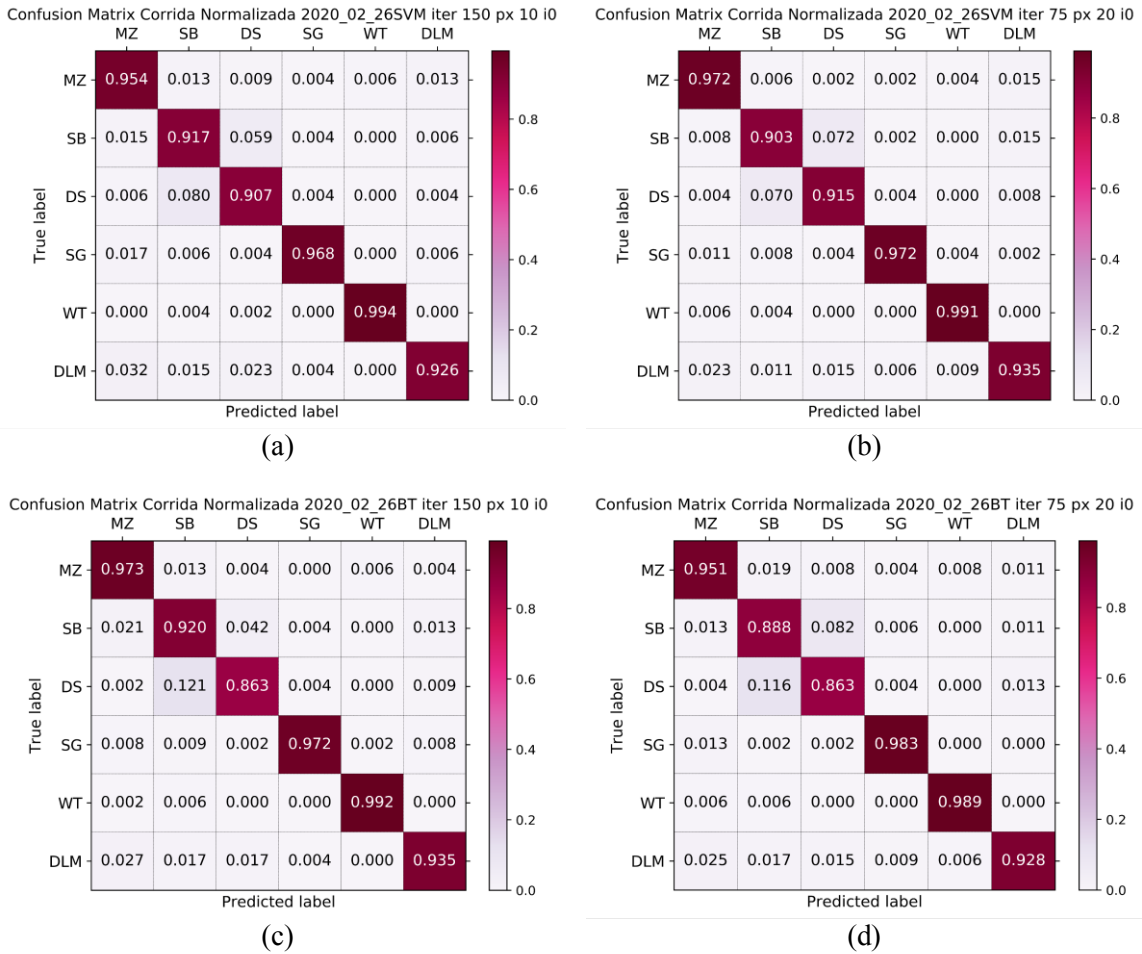


Figura 31 - Matriz de confusión para la imagen del 26 de febrero de 2020 con un conjunto de entrenamiento inicial de 5 píxeles por clase (30 píxeles en total). (a, c) 150 iteraciones y 10 nuevos píxeles por iteración (b, d) 75 iteraciones y 20 nuevos píxeles por iteración.

De los resultados obtenidos se desprende que, en la imagen del 25 de enero, el clasificador tiene un peor desempeño al clasificar la clase DLM y en algunos casos tiende a confundirla con la clase MZ. Lo cual tiene sentido debido a lo mencionado al principio, ya que estos son el mismo cultivo con la particularidad de que los lotes con DLM durante el año tuvieron otro cultivo previamente o fueron sembrados más tarde que los lotes con DM. En el caso de la imagen del 10 de febrero se observa que el clasificador tiene un mejor desempeño con la clase DLM aunque sigue teniendo dificultades para separarla de MZ. En la última imagen, del 26 de febrero, se observa que el clasificador funciona mejor para la clase DLM y ya no tiene las dificultades que poseía antes pero ahora tiene problemas para distinguir entre SB y DS. Al igual que con las otras dos clases estas dos clases pertenecen al mismo cultivo, donde el lote donde fue sembrado DS durante el año tuvo otro cultivo previamente lo que llevó además a que fuera sembrados más tarde que SB.

Si se analizan todas las métricas se puede determinar que en el caso de estas imágenes, el OA es una métrica que tiende a representar bien los resultados obtenidos debido a que cuando se realizó un análisis de las demás métricas estas indicaban que los resultados eran buenos. De las demás métricas se desprende que una clase pueda no tener

un desempeño similar o cuenta con una diferencia significativa con el resto de las clases. Pero esto no sucede con otros casos donde el OA es menor pero el Accuracy entre clases es más homogéneo.

