

 Escola Tècnica Superior
d'Enginyeria **ETSE-UV** !

! !
" # \$ % & ! () * + & ' \$ * % , ' * - ! & ! . * &) . * , ! / & ! / , % - \$!



UNIVERSITAT
DE VALÈNCIA!

! !
% , 0 , 1 - ! / & ! 2 *) ! / & ! " # \$ % & ' !

! !
3 ' & / * .. * 4) ! / & ! & " * \$ * + * / , / & \$! % & " & \$ % ' & \$! , ! !
3 , ' % * ' ! / & ! 5 - \$! / , % - \$! / & ! , / * ,) . * , \$! " & / * / , \$! !
3 - ' ! & 5 ! \$ &) \$ - ! * , \$ * ! , ! 0 - / - ! / & 5 ! \$, % 6 5 * % & !
" & % - 3 7 " & % & - \$, % !

! !
!!!! ! , (% - ' , 8
 , ' 5 , ! 9 , 0 * & 5 , ! , : ! (" & , ! !

! !
!!!! ! % (% - ' & \$ 8
!!!! ! + , 5 & ' - ! 5 , 3 , " !
!!!! ! 1 - / * ! " (; - < !
!!!! !
!!!! ! 1 (5 * - => ? @ A

!

!

!

!



VNIVERSITAT DE VALÈNCIA



Escola Tècnica Superior d'Enginyeria ETSE-UV

!

!

" # \$ % & ! () * + & ' \$ * % , ' * - ! &) ! . * &) . * , ! / & ! / , % - \$!

!

!

% , 0 , 1 - ! / & ! 2 *) ! / & ! " # \$ % & ' !

!

!

3 ' & / * . . * 4) ! / & ! & " * \$ * + * / , / & \$! % & " & \$ % ' & \$! , ! !

3 , % * ! / & ! 5 - \$! / , % - \$! / & ! , / * ,) . * , \$! " & / * / , \$! !

3 - ! & 5 ! \$ &) \$ - ! * , \$ * ! , ! 0 - / - ! / & 5 ! \$, % 6 5 * % & !

" & % - 3 7 " & % & - \$, % !

!

, (% - ' , 8 . , ' 5 , ! 9 , 0 * & 5 , ! , ! (" & , !

!

% (% - ' & \$ 8 + , 5 & ' - ! 5 , 3 , " , !

1 - / * ! " (; - < !

!

!

% * 0 () , 5 8

! " # \$ % & # (#) * + ,

- . / * 0 , 1 + ,

,

,

,

,

,

,

,

- . / * 0 , 2 + ,

2 & . B , ! / & ! / & 2 &) \$, 8 !

,

!

,

., 5 * 2 * . , . * 4) 8 !

,

,

,

,

,

,

,

,

A mi madre y a mi tío,
por siempre impulsarme a ser mejor.

Agradecimientos

A mi madre y a mi tío por siempre apostar por mí e impulsarme a ser mejor persona y profesional.

A mis tutores, Jordi y Valero por tenerme paciencia y siempre haber estado dispuestos a ayudar y a responder mis preguntas por más básicas que fuesen.

A los profesores del máster por su vocación educativa y dedicación. En particular, Emilio Soria y Jordi Muñoz, quienes sin saberlo tuvieron gran influencia sobre mí y contribuyeron en gran parte a formar la profesional que soy hoy.

A mis compañeros del máster, en particular a Sergio por ayudarme y explicarme algún tema del máster y a quien hoy considero mi amigo. A Dani Ruiz por no dejarme morir cuando tenemos seminarios por las tardes.

A Oriana por haber sido mi compañera en esta aventura, entregar este trabajo cierra el ciclo en el que todo comenzó, gracias por todo.

Por último, gracias a la Universidad de Valencia por haberme dado la oportunidad de cursar este máster y por siempre a mi alma mater la Universidad Simón Bolívar que me dio la base para salir y seguir formándome como profesional.

Resumen

En el presente trabajo se presentan los resultados obtenidos tras evaluar las predicciones de emisividades obtenidas tras aplicar una regresión no lineal regularizada basada en kernels a datos sintéticos obtenidos del IASI (Infrared Atmospheric Sounding Interferometer), un sensor a bordo del satélite Metop/Meteosat.

Para ello, se generaron mapas globales de emisividad. Ya que en algunos casos se tenía más de una predicción para un mismo punto en el mapa se tomó la media de las predicciones y a su vez se generaron mapas globales de densidad para determinar cuantas predicciones se tenía para cada punto y poder así conocer las zonas con predicciones más fiables.

Índice general

1. Motivación y objetivos	3
1.1. Motivación	3
1.2. Objetivo General	4
1.3. Objetivos específicos	4
2. Bases teóricas	5
2.1. Radiancia	5
2.2. Emisividad	6
2.3. Emisividad terrestre	9
2.4. PCA	10
2.4.1. Covarianza y matriz de covarianza	13
2.4.2. Vectores y valores propios	14
2.4.3. Algoritmo PCA	14
2.5. Regresión Lineal regularizada	16
2.6. Regresión Kernel Regularizada	18
3. Estado del Arte	21
3.1. Global Land Surface Emissivity Retrieved From Satellite Ultraspectral IR Measurements	22

3.2. Nonlinear Statistical Retrieval of Surface Emissivity From IASI Data	26
4. Conjunto de datos y métodos utilizados	31
4.1. Conjunto de datos	31
4.1.1. Satellite MetOp/Meteosat	32
4.2. Pre-procesado	33
4.3. Entrenamiento de los métodos estadísticos utilizados	34
4.4. Evaluación	35
4.5. Generación de mapas	36
5. Resultados obtenidos	39
5.1. Mapas de densidad	39
5.2. Mapas de medias	41
5.3. Comparación de Métodos	42
A. Ejemplos de código	53
A.1. Entrenamiento Modelos LR y KRR	54
A.2. Predicciones	56
A.3. Generación de Mapas	58
B. Mapas de densidad	65
C. Mapas de medias Método LR	71
D. Mapas de medias Método KRR	77
Bibliografía	83

Introducción

En la actualidad, se puede obtener gran información acerca de la atmósfera, la superficie terrestre, aerosoles y nubes gracias a las radiancias obtenidas de observaciones hechas por satélites de observación de la tierra. Los satélites operacionales actualmente proveen información sobre el ecosistema de la tierra, en particular, sobre la reflectividad y radiancia en superficie, a través de las cuales es posible derivar mediante métodos físicos o estadísticos la emisividad espectral superficial (Surface Spectral Emissivity, SSE), lo que permite revelar información crítica acerca de las propiedades de la superficie terrestre.

El avance en cuanto al aprendizaje de máquina, que no es más que la creación de programas capaces de generalizar comportamientos a partir de conocimiento previo, ha permitido que el análisis de datos de diferentes fuentes sea más factible y que, tanto los problemas de clasificación como predicción puedan arrojar resultados más acertados.

Al poder clasificar y predecir datos de fuentes tan diversas, se puede por ejemplo analizar datos provenientes de las lecturas de satélites que orbitan alrededor de la Tierra. Por lo que desde hace ya varios años se han lanzado varios satélites con la finalidad de

medir y obtener información acerca del ecosistema de la Tierra.

En mayo de 2002 se lanzó el satélite Atmospheric Infrared Sounder, conocido como AIRS por sus siglas en inglés, y los datos obtenidos a través de este han demostrado ser significativos para la investigación atmosférica y para monitorizar el medio ambiente de la Tierra.

Luego, en 2006 fue lanzado el Infrared Atmospheric Sounding Interferometer a bordo del satélite Metop-A, que fue el primero en enviar información relacionada con temperatura, humedad y trazas de gas con resolución ultra-espectral. A día de hoy ya han sido lanzados nuevos instrumentos que nos darán más información sobre radiancias infrarrojas ultra-espectrales e hiper-espectrales, las cuales serán utilizadas para una monitorización a largo plazo de la Tierra.

El presente trabajo, pretende analizar información de radiancias medidas por el sensor IASI sobre el satélite MetOp/Meteosat para poder así predecir emisividades terrestres que posteriormente podrán ser visualizadas a través de mapas globales. Para ello se utilizarán dos métodos estadísticos, uno lineal y otro no lineal, y se compararán los resultados obtenidos por ambos, para determinar cual obtiene mejor exactitud en la predicción.

Capítulo 1

Motivación y objetivos

1.1. Motivación

En las últimas décadas ha habido un avance significativo en cuanto a entender mejor las propiedades de la superficie terrestre, gracias al lanzamiento de varios satélites que permiten obtener datos precisos sobre el estado del medio ambiente de la tierra.

En el pasado se han realizado investigaciones similares a las de este trabajo, prediciendo emisividades terrestres utilizando una serie de métodos estadísticos lineales, que han permitido visualizar en gran medida el comportamiento de las emisividades terrestres [DKAMX + 11], sin embargo, se propone utilizar métodos estadísticos no lineales y comparar estos resultados con los del método lineal con conjunto con mapas globales de emisividades.

