

## Modelo de estimación regional de la humedad del suelo para determinar las demandas de riego

Diego Alberto Flores Carrillo<sup>1</sup>, Luis Pastor Sánchez Fernández<sup>1</sup>,  
Luis Alejandro Sánchez Pérez<sup>2</sup>

<sup>1</sup> Instituto Politécnico Nacional,  
Centro de Investigación en Computación,  
México

<sup>2</sup> University of Michigan,  
Department of Electrical and Computer Engineering,  
USA

dafc89@gmail.com, lsanchez@cic.ipn.mx, alejand@umich.edu

**Resumen.** La estimación regional de la humedad del suelo evita la complejidad de implementación y mantenimiento de los sistemas de riego automático. La estimación regional puede derivarse de un modelo de estimación puntual, como el modelo de estimación difusa basado en la toma de decisiones (FEADM). Sin embargo, FEADM requiere las condiciones meteorológicas donde se realiza una estimación puntual. En este trabajo, se desarrolla y emplea un modelo de ajuste inteligente de las condiciones meteorológicas basado en las características espaciales de la región (IWeCASF, por sus siglas en inglés) para suministrar a FEADM los datos necesarios para realizar una estimación puntual. Además, se realiza la integración de IWeCASF-FEADM para obtener una estimación regional como un conjunto de estimaciones puntuales. Se utilizan, sistemas difusos, procesamiento de imágenes y algoritmos de toma de decisiones. Los resultados obtenidos son comparados con modelos de interpolación. El rendimiento de los modelos desarrollados es mejor o similar a la interpolación. Sin embargo, los modelos de este trabajo solo requieren un punto de medición para obtener la humedad del suelo a diferencia de los métodos de interpolación. El modelo integrado reduce el costo operativo de las mediciones y modela la relación de las características del suelo, las condiciones meteorológicas y la humedad.

**Palabras clave.** Estimación regional, humedad del suelo, modelos difusos, toma de decisiones difusas, estimación difusa.

## Soil Moisture Regional Estimation Approach to Determine Irrigation Demands

**Abstract.** The regional estimation of soil moisture avoids the complexity of implementation and maintenance of automatic irrigation systems. The regional estimate can be derived from a point estimation model, such as the Fuzzy Estimation Approach based on Decision Making (FEADM). However, FEADM requires weather conditions where a point estimate is made. In this work, an intelligent weather adjustment model based on the spatial characteristics of the region (IWeCASF) is developed and used to provide FEADM with the necessary data to make a point estimate. In addition, the integration of IWeCASF-FEADM is performed to obtain a regional estimation as a set of point estimates. Fuzzy systems, image processing and decision-making algorithms are utilized. The results obtained are compared with interpolation models. The performance of the models developed better or similar to interpolation. However, the models in this work only require a measurement point to obtain soil moisture, unlike interpolation methods. The integrated approach reduces the operating cost and models the interactions of land features, weather conditions and soil moisture.

**Keywords.** Regional estimation, soil moisture, fuzzy approach, fuzzy decision-making, fuzzy estimation.

## 1. Introducción

Los sistemas de riego automático miden la humedad del suelo con una red de sensores de medición desplegada en puntos estratégicos (conjunto de puntos de control). La región de riego a veces se divide en  $Z^{r=1,2,\dots,R}$  zonas ( $R$  es el total de zonas dentro de la región), de acuerdo a las características zonales como las características del cultivo o del suelo las cuales determinan los requerimientos de agua de riego zonal [1, 2]. Por lo tanto, un modelo para obtener la estimación regional de la humedad del suelo basado en estimaciones puntuales obtiene la humedad del suelo mediante la realización de una estimación puntual en cada punto de control de la región de riego.

De esta manera, los problemas de una red de sensores derivados de la medición de la humedad del suelo pueden descartarse. La estimación regional puede desarrollarse utilizando algunos métodos de la literatura tales como la Ponderación inversa a la distancia (IDW, por sus siglas en inglés) [3-6], así como también Kriging y Co-Kriging [7, 8] y adquisición remota [9-11].

Sin embargo, el uso de un modelo de interpolación, como los mencionados anteriormente, requiere implementar una red de sensores para monitorear las condiciones meteorológicas en una región. Lo cual sería más complejo que medir la humedad del suelo in situ. Para estimar la humedad utilizando variables como la lluvia, no basta con interpolar su valor basándose únicamente en mediciones espaciales o en registros estadísticos porque estas variables pueden no ser homogénea en una región y, por lo tanto, la estimación puede ser errónea.

El modelo difuso de estimación basado en toma de decisiones (FEADM, por sus siglas en inglés) [12] es un modelo de estimación difusa que deduce estimaciones de humedad del suelo a partir del modelado de las relaciones entre la humedad del suelo, las condiciones meteorológicas y las características del suelo y la tierra en el punto de control donde se realiza la estimación. Este modelo realiza un mínimo de mediciones y un número reducido de pruebas en desarrollo, a diferencia de algunos modelos como las redes neuronales [13, 14], las máquinas de

vectores (SVM) [15] y modelos hidrológicos [1, 10, 16].

Por otra parte, IWEASF, el modelo de ajuste inteligente de las condiciones meteorológicas basado en características espaciales (IWeASF, por sus siglas en inglés), determina las condiciones meteorológicas en cualquier lugar de una región, a partir de las mediciones en un punto de control (punto de control primario).

IWEASF utiliza procesamiento de imágenes y modelado difuso para describir la influencia que ejercen las características espaciales de una región sobre las condiciones meteorológicas.

Un modelo integrado FEADM-IWeASF se puede utilizar para obtener una estimación regional de la humedad del suelo mediante la realización de un conjunto de estimaciones puntuales en varios puntos de control dentro de una región. Como consecuencia, un modelo de estimación regional de la humedad del suelo compuesto de dos etapas (FEADM-IWeASF) puede reducir la complejidad de implementación y mantenimiento de los sistemas de riego automático convencionales y su costo inherente. Además, este tipo de estimación regional de la humedad del suelo relaciona las condiciones meteorológicas y las características de los cultivos y la tierra, como factores importantes para determinar la humedad del suelo.

## 2. Revisión y propuesta

En la Fig. 1 se presenta una región de riego ilustrativa. Se representan los elementos de un sistema de riego convencional ( $Z^{r=1,2,\dots,14}$  zonas donde  $R = 14$  y el conjunto de puntos de control  $P^r$ ). Además, se ilustra el funcionamiento de una posible estimación regional de la humedad del suelo basada en estimaciones puntuales de la humedad obtenidas con el modelo difuso de estimación basado en toma de decisiones (FEADM) y el modelo de ajuste inteligente de las condiciones meteorológicas basado en características espaciales (IWeASF).

Primero, las condiciones meteorológicas  $C_i^0$  se miden en el punto de control primario  $P^0$ , luego a través de una función de ajuste  $f^R(C_i^0)$ , las condiciones meteorológicas se determinan en cada punto de control  $P^{r=1,2,\dots,14}$  donde se realiza

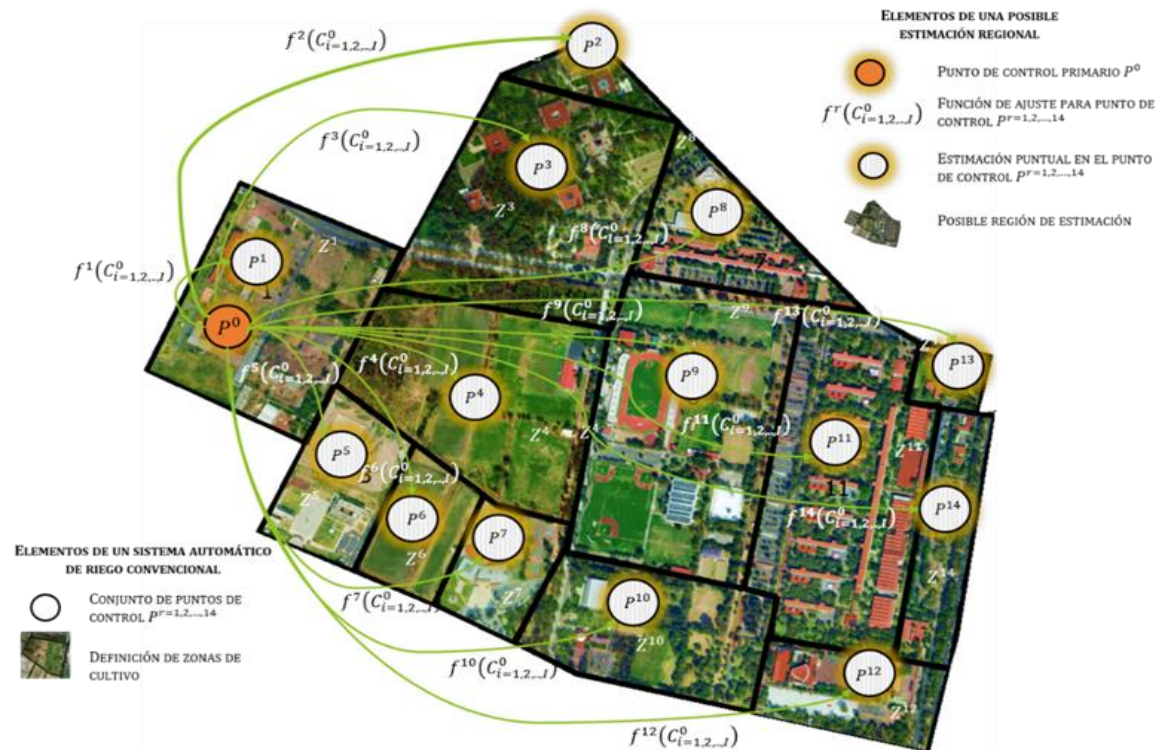


Fig. 1. Funcionamiento de una estimación regional basada en FEADM- IWeCASF

una estimación puntual de la humedad del suelo usando FEADM.

La función de ajuste de las condiciones meteorológicas  $f^r(C_{i=1,2...j}^0)$  utilizada es IWeCASF, el cual, utiliza las características espaciales de la región, la certeza de replicación de las condiciones meteorológicas y las condiciones meteorológicas en el punto de control primario. IWeCASF no requiere el despliegue de una red de sensores y considera las inconsistencias de las condiciones meteorológicas, como la lluvia.

### 3. Modelo de estimación de la humedad puntual

#### 3.1. FEADM

El Modelo Difuso de Estimación basado en Toma de Decisiones (FEADM, por sus siglas en inglés) para la estimación puntual de la humedad del suelo, es un modelo difuso complementado

con algoritmos de toma de decisiones, para elegir la alternativa (nivel de humedad del suelo) mejor evaluada bajo las actuales condiciones del entorno.