4.4. Discusión

La clasificación de la cobertura del suelo mediante datos de RS requiere el uso de una gran cantidad de datos etiquetados. El reto de encontrar un buen clasificador de cultivos de verano en la región del Noroeste de la Provincia de Buenos Aires a partir de la utilización de pocos datos etiquetados, que simplifique y facilite el uso por parte del experto fue lo que motivó la realización de este trabajo. Donde se utilizaron técnicas de AL sobre 3 imágenes satelitales Landsat de diferentes fechas con el objetivo de obtener un buen clasificador de dichos cultivos.

En el presente trabajo se pudo comprobar que la técnica AL-BT es la que mejor resultado tiene en las métricas aplicadas dentro de las heurísticas de AL desarrolladas, teniendo un desempeño de OA mayor al 1% con respecto a las demás y una mejor performance en la mayoría de las métricas evaluadas por clase. Cuando se analiza en comparación con SVM, en la imagen del 25 de Enero en particular el desempeño de AL-BT fue mejor, mientras que en las demás imágenes el desempeño de se aproxima teniendo un OA con una diferencia menor al 1% a excepción de una sola iteración.

Con respecto a las demás métricas, AL-RS, AL-MCLU y AL-MSO, tienen un desempeño similar en las imágenes de las dos primeras fechas y AL-RS es mejor en la imagen de la última fecha.

En el caso de AL-MS, a diferencia de los resultados encontrados para otros conjuntos de datos en la literatura, el rendimiento fue en todo momento peor, con una diferencia significativa en las métricas en comparación con el resto de las heurísticas. También se observa que en las primeras etapas del algoritmo, con pocas iteraciones o pocos píxeles etiquetados, AL-BT tiene un mejor rendimiento y ya en esas primeras etapas logra diferenciarse del resto.

Si se analizan los resultados en base a las fechas de las mismas, en general se obtuvieron mejores resultados en las imágenes del 25 de Enero y en el 26 de Febrero, destacándose la primera apenas por encima. Si se analiza además las dos configuraciones utilizadas se observa que, con la configuración de 150 iteraciones con 10 píxeles agregados por iteración, se obtiene un mejor clasificador que con la configuración de 75 iteraciones con 20 píxeles agregados por iteración.

De los diferentes análisis realizados anteriormente se observa que con las técnicas AL se alcanza un buen rendimiento en comparación con SVM, observando que en todos los casos la diferencia porcentual entre ambos no supera el 1%. Además, con AL se reduce el coste de etiquetado ya que, como se puede observar en las pruebas realizadas, se necesitan un total de 1530 píxeles para obtener un buen rendimiento frente a SVM con 7383 píxeles en el mejor de los casos. Es decir, con AL con estos datos y con las clases balanceadas, se puede conseguir un clasificador con un rendimiento similar al de SVM, pero con un coste mucho menor, principalmente en cuanto al coste de etiquetado de las

clases por parte del experto. Todo esto hace que AL sea una buena alternativa para la clasificación de este tipo de cultivos en esta región del país.

Capítulo 5. Conclusiones

5.1. Conclusiones

En el presente trabajo se probaron diferentes algoritmos de AL sobre imágenes Landsat para la clasificación de la cobertura terrestre en el noroeste de la provincia de Buenos Aires en Argentina. Para estas técnicas de AL, se analizaron cinco ejemplos de selección heurística recomendados en la literatura para aplicaciones de RS: AL-BT, AL-MS, AL-MSO, AL-MCLU y AL-RS.

La aplicación de estas técnicas a imágenes de satélite Landsat con diferentes fechas permitió obtener un clasificador de cultivos de verano para esta región con una precisión comparable a la obtenida con SVM. Podemos concluir que mediante la utilización de AL-BT y con unos pocos píxeles etiquetados, se pueden obtener resultados similares a los que se obtienen con SVM y toda la imagen etiquetada, con la particularidad de que se trataba de clasificar variedades de los mismos cultivos. Además, esto se aplica a una sola imagen multiespectral, lo que lo hace más simple en comparación con otras técnicas que requieren imágenes multitemporales o hiperespectrales. Los resultados obtenidos permiten hacer con menos trabajo un clasificador preciso, pudiendo convertirse en el futuro en una herramienta útil en la toma de decisiones para los expertos del sector.

5.2. Trabajo futuro

El trabajo realizado hasta el momento es parte del trabajo realizado para una tesis doctoral para un Doctorado en Ciencias Informáticas de la Universidad Nacional de La Plata, en el cual se busca obtener una herramienta que permita obtener un clasificador de cultivos que sea rápido y simple de utilizar, a partir de este tipo de técnicas de AL aplicado a datos propios de coberturas e imágenes de RS de la región

El objetivo de las pruebas futuras por un lado, se espera realizar pruebas con más conjuntos de datos, incorporando imágenes de otros años con el fin de estudiar cómo las variaciones climáticas y los cambios en las fechas de siembra de los cultivos pueden afectar a la hora de obtener un buen clasificador. Además estudiar la posibilidad de incorporar más clases al conjunto de datos, añadiendo coberturas como girasol, suelo desnudo, bosques, construcciones o rutas.

En lo que a las técnicas de ML respecta se buscará continuar con el estudio de técnicas y heurísticas para lograr modificaciones que mejoren los resultados obtenidos hasta el momento. Se considera que la incorporación de técnicas de procesamiento digital de imágenes puede aportar a la mejora de éstas técnicas.