1.2. Objetivo General

El objetivo general de este proyecto es generar mapas a escala global de emisividades terrestres. Para ello evaluaremos y aplicaremos modelos matemáticos estadísticos lineales y no lineales a datos sintéticos de radiancias del sensor IASI.

1.3. Objetivos específicos

Generar mapas a escala global de medias y de densidad de predicción de emisividades terrestres. Los mapas de medias permitirán visualizar los niveles de emisividad para las latitudes y longitudes observadas. Como es frecuente obtener más de una predicción en una misma coordenada, se hará una media de todas las predicciones para obtener un resultado más preciso. A su vez, los mapas de densidades permitirán visualizar aquellos puntos donde se tenga más de una predicción y que serán interesantes a la hora de evaluar los métodos utilizados.

Comparar resultados obtenidos por los métodos utilizados.

Se utilizará un método lineal y uno no lineal para las predicciones, luego se compararán y se mostrarán gráficamente las predicciones obtenidas por cada uno para cada longitud de onda.

Capítulo 2

Bases teóricas

Para comprender mejor el objetivo y resultados de este trabajo es necesario revisar algunos fundamentos teóricos de varias áreas. Se explicarán conceptos físicos de radiancias y emisividades así como también la explicación teórica de los métodos utilizados para hacer las predicciones, y se dedicará un apartado para explicar el análisis de componentes principales, que representa un paso fundamental previo a la obtención de las predicciones.

2.1. Radiancia

Para este trabajo los datos de entrada utilizados son radiancias medidas por el sensor IASI a bordo del satélite Metop/Meteosat. En física, la radiancia describe la distribución angular de la radiación de un objeto. Otra definición válida es la energía radiante emitida, reflejada, transmitida o recibida por alguna superficie.

La radiancia espectral se refiere entonces a la radiancia de una

superficie por unidad de frecuencia o de longitud de onda, dependiendo de si el espectro se toma como una función de frecuencia o de longitud de onda.

2.2. Emisividad

La emisividad ϵ se define como la capacidad de un material para emitir energía radiante, es decir, emitir calor por radiación. La energía radiante es una radiación electromagnética que puede incluir tanto radiación visible como infrarroja (la cual no es visible para el ojo humano). Para este trabajo, representa los resultados de la predicción dadas las radiancias medidas por el sensor.

La emisividad puede representarse como proporción de la emitancia radiante de un cuerpo a la de emitancia radiante de un cuerpo negro (un objeto ideal que absorbe toda la luz y toda la energía radiante que incide sobre él) a la misma temperatura. Dicho esto, la emisividad espectral se define como el resultado de expresar la emisividad como una función de las longitudes de onda.

Matemáticamente, podremos definir la emisividad a una determinada longitud de onda" (en unidades de μm) y temperatura T (representada en Kelvin), como la proporción entre la radiancia $R_\lambda(T)$ emitida por un cuerpo a una temperatura T y la radiancia $B_\lambda(T)$ emitida por un cuerpo negro a la misma temperatura T , luego

$$\epsilon_\lambda = \frac{R_\lambda(T)}{B_\lambda(T)}$$

donde $B_\lambda(T)$ se refiere a la Ley de Planck definida como

$$B_{\lambda}(T) = \frac{C_1 \lambda^{-5}}{\exp(C_2/\lambda T) - 1}$$

donde C_1 y C_2 son constantes tales que $C_1 = 1,91 \cdot 10^8 \text{ W } \mu\text{m}^4 \text{ sr}^{-1} \text{ m}^{-2}$ y $C_2 = 1,439 \cdot 10^4 \mu\text{mK}$ [ZLHN+ 13].

Al ser una proporción, los valores de la emisividad varían entre 0 y 1. Un cuerpo negro tendrá una emisividad de 1, mientras que un reflector perfecto o cuerpo blanco tendrá una emisividad de 0. La mayoría de los objetos son considerados "cuerpos grises" porque emiten una fracción de su radiación. Muchos minerales y metales tienen emisividades menores que 1 y dependiendo del material, la emisividad puede variar dependiendo de la temperatura. La tabla 2.1 muestra las emisividades de algunos de los materiales más comunes [Uni].

Cuadro 2.1: Tabla de emisividades de materiales.

Material	Emisividad
Aluminio (anodizado)	0.77
Aluminio (pulido)	0.05
Concreto	0.92
Cobre (pulido)	0.05
Cobre (oxidado)	0.65
Vidrio	0.92
Hielo	0.97
Arena	0.9
Nieve	0.8
Agua	0.5

Si se quisiera calcular el nivel de emisividad de una superficie o material particular se utilizaría un dispositivo llamado Cubo de Leslie, que mide las variaciones de la radiación termal emitidas por diferentes superficies a la misma temperatura, en conjunto con un bolómetro. Este último dispositivo compara la radiación termal de la superficie en cuestión con la de un cuerpo negro. La Figura 2.1 muestra un Cubo de Leslie, en el cual se ve la diferencia de emisividad entre los lados del cubo pintados de blanco o negro. Nótese que el lado del cubo pintado de negro es el que muestra un mayor valor de emisividad, mientras que el blanco muestra un valor bastante pequeño.

Muchos materiales tienen emisividad menor que 1 y es constante para cualquier valor de longitud de onda. La emisividad de algunos materiales puede variar dependiendo de la longitud de onda. A estos objetos se les conocen como radiadores selectivos por ser selectivamente radiantes. Incluso algunos materiales podrían comportarse como cuerpos negros a ciertas longitudes de onda (y cercana a 1) pero pueden reducir su emisividad para otros valores de longitud de onda. La Figura 2.2 muestra como la emisividad varía dependiendo de la longitud de onda para el cuarzo y el feldespato, que son ambos radiadores selectivos, solo que el cuarzo tiene más variación en la emisividad a diferentes longitudes de onda.




Figura 2.1: Las primeras dos imágenes fueron tomadas utilizando una cámara infrarroja mientras que las blanco y negro con una cámara normal. Todas las caras del cubo están a la misma temperatura. En la tercera foto, la cara pintada de negro indica un alto nivel de emisividad.

2.3. Emisividad terrestre

Anteriormente hemos definido la emisividad como la capacidad de una superficie para emitir energía radiante. Ahora bien, la emisividad en la superficie terrestre, o LSE por sus siglas en inglés (Land Surface Emissivity), es un factor de proporcionalidad que escala la radiancia de un cuerpo negro (mediante Ley de Planck) para predecir la radiancia emitida. A su vez representa la eficiencia de transmitir energía termal a través de la superficie terrestre hacia

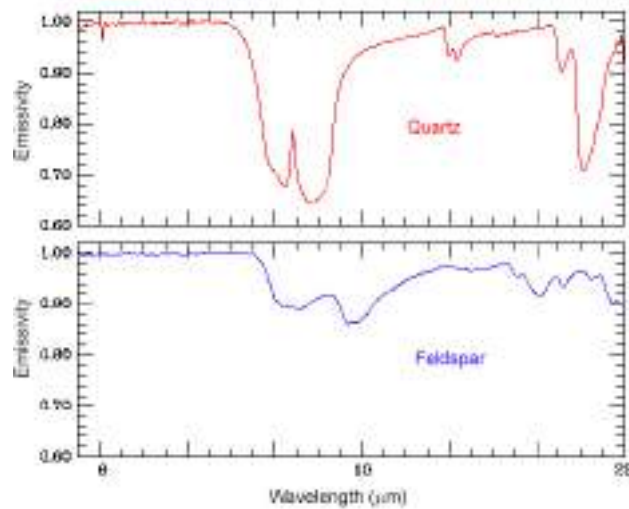


Figura 2.2: Emisividad del cuarzo (arriba) y el feldespato (abajo) para diferentes valores de longitud de onda.

la atmósfera [JAJCG 08].

Para ilustrar como se veña la emisividad de la superficie terrestre, se muestra en la Figura 2.3 la emisividad en un mapa global para el verano de 2008. En la Figura podemos ver que para los desiertos (Sahara, Namib, Australia) se tienen valores de emisividad menores que el resto para la longitud de onda $8.6 \mu\text{m}$.

2.4. PCA

El análisis de componentes principales, o PCA por sus siglas en inglés Principal Component Analysis es un método que permite hallar una proyección donde los datos quedan ordenados de mayor a menor varianza. Esto permite utilizar el método para reducir la dimensionalidad, ya que permite utilizar las componentes principales




Figura 2.3: Emisividad para el verano de 2008 a $8\mu\text{m}$, obtenida de Digital Earth Emissivity Information System (DEEIS) [fSAR].

como representantes de los datos, por lo que también es utilizado para simplificar su exploración y visualización.

Planteemos un ejemplo de dos dimensiones, digamos dos variables: peso y altura. El conjunto de datos podría representarse como puntos sobre un plano. Si se quisiera determinar la variación de los datos, el aplicar una PCA daría como resultado un nuevo sistema de coordenadas en donde cada punto tiene un nuevo valor (x y y). Los ejes no representan nada físico, sino que son combinaciones de pesos y alturas llamadas componentes principales que se escogen para dar a un eje mucha variación [Pow].