Sin embargo, el modelo propuesto no se limita a la toma de decisiones debido a que también permite la estimación cuantitativa de la humedad del suelo utilizando operaciones difusas.

Tampoco se limita a un sistema de estimación difusa convencional porque no es necesario realizar la evaluación de todas las combinaciones posibles de las variables de entrada debido a que se utiliza el conocimiento experto de los evaluadores para seleccionar y evaluar únicamente las variables de entrada relevantes para cada nivel de humedad del suelo definido Variables de entrada.

Para la estimación de la humedad del suelo  $Sm_e$  en un punto de interés con base en las condiciones del entorno, se utilizan como entrada las cinco variables en la Tabla 1, las cuales son factores relevantes en la conservación de la



Fig. 2. a) Suite de Sensores Integrados (ISS), b) Consola de datos de la ISS




Fig. 3. Funciones de pertenencia de los criterios  $C_{i=1,2,\dots,I}$

humedad del suelo [17, 18] y son medidas con sensores integrados, mostrados en la a o calculadas en la consola de datos de la Fig. 2b.

### 3.1.1. Toma de decisiones

En la etapa de toma de decisiones, el modelo FEADM parte de la solución de un problema, en el cual, se cuenta con  $I$  variables de entradas que al ser evaluadas por  $J$  funciones de pertenencia, pueden ser utilizadas como criterios de evaluación  $C_{i=1,2,\dots,I}$ . Los criterios de evaluación  $C_{i=1,2,\dots,I}$  donde  $I=5$ , corresponden a las cinco variables de entrada de la Tabla 2.

Por otra parte, se proponen  $K = 5$  alternativas de decisión  $A_{k=1,2,\dots,K}$ , las cuales representan los niveles de la humedad del suelo y son presentadas en la Tabla 3.

En este trabajo, se aplica el método presentado por [19] y las modificaciones realizadas por [20, 21] para obtener el vector de ponderación normalizado  $\vec{w}$ . El vector  $\vec{w}$  está conformado por los pesos  $w_i$  donde  $i = 1, 2, \dots, I$ . Cada  $w_i$

corresponde al peso asignado a cada criterio de evaluación  $C_{i=1,2,\dots,I}$ .

Para conocer el vector de ponderación  $\vec{w}$  es necesario primero calcular la matriz de juicios  $\tilde{P}$  definida en (1):

$$\tilde{P} = \begin{matrix} & C_1 & C_2 & \dots & C_I \\ \begin{matrix} C_1 \\ C_2 \\ \vdots \\ C_I \end{matrix} & \begin{bmatrix} \tilde{p}_{1,1} & \tilde{p}_{1,2} & \dots & \tilde{p}_{1,I} \\ \tilde{p}_{2,1} & \tilde{p}_{2,2} & \dots & \tilde{p}_{2,I} \\ \vdots & \vdots & \ddots & \vdots \\ \tilde{p}_{I,1} & \tilde{p}_{I,2} & \dots & \tilde{p}_{I,I} \end{bmatrix} \end{matrix} \quad (1)$$

La matriz de juicios  $\tilde{P}$  contiene los valores de importancia relativa  $\tilde{p}_{x,y}$ , obtenidos de la comparación ordenada en pares entre los criterios  $(C_x, C_y)$  donde  $x=1, 2, \dots, I$  y  $y=1, 2, \dots, I$ . Es decir, el valor de importancia relativa  $\tilde{p}_{x,y}$  indica la importancia que tiene el criterio  $C_x$  con respecto al criterio  $C_y$ . Por ejemplo, la importancia relativa entre la *Temperatura* ( $C_1$ ) y la *Lluvia* ( $C_2$ ) se establece como  $\tilde{p}_{1,2}$ .

**Tabla 1.** Entradas del modelo propuesto FEADM (i=5)

<i>i</i>	Variable	Método de adquisición
1	Temperatura ( <i>T</i> )	Medida
2	Lluvia ( <i>L</i> )	Medida
3	Radiación Solar ( <i>Rs</i> )	Medida
4	Velocidad del viento ( <i>Vv</i> )	Medida
5	Evapotranspiración ( <i>Et</i> )	Calculada

**Tabla 2.** Criterios de decisión (i=5)

Criterio	Variable
<i>C</i> <sub>1</sub>	Temperatura
<i>C</i> <sub>2</sub>	Lluvia
<i>C</i> <sub>3</sub>	Radiación solar
<i>C</i> <sub>4</sub>	Velocidad del viento
<i>C</i> <sub>5</sub>	Evapotranspiración

**Tabla 3.** Alternativas de decisión (k=5)

Alternativa	Nivel de humedad
<i>A</i> <sub>1</sub>	Muy Bajo
<i>A</i> <sub>2</sub>	Bajo
<i>A</i> <sub>3</sub>	Medio
<i>A</i> <sub>4</sub>	Alto
<i>A</i> <sub>5</sub>	Muy Alto

La importancia relativa entre criterios  $\tilde{p}_{x,y}$  es un valor lingüístico asociada a un número triangular difuso (TFN, por sus siglas en inglés). Tanto el valor lingüístico como el TFN son establecidos por expertos evaluadores. Un TFN se representa como  $\mu(z) = (f, g, h)$  una función de membresía triangular [22], los valores  $f, g, h$  indican los valores que delimitan la función de membresía. Los valores lingüísticos y los TFN's utilizados en este trabajo para  $\tilde{p}_{x,y}$  se presentan en la Tabla 4.

Por otra parte, la matriz de juicios  $\tilde{P}$  permite calcular el valor sintético extendido  $\tilde{S}_{i=1,2,\dots,I}$  para cada criterio de evaluación utilizado en la *Evaluación Experta*. El cálculo de  $\tilde{S}_{i=1,2,\dots,I}$  se describe en (2). Y se realiza de la forma descrita en [19, 23]:

$$\tilde{S}_{i=1,2,\dots,I} = \sum_{n=1}^I \tilde{p}_{i,n} \odot \left[ \sum_{i=1}^I \sum_{n=1}^I \tilde{p}_{i,n} \right]^{-1}, \quad (2)$$

$i = 1, 2, \dots, I.$

De acuerdo a [20], el grado de posibilidad del análisis extendido de [19] solo muestra el grado en el cual un TFN es mayor a otro y no un indicador

de la importancia relativa entre ellos. Con [21], este problema es resuelto usando el método del valor total de la integral con índice de optimismo  $I_T^\alpha(\tilde{S}_{i=1,2,\dots,I})$  propuesto en [24]. A partir de este método se obtienen las prioridades del valor extendido sintético usando (3):

$$I_T^\alpha(\tilde{S}_{i=1,2,\dots,I}) = \frac{1}{2} \alpha (g_i + h_i) + \frac{1}{2} (1-\alpha)(f_i + g_i) \quad (3)$$

$$= \frac{1}{2} (\alpha h_i + g_i + (1-\alpha)f_i),$$

donde  $\alpha$  es el índice de optimismo otorgado por expertos evaluadores, acotado en el intervalo [0,1] y  $f_i, g_i, h_i$  definen el TFN obtenido para  $\tilde{S}_i$ . Cada elemento  $w_i \in W$  correspondiente al peso asignado a cada criterio, se calcula de acuerdo con (4). De este modo queda conformado el conjunto de ponderación  $W = \{w_1, \dots, w_i, \dots, w_I\}$  que se utiliza para ponderar los criterios:

$$w_i = \frac{I_T^\alpha(\tilde{S}_i)}{\sum_{n=1}^I I_T^\alpha(\tilde{S}_n)} \quad i = 1, 2, \dots, I. \quad (4)$$

Se propone para cada criterio  $C_i$ ,  $J$  valores lingüísticos asociados a las funciones de membresía  $\mu_{C_{i,j}}(z) \mid j = 1, 2, \dots, J$  donde  $J = 5$ . La función  $\mu_{C_{i,1}} \mid i = 1, 2, \dots, I$  con forma L mientras que  $\mu_{C_{i,5}} \mid i = 1, 2, \dots, I$  con forma gamma [22]. El resto de las funciones de membresía son funciones triangulares. En la Fig. 3, se ilustran las funciones de membresía  $\mu_{C_{i,j}}(z) \mid j = 1, 2, \dots, J$ .

Se plantean los criterios difusos  $\tilde{C}_{i=1,2,\dots,I}$ , donde  $\tilde{C}_i$  es el conjunto de los valores de membresía  $\mu_{C_{i,j}}(z) \mid j = 1, 2, \dots, J$  dado un valor medido o calculado  $z$  para el criterio  $C_i$  como se muestra en (5)-(9). Donde  $z \in Z_i$  y  $Z_i$  es el universo de discurso del criterio  $C_i$  descrito en [23]:

$$\tilde{C}_1 = \{\mu_{C_{1,1}}(z), \dots, \mu_{C_{1,5}}(z)\}, \tag{5}$$

$$\tilde{C}_2 = \{\mu_{C_{2,1}}(z), \dots, \mu_{C_{2,5}}(z)\}, \tag{6}$$

$$\tilde{C}_3 = \{\mu_{C_{3,1}}(z), \dots, \mu_{C_{3,5}}(z)\}, \tag{7}$$

$$\tilde{C}_4 = \{\mu_{C_{4,1}}(z), \dots, \mu_{C_{4,5}}(z)\}, \tag{8}$$

$$\tilde{C}_5 = \{\mu_{C_{5,1}}(z), \dots, \mu_{C_{5,5}}(z)\}. \tag{9}$$

Rescribiendo (5)-(9) de la manera  $\mu_{C_{i,j}} = c_{i,j}$  para todo  $\tilde{C}_{i=1,2,\dots,I}$  y agrupando los  $\tilde{C}_{i=1,2,\dots,I}$  en una matriz se obtiene la matriz de criterios difusos  $\tilde{C}$  definida en (10):

$$\tilde{C} = \begin{bmatrix} c_{1,1} & \dots & c_{1,J} \\ \vdots & \ddots & \vdots \\ c_{I,1} & \dots & c_{I,J} \end{bmatrix}. \tag{10}$$

Se utiliza el vector  $W = \{w_1, \dots, w_i, \dots, w_J\}$  descrito en (4). Para ponderar los elementos  $c_{i,j}$  de  $\tilde{C}$  utilizando (11):

$$c_{i,j}^w = c_{i,j} * w_i, \tag{11}$$

donde  $c_{i,j}$  es el valor de  $\mu_{C_{i,j}}(z) \mid j = 1, 2, \dots, J$ , correspondiente al criterio  $C_{i=1,2,\dots,I}$  mientras que  $w_i$  es el valor de ponderación calculado para el criterio  $C_i$ .