Capítulo 6. Bibliografía

- [1] C. Fernández-Quintanilla and César, “Agricultura de precisión,” *Segundas jornadas científicas sobre medio Ambient. del CCMA-CSIC*, vol. 2, pp. 187–194, 2002, Accessed: Sep. 26, 2019. [Online]. Available: <http://hdl.handle.net/10261/118267>.
- [2] D. Tilman, C. Balzer, J. Hill, and B. L. Befort, “Global food demand and the sustainable intensification of agriculture,” *Proc. Natl. Acad. Sci. United States Am. United States Am.*, vol. 108, no. 50, pp. 20260–20264, 2011, doi: 10.1073/pnas.1116437108.
- [3] S. Blackmore, “The role of yield maps in Precision Farming,” Cranfield University, 2003.
- [4] T. Lillesand, R. Kiefer, and J. Chipman, *Remote sensing and image interpretation Seventh Ed.* 2015.
- [5] D. J. Lary, A. H. Alavi, A. H. Gandomi, and A. L. Walker, “Machine learning in geosciences and remote sensing,” *Geosci. Front.*, vol. 7, no. 1, pp. 3–10, 2016, doi: 10.1016/j.gsf.2015.07.003.
- [6] G. Camps-Valls, “Machine learning in remote sensing data processing,” *Mach. Learn. Signal Process. - IEEE Int. Work.*, p. 6, 2009, doi: <https://doi.org/10.1109/MLSP.2009.5306233>.
- [7] P. Scheunders, D. Tuia, and G. Moser, “Contributions of Machine Learning to Remote Sensing Data Analysis,” in *Comprehensive Remote Sensing*, P. Scheunders, D. Tuia, and G. Moser, Eds. Elsevier BV, 2018, pp. 199–243.
- [8] D. Marcos *et al.*, “Learning deep structured active contours end-to-end,” Mar. 2018, Accessed: Jul. 18, 2019. [Online]. Available: <http://arxiv.org/abs/1803.06329>.
- [9] J. J. Maynard and M. R. Levi, “Hyper-temporal remote sensing for digital soil mapping: Characterizing soil-vegetation response to climatic variability,” *Geoderma*, vol. 285, p. In Press, 2017, doi: 10.1016/j.geoderma.2016.09.024.
- [10] P. Teluguntla *et al.*, “A 30-m landsat-derived cropland extent product of Australia and China using random forest machine learning algorithm on Google Earth Engine cloud computing platform,” *ISPRS J. Photogramm. Remote Sens.*, vol. 144, no. July, pp. 325–340, 2018, doi: 10.1016/j.isprs.2018.07.017.

- [11] X. Song *et al.*, “National-scale soybean mapping and area estimation in the United States using medium resolution satellite imagery and field survey,” *Remote Sens. Environ.*, vol. 190, pp. 383–395, 2017, doi: 10.1016/j.rse.2017.01.008.
- [12] A. Gonzalez-Sanchez, J. Frausto-Solis, and W. Ojeda-Bustamante, “Predictive ability of machine learning methods for massive crop yield prediction,” *Spanish J. Agric. Res.*, vol. 12, no. 2, pp. 313–328, 2014, doi: 10.5424/sjar/2014122-4439.
- [13] S. Veenadhari, B. Misra, and C. D. Singh, “Machine learning approach for forecasting crop yield based on climatic parameters,” *2014 Int. Conf. Comput. Commun. Informatics Ushering Technol. Tomorrow, Today, ICCCI 2014*, pp. 1–5, 2014, doi: 10.1109/ICCCI.2014.6921718.
- [14] S. Dimitriadis and C. Goumopoulos, “Applying machine learning to extract new knowledge in precision agriculture applications,” *Proc. - 12th Pan-Hellenic Conf. Informatics, PCI 2008*, pp. 100–104, 2008, doi: 10.1109/PCI.2008.30.
- [15] X. X. Zhu *et al.*, “Deep learning in remote sensing: a review,” Oct. 2017, doi: 10.1109/mgrs.2017.2762307.
- [16] A. Kamilaris and F. X. Prenafeta-Boldú, “Deep learning in agriculture: A survey,” *Comput. Electron. Agric.*, vol. 147, no. July 2017, pp. 70–90, 2018, doi: 10.1016/j.compag.2018.02.016.
- [17] X. X. Zhu *et al.*, “Deep Learning in Remote Sensing: A Comprehensive Review and List of Resources,” *IEEE Geosci. Remote Sens. Mag. Press.*, no. October, p. 60, 2017, doi: 10.1109/MGRS.2017.2762307.
- [18] B. Settles, “Active Learning Literature Survey,” *Mach. Learn.*, vol. 15, no. 2, pp. 201–221, 2010, doi: 10.1.1.167.4245.
- [19] M. M. Crawford, D. Tuia, and H. L. Yang, “Active learning: Any value for classification of remotely sensed data?,” *Proc. IEEE*, vol. 101, no. 3, pp. 593–608, 2013, doi: 10.1109/JPROC.2012.2231951.
- [20] J. Li, X. Huang, and X. Chang, “A label-noise robust active learning sample collection method for multi-temporal urban land-cover classification and change analysis,” *ISPRS J. Photogramm. Remote Sens.*, vol. 163, pp. 1–17, May 2020, doi: 10.1016/j.isprsjprs.2020.02.022.
- [21] P. Liu, H. Zhang, and K. B. Eom, “Active Deep Learning for Classification of Hyperspectral Images,” *IEEE J. Sel. Top. Appl. EARTH Obs. Remote Sens.*, vol. 10, no. 2, pp. 712–724, 2016, doi: 10.1109/JSTARS.2016.2598859.