Ahora bien, cuando hablamos de más de dos dimensiones es donde la PCA tiene más utilidad, porque es complicado analizar una nube de puntos. La Figura 2.4 muestra un ejemplo de un conjunto de datos en tres dimensiones. La segunda imagen muestra las dos primeras componentes principales, de manera que en el eje hori-

zontal se muestra la componente con mayor variación. Finalmente la componente descartada será la tercera porque es la que ofrece menos variación.




Figura 2.4: Ejemplo de PCA. En la primera gráfica se muestra un conjunto de datos de tres dimensiones. La siguiente muestra las dos primeras componentes principales. En el tercer panel se muestra la distribución de los datos originales contra las componentes principales.

La Figura 2.4 ilustra un ejemplo de tres dimensiones. Ahora bien, cuando se cuenta con un conjunto de datos de gran dimensionalidad, es difícil encontrar patrones y representar gráficamente los datos. Es por ello que este método resulta muy útil ya que permite reducir la dimensionalidad de los datos sin que haya mucha pérdida de información.

Para poder entender el método de componentes principales es necesario entender una serie de conceptos matemáticos utilizados en el algoritmo y que se explicarán a continuación.

2.4.1. Covarianza y matriz de covarianza

Cuando se tiene un conjunto de datos de más de una dimensión, a veces se tiene como objetivo investigar si existe alguna relación entre las dimensiones. La desviación estándar y la varianza son útiles cuando hablamos de una sola dimensión, pero es interesante tener una medida que permita saber cuánto varían las dimensiones de la media. La covarianza permite saber la relación existente entre dos dimensiones.

La covarianza es la media aritmética de los productos de las desviaciones de cada una de las variables respecto a sus medias respectivas. Matemáticamente, sea X e Y dos variables con n elementos, y \bar{X} e \bar{Y} las medias de los elementos de X e Y respectivamente. Se define la covarianza entre ellas, $\text{cov}(X, Y)$ como:

$$\text{cov}(X, Y) = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y}). \quad (2.1)$$

Cuando se tienen más de dos dimensiones se utiliza la matriz de covarianza. Crear una matriz de covarianza consiste en calcular la covarianza de todas las dimensiones y denotarlas en forma matricial. Matemáticamente, sea C una matriz compuesta por n variables, los elementos de la matriz de covarianza estarán dados por la covarianza de cada par de variables de C , tal que

$$C = \begin{pmatrix} \text{cov}(X_1, X_1) & \text{cov}(X_1, X_2) & \text{cov}(X_1, X_3) & \dots & \text{cov}(X_1, X_n) \\ \text{cov}(X_2, X_1) & \text{cov}(X_2, X_2) & \text{cov}(X_2, X_3) & \dots & \text{cov}(X_2, X_n) \\ \dots & \dots & \dots & \dots & \dots \\ \text{cov}(X_n, X_1) & \text{cov}(X_n, X_2) & \text{cov}(X_n, X_3) & \dots & \text{cov}(X_n, X_n) \end{pmatrix} \quad (2.2)$$

2.4.2. Vectores y valores propios

Los vectores propios son aquellos vectores no nulos que cuando son transformados por el operador dan como resultado un múltiplo escalar de si mismos, por lo que no cambian su dirección.

Matemáticamente, un vector propio de una matriz A de $n \times n$ es un vector $v \in \mathbb{R}^n$, distinto de 0, tal que para cierto escalar $\lambda \in \mathbb{R}$ se tiene que

$$Av = \lambda v \quad (2.3)$$

Al escalar λ se le denomina valor propio de A asociado al vector propio v [Her].

2.4.3. Algoritmo PCA

Sean X_1, X_2, \dots, X_n las n variables de un conjunto de datos y sean $\bar{X}_1, \bar{X}_2, \dots, \bar{X}_n$ las medias de cada una de las variables.

1. Substraer la media de cada dimensión .

Para cada elemento de cada dimensión del conjunto de datos, se obtiene la media de esa dimensión y se substraer para obtener un nuevo conjunto de datos con media cero. Esto es

$$\tilde{X}_i = X_i - \bar{X}_i, \quad (2.4)$$

con $i = (1, 2, 3, \dots, n)$.

2. Calcular la matriz de covarianza C .
 Obtener la matriz de covarianza C , para conocer la relación entre cada dimensión, utilizando la fórmula (2.5).
3. Calcular los vectores y valores propios de la matriz de covarianza C .
 Se obtienen los vectores y valores propios de la matriz de covarianza utilizando la fórmula (2.3), luego $Cv = \lambda v$, y se obtienen v y λ , que son los vectores y valores propios de C .
4. Escoger las componentes k .
 En este punto es donde se da realmente la reducción de la dimensionalidad del conjunto de datos. Una vez obtenidos los valores y vectores propios, nos fijaremos en el vector propio que tenga el mayor valor propio y será esta nuestra componente principal. Para escoger las componentes principales se ordenan los vectores propios por sus valores propios de mayor a menor y finalmente se crea una matriz con estos vectores en las columnas que denotaremos como P .
 Es necesario destacar que al momento de reducir la dimensionalidad se necesita retener la mayor cantidad de información posible, por ello, se podrá decidir ignorar aquellas componentes con menor significancia, es decir, aquellas donde los valores propios sean muy pequeños y no se pierda gran información sobre los datos.
5. Obtener los datos originales de las componentes escogidas.
 Una vez obtenida la matriz de vectores propios P , debemos

trasponerlo y multiplicar por la izquierda por el conjunto de datos original. Al hacer esto obtendremos los datos originales únicamente en términos de las componentes que fueron escogidas. Finalmente, la formulación de la PCA será:

$$PCA(X) = (X^T X)^{-1} X^T P \quad (2.5)$$

2.5. Regresión Lineal regularizada

La regresión lineal regularizada es una versión de la regresión lineal de mínimos cuadrados a la que se le añade un término de regularización para evitar el sobre-entrenamiento (overfitting) y condicionar mejor el problema de regresión. Matemáticamente se define como: sea $x_i \in \mathbb{R}^d$ el conjunto de datos de entrada y y_i la salida que se va a estimar, donde $i = 1, \dots, n$ indican el índice de las muestras de entrenamiento. Se quiere realizar la regresión lineal de mínimos cuadrados donde la ecuación es $y_i = w^T x_i + b$, y asumimos un modelo con variables aleatorias independientes e idénticamente distribuidas tal que $y_i = y_i + \epsilon$, con ruido Gaussiano $\epsilon \sim N(0, \sigma^2)$ de media cero y desviación estándar σ . A partir de este punto, se descarta el bias ya que puede ser incluido en los pesos del modelo agregando una columna de unos al conjunto de datos de entrada.

En el ajuste de la regresión lineal queremos minimizar la función cuadrática de pérdida con respecto a los pesos del modelo

$$L = \frac{1}{n} \sum_i (x_i^T w - y_i)^2 + \lambda \|w\|^2, \quad (2.6)$$

donde $e_i = y_i - x_i^T w$ es el error de la regresión que queremos minimizar y λ es el parámetro de regularización que controla la norma de los pesos del modelo $\|w\|$, para evitar overfitting y forzar que haya más suavidad en la solución y así evitar valores muy desiguales.

Esta definición también puede expresarse en notación matricial para así considerar múltiples entradas y salidas. El modelo vendrá dado por $Y = XW$, donde X es la matriz de muestras de entrenamiento, $X = [x_1 \ x_2 \ \dots \ x_n]^T$, de tamaño $n \times d$, y $W \in \mathbb{R}^{d \times p}$ es la matriz de pesos que definen la relación lineal entre las entradas $X \in \mathbb{R}^{n \times d}$ y las salidas $Y \in \mathbb{R}^{n \times p}$ que serán predichas. Derivando la función cuadrática de pérdida, $J = \|XW - Y\|^2 + \lambda \|W\|^2$, con respecto a los pesos del modelo W , e igualándolos a cero, se obtiene la solución de ecuación normal

$$W = (X^T X + \lambda I)^{-1} X^T Y. \quad (2.7)$$

El único parámetro por ajustar (por ejemplo, por validación cruzada) es el parámetro de regularización, que es un valor (típicamente pequeño) que se suma a la diagonal de la matriz de covarianza estimada, $\frac{1}{n-1} X^T X$. Por lo tanto, en una regresión regularizada, se debe estimar la inversa de la matriz de covarianza (regularizada) para obtener los parámetros de recuperación (un peso por característica de entrada y salida estimada).

Finalmente, lo que se quiere en la práctica es el valor de salida para nuevas muestras de entrada $X_{\$}$, que se calcula proyectándolo sobre la solución, $\hat{y}_{\$} = X_{\$} W$.

2.6. Regresión Kernel Regularizada

A menudo el espacio de datos de entrada no es apropiado para obtener un buen modelo puesto que las características demuestran tener relaciones no lineales. En estos casos se desea transformar los datos para plantear las distribuciones de manera que muestren dependencias lineales, que son más fáciles de analizar. Sin embargo, diseñar estas transformaciones no es tarea fácil. Una alternativa consiste en mapear los datos a un espacio de mayor dimensión.