El valor ponderado  $c_{i,j}^w$  de cada elemento de la matriz  $\tilde{C}$  conforma la matriz  $\tilde{C}^w$  mostrada en (12):

$$\tilde{C}^w = \begin{bmatrix} c_{1,1}^w & \dots & c_{1,J}^w \\ \vdots & \ddots & \vdots \\ c_{I,1}^w & \dots & c_{I,J}^w \end{bmatrix}. \tag{12}$$

La ponderación de los criterios de evaluación obtenida en  $\tilde{C}^w$  asigna mayor relevancia a criterios decisivos en el proceso evaluativo, mientras que resta relevancia a los criterios que no desempeñan un papel importante en este proceso. Por ejemplo, la *Lluvia* ( $C_2$ ) es más importante para la humedad del suelo que la *Velocidad del viento* ( $C_4$ ), por lo tanto  $w_2 > w_4$ .

Después se determina la alternativa de decisión  $A_{k=1,2,\dots,K}$  que corresponde mejor a las condiciones actuales determinadas por los valores actuales de los criterios de evaluación. La evaluación empleada solamente considera aquellos criterios  $c_{i,j}^w$  relevantes para cada alternativa evaluada  $A_{k=1,2,\dots,K}$ .

Es necesario definir el conjunto de evaluaciones  $E^k = \{e_1^k, e_2^k, \dots, e_{N_k}^k\}$ , el cual contiene los resultados de las  $N_{k=1,2,\dots,K}$  evaluaciones ( $e_{n=1,2,\dots,N_k}^k$ ) correspondientes a cada alternativa  $A_{k=1,2,\dots,K}$ .

El número  $N_{k=1,2,\dots,K}$  de evaluaciones está determinado por los expertos y depende de los criterios de evaluación difusos ponderados,  $c_{i,j}^w$ , utilizados para  $A_{k=1,2,\dots,K}$ . Las  $e_n^k$  se obtienen con (13):

$$e_{n=1,2,\dots,N}^k = f^k(n, \tilde{C}^w), \tag{13}$$

donde  $f^k(n, \tilde{C}^w) \mid n = 1, 2, \dots, N_k$  está definida en (14) como la función de evaluación selectiva de la matriz de criterios difusos ponderados  $\tilde{C}^w$ . Esta función evalúa los valores  $c_{i,j}^w$  seleccionados para cada una de las  $e_{n=1,2,\dots,N_k}^k$  evaluaciones de la alternativa  $A_{k=1,2,\dots,K}$ :

$$f^k(n, \tilde{C}^w) = \min \left( D_n^k = \left\{ d_{i,j}^k \mid \begin{matrix} i = 1, 2, \dots, I \\ j = 1, 2, \dots, J \end{matrix} \right\} \right), \tag{14}$$

donde  $D_n^k$  es la matriz de modelado relacional,  $d_{i,j}^k = 1$  si el criterio  $c_{i,j}^w$  no se usa en la evaluación  $n$  de la alternativa  $k$  y  $d_{i,j}^k = c_{i,j}^w$  en otro caso.

La matriz  $D_n^k$  contiene las relaciones entre los criterios difusos ponderados, cambian de acuerdo con las características espaciales del punto de control donde se realiza la estimación y están relacionadas con la distribución espacial de la humedad del suelo, la cual es una consecuencia de las características del punto de control como la topografía, las propiedades del suelo, los patrones climáticos, la vegetación y las barreras naturales [25].

Entre más grande sea el área del punto de control más grande será la variación espacial de la humedad del suelo.

Las matrices de modelado relacional  $D_n^k$  son diferentes para la misma evaluación  $n$  de la alternativa  $A_k$ . La matriz  $D_1^5$  correspondiente a la evaluación  $n = 1$  de la alternativa  $A_5$  (*Muy Alto*) en el mismo punto de control  $P^r=x$  se muestra en (15). Del mismo modo la matriz  $D_1^5$  correspondiente a la misma evaluación  $n = 1$  de la misma alternativa  $A_5$  (*Muy Alta*) en el punto de control  $P^r=y$  se presenta en (16).

Los criterios difusos ponderados  $c_{i,j}^w$  relevantes para la matriz  $D_1^5$  de (15) no son los mismos que son relevantes para la matriz  $D_1^5$  de (16). Aunque ambas matrices representan la evaluación  $n = 1$  de la alternativa  $A_5$  (*Muy Alto*) las características espaciales de cada punto son diferentes i.e., las características espaciales determinan la matriz  $D$ :

$$D_1^5 = \begin{bmatrix} 1 & 1 & c_{1,Mild}^w & 1 & 1 \\ 1 & 1 & 1 & 1 & c_{2,Higher}^w \\ 1 & c_{3,Dim}^w & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ c_{5,Lower}^w & c_{5,Low}^w & 1 & 1 & 1 \end{bmatrix}, \quad (15)$$

$$D_1^5 = \begin{bmatrix} 1 & 1 & c_{1,Mild}^w & c_{1,Warm}^w & 1 \\ 1 & 1 & 1 & c_{2,High}^w & c_{2,Higher}^w \\ 1 & c_{3,Dim}^w & c_{3,Clear}^w & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & c_{5,Low}^w & c_{5,Medium}^w & 1 & 1 \end{bmatrix}. \quad (16)$$

Para obtener la alternativa mejor evaluada  $\hat{A}$  se debe conocer la mejor evaluación  $a_k$  para cada alternativa  $A_{k=1,2,\dots,K}$  este proceso se lleva a cabo utilizando la ecuación (17)(17), donde  $\hat{f}^k$  es la

función de evaluación del conjunto de evaluaciones  $E^k$ :

$$a_k = \hat{f}^k(E^k) = \max(E^k). \quad (17)$$

Cada valor  $a_k$  correspondiente a la mejor evaluación de la alternativa  $A_{k=1,2,\dots,K}$  es un elemento de la matriz  $[a_1 \dots a_K]^T$  la cual contiene la mejor evaluación de cada alternativa de decisión. Como se muestra en (18), se elige el valor máximo de la matriz  $[a_1 \dots a_K]^T$  como alternativa mejor evaluada  $\hat{A}$ :

$$\hat{A} = \max \left( \begin{bmatrix} a_1 \\ \vdots \\ a_K \end{bmatrix} \right). \quad (18)$$

### 3.1.2. Estimación difusa

A partir de los valores  $a_k$  se obtiene el valor estimado de la humedad del suelo  $Sm_e$ . A cada alternativa de decisión  $A_{k=1,2,\dots,K}$  se le asigna un conjunto difuso de salida representado por la función de membresía  $\mu_{A_{k=1,2,\dots,K}}(z)$  de forma triangular.

En este trabajo se acota  $\mu_{A_{k=1,2,\dots,K}}(z)$  como se muestra en (19), obteniéndose la función de membresía  $\mu_{A_{k=1,2,\dots,K}}^*(z)$ . La altura o máximo valor de dicha función corresponde a la mejor evaluación  $a_k$ , obtenida en la etapa de toma de decisiones:

$$\mu_{A_k}^*(z) = \begin{cases} \mu_{A_k}(z); & \mu_{A_k}(z) < a_k \\ a_k; & \mu_{A_k}(z) \geq a_k \end{cases}. \quad (19)$$

En la Fig. 4 se muestran las funciones de membresía  $\mu_{A_{k=1,2,\dots,K}}(z)$  asociadas a cada alternativa de decisión  $A_{k=1,2,\dots,K}$ . Asimismo, se proponen valores de  $a_k$  para ilustrar las funciones  $\mu_{A_{k=1,2,\dots,K}}^*(z)$ .

Se realiza la t-conorma de las mismas utilizando la operación  $\max$ , como se muestra en (20), para realizar la agregación de las funciones de membresía  $\mu_{A_{k=1,2,\dots,K}}^*(z)$ , obteniéndose como resultado  $\mu_{Sm_e}(z)$ :

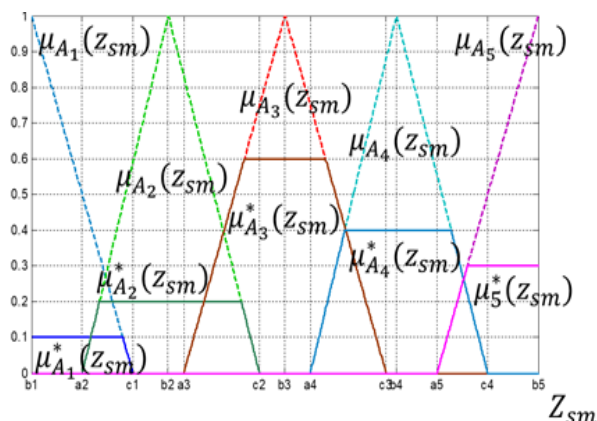


Fig. 4. Funciones de membresía de la humedad del suelo

Tabla 4. Valores difusos de la importancia relativa

Etiqueta lingüística	TFN (f,g,h)
Extremadamente insignificante	(1/9, 1/8, 1/7)
Muy insignificante	(1/8, 1/6, 1/4)
Insignificante	(1/6, 1/4, 1/2)
Apenas insignificante	(1/3, 1/2, 1)
Igualmente importante	(1,1,1)
Apenas importante	(1,2,3)
Importante	(2,4,6)
Muy importante	(4,6,8)
Extremadamente importante	(7,8,9)

Tabla 5. Valores de las entradas de FEADM

C <sub>i</sub>	Variable	Valor
C <sub>1</sub>	Temperatura (°C)	15.8
C <sub>2</sub>	Lluvia (mm)	20.4
C <sub>3</sub>	Radiación solar (W/m <sup>2</sup> )	200
C <sub>4</sub>	Velocidad del viento (km/hr)	14
C <sub>5</sub>	Evapotranspiración (mm)	2.3

$$\mu_{Sm_e}(z) = \max(\mu_{A_1}^*(z), \mu_{A_2}^*(z), \dots, \mu_{A_5}^*(z)). \quad (20)$$

resultado es la estimación puntual de la humedad del suelo  $Sm_e$  a partir de alternativas de decisión:

Finalmente, para defuzificar  $\mu_{Sm_e}(z)$ , se utiliza el método del centroide mostrado en (21). El

$$Sm_e = \frac{\sum_{l=0}^L \mu_{Sm_e}(z_l) |z_l|}{\sum_{l=0}^L \mu_{Sm_e}(z_l)}. \quad (21)$$






Fig. 5. Agregación difusa de las funciones de membresía  $\mu_{A_{k=1,2,\dots,K}}^*(z)$

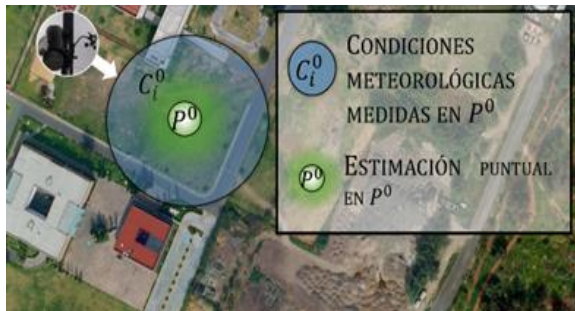


Fig. 6. Localización del Punto de Control  $P^0$



Fig. 7. Comparación de los resultados entre la humedad del suelo estimada ( $Sm_e$ ) y la humedad del suelo medida ( $Sm_m$ )

### 3.2. Experimentos

Las entradas de FEADM son *Temperatura*, *Lluvia*, *Radiación Solar*, *Velocidad del viento* y *Evapotranspiración* como se describe en la Tabla 1. Estas entradas son usadas como criterios de evaluación  $C_{i=1,2,\dots,I}$  como se muestra en la Tabla 2.