- [22] D. Tuia, M. Volpi, L. Copa, M. Kanevski, and J. Munoz-Mari, "A Survey of Active Learning Algorithms for Supervised Remote Sensing Image Classification," *IEEE J. Sel. Top. Signal Process.*, vol. 5, no. 3, pp. 606–617, 2011, doi: 10.1109/JSTSP.2011.2139193.
- [23] A. S. Brendel, F. Ferrelli, M. C. Piccolo, and G. M. E. Perillo, "Assessment of the effectiveness of supervised and unsupervised methods: maximizing land-cover classification accuracy with spectral indices data," *J. Appl. Remote Sens.*, vol. 13, no. 01, p. 1, 2019, doi: 10.1117/1.jrs.13.014503.
- [24] E. Alvarez-Vanhard, T. Corpetti, and T. Houet, "UAV & satellite synergies for optical remote sensing applications: A literature review," *Sci. Remote Sens.*, vol. 3, p. 100019, Jun. 2021, doi: 10.1016/j.srs.2021.100019.
- [25] G. Forkuor, O. K. L. Hounkpatin, G. Welp, and M. Thiel, "High Resolution Mapping of Soil Properties Using Remote Sensing Variables in South-Western Burkina Faso: A Comparison of Machine Learning and Multiple Linear Regression Models," *PLoS One*, vol. 12, no. 1, p. e0170478, Jan. 2017, doi: 10.1371/journal.pone.0170478.
- [26] G. Shaw and D. Manolakis, "Signal processing for hyperspectral image exploitation," *IEEE Signal Process. Mag.*, vol. 19, no. 1, pp. 12–16, 2002, doi: 10.1109/79.974715.
- [27] T. M. Kiefe and R. W. Lillesand, *Remote Sensing and Image Interpretation*, Seventh Ed. New Jersey, EEUU: Wiley International Editions, 2015.
- [28] R. D. Jackson and A. R. Huete, "Interpreting vegetation indices," *Prev. Vet. Med.*, vol. 11, no. 3–4, pp. 185–200, Dec. 1991, doi: 10.1016/S0167-5877(05)80004-2.
- [29] L. Gu *et al.*, "Angle Effect on Typical Optical Remote Sensing Indices in Vegetation Monitoring," *Remote Sens. 2021, Vol. 13, Page 1699*, vol. 13, no. 9, p. 1699, Apr. 2021, doi: 10.3390/RS13091699.
- [30] J. W. Rouse, R. H. Haas, D. W. Deering, J. A. Schell, and J. C. Harlan, "Monitoring the Vernal Advancement and Retrogradation (Green Wave Effect) of Natural Vegetation. [Great Plains Corridor]," 1973.
- [31] C. F. Jordan, "Derivation of Leaf-Area Index from Quality of Light on the Forest Floor," *Ecology*, vol. 50, no. 4, pp. 663–666, Jul. 1969, doi: 10.2307/1936256.
- [32] A. R. Huete, "A soil-adjusted vegetation index (SAVI)," *Remote Sens. Environ.*, vol. 25, no. 3, pp. 295–309, Aug. 1988, doi: 10.1016/0034-4257(88)90106-X.

- [33] J. Qi, A. Chehbouni, A. R. Huete, Y. H. Kerr, and S. Sorooshian, “A modified soil adjusted vegetation index,” *Remote Sens. Environ.*, vol. 48, no. 2, pp. 119–126, May 1994, doi: 10.1016/0034-4257(94)90134-1.
- [34] A. Huete, K. Didan, T. Miura, E. P. Rodriguez, X. Gao, and L. G. Ferreira, “Overview of the radiometric and biophysical performance of the MODIS vegetation indices,” *Remote Sens. Environ.*, vol. 83, no. 1–2, pp. 195–213, Nov. 2002, doi: 10.1016/S0034-4257(02)00096-2.
- [35] B. C. Gao, “NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space,” *Remote Sens. Environ.*, vol. 58, no. 3, pp. 257–266, Dec. 1996, doi: 10.1016/S0034-4257(96)00067-3.
- [36] S. K. McFeeters, “The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features,” <https://doi.org/10.1080/01431169608948714>, vol. 17, no. 7, pp. 1425–1432, 2007, doi: 10.1080/01431169608948714.
- [37] “Sensor Aviris - Airborne Visible / Infrared Imaging Spectrometer.” <https://aviris.jpl.nasa.gov/> (accessed Jun. 12, 2017).
- [38] “Landsat Science.” <https://landsat.gsfc.nasa.gov/> (accessed Jun. 30, 2022).
- [39] S. Marsland, *Machine Learning: An Algorithmic Perspective*, Second. Ed. Boca Raton, Florida, EEUU: CRC Press Taylor & Francis Group, 2014.
- [40] Hong Kong University of Science and Technology, “A Survey on Transfer Learning,” *Ieee Trans. Knowl. Data Eng.*, vol. 22, no. 10, 2010.
- [41] M. M. Crawford, D. Tuia, and H. L. Yang, “Active learning: Any value for classification of remotely sensed data?,” *Proc. IEEE*, vol. 101, no. 3, pp. 593–608, 2013, doi: 10.1109/JPROC.2012.2231951.
- [42] D. Rudrapal and M. Subhedar, “Land Cover Classification using Support Vector Machine,” *Int. J. Eng. Res.*, vol. V4, no. 09, pp. 584–588, 2015, doi: 10.17577/ijertv4is090611.
- [43] P. Thanh Noi and M. Kappas, “Comparison of Random Forest, k-Nearest Neighbor, and Support Vector Machine Classifiers for Land Cover Classification Using Sentinel-2 Imagery,” *Sensors (Basel)*, vol. 18, no. 1, pp. 1–20, 2017, doi: 10.3390/s18010018.
- [44] N. Candade and B. Dixon, “Multispectral classification of Landsat images: a comparison of support vector machine and neural network classifiers,” *ASPRS*