La regresión Kernel Ridge (KRR por sus siglas en inglés, Kernel Ridge Regression) [STC04] es la versión kernel de la regresión lineal regularizada. La formulación es la siguiente:

Se quiere realizar una regresión lineal de mínimos cuadrados en un espacio de Hilbert, H , de gran dimensionalidad (posiblemente infinita) d_H , donde las muestras han sido mapeadas a través de una función no lineal $\phi(x_i)$. En notación matricial, el modelo viene dado por $Y = \Phi W$ y, bajo la premisa de un modelo de ruido aditivo con variables independientes e idénticamente distribuidas, $\hat{Y} = Y + E$ con ruido Gaussiano $E \sim N(0, \sigma_n^2 I)$ de media cero y desviación estándar σ_n .

Luego, en el ajuste de la regresión lineal regularizada, se quiere minimizar la función de pérdida cuadrática regularizada, $\|W\|^2 + \lambda \|W\|^2$ con respecto a los pesos del modelo W . Por lo tanto, derivando con respecto a W e igualando los pesos a cero, se obtiene $W = (\Phi^T \Phi + \lambda I)^{-1} \Phi^T Y$, donde Φ es la matriz de las muestras mapeadas, $[\phi(x_1) \ \phi(x_2) \ \dots \ \phi(x_n)]^T$, con tamaño $n \times d_H$. Este problema no se puede resolver directamente ya que la inversa se ejecuta en la matriz $\Phi^T \Phi$ que es de tamaño $d_H \times d_H$,

y \hat{a} es en principio desconocido. Aquí se aplica el Teorema del Representante con el que podemos expresar la solución como una combinación lineal de muestras mapeadas $\hat{a} = \sum A$, y entonces, la solución es derivada y expresada en función de los pesos duales A (una β por muestra), $A = (\sum \lambda + I)^{-1} Y$. Ahora el problema se puede resolver, ya que solo se necesita calcular la inversa de la matriz de Gram (regularizada) $K = \sum$ de tamaño $n \times n$. A pesar de que el mapeo es desconocido, se puede reemplazar este producto de matrices con una matriz de similitud entre las muestras, que se conoce como la matriz kernel, K .

Para obtener nuevas predicciones \hat{y}_s se proyecta sobre la solución W :

$$\hat{y}_s = \sum_s W = \sum_s \sum A = K_s A = K_s (K + I)^{-1} Y, \quad (2.8)$$

donde la matriz K_s contiene las similitudes entre todas las muestras de prueba y todas las muestras de entrenamiento, cuyos elementos son $K(x_i, x_j) = \sum (x_i) \sum (x_j)$. Lo importante aquí es que solo se necesita acceso a la función kernel. Ejemplos de típicas funciones kernel son las lineales $K(x_i, x_j) = x_i \sum x_j$, las polinómicas, $K(x_i, x_j) = (x_i \sum x_j + 1)^d$, o la que se utiliza en este trabajo, la función kernel base radial Gaussiana (RBF por sus siglas en inglés, Gaussian radial basis function): $K(x_i, x_j) = \exp(-\sum_i \sum_j / (2\sigma^2))$. Por lo tanto en KRR, se deben ajustar dos parámetros: el parámetro de regularización λ , y el parámetro del ancho kernel RBF σ .

Capítulo 3

Estado del Arte

En el estudio de los niveles de emisividad terrestre se han hecho numerosas investigaciones y artículos con la finalidad de predecir y entender el comportamiento de las emisividades. En este capítulo se analizarán algunos trabajos que fueron considerados como base para la realización de este trabajo. Por un lado, se analizará el artículo Global Land Surface Emissivity Retrieved From Satellite Ultraspectral IR Measurements [DKAMX + 11] y por otro, el artículo Nonlinear Statistical Retrieval of Surface Emissivity From IASI Data [LMMGC + 16].

3.1. Global Land Surface Emissivity Retrieved From Satellite Ultraspectral IR Measurements

En este artículo se aplican modelos de transferencia radiativa bajo cualquier tipo de condición climática que luego se utilizan para generar un perfil atmosférico y recuperar parámetros de sondeos infrarrojos espaciales ultra espectrales o hiper espectrales. A su vez, se desarrolla un esquema con el que se pueden tratar radiancias en condiciones nubladas o sin nubes y que ha sido aplicado a IASI.

Parte de la motivación de este trabajo surge para poder monitorizar cambios climáticos a nivel global, y al mismo tiempo, predecir la SSE de las medidas infrarrojas ultra espectrales de un satélite permite obtener otros parámetros como la temperatura de la superficie terrestre, la asimilación de radiancias IR en modelos de predicción de clima, etc.

Previamente se habían desarrollado algoritmos para determinar la emisividad IR provenientes de medidas de satélites. En este artículo, se ha mejorado uno de estos algoritmos (desarrollado previamente por Zhou [DKWLJ⁺ 02]). El mismo se enfoca en el proceso de entrenamiento y en utilizar una PCA para la fase de predicción de la SSE.

Para la predicción, en primer lugar se utilizaron datos del NPOESS Airborne Sounder Testbed Interferometer (NAST-I) [CS97] para obtener las amplitudes de la función empírica ortogonal (o EOF por sus siglas en inglés Empirical Orthogonal Function). Note que en este artículo la EOF se refiere a la PCA descrita previamente en

3.1. GLOBAL LAND SURFACE EMISSIVITY RETRIEVED FROM SATELLIT

la sección 2.4.

La primera parte del análisis consiste en obtener la ecuación de transferencia radiativa y calcular la radiancia, las expresiones detalladas para llegar a las fórmulas se encuentran disponibles en [DKAMX + 11].

La radiancia es una función lineal de la emisividad y si la radiación solar y la reflectividad no afectan los canales utilizados en la predicción, la SSE continúa siendo lineal con respecto a la radiancia en condiciones nubladas. En condiciones no nubladas, la radiancia es sensible a la temperatura de la superficie terrestre y a la SSE, que se representará en función del número de frecuencia. Es por ello que la SSE predicha por la regresión lineal debería ser igual de acertada que las medidas físicamente, si el conjunto de datos de entrenamiento utilizado en la regresión representa de manera óptima el valor de SSE como una combinación lineal de las condiciones de la base de datos.

Para obtener valores de propiedades de la superficie de la tierra, se utilizaron medidas provenientes de IASI, que es un interferómetro de Michelson con una cobertura espectral entre 3.62 y 15.5 μm que recopila datos en intervalos de 25 km, donde cada muestra tiene 4 píxeles y cada píxel tiene un máximo diámetro espacial de 12 km.

Seguidamente se procede a realizar el entrenamiento para la regresión. La base de datos utilizada consistió en perfiles obtenidos de la base de datos SeaBor [SWSER08], SSEs de varias superficies medidas en un laboratorio y propiedades microfísicas de nubes a partir de una parametrización basada en una base de datos microfísica de nubes de globos y aeronaves.

En la base de datos de entrenamiento se realizaron varias modi-

Modificaciones para mejorar la predicción. La precisión de la predicción de los parámetros de la superficie se mejoró utilizando diversos contrastes de temperatura del aire y de la superficie. Por lo que la temperatura de la superficie de la base de datos SeeBor se reemplaza por:

$$T_s = T_a + T_r$$

donde T_a y T_r son las temperaturas del aire y de la superficie.

Los valores de SSE utilizado, están representados por las nueve componentes con mayor puntuación provenientes de la EOF (PCA). Los vectores propios de estas nueve componentes son utilizados para minimizar el error de compresión.

Aunado a las modificaciones realizadas en la base de datos de entrenamiento, también se realizaron modificaciones en la regresión utilizada para la predicción. En primer lugar, se incluyeron nuevos canales de regresión. Se genera entonces un vector de estado que contiene un perfil atmosférico con información de la temperatura, humedad, ozono y monóxido de carbono, también parámetros de nubes, temperaturas de la superficie, etc. Seguidamente, se clasifican los coeficientes de regresión como libre de nubes, nublado, y mixto.

En este punto, se realizó la regresión con un enfoque de dos etapas. La primera etapa consiste en hacer la regresión bajo condiciones mixtas (nubladas y no nubladas) y la segunda etapa hará la regresión en función de los resultados obtenidos en la primera etapa.

A continuación se realiza un análisis del rendimiento del algoritmo de recuperación de SSE estimando su nivel de precisión para

3.1. GLOBAL LAND SURFACE EMISSIVITY RETRIEVED FROM SATELLIT

luego validar los resultados sobre los desiertos de Namib y Kalahari. La validación se realizó con muestras de laboratorio medidas directamente del campo.

Como también se tenían datos globales de SSE del IASI, se procedió a calcular la media mensual de SSE. La Figura 3.1 muestra mapas globales con esta información para un grupo de frecuencias seleccionadas. En los mapas de la Figura 3.1, se distinguen los principales desiertos porque tienen valores de emisividad bajos para la región espectral de 1000 a 1200 cm^{-1} .

Finalmente, como resultado del desarrollo de este artículo se implementó un algoritmo que toma en cuenta todas las posibles condiciones climáticas y se aplica a medidas de radiancia de IASI. A su vez, se demostró que se predicen los datos de forma más eficiente utilizando una regresión lineal sobre las componentes de la PCA.