FEADM comienza con la evaluación comparativa en pares ordenados  $(C_x, C_y)$ , de la importancia relativa  $\tilde{p}_{x,y}$  (valores TFM) entre los criterios de decisión, con los cuales se establece la matriz de juicios  $\tilde{P}$  definida en (1). La matriz  $\tilde{P}$  utilizada en este trabajo se define en (22):

$$\tilde{P} = \begin{matrix} & C_1 & C_2 & C_3 & C_4 & C_5 \\ \begin{matrix} C_1 \\ C_2 \\ C_3 \\ C_4 \\ C_5 \end{matrix} & \begin{bmatrix} (1,1,1) & (1,1,1) & (1,2,3) & (1,2,3) & (1,2,3) \\ (1,1,1) & (1,1,1) & (2,4,6) & (4,6,8) & (4,6,8) \\ (1/3, 1/2, 1) & (1/3, 1/2, 1) & (1,1,1) & (4,6,8) & (1,2,3) \\ (1/3, 1/2, 1) & (1/8, 1/6, 1/4) & (1/8, 1/6, 1/4) & (1,1,1) & (1,1,1) \\ (1/3, 1/2, 1) & (1/8, 1/6, 1/4) & (1/3, 1/2, 1) & (1,1,1) & (1,1,1) \end{bmatrix} \end{matrix} \quad (22)$$

Los valores  $\tilde{p}_{x,y}$  mostrados en (22) se establecen con base en los valores propuestos en la Tabla 4.

Por ejemplo, la *Temperatura* ( $C_1$ ) es un *poco más importante* que la *Velocidad del viento* ( $C_4$ ), por lo tanto  $\tilde{p}_{1,4} = (1,2,3)$ .

El valor sintético extendido  $\tilde{S}_{i=1,2,\dots,I}$  se calcula con (2) utilizando (1). Después se obtiene el valor total de la integral con índice de optimismo  $I_T^\alpha(\tilde{S}_{i=1,2,\dots,I})$  utilizando (3).

El índice de optimismo  $\alpha$  utilizado en este trabajo es  $\alpha = 0.5$ , obtenido a partir del análisis experimental.

De acuerdo con el vector de ponderación  $\vec{w}$  (23) calculado con (4), el criterio  $C_{i=1,2,\dots,I}$  más importante es la *Lluvia* ( $C_2$ ):

$$w = (0.1834, 0.3805, 0.2555, 0.0791, 0.1015)^T. \quad (23)$$

En este trabajo, a cada criterio  $C_{i=1,2,\dots,I}$ , se le asignan  $J = 5$  valores lingüísticos asociados a funciones de membresía  $\mu_{C_{i,j}}(z) \mid j = 1, 2, \dots, J$ . Las funciones de membresía  $\mu_{C_{i,j}}(z)$  para cada  $C_{i=1,2,\dots,I}$  están definidas con base en los mejores resultados obtenidos durante el análisis experimental.

Los valores de los criterios  $C_{i=1,2,\dots,I}$  mostrados en la Tabla 5 son evaluados usando las funciones  $\mu_{C_{i,j}}(z)$ . Los valores de *Temperatura* ( $C_1$ ), *Radiación solar* ( $C_3$ ) y *Velocidad del viento* ( $C_4$ ) corresponden al promedio de los registros durante un día en un punto de medición, mientras que los valores de *Lluvia* ( $C_2$ ) y *Evapotranspiración* ( $C_5$ ) corresponden a la suma de los registros del mismo día en dicho punto. Con las funciones evaluadas se obtiene la matriz de criterios difusos  $\tilde{C}$  mostrada en (24) y definida en (10). Utilizando (11) y el

vector de ponderación  $\vec{w}$  (23) se obtiene la matriz de criterios difusos  $\tilde{C}^w$  mostrada en (25):

$$\tilde{C} = \begin{bmatrix} 0 & 0.0333 & 0.36 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 \\ 0 & 0.6667 & 0 & 0 & 0 \\ 0 & 0 & 0.8 & 0 & 0 \\ 0 & 0.3 & 0 & 0 & 0 \end{bmatrix}, \quad (24)$$

$$\tilde{C}^w = \begin{bmatrix} 0 & 0.0061 & 0.066 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0.385 \\ 0 & 0.1703 & 0 & 0 & 0 \\ 0 & 0 & 0.0633 & 0 & 0 \\ 0 & 0.0305 & 0 & 0 & 0 \end{bmatrix}. \quad (25)$$

De acuerdo a (13), para cada evaluación  $e_{n=1,2,\dots,N_k}^k$  se utilizan los criterios  $c_{i,j}^w$  de la establecidos en la matriz  $D_{n=1,2,\dots,N_k}^k$  definida en (14). Al evaluar cada  $n = 1, 2, \dots, N_k$  se obtiene el conjunto de evaluaciones  $E^k = \{e_1^k, e_2^k, \dots, e_{N_k}^k\}$ .

Por ejemplo, para la alternativa  $A_{k=1}$  (Muy Baja), el conjunto de evaluaciones es  $E^1 = \{e_n^1 = 0 | n = 1, 2, \dots, 37\}$ , mientras que para la alternativa  $A_{k=5}$  (Muy Alta), el conjunto de evaluaciones es  $E^5 = \{0.385, e_n^5 = 0 | n = 2, 3, \dots, 25\}$ . Con (17), se obtiene la mejor evaluación  $a_k$  del conjunto  $E^k = \{e_1^k, e_2^k, \dots, e_{N_k}^k\}$ . En la Tabla 6, se muestran las mejores evaluaciones de todas las alternativas de decisión.

Utilizando (18), se elige la alternativa mejor evaluada, la cual, en este experimento es  $\hat{A} = \max([0,0,0,0,0.385]^T) = 0.385$ , siendo la alternativa  $A_5$  el nivel de humedad del suelo mejor correspondido a las condiciones actuales del entorno.

Para la inferencia difusa se considera el universo de discurso de la humedad del suelo como  $Z_{Sm} = [0,10]$ .  $Z_{Sm}$  definida por el rango de medición del sensor de humedad de suelo utilizado, donde 0 representa el mínimo y 10 el máximo nivel de humedad del suelo.

Utilizando (19) y (20) se realiza la agregación de las funciones de membresía  $\mu_{A_{k=1,2,\dots,K}}^*(z)$ , obteniéndose como resultado  $\mu_{Sm_e}(z)$ , mostrada en la Fig. 5.

Empleando el método del centroide definido en (21) se obtiene la humedad del suelo estimada  $Sm_e$  = para este experimento  $Sm_e = 9.179$ . Este valor fue verificado comparándolo con el valor de la humedad del suelo medido  $Sm_e = 9.5$ .

### 3.3. Discusión de resultados

La región de estimación de la humedad del suelo es un área que se extiende por 1,8 km. En la Fig. 6, se muestra una zona de la región de estimación. Todas las pruebas realizadas se desarrollaron en esta área. Las condiciones ambientales  $C_{i=1,2,\dots,I}^0$  se midieron con una ISS como la que se muestra en la Fig. 2. Todas las mediciones de humedad del suelo  $Sm_m$  y las estimaciones de humedad del suelo presentadas  $Sm_e$  en esta sección corresponden al punto de control  $P^0$ .

Con el fin de validar los resultados obtenidos con el modelo *FEADM*, se utilizó el 70% del conjunto de datos para optimizar el modelo. El otro 30% se utilizó para validar los resultados. El conjunto de datos incluye una amplia gama de condiciones ambientales. Se espera que, *FEADM* pueda ser probada en un amplio rango condiciones meteorológicas.

Una comparación global de los resultados de *FEADM* se muestra en la Tabla 7. Los resultados del modelo de toma de decisiones utilizando *FEADM* y *TOPSIS*, un modelo de toma de decisiones [26-31] utilizado en este trabajo para validar resultados. Además, los resultados de la estimación de la humedad del suelo  $Sm_e$  se comparan con la humedad del suelo medida  $Sm_m$ . Los mejores resultados fueron obtenidos cuando se registran niveles de humedad del suelo *Muy Bajo* ( $A_1$ ), *Medio* ( $A_3$ ), o *Muy Alto* ( $A_5$ ). Sin embargo, existen pequeñas variaciones en las pruebas en las que se obtienen niveles de humedad *Bajo* ( $A_2$ ) y *Alto* ( $A_4$ ). Estas variaciones no afectan a la estimación.

Las pruebas F, G y H se realizaron en días con precipitaciones muy altas, mientras que en las pruebas B, C, D, I y L no se registran precipitaciones. En las pruebas sin lluvia, los niveles de radiación solar y evapotranspiración son altos.