- Annu. Meet. Proc.*, vol. 43, pp. 1882–1889, 2003, Accessed: Aug. 05, 2020. [Online]. Available: https://www.researchgate.net/publication/228940559_Multispectral_classification_of_Landsat_images_a_comparison_of_support_vector_machine_and_neural_network_classifiers.
- [45] B. E. Boser, I. M. Guyon, and V. N. Vapnik, “A training algorithm for optimal margin classifiers,” in *Proceedings of the Fifth Annual ACM Workshop on Computational Learning Theory*, 1992, pp. 144–152, doi: 10.1145/130385.130401.
- [46] C. Cortes and V. Vapnik, “Support-vector networks,” *Mach. Learn.*, vol. 20, no. 3, pp. 273–297, Sep. 1995, doi: 10.1007/bf00994018.
- [47] X. Su, X. Yan, and C. L. Tsai, “Linear regression,” *Wiley Interdiscip. Rev. Comput. Stat.*, vol. 4, no. 3, pp. 275–294, May 2012, doi: 10.1002/WICS.1198.
- [48] D. G. Luenberger and Y. Ye, *Linear and Nonlinear Programming*, vol. 228. Cham: Springer International Publishing, 2016.
- [49] B. Schölkopf and A. J. Smola, *Learning with Kernels: Support Vector Machines, Regularization, Optimization, and Beyond Adaptive computation and machine learning*. Cambridge, MA, USA: MIT Press, 2002.
- [50] T. W. Anderson and R. R. Bahadur, “Classification into two Multivariate Normal Distributions with Different Covariance Matrices,” <https://doi.org/10.1214/aoms/1177704568>, vol. 33, no. 2, pp. 420–431, Jun. 1962, doi: 10.1214/AOMS/1177704568.
- [51] A. Patle and D. S. Chouhan, “SVM kernel functions for classification,” *2013 Int. Conf. Adv. Technol. Eng. ICATE 2013*, 2013, doi: 10.1109/ICADTE.2013.6524743.
- [52] J. L. Rojo-Álvarez, M. Martínez-Ramón, J. Muñoz Marí, and G. Camps-Valls, *Digital signal processing with kernel methods*. .
- [53] M. Ferecatu and N. Boujemaa, “Interactive remote-sensing image retrieval using active relevance feedback,” *IEEE Trans. Geosci. Remote Sens.*, vol. 45, no. 4, pp. 818–826, Apr. 2007, doi: 10.1109/TGRS.2007.892007.
- [54] D. Tsujinishi, Y. Koshiba, and S. Abe, “Why pairwise is better than one-against-all or all-at-once,” *2004 IEEE Int. Jt. Conf. Neural Networks (IEEE Cat. No.04CH37541)*, vol. 1, no. August 2004, 2004, doi: 10.1109/IJCNN.2004.1380001.

- [55] J. C. Platt and J. C. Platt, “Probabilistic Outputs for Support Vector Machines and Comparisons to Regularized Likelihood Methods,” in *ADVANCES IN LARGE MARGIN CLASSIFIERS*, MIT Press, 1999, pp. 61--74.
- [56] T.-F. Wu, C.-J. Lin, and R. C. Weng, “Probability Estimates for Multi-class Classification by Pairwise Coupling,” *J. Mach. Learn. Res.*, vol. 5, pp. 975–1005, 2004, doi: 10.5555/1005332.1016791.
- [57] M. Grandini, E. Bagli, and G. Visani, “Metrics for Multi-Class Classification: an Overview,” Aug. 2020, Accessed: Jul. 04, 2022. [Online]. Available: <http://arxiv.org/abs/2008.05756>.
- [58] “QGIS.” <https://www.qgis.org/es/site/index.html> (accessed Jul. 04, 2022).
- [59] “Python,” 2017. <https://www.python.org/> (accessed Apr. 20, 2017).
- [60] “Scikit-Learn: Machine Learning in Python.” <http://scikit-learn.org/stable/index.html> (accessed Jun. 12, 2017).

Capítulo 7. Anexos

Anexo 1 - Resultados Estadísticos

Tabla 13 - Resultados de las métricas con todas las heurísticas, para la imagen del 25 de Enero, con 20 píxeles agregados por iteración

Etiqueta	25 January 2020 SVM			25 January 2020 AL-RS			25 January 2020 AL-BT			25 January 2020 AL-MCLU			25 January 2020 AL-MS			25 January 2020 AL-MSO		
	<i>Precisio n</i>	<i>Recall</i>	<i>F1- Score</i>	<i>Precisio n</i>	<i>Recall</i>	<i>F1- Score</i>	<i>Precisio n</i>	<i>Recall</i>	<i>F1- Score</i>	<i>Precisio n</i>	<i>Recall</i>	<i>F1- Score</i>	<i>Precisio n</i>	<i>Recall</i>	<i>F1- Score</i>	<i>Precisio n</i>	<i>Recall</i>	<i>F1- Score</i>
MZ	89.39 %	94.13 %	91.7 %	90.34 %	90.51 %	90.43 %	89.01 %	93.56 %	91.23 %	82.89 %	89.02 %	85.84 %	74.92 %	88.99 %	81.35 %	85.4 %	88.64 %	86.99 %
SB	94.98 %	93.36 %	94.16 %	87.2 %	95.45 %	91.14 %	94.48 %	94.12 %	94.3 %	94.59 %	92.8 %	93.69 %	72.11 %	92.05 %	80.87 %	95.3 %	96.2 %	95.75 %
DS	95.67 %	96.21 %	95.94 %	96.98 %	91.29 %	94.05 %	97.71 %	96.96 %	97.33 %	96.24 %	96.97 %	96.6 %	90.49 %	74.0 %	81.42 %	96.14 %	94.50 %	95.31 %
SG	96.76 %	96.39 %	96.58 %	95.12 %	92.41 %	93.74 %	96.56 %	96.02 %	96.29 %	97.86 %	95.26 %	96.54 %	85.78 %	73.11 %	78.94 %	97.51 %	96.77 %	97.14 %
WT	99.05 %	99.43 %	99.24 %	98.28 %	97.72 %	98.0 %	99.43 %	99.62 %	99.53 %	99.05 %	99.24 %	99.15 %	99.22 %	96.97 %	98.08 %	99.62 %	99.43 %	99.53 %
DLM	94.27 %	90.34 %	92.26 %	89.16 %	88.83 %	88.99 %	92.93 %	89.58 %	91.22 %	86.0 %	82.73 %	84.33 %	78.42 %	69.64 %	73.77 %	85.69 %	83.9 %	84.78 %
Accurac y	94.98 %			92.70 %			94.98 %			92.67 %			82.46 %			93.24 %		