3.2. Nonlinear Statistical Retrieval of Surface Emissivity From IASI Data

El objetivo de este artículo consiste en predecir las emisividades espectrales dadas las radiancias mediante el uso de una regresión kernel no lineal como la descrita en la sección 2.6, y comparar los resultados obtenidos con los de una regresión lineal regularizada como la descrita en la sección 2.5.

El conjunto de datos consistió de 8461 canales espectrales o longitudes de onda entre 3.62 y 1.65 μm con una resolución espectral de 0.5cm^{-1} y en el que además se pretendió predecir la SSE, que es a su vez un vector de alta dimensionalidad.

El método utilizado fue la Regresión Kernel Rigde (KRR por sus siglas en inglés, Kernel Ridge Regression) y se comparó su rendimiento con el método de regresión lineal (LR). La formulación utilizada para esta regresión está disponible en la sección 2.7

Como el conjunto de datos tiene una alta dimensionalidad, aplicar el método descrito en la sección 2.7 directamente no era una solución viable, por lo que se decidió seguir la misma estrategia descrita en la sección 3.1, que consiste en aplicar los modelos a las componentes principales tanto de X (radiancias) como de Y (emisividades), es decir $X_p = X V_x$ y $Y_q = Y V_y$, donde p y q representan el número de componentes principales seleccionadas para X y Y respectivamente. Este enfoque es muy efectivo sobretodo por la correlación que existe entre las radiancias y entre las emisividades. Además, computacionalmente es muy eficiente, ya que solo se uti-

3.2. NONLINEAR STATISTICAL RETRIEVAL OF SURFACE EMISSIVITY F

liza un modelo para la estimación de las emisividades en lugar de utilizar M modelos.

Una vez aplicado el modelo a las componentes principales se seleccionan los parámetros para el KRR. En este caso se utilizó una función kernel llamada Radial Basis Function (RBF), gracias a ello solo se debe ajustar dos parámetros para el KRR, que es el parámetro de regularización λ , que es el parámetro kernel. Ambos parámetros fueron seleccionados mediante validación cruzada.

Luego, se seleccionó un conjunto de entrenamiento que fue a su vez dividido en entrenamiento y validación. Con el grupo de entrenamiento se ajustaron los pesos y con el grupo de validación se evaluó el rendimiento para cada par (λ, γ). Una vez encontrado el mejor par (λ, γ) se generaron las predicciones y se validaron con un conjunto de pruebas independiente de los anteriores.

Seguidamente se procede a comparar la eficiencia del método lineal (LR) contra el KRR. La Figura 3.2 (a) muestra el error de cada modelo de regresión para estimar el valor de las dimensiones correspondientes a las componentes principales de las emisividades, donde puede notarse que el KRR tiene menos error. Las Figuras 3.2 (b) y (c) muestran el error de bias y la raíz del error cuadrático medio (RMSE) para las emisividades reconstruidas. Finalmente la Figura 3.2 (d) muestra los resultados relativos en porcentaje entre LR y KRR.

Finalmente, se concluye que el KRR tiene mejor rendimiento que el método lineal tanto en error absoluto (bias) como en error cuadrático medio, y para algunas longitudes de onda se obtiene casi un 50% menos error y una reducción promedio del 25% en error cuadrático medio.

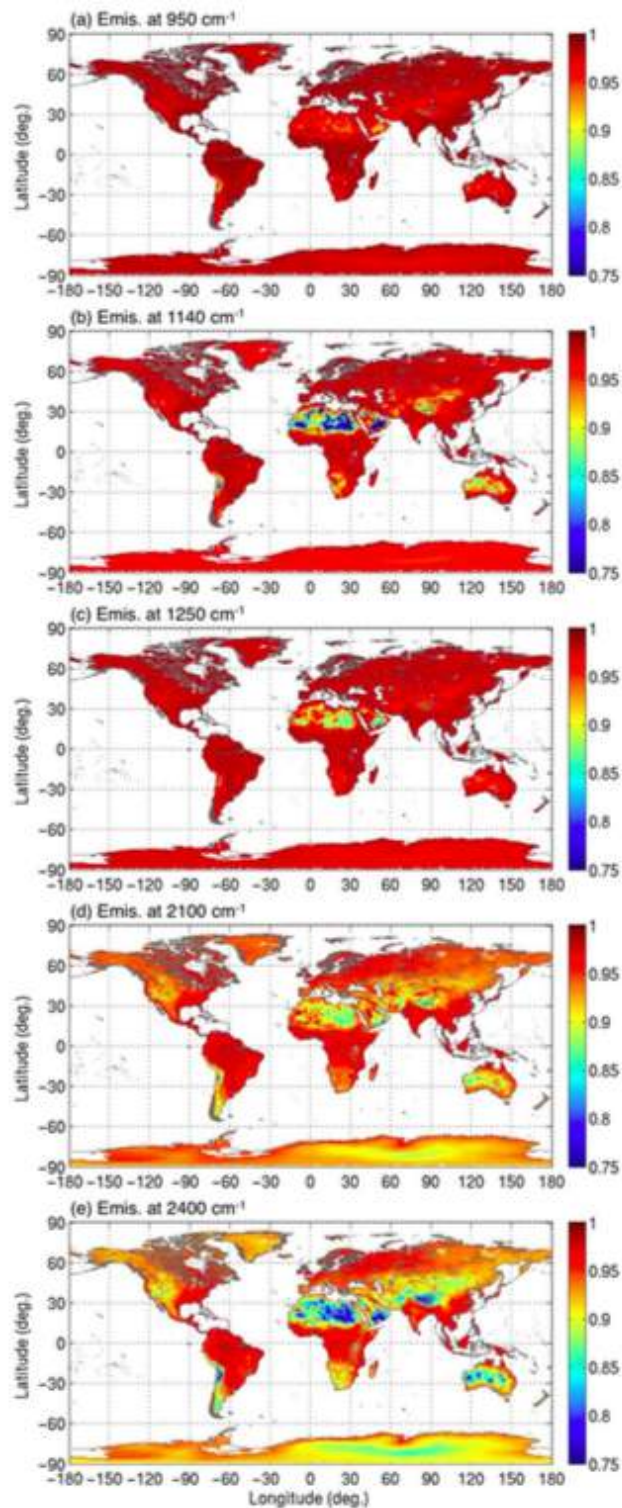


Figura 3.1: Resultados obtenidos por Daniel Zhou para medias mensuales de SSE globales en julio de 2007 para las frecuencias indicadas.