En las pruebas con baja precipitación, como J y K, a pesar de haber registrado los mismos niveles de lluvia, la radiación solar y la evapotranspiración son muy diferentes en ambos días. Estos fenómenos pueden ser modelados utilizando las matrices  $D_{n=1,2,\dots,N_k}^k$  en *FEADM*. Estas matrices también pueden cambiar de

Modelo de estimación regional de la humedad del suelo para determinar las demandas de riego 369

**Tabla 6.** Mejor evaluación a (k) de las alternativas  $a_{k=1,2,\dots,k}$

Nivel de humedad del suelo	Alternativa $A_{k=1,2,\dots,K}$	Mejor evaluación $a_{k=1,2,\dots,K}$
Muy Bajo	$A_1$	0
Bajo	$A_2$	0
Medio	$A_3$	0
Alto	$A_4$	0
Muy Alto	$A_5$	0.385

**Tabla 7.** Comparación de resultados de la estimación de la humedad del suelo y la alternativa mejor evaluada

Prueba	Humedad del suelo		Alternativa mejor evaluada	
	(Estimada) $Sm_e$	(Medida) $Sm_m$	(FEADM)	(TOPSIS)
A	5	5	Medio	Medio
B	2.7488	2.5	Bajo	Bajo
C	0.9856	1	Muy Bajo	Muy Bajo
D	0.9802	1.5	Muy Bajo	Muy Bajo
E	0.9831	1	Muy Bajo	Muy Bajo
F	8.9642	9	Muy Alto	Muy Alto
G	8.2963	8.5	Alto	Alto
H	8.9678	9	Muy Alto	Muy Alto
I	2.7483	3	Bajo	Bajo
J	2.7481	2.5	Bajo	Bajo
K	5	5	Medio	Medio
L	2.7488	3	Bajo	Bajo
M	5	5	Medio	Medio
N	5.1186	5	Medio	Medio
O	0.99	1	Muy Bajo	Muy Bajo
P	2.7487	3	Bajo	Bajo

acuerdo con características del suelo y / o el tipo de cultivo. *FEADM*, basándose en las matrices  $D_{n=1,2,\dots,N_k}^k$ , disminuye el número de evaluaciones habitualmente requeridas con un sistema de inferencia difusa convencional.

El rendimiento de *FEADM* en las pruebas *A-P* es evaluado con los errores  $E_{RMS} = 0.2003$  el error  $E_{MA} = 0.0401$ , así como con la desviación estándar de la diferencia entre las medias  $\sigma_d = 0.9814$ .

Un error inferior a 0,5, que fue la resolución del medidor de humedad del suelo, representa una estimación bastante precisa para determinar los requisitos de riego.

Además, la Fig. 7 representa una comparación de las estimaciones de humedad del suelo  $Sm_e$  utilizando *FEADM* y las mediciones de humedad del suelo  $Sm_m$ .

Existen algunas variaciones de la estimación en pruebas con niveles de humedad del suelo *Bajo* ( $A_2$ ) y *Alto* ( $A_4$ ), que podrían ser producidos por algunas acciones de riego no registradas o la resolución del medidor de humedad del suelo.

Las mejores estimaciones derivadas de *FEADM* se obtuvieron cuando existe un nivel de humedad del suelo *Muy Bajo* ( $A_1$ ), *Medio* ( $A_3$ ) o *Muy Alto* ( $A_5$ ).

## 4. Ajuste inteligente de las condiciones meteorológicas

### 4.1. IWeCASF

El modelo de Ajuste inteligente de las condiciones meteorológicas basado en características espaciales IWeCASF, realiza tres tareas principales: extracción de las características del paisaje, selección de las características del paisaje particulares de cada punto de control y el ajuste de las condiciones meteorológicas en cada punto de control de la región.

#### 4.1.1. Entradas

Una de las entradas son las imágenes, se adquieren utilizando la capa de satélite de Google y la capa de paisaje OpenCycleMap. Ambas se procesan utilizando el Sistema de Información Geográfica de Quantum. La escala de estas capas es 1: 10000.

Cada imagen satelital se divide en  $S$  sectores, dando como resultado sectores pares  $s(x, y)$  donde  $x = 1, 2, \dots, X$ ,  $y = 1, 2, \dots, Y$ ,  $X$  es el ancho de la imagen dividido en  $S$  sectores e  $Y$  es la altura de la imagen dividida en  $S$  sectores. Un sector  $s(x, y)$  es un área pequeña de la región, el tamaño de esta área está determinado por el tamaño máximo con el que en todas las áreas definidas como sectores  $s(x, y)$ , una característica del paisaje predomina sobre el resto.

Las zonas de suelo y cultivo son datos geográficos que necesitan ser introducidos a IWeCASF. El cual los procesa y categoriza el tipo de suelo, el tipo de cultivo y la etapa del cultivo de acuerdo con [32, 33]. Estas bases de datos geográficas se utilizan para desarrollar las matrices características  $M^{t=1,2,\dots,T}$ , donde  $T$  es el total de características (tipo de suelo, tipo de cultivo y etapa de cultivo).

En este trabajo las matrices de características  $M^{t=1,2,\dots,T}$ , donde  $T = 3$ , son las siguientes:

- $M^{t=1}$  contiene datos del tipo de suelo.
- $M^{t=2}$  contiene datos de tipo de cultivo.
- $M^{t=3}$  contiene datos de la etapa de cultivo.

Debido a las imágenes satelitales, las matrices de características  $M^{t=1,2,\dots,T}$  son matrices  $X \times Y$ .

Para cada matriz  $M^{t=1,2,\dots,T}$  cada elemento  $m_{x,y}^t$ , donde  $x = 1, 2, \dots, X$  e  $y = 1, 2, \dots, Y$ , representan la característica  $t$  en el sector  $s(x, y)$  de la región de estimación; p.ej., el elemento  $m_{10,10}^{t=1} = 100, I$ ,  $I$  denota que en el sector  $s(x = 10, y = 10)$  hay 100 píxeles de suelo tipo  $I$  como se define en [32, 33].

La ubicación  $s(x_r, y_r)$  de cada punto de control  $p^{r=1,2,\dots,R}$  se usa para identificar las características particulares de la subzona correspondiente al sector  $s(x_r, y_r)$  donde se encuentra el punto de control. La distribución del conjunto de puntos de control se realiza considerando dos condiciones: cada característica del paisaje debe predominar en al menos un punto de control  $P^r$  y los puntos de control  $P^{r=1,\dots,R}$  deben permitir la prueba IWeCASF a diferentes distancias punto de control primario  $P^0$ .

Las condiciones meteorológicas medidas  $C_{i=1,2,\dots,I}^0$  corresponden a  $I = 5$  variables ambientales del punto de control primario  $P^0$ . Estas condiciones meteorológicas  $C_{i=1,2,\dots,I}^0$  son necesarias para estimar la humedad del suelo [17, 18, 34] y son las mismas descritas en la Tabla 1.

#### 4.1.2. Definición de subzonas

De acuerdo con la literatura, la región de estimación se divide en zonas de riego [1, 2]. En la definición de subzonas, se realiza una división de la región de riego de acuerdo con las características del paisaje (pastizales, áreas de árboles, áreas de edificios, elevación y configuración espacial). Las imágenes satelitales de la región se procesan con la finalidad de realizar una mejor segmentación de colores para extraer características del paisaje mediante una combinación de algoritmos, filtros y técnicas [35, 7].

Primero se emplea una conversión del espacio de color Rojo Verde Azul (RGB, por sus siglas en inglés), al espacio de color de la Comisión Internacional de Iluminación (CIE  $L^* a^* b$ , por sus siglas en inglés) [13, 38], posteriormente se utiliza un proceso de decorrelación [39, 40].

Algunas las características del paisaje ampliamente identificadas son el contenido de agua del suelo [13, 39, 41], la vegetación de un área [38, 40, 42], edificios y carreteras [43, 44]. Luego, se realiza la segmentación de la imagen en




Fig. 8. Vecindario de ocho elementos del sector  $s(x,y)$

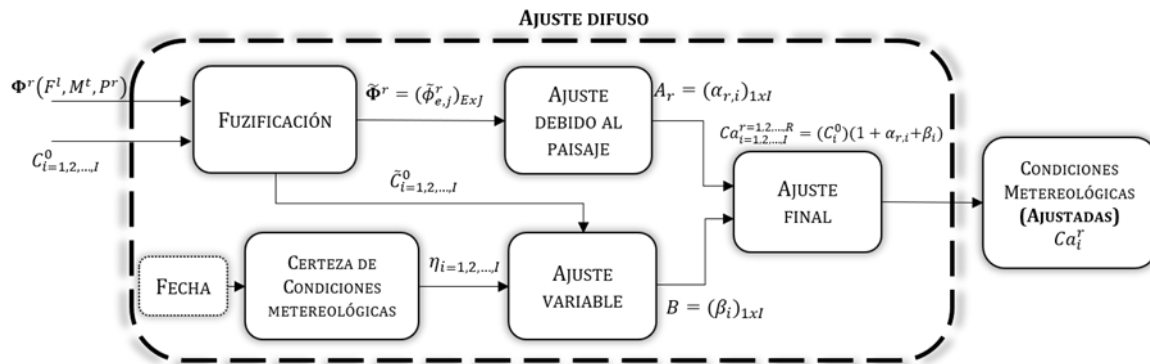


Fig. 9. Ajuste difuso

bandas de color. Este proceso se basa en obtener el componente principal de una imagen cuando las bandas de color están correlacionadas [45].

Por lo tanto, a través de una decorrelación, los colores son exagerados lo que permite una segmentación del color más fácil [46].

Las bandas de color  $L$  son identificadas. Los objetos presentes en cada una de las bandas de color  $l = 1, 2, \dots, L$  son reconocidos como objetos que pertenecen a una matriz de características de paisaje  $F^{l=1,2,\dots,L}$ . Como se mencionó anteriormente,  $L = 5$  bandas de color, es decir,  $L = 5$  características del paisaje (pastizales, áreas de árboles, áreas de edificios, elevación y configuración espacial) son identificadas.

El objetivo es obtener la región como un cúmulo espacial de píxeles con las mismas características. Cada píxel es miembro de una región. El método de fusión, que se utiliza en este trabajo, supone

que las características de todos los píxeles son diferentes al principio.

Sin embargo, a través de algoritmos como K-medias, se realiza una fusión de píxeles de acuerdo con un criterio de similitud hasta que no queden más píxeles por fusionar.

El algoritmo de K-medias establece lo siguiente: Dado un conjunto de vectores de muestras de píxeles  $d$ -dimensionales  $A = \{\vec{a}_1, \vec{a}_2, \dots, \vec{a}_D\}$ , donde  $D$  es el total de muestras de píxeles, en este caso el total de píxeles de la imagen satelital determinados por (*ancho*)  $\times$  (*altura*). El algoritmo K-medias asigna cada muestra de color  $\vec{a}_d$  a uno de los cúmulos  $K_{l=1,2,\dots,L}$  donde  $L$  es el total de cúmulos identificados; en este caso, el total de las características del paisaje identificadas.