Tabla 14 - Resultados de las métricas con todas las heurísticas, para la imagen del 25 de Enero, con 10 píxeles agregados por iteración

Etiqueta	25 January 2020 SVM			25 January 2020 AL-RS			25 January 2020 AL-BT			25 January 2020 AL-MCLU			25 January 2020 AL-MS			25 January 2020 AL-MSO		
	<i>Precisio n</i>	<i>Recall</i>	<i>F1- Score</i>	<i>Precisio n</i>	<i>Recall</i>	<i>F1- Score</i>	<i>Precisio n</i>	<i>Recall</i>	<i>F1- Score</i>	<i>Precisio n</i>	<i>Recall</i>	<i>F1- Score</i>	<i>Precisio n</i>	<i>Recall</i>	<i>F1- Score</i>	<i>Precisio n</i>	<i>Recall</i>	<i>F1- Score</i>
MZ	87.78 %	95.27 %	91.37 %	85.36 %	90.53 %	87.87 %	92.74 %	94.5 %	93.61 %	86.59 %	83.3 %	84.91 %	65.71 %	82.77 %	73.26 %	87.21 %	72.35 %	79.09 %
SB	94.39 %	95.83 %	95.1 %	96.4 %	91.29 %	93.77 %	95.07 %	95.07 %	95.07 %	95.29 %	95.83 %	95.56 %	91.28 %	89.2 %	90.23 %	95.83 %	95.83 %	95.83 %
DS	95.64 %	95.64 %	95.64 %	93.52 %	95.83 %	94.66 %	95.29 %	96.02 %	95.65 %	94.61 %	96.4 %	95.5 %	89.07 %	92.79 %	90.89 %	96.23 %	96.77 %	96.5 %
SG	98.05 %	95.45 %	96.74 %	94.39 %	95.83 %	95.1 %	98.1 %	97.54 %	97.82 %	98.07 %	96.21 %	97.13 %	93.18 %	93.18 %	93.18 %	95.9 %	97.72 %	96.8 %
WT	99.24 %	99.43 %	99.34 %	97.21 %	99.05 %	98.12 %	99.06 %	99.43 %	99.24 %	98.68 %	99.24 %	98.96 %	99.04 %	97.72 %	98.38 %	99.81 %	99.24 %	99.53 %
DLM	94.05 %	86.91 %	90.34 %	89.23 %	83.3 %	86.16 %	94.17 %	91.86 %	93.0 %	83.18 %	85.39 %	84.27 %	76.23 %	55.98 %	64.55 %	76.44 %	88.05 %	81.83 %
Accuracy	94.76 %			92.64 %			95.73 %			92.73 %			85.28 %			91.66 %		

Tabla 15 - Resultados de las métricas con todas las heurísticas, para la imagen del 10 de Febrero, con 20 píxeles agregados por iteración

Etiqueta	10 February 2020 SVM			10 February 2020 AL-RS			10 February 2020 AL-BT			10 February 2020 AL-MCLU			10 February 2020 AL-MS			10 February 2020 AL-MSO		
	<i>Precisión</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Precisión</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Precisión</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Precisión</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Precisión</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Precisión</i>	<i>Recall</i>	<i>F1-Score</i>
MZ	91.24 %	94.88 %	93.02 %	81.9 %	90.13 %	85.82 %	89.19 %	93.93 %	91.5 %	92.69 %	88.83 %	90.72 %	78.96 %	86.15 %	82.4 %	89.82 %	93.74 %	91.74 %
SB	93.48 %	95.08 %	94.27 %	87.87 %	90.53 %	89.18 %	92.31 %	93.36 %	92.83 %	93.09 %	92.03 %	92.56 %	69.73 %	87.69 %	77.68 %	92.6 %	87.86 %	90.17 %
DS	96.69 %	94.12 %	95.38 %	92.95 %	92.6 %	92.78 %	95.72 %	93.36 %	94.52 %	95.04 %	94.5 %	94.77 %	76.88 %	85.04 %	80.76 %	89.36 %	95.45 %	92.31 %
SG	93.75 %	90.91 %	92.31 %	89.35 %	85.8 %	87.54 %	93.5 %	92.61 %	93.05 %	90.84 %	88.43 %	89.62 %	82.33 %	82.95 %	82.64 %	92.25 %	94.7 %	93.46 %
WT	99.81 %	98.86 %	99.33 %	97.85 %	94.88 %	96.34 %	98.11 %	98.48 %	98.3 %	98.87 %	99.43 %	99.15 %	93.76 %	94.12 %	93.94 %	99.04 %	97.91 %	98.47 %
DLM	91.17 %	92.03 %	91.6 %	91.77 %	86.55 %	89.08 %	94.51 %	91.29 %	92.87 %	85.09 %	91.86 %	88.34 %	81.14 %	43.26 %	56.44 %	94.26 %	87.12 %	90.55 %
Accurac y	94.31 %			90.08 %			93.84 %			92.51 %			79.87 %			92.80 %		