3.2. NONLINEAR STATISTICAL RETRIEVAL OF SURFACE EMISSIVITY F

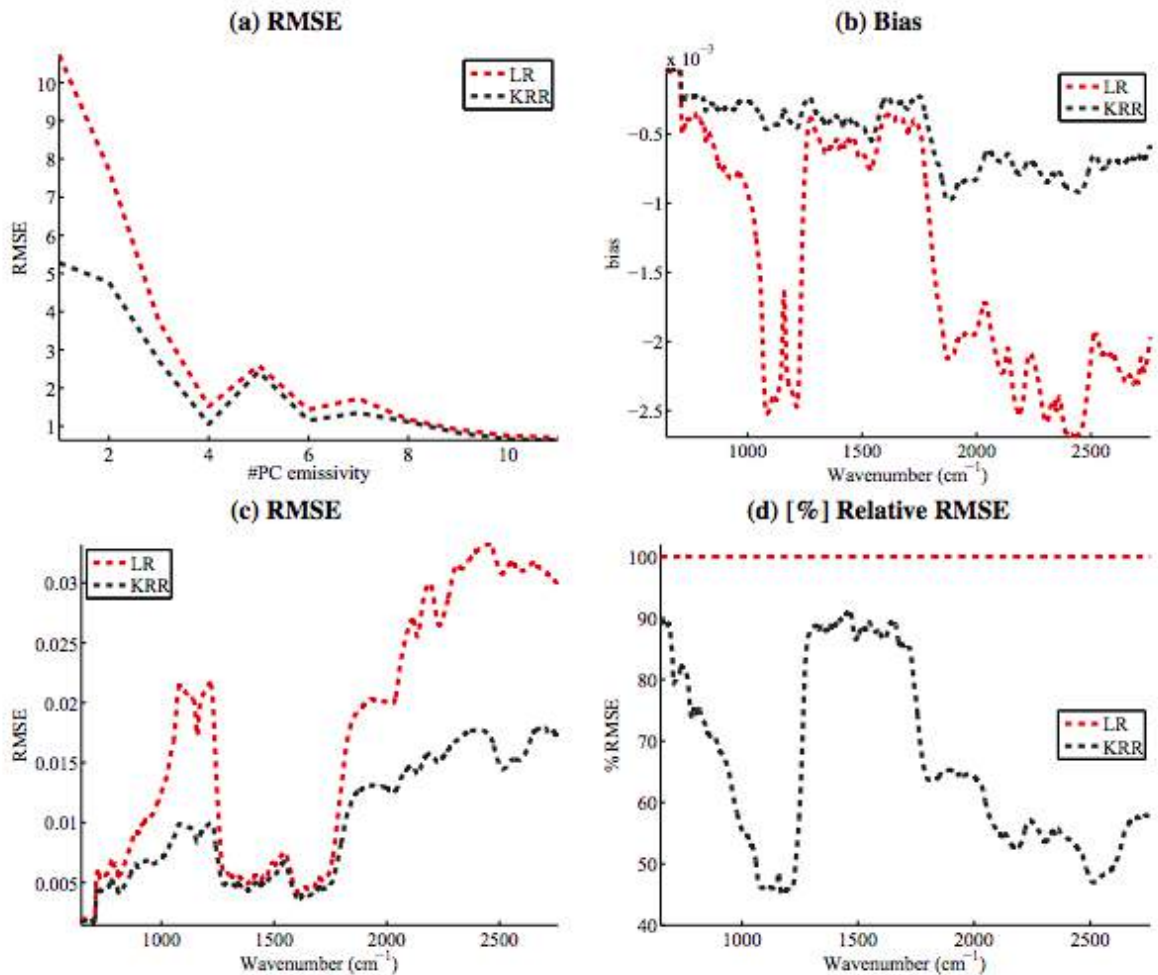


Figura 3.2: Resultados de la regresión. Comparación de resultados de regresión del modelo lineal (LR) y el modelo no lineal (KRR). a) RMSE de cada método para predecir las emisividades en las componentes principales. b) Bias de cada método prediciendo las emisividades de cada uno. c) RMSE de cada método prediciendo las emisividades para cada número de onda. d) Porcentaje de RMSE de cada método dividido por el RMSE del método LR.

Capítulo 4

Conjunto de datos y métodos utilizados

En este capítulo se describirá el conjunto de datos utilizado en este proyecto. A su vez se explicará como se realizó el pre-procesado de los datos, el entrenamiento de los modelos y la evaluación de sus resultados. Finalmente se explicará como se generaron los mapas globales tanto de medias como de densidad.

4.1. Conjunto de datos

El conjunto de datos reales de IASI consiste en 8461 canales espectrales, que van de $6.62 \mu\text{m}$ y $15.5 \mu\text{m}$, con una resolución espectral de 0.5 cm^{-1} . La resolución espacial de los datos consiste en 25 km con un campo de visión (Instantaneous Field Of View IFOV) de 12 km a una altitud de 819 km. Los datos son medidos desde el satélite MetOp/Meteosat. Sin embargo, como ya se ha mencionado,

32CAPÍTULO 4. CONJUNTO DE DATOS Y MÉTODOS UTILIZADOS

el conjunto de datos utilizado para este trabajo consiste en datos sintéticos de IASI y de emisividades.

El conjunto de datos sintéticos está compuesto por 298 *Perchers* de extensión mat. Cada *Perchero* representa una lectura o *Ópasada* del sensor sobre la superficie terrestre en una determinada fecha y hora. Note que como el sensor hace varias pasadas al día es posible que haya más de una radiancia para una misma latitud y longitud, por lo que se puede tener más de una predicción de emisividad para un mismo punto.

Para el proceso de entrenamiento se utilizaron 20000 muestras y un esquema de validación cruzada donde la mitad de las muestras se utilizaron para obtener diferentes conjuntos de coeficientes de regresión para cada combinación de parámetros β , y la otra mitad se utilizó como conjunto de datos de validación para probar todos los conjuntos de coeficientes. El conjunto de datos para probar los modelos es diferente del conjunto de datos de entrenamiento y validación.

4.1.1. Satélite MetOp/Meteosat

Metop es una serie de tres satélites meteorológicos de órbita polar que forman el componente del segmento espacial del Sistema Polar Eumetsat general (EPS).

El Metop-A fue lanzado el 19 de octubre de 2006 y Metop-B fue lanzado el 17 de septiembre de 2012, ambos satélites operaron en paralelo mientras las capacidades disponibles de Metop-A brinden beneficios a los usuarios. Estos satélites se encuentran en una órbita polar inferior, a una altitud de 817 kilómetros, para proporcionar observaciones más detalladas de la atmósfera, los océanos y

los continentes. Metop-C se lanzará en octubre de 2018 [EUM88].

La segunda generación de Meteosat (MSG por sus siglas en inglés *Meteosat Second Generation*) proporciona imágenes completas de la tierra e información de pronóstico del tiempo. Tener esta información permite la detección temprana de tormentas tropicales, permitiendo salvar vidas y recursos gracias a las alertas que se pueden generar.

4.2. Pre-procesado

Como ya se ha mencionado anteriormente, este problema presenta un reto debido a la alta dimensionalidad de los datos, que no solo tienen los datos de entrada sino también las salidas. Debido a esto, es computacionalmente ineficiente aplicar algoritmos y modelos estadísticos directamente sobre los datos.

La Figura 4.1 muestra el diagrama con el flujo seguido en el proceso de predicción. En primer lugar se aplica una primera normalización para luego aplicar una PCA (descrita en la sección 2.4.3), seguidamente se aplica una segunda normalización necesaria para el método kernel regularizado. A continuación se aplican los modelos solo a las componentes principales escogidas tanto de las entradas, X como de las salidas Y , esto es $X_p = X V_x$ y $Y_q = Y V_y$, donde p y q representan el número de componentes escogidas para X y Y respectivamente. Como solo se aplicaron los modelos a las componentes principales, se debe hacer la inversa de la PCA para volver a la dimensionalidad original y finalmente desnormalizar para obtener los resultados correctos.

Note que es la alta correlación entre las radiancias y las emisi-

34CAPÍTULO 4. CONJUNTO DE DATOS Y MÉTODOS UTILIZADOS

vidades lo que permite que este enfoque sea mejor y computacionalmente más eficiente, porque además solo se utilizará un modelo para la estimación de las emisividades, en vez de usar modelos, o en su defecto, las componentes principales escogidas.



Figura 4.1: Flujo de trabajo para el proceso de predicción. Dadas las radiancias se normalizan para aplicar una PCA. Luego se normalizan las componentes principales previamente a aplicar la regresión. Seguidamente se invierte la PCA para volver a la dimensionalidad original y se deshace la primera normalización para obtener los valores de las predicciones de emisividad.

4.3. Entrenamiento de los métodos estadísticos utilizados

Los métodos estadísticos utilizados fueron el modelo lineal regularizado descrito en la sección 2.6 y el método kernel regularizado descrito en la sección 2.7.

Una vez preparados los datos para el entrenamiento, se procede a entrenar el primer modelo, el lineal regularizado. Anteriormente se describió en la sección 2.6 la formulación utilizada por este método, por lo que sabemos que el problema a resolver es XW y que W viene dado por la ecuación (2.7) en la cual se debe ajustar el parámetro de regularización λ . Para ajustar λ se utilizó validación

cruzada y se escogió el valor de con el menor error. El código utilizado para esta estimación se encuentra disponible en [CV].

Seguidamente se procede a entrenar el segundo modelo, el KRR. Como se ha planteado anteriormente en la sección 2.7 donde el problema a resolver viene dado por $\gamma = \frac{1}{W}$ y que deriva finalmente en la ecuación 2.8, donde se debe definir la función kernel a utilizar. En este caso, la función kernel a utilizar será la cuadrada exponencial, como RBF por sus siglas en inglés Radial Basis Function, definida como:

$$K(x_i, x_j) = \exp(-\frac{\|x_i - x_j\|^2}{2\sigma^2}) \quad (4.1)$$

Con esta función kernel solo se deben ajustar dos parámetros, el parámetro de regularización λ y el parámetro kernel σ , que fueron seleccionados por validación cruzada. Para ello se seleccionó un conjunto de entrenamiento y se dividió en entrenamiento y validación, el primero fue utilizado para ajustar los pesos duales y el último para evaluar el rendimiento de cada par escogido (λ, σ).

4.4. Evaluación

Para evaluar las predicciones a partir de los modelos se utilizó un conjunto de datos de pruebas independiente de los utilizados para el entrenamiento y validación de los modelos. La Figura 4.1 muestra el proceso seguido para la implementación de la predicción. Una vez se tienen las predicciones, se procede a guardarlas en archivos de extensión `.mat` para poder acceder de manera más

eficiente más adelante. El ejemplo de código utilizado en este punto está disponible en el apéndice A.3

4.5. Generación de mapas

Parte de los objetivos específicos de este trabajo consiste en generar mapas globales. Un mapa global es un mapa que muestra la mayoría de la superficie terrestre. Existen varios tipos de mapas globales debido a problemas de proyección. Para este trabajo, se ha utilizado la proyección Mercator.

La proyección Mercator es una proyección de la superficie terrestre en la cual los meridianos están representados como líneas verticales separadas uniformemente y los paralelos de latitud son líneas horizontales que se van separando cada vez más a medida que aumenta su distancia del Ecuador. Esta proyección es muy usada para gráficos de navegación, porque cualquier línea recta en un mapa de proyección de Mercator es una línea de rumbo constante que permite a un navegador trazar un rumbo en línea recta [oEB].

Ahora bien, cuando ya se tienen las predicciones de ambos modelos utilizados, se procede a generar mapas globales que permitan visualizar los resultados obtenidos.