Esta asignación se realiza mediante la minimización de la distancia entre el vector de observación  $\vec{a}_d$  y cada elemento del conjunto de centroides de cúmulos  $B = \{\vec{b}_1, \vec{b}_2, \dots, \vec{b}_L\}$ , para lo cual se utiliza la función objetivo  $G$  definida en. Cada elemento centroide del conjunto grupo  $\vec{b}_l$  se establece con base en los cúmulos prototipos propuestos  $K_{l=1,2,\dots,L}$ :

$$G = \sum_{l=1}^L \sum_{\vec{a}_d \in K_l} \|\vec{a}_d - \vec{b}_l\|^2. \quad (26)$$

El resultado de la función objetivo  $G$  asigna cada muestra  $\vec{a}_d$  a un cúmulo prototipo  $K_{l=1,2,\dots,L}$ . El cúmulo elegido es el que tiene la distancia mínima entre el centroide  $\vec{b}_l$  y la muestra  $\vec{a}_d$ . Es decir, la función  $G$  asigna cada píxel a un clúster prototipo  $K_{l=1,2,\dots,L}$ . Hasta ahora, la imagen está segmentada píxel por píxel en  $L$  cúmulos. No obstante, para obtener las matrices de características del paisaje  $F^{l=1,2,\dots,L}$ , la imagen debe dividirse en sectores  $s(x, y)$ .

Las matrices de característica del paisaje  $F^{l=1,2,\dots,L}$  definidas a partir de los cúmulos prototipo  $K_{l=1,2,\dots,L}$  son las siguientes:

- Matriz  $F^{l=1}$  pastizales.
- Matriz  $F^{l=2}$  áreas de árboles.
- Matriz  $F^{l=3}$  áreas de edificios.
- Matriz  $F^{l=4}$  elevación del terreno.
- Matriz  $F^{l=5}$  configuración espacial.

Las matrices de características de paisaje son matrices  $X \times Y$ . Para las matrices  $F^{l=1,2,3,4}$  cada elemento  $f_{x,y}^l$  representa el número de píxeles correspondientes a la característica de paisaje  $l$  en el sector  $s(x, y)$ .

La matriz de características de paisaje  $F^{l=4}$  (elevación) contiene el nivel de elevación de los píxeles, como ocurre con las matrices  $M^{t=1,2,\dots,T}$ . Los niveles de elevación se nombran como  $A, B, C, \dots$ , según el modelo de elevación de la región.

Además, para la matriz de características del paisaje  $F^{l=5}$  (configuración espacial), los elementos  $f_{x,y}^{l=5}$  contienen el número de píxeles correspondientes a edificios, carreteras o barreras naturales en sectores alrededor de  $s(x, y)$ . Por

ejemplo, dado un sector  $s(x, y)$ , como en la Fig. 8, las características de los 8 sectores vecinos ( $N, NE, E, SE, S, SO, O, NO$ ).

Los sectores vecinos  $N, S, SO$  no presentan edificios, carreteras o barreras naturales; mientras que, los sectores vecinos  $NE, E, SE, O, NO$  denotan la existencia de edificios. IWeCASF  $F^{l=5}$  (configuración espacial), modela las interacciones entre el vecindario del sector  $s(x, y)$  y el sector  $s(x, y)$  porque las condiciones climáticas de un sector  $s(x, y)$  están influenciados por sus características particulares y por aquellas de los sectores circundantes ( $N, NE, E, SE, S, SO, O, NO$ ).

Posteriormente, se identifican las características del paisaje en el punto de control en cuestión (características particulares  $\Phi^r(F^l, M^t, P^r)$ ) mostradas en (27):

$$\Phi^r(F^l, M^t, P^r) = [f_{x_r, y_r}^1, f_{x_r, y_r}^2, \dots, f_{x_r, y_r}^L, m_{x_r, y_r}^1, m_{x_r, y_r}^2, \dots, m_{x_r, y_r}^T, \quad (27)$$

$\Phi^r(F^l, M^t, P^r)$  están compuestas por los elementos de las matrices de características de paisaje  $F^{l=1,2,\dots,L}$  y los elementos de las matrices de características  $M^{t=1,2,\dots,T}$  y definidas por la ubicación del punto de control  $P^r=0,1,\dots,R$  en cuestión. La ubicación  $s(x_r, y_r)$  de los puntos de control  $P^r=0,1,\dots,R$  se usa para seleccionar los elementos  $f_{x,y}^l$  y  $m_{x,y}^t$  donde  $x = x_r, y = y_r$ , seleccionados de las matrices  $F^{l=1,2,\dots,L}$  y  $M^{t=1,2,\dots,T}$ .

Los elementos  $f_{x,y}^l$  y  $m_{x,y}^t$  se convierten en  $\phi_{e=1,2,\dots,E}^r$  cuando sus valores se expresan en porcentaje con respecto al tamaño del sector donde está ubicado el punto de control  $s(x_r, y_r)$ .  $E = L + T$  es el total  $F^{l=1,2,\dots,L}$  más el total de  $M^{t=1,2,\dots,T}$ .

Las características particulares reales  $\Phi^r(F^l, M^t, P^r)$  se muestran en (28):

$$\Phi^r(F^l, M^t, P^r) = [\phi_{e=1}^r, \phi_{e=2}^r, \dots, \phi_{e=L}^r, \phi_{e=L+1}^r, \phi_{e=L+2}^r, \dots, \phi_{e=E}^r]. \quad (28)$$

#### 4.1.3. Ajuste difuso

El ajuste difuso está representado en la Fig. 9. Las entradas se fuzifican usando funciones de pertenencia con la forma triangular,  $L$  y gamma definidas en [7].

La fuzificación de las condiciones meteorológicas medidas  $C_{i=1,2,\dots,I}^0$ , se realiza utilizando los mismos parámetros empleados en la sección 3.1.2. El resultado es un vector de condiciones meteorológicas difusas  $\tilde{C}_i^0(v_i)$  donde  $v_i \in V_i$ .  $v_i$  es el valor de la condición climática  $C_i^0$  y  $V_i$  es el universo del discurso.

Por otra parte, para fuzificar las características particulares  $\Phi^r(F^l, M^t, P^r)$  definidas en (28), es necesario comparar las diferencias entre las características particulares en el punto de control primario  $\Phi^0(F^l, M^t, P^0)$  y las características particulares en cada punto de control  $\Phi^r(F^l, M^t, P^r)$ . Las diferencias del paisaje que causan variaciones de las condiciones meteorológicas en cada punto de control puedan ser identificadas con esta comparación. Esta  $\Phi^{0,r}$  se obtienen con una diferencia como se muestra en (29):

$$\begin{aligned} \Phi^{0,r} &= \Phi^0(F^l, M^t, P^0) - \Phi(F^l, M^t, P^r) \\ &= [\phi_{e=1}^0 - \phi_{e=1}^r, \phi_{e=2}^0 - \phi_{e=2}^r, \dots, \phi_{e=E}^0 - \phi_{e=E}^r] \end{aligned} \quad (29)$$

La comparación  $\Phi^{0,r}$  entre las características particulares se fuzifica con un proceso similar al seguido para fuzificar las condiciones meteorológicas  $C_{(i=1,2,\dots,I)}^0$ . Esta comparación  $\Phi^{\wedge}(0,r)$  indica si, en el punto de control primario  $P^{\wedge}(0)$ , la característica particular  $\phi_{e=0}$  es menor, igual o mayor que la característica particular  $\phi_{e=r}$  en el punto de control  $P^{\wedge}(r)$ .  $\Phi^{\wedge}(0,r)$  se convierte en una matriz cuando se fuzifica. El resultado es la matriz de características difusas  $\tilde{\Phi}^{\wedge}r$ , definida en (30):

$$\tilde{\Phi}^{\wedge}r = \begin{bmatrix} \tilde{\phi}_{1,1}^r & \tilde{\phi}_{1,2}^r & \tilde{\phi}_{1,3}^r \\ \tilde{\phi}_{2,1}^r & \tilde{\phi}_{2,2}^r & \tilde{\phi}_{2,3}^r \\ \vdots & \vdots & \vdots \\ \tilde{\phi}_{E,1}^r & \tilde{\phi}_{E,1}^r & \tilde{\phi}_{E,3}^r \end{bmatrix} \quad (30)$$

Las filas de la matriz representan cada elemento (característica particular) del vector de comparación  $\Phi^{\wedge}(0,r)$ . Las columnas contienen el valor difuso  $\tilde{\phi}_{(e,j)}^r \mid j=1,2,\dots,J$  derivado de las funciones de membresía  $j = 1,2,\dots,J$  para cada elemento de la comparación  $\Phi^{\wedge}(0,r)$ .

El universo de discurso es el mismo para todos los elementos  $\phi_e^0 - \phi_e^r$  y se expresa en porcentaje como  $U = [-100, 100]$ . Mientras que, las

funciones de membresía son de forma triangular,  $L$  y  $\gamma$ . En la Tabla 8, se muestran los valores lingüísticos y las funciones de membresía, obtenidas a través del análisis experimental, correspondientes a todas las características particulares  $\phi_{e=1,2,\dots,E}^r$ .

En la Fig. 10, se muestra el sistema de inferencia difusa empleado para modelar las variaciones de las condiciones meteorológicas debidas al paisaje. La entrada es la matriz de características particulares difusas  $\tilde{\Phi}^r$ , las salidas son los elementos del factor de ajuste  $\alpha_{r,i} \mid i = 1,2, \dots, I$ .

Las funciones de pertenencia utilizadas para todas las salidas (factores de ajuste  $\alpha_{r,i}$ ), se definen en la Tabla 9.

Las reglas  $n = 1,2, \dots, N$  donde  $N = 245$  son establecidas y procesadas para modelar los factores de ajuste  $\alpha_{r,i}$ . Las reglas son de la forma:

$$\text{SI } \tilde{\phi}_{1,1}^r \wedge \tilde{\phi}_{2,3}^r \wedge \tilde{\phi}_{3,1}^r \wedge \tilde{\phi}_{4,2}^r \tilde{\phi}_{5,2}^r \text{ ENTONCES } \alpha_{r,1} = \lambda_{1,2}, \alpha_{r,2} = \lambda_{2,3}, \alpha_{r,3} = \lambda_{3,1}, \alpha_{r,4} = \lambda_{4,1}, \alpha_{r,5} = \lambda_{5,2}.$$

La regla anterior corresponde a la regla  $n = 47$  y se puede interpretar de la siguiente manera:

– **SI** pastizal es *Menor* ( $\tilde{\phi}_{1,1}^r$ ) y árboles es *Mayor* ( $\tilde{\phi}_{2,3}^r$ ) y edificios es *Menor* ( $\tilde{\phi}_{3,1}^r$ ) y elevación es *Igual* ( $\tilde{\phi}_{4,2}^r$ ) y configuración espacial es *Igual* ( $\tilde{\phi}_{5,2}^r$ ) **ENTONCES** el factor de ajuste para la temperatura ( $\alpha_{r,1}$ ) es *Apenas bajo* ( $\lambda_{1,2}$ ), para la lluvia ( $\alpha_{r,2}$ ) es *Nulo* ( $\lambda_{2,3}$ ), para la radiación solar ( $\alpha_{r,3}$ ) es *Bajo* ( $\lambda_{3,1}$ ), para la velocidad del viento ( $\alpha_{r,4}$ ) es *Bajo* ( $\lambda_{4,1}$ ), mientras que para la evapotranspiración ( $\alpha_{r,5}$ ) es *Apenas bajo* ( $\lambda_{5,2}$ ).