Tabla 16 - Resultados de las métricas con todas las heurísticas, para la imagen del 10 de Febrero, con 10 píxeles agregados por iteración

Etiqueta	10 February 2020 SVM			10 February 2020 AL-RS			10 February 2020 AL-BT			10 February 2020 AL-MCLU			10 February 2020 AL-MS			10 February 2020 AL-MSO		
	<i>Precisio n</i>	<i>Recall</i>	<i>F1- Score</i>	<i>Precisio n</i>	<i>Recall</i>	<i>F1- Score</i>	<i>Precisio n</i>	<i>Recall</i>	<i>F1- Score</i>	<i>Precisio n</i>	<i>Recall</i>	<i>F1- Score</i>	<i>Precisio n</i>	<i>Recall</i>	<i>F1- Score</i>	<i>Precisio n</i>	<i>Recall</i>	<i>F1- Score</i>
MZ	89.31 %	93.55 %	91.38 %	80.33 %	91.29 %	85.46 %	88.37 %	93.74 %	90.98 %	88.81 %	90.15 %	89.47 %	66.25 %	90.72 %	76.58 %	87.05 %	91.84 %	89.38 %
SB	94.65 %	93.75 %	94.2 %	96.21 %	91.29 %	93.68 %	94.39 %	92.42 %	93.4 %	89.29 %	93.36 %	91.28 %	84.18 %	75.71 %	79.72 %	93.76 %	88.26 %	90.93 %
DS	94.58 %	95.83 %	95.2 %	94.33 %	94.69 %	94.51 %	94.61 %	92.99 %	93.79 %	95.02 %	90.34 %	92.62 %	76.22 %	77.08 %	76.65 %	92.71 %	93.94 %	93.32 %
SG	94.08 %	90.34 %	92.17 %	88.43 %	88.26 %	88.34 %	91.39 %	92.6 %	91.99 %	94.18 %	85.96 %	89.88 %	88.71 %	71.54 %	79.2 %	90.89 %	94.69 %	92.75 %
WT	98.3 %	98.86 %	98.58 %	96.79 %	97.15 %	96.97 %	98.1 %	97.91 %	98.01 %	98.29 %	98.29 %	98.29 %	96.31 %	94.12 %	95.2 %	99.23 %	97.92 %	98.57 %
DLM	90.93 %	89.37 %	90.14 %	90.61 %	82.35 %	86.28 %	91.76 %	88.64 %	90.17 %	85.74 %	92.23 %	88.87 %	81.58 %	76.33 %	78.86 %	90.53 %	87.1 %	88.78 %
Accuracy	93.62 %			90.84 %			93.05 %			91.72 %			80.92 %			92.29 %		

Tabla 17 - Resultados de las métricas con todas las heurísticas, para la imagen del 26 de Febrero, con 20 píxeles agregados por iteración

Etiqueta	26 February 2020 SVM			26 February 2020 AL-RS			26 February 2020 AL-BT			26 February 2020 AL-MCLU			26 February 2020 AL-MS			26 February 2020 AL-MSO		
	<i>Precisio n</i>	<i>Recall</i>	<i>F1- Score</i>	<i>Precisio n</i>	<i>Recall</i>	<i>F1- Score</i>	<i>Precisio n</i>	<i>Recall</i>	<i>F1- Score</i>	<i>Precisio n</i>	<i>Recall</i>	<i>F1- Score</i>	<i>Precisio n</i>	<i>Recall</i>	<i>F1- Score</i>	<i>Precisio n</i>	<i>Recall</i>	<i>F1- Score</i>
MZ	94.99 %	97.15 %	96.06 %	92.88 %	94.12 %	93.5 %	90.02 %	95.83 %	92.83 %	93.97 %	94.69 %	94.33 %	90.06 %	90.91 %	90.48 %	86.88 %	96.77 %	91.56 %
SB	90.17 %	90.34 %	90.26 %	84.19 %	83.87 %	84.03 %	89.56 %	87.69 %	88.61 %	81.82 %	92.22 %	86.71 %	81.9 %	70.4 %	75.71 %	79.28 %	74.62 %	76.88 %
DS	90.79 %	91.48 %	91.13 %	86.25 %	86.74 %	86.5 %	89.25 %	88.07 %	88.66 %	92.32 %	79.89 %	85.66 %	85.36 %	78.41 %	81.74 %	80.54 %	78.41 %	79.46 %
SG	98.65 %	97.16 %	97.9 %	91.88 %	96.4 %	94.09 %	97.34 %	97.34 %	97.34 %	95.76 %	98.3 %	97.01 %	72.56 %	91.67 %	81.0 %	95.22 %	94.5 %	94.86 %
WT	98.31 %	99.05 %	98.68 %	99.61 %	97.73 %	98.66 %	98.11 %	98.67 %	98.39 %	99.62 %	99.43 %	99.53 %	97.94 %	99.05 %	98.49 %	98.86 %	98.86 %	98.86 %
DLM	95.91 %	93.55 %	94.72 %	92.45 %	88.24 %	90.29 %	96.46 %	92.99 %	94.7 %	94.95 %	92.61 %	93.77 %	90.08 %	84.44 %	87.17 %	92.07 %	90.15 %	91.1 %
Accuracy	94.79 %			91.18 %			93.43 %			92.86 %			85.81 %			88.88 %		

Tabla 18 - Resultados de las métricas con todas las heurísticas, para la imagen del 26 de Febrero, con 10 píxeles agregados por iteración