A pesar de que se cuenta con las predicciones para 8461 números de onda, los mapas serán generados para los números de onda 950, 1140, 1250, 2100 y 2400 m^{-1} . Por lo que para cada número de onda, se generará un mapa global de densidad y dos mapas globales de medias, uno con los resultados obtenidos por el método LR y otro por el KRR.

Un mapa global de medias de predicción será un mapa global de

proyección Mercator con una escala de color que irá de azul oscuro a rojo oscuro para valores de 0 a 1 respectivamente. Luego para cada punto en el mapa en el cual se tenga más de una predicción, se calculará la media entre todas las predicciones y será este el valor mostrado en el mapa.

Por otro lado, se generarán mapas globales de densidad. Como es posible tener más de una predicción para un punto (latitud-longitud), es interesante determinar en que puntos hay más de una predicción. Para ello el mapa de densidad tendrá una escala igual a la de los mapas globales de media, teniendo en cuenta que para mantener la escala de 0 a 1 se normalizaron las densidades.

Teniendo claro los mapas que se generarán, se implementa el algoritmo que se describe a continuación:

1. Inicializar directorios de datos y resultados
2. Cargar vectores y valores propios de las radiancias
3. Cargar medias de las radiancias
4. Para cada longitud de onda,
 - a) Inicializar matrices que guardarán la información de los mapas (matriz de latitud, longitud)
 - b) Para cada Pchero que contiene información de los datos,
 - 1) Cargar las predicciones correspondientes
 - 2) Cargar datos originales para obtener la máscara de nubes y de océano
 - 3) Descartar predicciones donde haya nubes y agua

38CAPÍTULO 4. CONJUNTO DE DATOS Y MÉTODOS UTILIZADOS

- 4) Guardar predicciones en matrices de latitud y longitud
 - 5) Obtener el número de predicciones en cada punto
 - 6) Calcular predicciones medias
- c) Obtener valores medios de las predicciones LR y KRR
 - d) Generar y guardar mapa global de densidad
 - e) Generar y guardar mapa global de medias

Capítulo 5

Resultados obtenidos

Como parte de los resultados obtenidos en este trabajo, y como se ha mencionado anteriormente, se generaron una serie de mapas globales de emisividad para poder obtener conclusiones. En la generación de mapas se descartaron aquellas predicciones que no estuviesen en tierra o donde hubiese un porcentaje de nubes mayor al 0%. La descripción del algoritmo se encuentra en el capítulo 4.

Note que para este tipo de problema no es sencillo comparar con resultados reales debido a la logística que requeriría, por lo que se han comparado los resultados obtenidos en este trabajo con los de otros trabajos previos.

5.1. Mapas de densidad

El primer tipo de mapa global generado consiste en un mapa de densidad de predicciones. Este tipo de mapa es en esencia un histograma de la cantidad de predicciones obtenidas en cada loca-

lización observada por el satélite. El objetivo es obtener una idea de las zonas con mayor o menor cobertura del satélite.

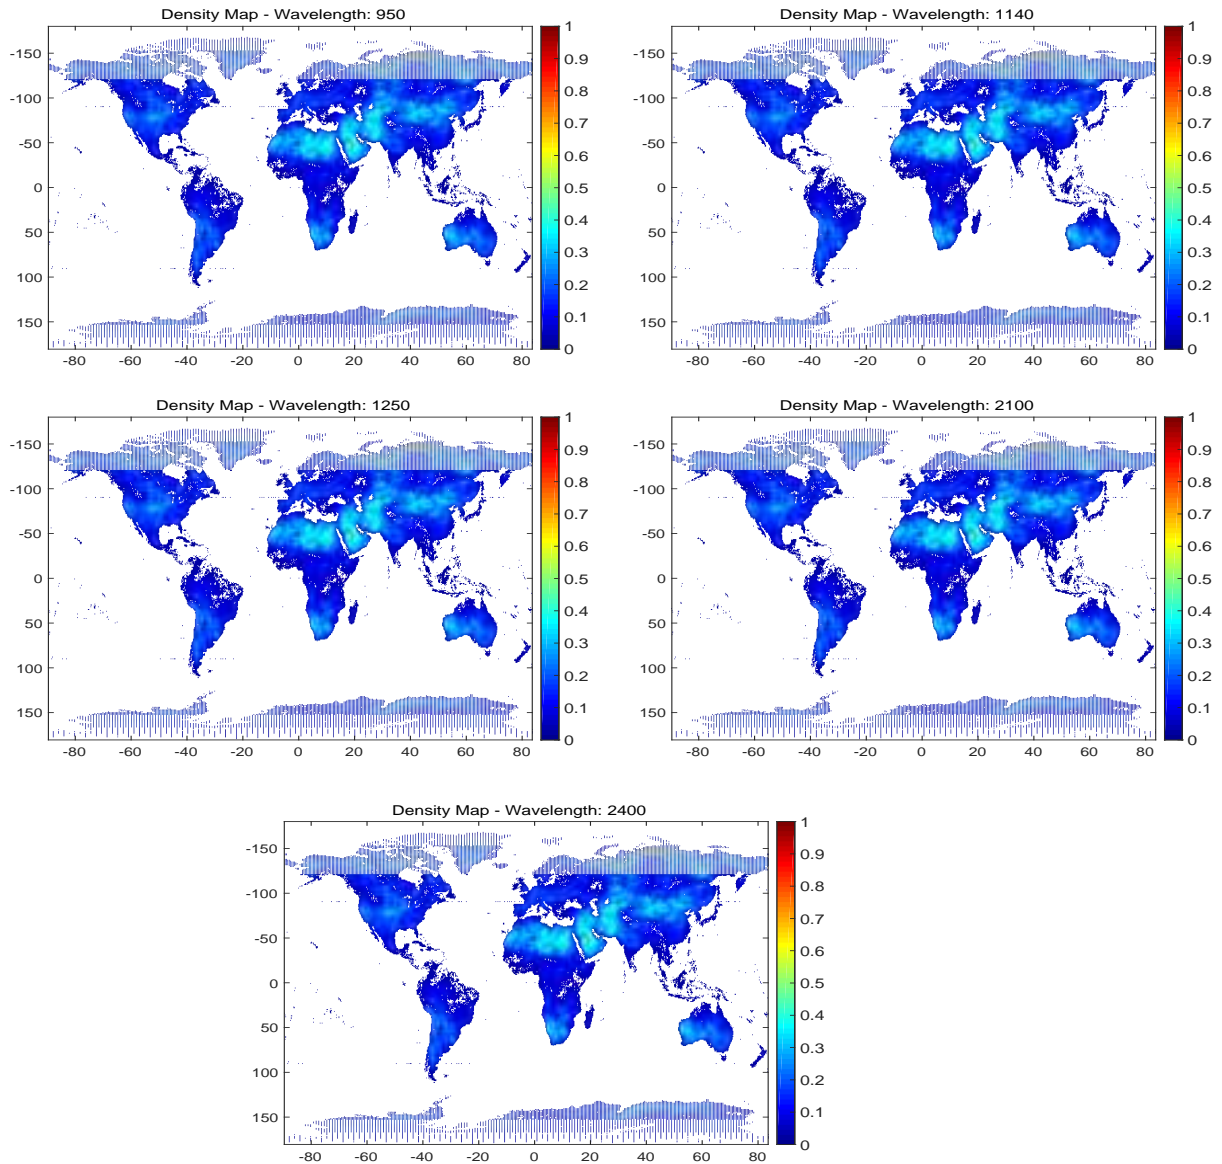


Figura 5.1: Mapas de densidad para números de onda 950, 1140, 1250, 2100 y 2400 cm^{-1} .

La Figura 5.1 muestra los mapas globales de densidad para los números de onda seleccionadas. La razón por la cual se escogieron

estos números de onda, es en primer lugar porque son las más comunes y donde se suelen ver patrones de emisividad en zonas de temperaturas extremas como desiertos o en los polos. Por otro lado, en otros trabajos también se utilizaron estas longitudes de onda por lo que resultan convenientes para realizar comparaciones.

De ellos podemos notar que se tiene al menos una predicción en gran parte del mundo, a excepción de Centro América, la parte norte de América del Sur y en la zona central de África. Note que hay una alta densidad de predicciones en ambos polos, al norte de África y en la zona sur de Asia. Los mapas detallados se encuentran disponibles en el apéndice B.

5.2. Mapas de medias

En este trabajo también se generaron mapas globales de emisividades. Estos mapas muestran las emisividades medias predichas por los modelos utilizados. Se ha generado un mapa de medias para cada número de onda seleccionado y para cada modelo estadístico utilizado.

La Figura 5.2 muestra los mapas globales de medias generados, aquellos situados a la izquierda son los predichos por el método estadístico LR yendo de arriba a abajo por los números de onda 950, 1140, 1250, 2100 y 2400 cm^{-1} . Análogamente para los mapas situados a la derecha para el método KRR.