El conjunto de reglas para el ajuste debido al paisaje se define en la matriz de definición de reglas  $H^L = (h_{n,e}^L)_{N \times E}$ , donde los elementos se definen en (31)(31):

$$h_{n,e}^L = \begin{cases} 1 & \text{si } \tilde{\phi}_{e,j}^r \text{ no se usa en la regla } n, \\ \tilde{\phi}_{e,j}^r & \text{de otro modo.} \end{cases} \quad (31)$$

Además,  $S^L = (s_{n,i}^L)_{N \times I}$  es la matriz de definición de salidas para el ajuste debido al paisaje. Los elementos  $s_{n,i}^L$  denotan que función de membresía de salida  $\lambda_{i,o}$  representa la salida  $\alpha_{r,i}$  según la regla  $n$ .

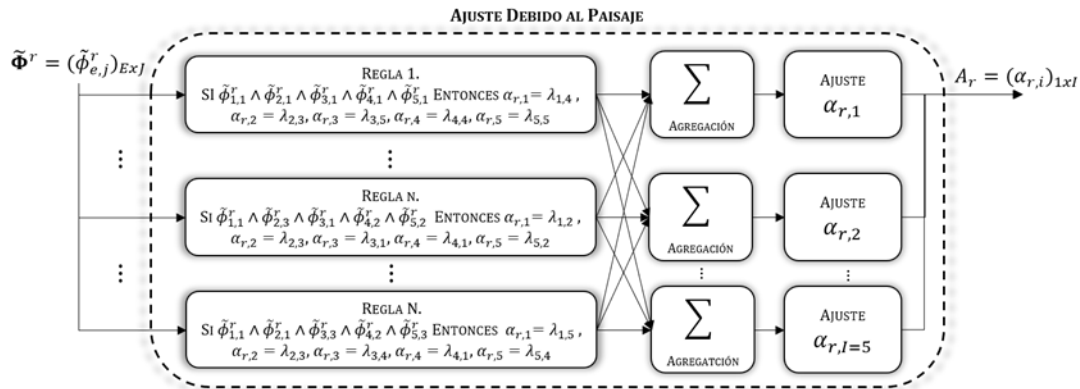


Fig. 10. Ajuste debido al paisaje

Tabla 8. Parámetros de las características particulares

Valor Lingüístico	Tipo de Función	Parámetros en porcentaje (f, g, h)
Más Bajo	L	(-60,-20)
Igual	Triangulo	(-25,0,25)
Más Alto	Gamma	(20,60)

Tabla 9. Funciones de membresía de salida  $\alpha_{r,i}$

Función de salida $\lambda_{0=1,2,\dots,0}$	Valor lingüístico	Tipo de Función	Parámetros (f, g) o (f, g, h)
$\lambda_{i,1}$	Bajo	L	(-0.3,-0.15)
$\lambda_{i,2}$	Apenas Bajo	Triangulo	(-0.17,-0.1,-0.03)
$\lambda_{i,3}$	Nulo	Triangulo	(-0.05,0,0.05)
$\lambda_{i,4}$	Apenas Alto	Triangulo	(0.03,0.1,0.17)
$\lambda_{i,5}$	Alto	Gamma	(0.15,0.3)

La implicación de la matriz  $H^L$  se denota por la palabra "y", que se define como la función *min*. El resultado de la evaluación  $\tau_{n,o}^i$  se obtiene como se define en (32):

$$\tau_{n,o}^i = \begin{cases} \min(h_{n,1}^L, h_{n,2}^L, \dots, h_{n,E}^L), & \lambda_{i,o} = s_{n,i}^L \\ 0, & \lambda_{i,o} \neq s_{n,i}^L \end{cases} \quad (32)$$

Después, los vectores  $\tau_i^n$  se envían al proceso de agregación.

La agregación delimita las funciones de salida  $\lambda_{i,o}$  y agrega todas las funciones de salida delimitadas en una sola área.

El método utilizado para la agregación es el máximo definido en (33) donde  $T_o^i$  es la función agregada para la salida  $\alpha_{r,i}$ :

$$T^i = \max(\tau_{1,o}^i, \tau_{2,o}^i, \dots, \tau_{N,o}^i) \quad (33)$$

$o = 1, 2, \dots, O ; i = 1, 2, \dots, I$

Utilizando (21), la función agregada  $T^i$  es defuzificada para obtener el factor de ajuste constante  $\alpha_{r,i}$  de la condición climática  $C_i^0$ .

Las salidas  $\alpha_{r,i}$  conforman el vector de factores de ajuste constante  $A_r$  (34):

$$A_r = [\alpha_{r,1}, \alpha_{r,2}, \dots, \alpha_{r,I}] \quad (34)$$

Las condiciones meteorológicas pueden ser diferentes en dos lugares dentro de una región, a pesar de su proximidad. Esta situación es causada por diferentes eventos [47], por ejemplo, la temporada del año, aumenta la certeza de que una condición climática como la lluvia sea similar en la



mayoría de los lugares dentro de una región de interés.

Al introducir una función de distribución de certeza que dependa de la fecha, se puede describir la certeza de la replicación de la condición meteorológica en una región. El ajuste debido a las condiciones meteorológicas utiliza una función de distribución de certeza para describir la certeza de la condición climática  $\eta_{i=1,2,\dots,I}$ . La fecha determina la certeza de las condiciones meteorológicas  $\eta_{i=1,2,\dots,I}$ . La función de distribución de certezas de las condiciones meteorológicas esta descrita en (35), la temperatura ( $C_{i=1}^0$ ) no se considera influenciada por la fecha (estación del año):

$$\eta_i = e^{-\frac{(d-g)^2}{2f^2}}, \quad (35)$$

donde  $d$  es el mes,  $(f, g)$  son los parámetros de la función.  $f$  indica la desviación de la temporada de lluvias expresada en meses y  $g$  define el mes de la temporada alta de lluvias. Los parámetros  $(f, g)$  para certezas  $\eta_{i=2,3,5}$  (lluvia, radiación solar y evapotranspiración) son (3,7), mientras que para la certeza  $\eta_{i=4}$  (velocidad del viento) los parámetros son (1,10). Ambos conjuntos de parámetros se basan en el análisis experimental.

El ajuste debido a las condiciones meteorológicas modela la influencia de cada condición climática sobre las demás en el punto de control  $P^r$  usando un sistema de inferencia difusa. La Fig. 10 representa el ajuste debido a las condiciones meteorológicas. Aunque, para este ajuste, primero, la certeza  $\eta_{i=1,2,\dots,I}$  pondera las condiciones meteorológicas difusas  $\tilde{C}_i^0$  mediante el producto de  $\tilde{C}_i^0$  y  $\eta_{i=1,2,\dots,I}$ . Las salidas  $\beta_i \mid i = 1, 2, \dots, I$  (elementos del factor de ajuste variable), se representan como un porcentaje de las condiciones meteorológicas medidas  $C_i^0$ .

Además, las funciones de membresía de salida  $\omega_{i,0=1,2,\dots,0}$  ( $O = 5$ ) de cada salida  $\beta_i$ , también están asociadas a etiquetas lingüísticas que se refieren al ajuste requerido de la condición climática  $C_i^0$ . Las funciones de salida  $\omega_{i,1}$  y las  $Q = 445$  reglas, así como el procedimiento realizado se desarrolla de la misma forma que en el sistema de inferencia difusa utilizado en Un ejemplo de las interacciones que modelan las  $q = 1, 2, \dots, Q$  es el

siguiente:  $C_{i=1}^r$  (temperatura) disminuye con niveles altos de  $C_{i=2}^r$  (lluvia), o  $C_{i=4}^r$  (velocidad del viento), mientras que con niveles altos de  $C_{i=2}^r$  (radiación solar),  $C_{i=1}^r$  (temperatura) aumenta.

El resultado del ajuste debido a las condiciones meteorológicas es el vector de factores de ajuste variable  $B$ , definido en (36), el cual es el conjunto de ajustes variables  $\beta_i \mid i = 1, 2, \dots, I$ . El vector de factores de ajuste variable es el mismo para todos los puntos de control  $P^{r=1,2,\dots,R}$ :

$$B = [\beta_1, \beta_2, \dots, \beta_I]. \quad (36)$$

El ajuste final se implementa para obtener las condiciones meteorológicas ajustadas  $Ca_{i=1,2,\dots,I}^r$  calculadas en (37). Las  $Ca_{i=1,2,\dots,I}^r$  están dados por el producto del valor de las condiciones meteorológicas medidas  $C_i^0$  y la adición de los elementos  $\alpha_{r,i}, \beta_i$  de los vectores  $(A_r, B)$  definidos en (34) y (36) respectivamente:

$$Ca_i^r = (C_i^0)(1 + \alpha_{r,i} + \beta_i) \mid r = 1, 2, \dots, R; \quad (37)$$

$$i = 1, 2, \dots, I.$$

## 4.2. Experimentos

La región de interés, Fig. 11, es la misma utilizada en la sección anterior. Se realizaron un conjunto de pruebas preliminares para obtener el tamaño y la resolución apropiada de la imagen, estas pruebas evitan incertidumbres en la etapa de selección de características de la subzona y una propagación de errores. En la Fig. 11, matriz de características  $M^1$  (tipo de suelo), cada sector  $s(x, y)$  tiene una extensión de 40x40 m, por consecuencia, la imagen se divide en  $S = 2150$  sectores.