Etiqueta	26 February 2020 SVM			26 February 2020 AL-RS			26 February 2020 AL-BT			26 February 2020 AL-MCLU			26 February 2020 AL-MS			26 February 2020 AL-MSO		
	<i>Precisio n</i>	<i>Recall</i>	<i>F1- Score</i>	<i>Precisio n</i>	<i>Recall</i>	<i>F1- Score</i>	<i>Precisio n</i>	<i>Recall</i>	<i>F1- Score</i>	<i>Precisio n</i>	<i>Recall</i>	<i>F1- Score</i>	<i>Precisio n</i>	<i>Recall</i>	<i>F1- Score</i>	<i>Precisio n</i>	<i>Recall</i>	<i>F1- Score</i>
MZ	93.15 %	95.45 %	94.28 %	92.15 %	95.64 %	93.87 %	94.31 %	97.35 %	95.81 %	94.6 %	96.21 %	95.4 %	76.39 %	96.21 %	85.16 %	90.49 %	97.35 %	93.8 %
SB	88.62 %	91.65 %	90.11 %	84.62 %	89.75 %	87.11 %	84.64 %	92.03 %	88.18 %	74.12 %	79.89 %	76.89 %	82.98 %	74.0 %	78.23 %	73.21 %	81.25 %	77.02 %
DS	90.38 %	90.72 %	90.55 %	90.16 %	86.74 %	88.42 %	93.05 %	86.34 %	89.57 %	76.61 %	71.97 %	74.22 %	76.6 %	90.7 %	83.06 %	78.65 %	68.5 %	73.23 %
SG	98.46 %	96.78 %	97.61 %	96.15 %	94.51 %	95.32 %	98.84 %	97.16 %	97.99 %	96.6 %	97.15 %	96.88 %	78.39 %	86.72 %	82.34 %	96.8 %	97.72 %	97.26 %
WT	99.43 %	99.43 %	99.43 %	99.04 %	97.91 %	98.47 %	99.24 %	99.24 %	99.24 %	99.24 %	99.24 %	99.24 %	99.6 %	95.27 %	97.39 %	99.05 %	98.48 %	98.77 %
DLM	97.02 %	92.6 %	94.76 %	93.53 %	90.51 %	92.0 %	96.48 %	93.55 %	94.99 %	95.46 %	91.67 %	93.53 %	98.43 %	59.28 %	74.0 %	96.36 %	90.51 %	93.35 %
Accuracy	94.44 %			92.51 %			94.28 %			89.35 %			83.70 %			88.97 %		

Anexo 2 - Matrices de Confusión


A continuación se muestran todos los resultados de las matrices de confusión para cada una de las heurísticas, aplicados a las imágenes de las diferentes fechas y con las dos configuraciones por iteración 150 iteraciones adicionando 10 px por iteración y 75 iteraciones con 20 px por cada iteración. En todos los casos se muestran las mejores corridas de las instancias ejecutadas.




(a)



(b)




(c)



(d)




(e)




(f)


Figura 32 – Matrices de confusión para las imágenes de todas las fechas con ambas combinaciones de iteraciones para la heurística AL-BT.




(a)




(b)



(c)



(d)



(e)



(f)

Figura 33 - Matrices de confusión para las imágenes de todas las fechas con ambas combinaciones de iteraciones para la heurística AL-MCLU.

Confusion Matrix Corrida Normalizada 2020_01_25MS iter 150 px 10 i0



(a)

Confusion Matrix Corrida Normalizada 2020_01_25MS iter 75 px 20 i0



(b)

Confusion Matrix Corrida Normalizada 2020_02_11MS iter 150 px 10 i2




(c)

Confusion Matrix Corrida Normalizada 2020_02_11MS iter 75 px 20 i2



(d)

Confusion Matrix Corrida Normalizada 2020_02_26MS iter 150 px 10 i0




(e)

Confusion Matrix Corrida Normalizada 2020_02_26MS iter 75 px 20 i0



(f)


Figura 34 - Matrices de confusión para las imágenes de todas las fechas con ambas combinaciones de iteraciones para la heurística AL-MS.




(a)




(b)




(c)



(d)




(e)



(f)

Figura 35 - Matrices de confusión para las imágenes de todas las fechas con ambas combinaciones de iteraciones para la heurística AL-MSO.

Confusion Matrix Corrida Normalizada 2020_01_25RS iter 150 px 10 i0



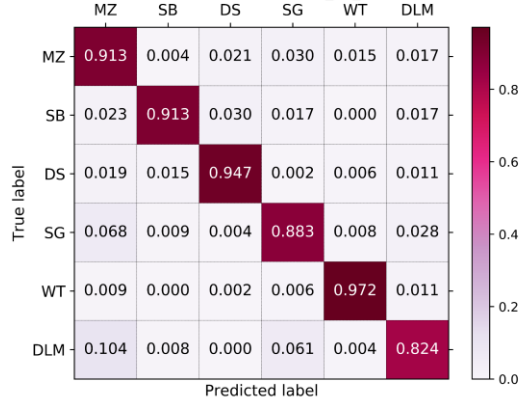
(a)

Confusion Matrix Corrida Normalizada 2020_01_25RS iter 75 px 20 i0



(b)

Confusion Matrix Corrida Normalizada 2020_02_11RS iter 150 px 10 i2




(c)

Confusion Matrix Corrida Normalizada 2020_02_11RS iter 75 px 20 i2



(d)

Confusion Matrix Corrida Normalizada 2020_02_26RS iter 150 px 10 i0



(e)

Confusion Matrix Corrida Normalizada 2020_02_26RS iter 75 px 20 i0




(f)


Figura 36 - Matrices de confusión para las imágenes de todas las fechas con ambas combinaciones de iteraciones para la heurística AL-RS.




(a)




(b)



(c)



(d)



(e)



(f)

Figura 37 - Matrices de confusión para las imágenes de todas las fechas con ambas combinaciones de iteraciones para la heurística SVM.