El mapa inferior de la Figura 5.3b, disponible en [BHF18], se toma como ejemplo para comparar. En él se muestran las emisividades en el continente africano a una longitud de onda de $2.9\ \mu\text{m}$, es decir, a número de onda $1098\ \text{cm}^{-1}$. Los mapas superiores de esta

misma figura muestran África al mismo número de onda obtenido utilizando los métodos KRR (a la izquierda) y LR (a la derecha) de este trabajo. Note que el mapa del KRR tiene más similitud con el de la figura 5.3b, sobretodo en los desiertos del Sahara y Namib. En el caso del LR, se puede notar que se obtienen valores de emisividad mucho más bajos con respecto a los otros mapas, tanto en el desierto del Sahara como el de Namib. A pesar de provenir de fuentes de datos diferentes, el mapa del KRR y el de la figura 5.3b son bastante similares, lo que sugiere buenos resultados para el método KRR.

5.3. Comparación de Métodos

En esta sección se comparan las emisividades predichas utilizando los métodos basados en LR y en KRR con valores conocidos de emisividades. Para ello se seleccionan emisividades para distintas regiones del planeta y se muestran en una gráfica junto con emisividades medidas. Estas gráficas se utilizarán para comparar los resultados de los métodos lineal (LR) y no lineal (KRR).

Por un lado se han generado dos gráficas para suelo desértico, en particular para el Desierto del Sahara y el centro de Australia, dos gráficas para suelo de tipo selvático, en el Amazonas y en Myanmar, y dos en hielo, en la cima del Himalaya y en la Antártida. Estas gráficas se utilizaron para comparar con las de otros artículos.

Para comparar los resultados obtenidos, en la figura 5.6 se han superpuesto las gráficas mencionadas anteriormente y de las figuras 5.4 y 5.5. El objetivo de superponer las figuras consiste en comparar la tendencia de ambas gráficas para las regiones especificadas.

Se observa que en todos los casos los resultados obtenidos en este trabajo siguen el mismo patrón que en la de otros trabajos. Las Figuras de la parte superior muestran los resultados obtenidos en este trabajo para zona helada, en ambas Figuras se puede notar como el método KRR parece seguir mejor la tendencia de las emisividades para este tipo de zona. La Figura superior izquierda, muestra las emisividades para varios tipos de suelos fríos (nieve, agua helada, etc) con ella se puede notar que el método KRR sigue una tendencia más parecida que el método LR para este tipo de suelo. La Figura superior a la derecha parece diferir en cuanto a los valores de emisividades a longitudes de onda por encima a $10\mu\text{m}$, sin embargo notamos que la tendencia de la gráfica se mantiene, por lo que podría tratarse de la diferencia entre los conjuntos de datos utilizados para cada una.

Luego, en la misma Figura se comparan regiones desérticas. La Figura inferior izquierda muestra que tanto en este trabajo como en [SWD] se obtienen prácticamente los mismos resultados para el KRR. Note que a partir de $10\mu\text{m}$ las emisividades predichas por el método LR se mantienen relativamente constantes mientras que el método KRR cumple con la misma tendencia. De forma análoga se puede notar en la Figura inferior derecha que para tipos de suelo desérticos disminuyen las emisividades entre $3\mu\text{m}$ y $10\mu\text{m}$ y luego muestran diferentes valores para las siguientes longitudes de onda. De nuevo los resultados del KRR parecen ser más precisos que los del LR.

Para la siguiente comparación se han obtenido gráficas con datos provenientes de la librería ECOSTRESS o ASTER [oT]. Esta librería contiene una compilación de más de 2800 espectros de

materiales. El ASTER es un instrumento a bordo del satélite Terra de la NASA, su nombre proviene de Advanced Spaceborne Thermal Emission Reflection Radiometer. La figura 5.7 compara las predicciones del método LR (línea azul), el método KRR (línea roja) y los datos del ASTER. Note que para todos los espectros la predicción del KRR sigue una tendencia muy similar a la de los datos de la librería ASTER, mientras que las predicciones del LR tienen ciertos picos en las longitudes de onda bajas (entre 3 y 5 μm) y en la zona media (de 8 a 10 μm).

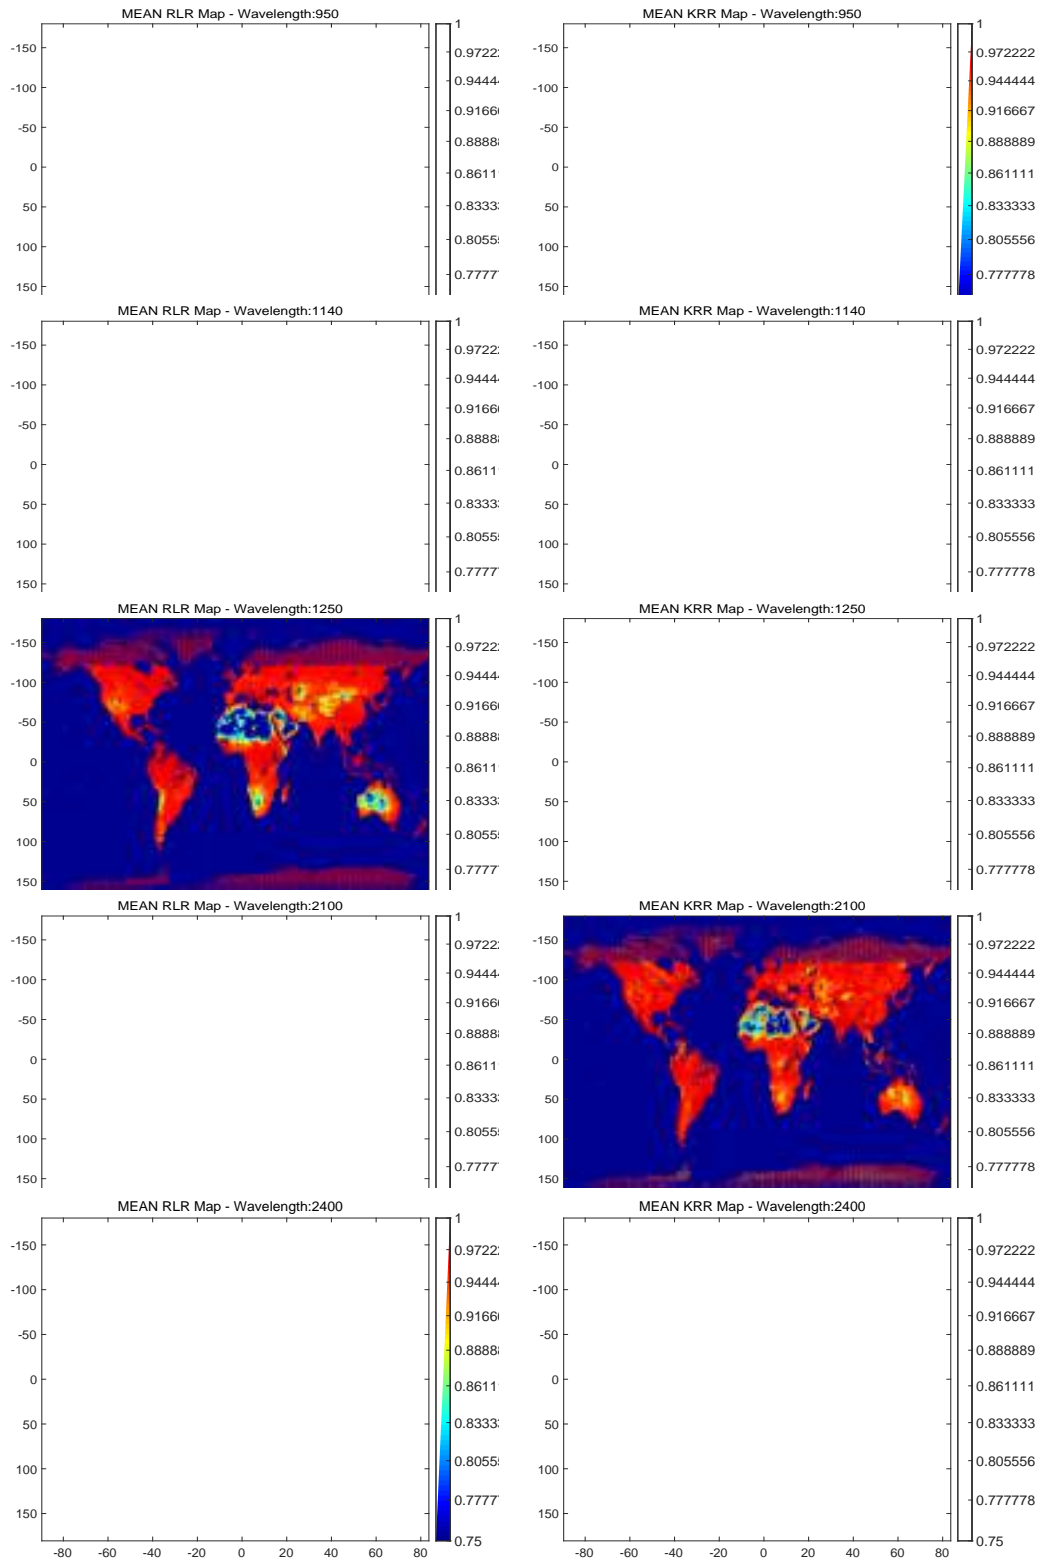


Figura 5.2: Mapas globales de predicciones de emisividades.