La resolución de la imagen es  $1450 \times 1247$  pixeles,  $1 \text{ pixel} \cong 1.8 \text{ m}^2$ . Según los resultados experimentales, el tamaño de las matrices  $M_{x \times y}^t$  es  $X = 43$  e  $Y = 50$ . De acuerdo con la Fig. 11, el tipo de suelo es el mismo para la región de interés; es decir, todos los elementos  $m_{x,y}^1$  de la matriz  $M^1$  tienen la forma  $m_{x,y}^1 = II$  debido a que la región de estimación no es una tierra de cultivo, del tipo de cultivo  $M^2$  solo se refieren al tipo de vegetación que prevalece en cada sector de la región. La

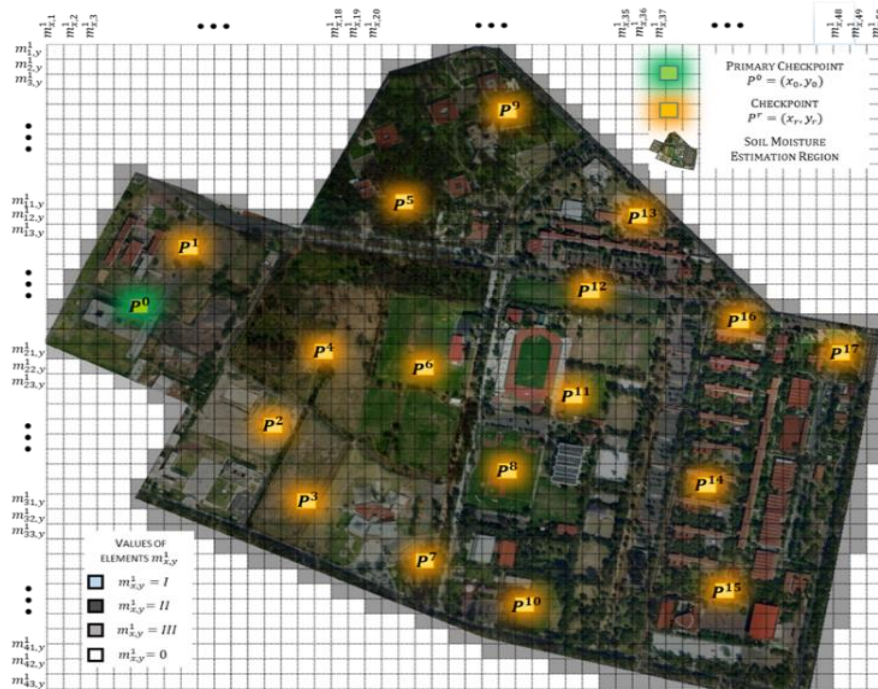


Fig. 11. Matriz de características  $M^1$  (tipo de suelo)

Tabla 10. Condiciones meteorológicas medidas ( $c_{i=1,2,\dots,i}^0$ ) en el punto de control primario  $p^0$  con ( $i=5$ )

$C_{i=1,2,\dots,i}^0$	Variable	Unidades	Valor ( $v_i$ )
$C_1^0$	Temperatura ( $T$ )	$^{\circ}C$	18.1
$C_2^0$	Lluvia ( $Ll$ )	$mm$	0
$C_3^0$	Radiación solar ( $Rs$ )	$W/m^2$	890
$C_4^0$	Velocidad del viento ( $Vv$ )	$Km/hr$	16
$C_5^0$	Evapotranspiración ( $Et$ )	$mm/d$	5

localización  $s(x_r, y_r)$  de los puntos de control  $p^{r=0,1,\dots,R}$  es representada en la fig. 11.

Los valores  $v_{i=1,2,\dots,i}$  de las condiciones meteorológicas  $C_{i=1,2,\dots,i}^0$  mostrados en la Tabla 10 corresponden a un día de medición en el punto de control primario  $P^0$ .

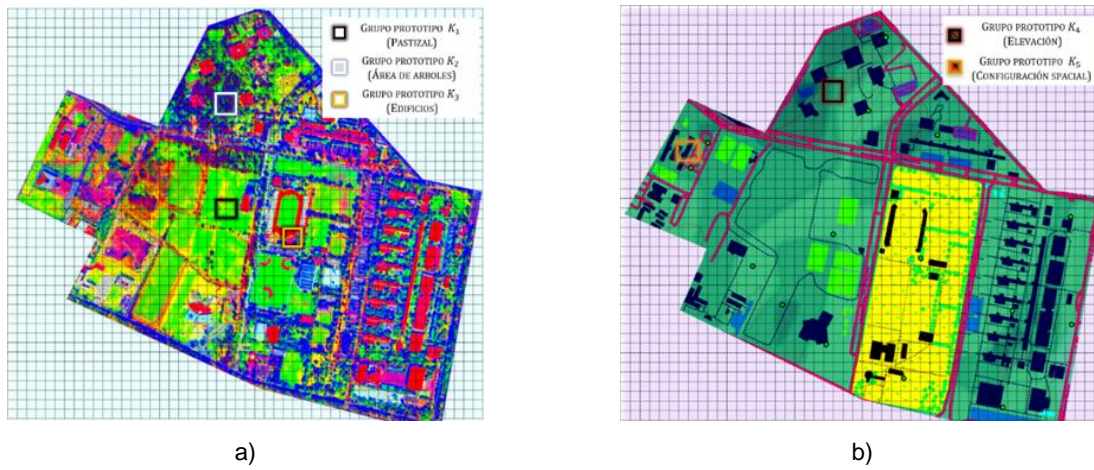
Se procesaron dos imágenes para obtener las matrices de características de paisaje  $F^{l=1,2,\dots,L}$ . La primera imagen se muestra en la Fig. 12a. Las áreas cubiertas de árboles son convertidas a color azul y las construcciones a color rosa, mientras que las áreas de pastizales permanecen verdes.

La Fig. 12b se usa para identificar la elevación y la configuración espacial.

La segmentación de colores de las imágenes procesadas se realiza con (26).

Los grupos  $K_{l=1,2,\dots,L}$  son utilizados para formar las matrices de características del paisaje  $F^{l=1,2,\dots,L}$ .

Por ejemplo, las matrices de características del paisaje  $F^1$  (pastizal) y  $F^3$  (edificios) provienen de la segmentación de colores ilustrada en la Fig. 12. La matriz  $F^1$  (pastizal) se representan en la Fig. 13. El número de píxeles de cada sector  $s(x, y)$  es de 858 píxeles.



**Fig. 12.** Región de interés bajo la decorrelación. a) Imagen usada para obtener las matrices  $F^{l=1,2,3}$ . b) Imagen usada para obtener las matrices  $F^{l=4,5}$



**Fig. 13.** Matriz de características del paisaje  $F^1$  (pastizal)

Por lo tanto, en el caso de  $F^1$  (pastizal), el valor del elemento  $f_{21,25}^1$  correspondiente al sector

$s(20,25)$  es  $f_{20,25}^1 = 596$  porque hay 596 píxeles que pertenecen al grupo  $K_1$ .

De acuerdo con la Fig. 11, el punto de control  $P^4$  tiene la ubicación  $s(x_4 = 21, y_4 = 17)$ . Los cálculos desarrollados en este experimento corresponden al punto  $P^4$ . Los elementos del vector de características particulares  $\Phi^4(F^4, M^4, P^4)$ , que se muestran en (38), se seleccionan como se define en (27).

Es decir, hay 818 pixeles correspondientes a  $F^1$  (pastizales), en el punto de control  $P^4$ , del mismo modo hay 17 pixeles correspondientes a  $F^3$  (árboles) y así sucesivamente:

$$\Phi^4(F^4, M^4, P^4) = [818, 17, 17, (858/A), 121, (858/II), (858/1), (858/1)]. \quad (38)$$

El vector de características particulares  $\Phi^4(F^4, M^4, P^4)$  de (38) se expresa en porcentaje como se muestra en (39), la cual denota que en el punto de control  $P^4$ , el 65.3846 % del sector corresponde a  $F^1$  (pastizal), el 1.9231% del sector corresponde a  $F^2$  (árboles) y así sucesivamente:

$$\Phi^4(F^4, M^4, P^4) = [95.338, 1.9813, 1.9813, (100/A), 14.1025, (100/II), (100/1), (100/1)]. \quad (39)$$

Para la fuzificación de las condiciones meteorológicas  $C_{i=1,2,\dots,l}^0$  se utilizan se realiza utilizando los mismos parámetros empleados en la sección 3.1.2 La comparación de las características particulares  $\Phi^{0,4}$  se realiza de acuerdo con (29). Las características particulares  $\Phi^0(F^0, M^0, P^0)$  en el punto de control primario  $P^0$  se muestran en (40):

$$\Phi^0(F^0, M^0, P^0) = [100, 0, 0, (100/A), 22.76, (100/II), (100/1), (100/1)]. \quad (40)$$

$\Phi^0(F^0, M^0, P^0)$  son obtenidas con un proceso similar al seguido para obtener las características particulares  $\Phi^0(F^4, M^4, P^4)$  en  $P^4$  que se presentan en (39)(39).

El resultado de la comparación  $\Phi^{0,4}$  se muestra (41)-(42):

$$\Phi^{0,4} = [100 - 65.3846, 0 - 1.9231, 0 - 1.9231, (100 - 100)/A, 22.76 - 14.1025, (100 - 100)/I, (100 - 100)/1, (100 - 100)/1], \quad (41)$$

$$\Phi^{0,4} = [34.6154, -1.9231, -1.9231, (0/A), 8.6575, (0/I), (0/1), (0/1)]. \quad (42)$$

La matriz difusa de características particulares se obtiene utilizando (30) y los parámetros de la Tabla 9. En (43), se muestra la matriz de características particulares resultante  $\tilde{\Phi}^4$ :

$$\tilde{\Phi}^4 = \begin{bmatrix} 0 & 0.8152 & 0 \\ 0 & 0.9615 & 0 \\ 0 & 0.9615 & 0 \\ 0 & 1 & 0 \\ 0 & 0.6537 & 0 \end{bmatrix}. \quad (43)$$

De acuerdo con la Fig. 10, el ajuste debido al paisaje realiza la evaluación de  $N = 245$  reglas. Las reglas  $n$  son de la forma:

$$\text{SI } \tilde{\phi}_{1,3}^r \wedge \tilde{\phi}_{2,2}^r \wedge \tilde{\phi}_{3,2}^r \wedge \tilde{\phi}_{4,2}^r \wedge \tilde{\phi}_{5,2}^r \\ \text{ENTONCES } \alpha_{r,1} = \lambda_{1,4}, \alpha_{r,2} = \lambda_{2,3}, \alpha_{r,3} = \lambda_{3,4}, \\ \alpha_{r,4} = \lambda_{4,3}, \alpha_{r,5} = \lambda_{5,4}.$$

La regla anterior ( $n = 41$ ) puede ser interpretada como a continuación:

– **SI** pastizal es *Mayor* ( $\tilde{\phi}_{1,3}^4$ ) y areas cubiertas de árboles es *Igual* ( $\tilde{\phi}_{2,2}^4$ ) y edificios es *Igual* ( $\tilde{\phi}_{3,2}^4$ ) y elevación es *Igual* ( $\tilde{\phi}_{4,2}^4$ ) y la configuración espacial es *Igual* ( $\tilde{\phi}_{5,2}^4$ ) **ENTONCES** el factor de ajuste para temperatura ( $\alpha_{4,1}$ ) es *Apenas Alto* ( $\lambda_{1,4}$ ), para lluvia ( $\alpha_{4,2}$ ) es *Nulo* ( $\lambda_{2,3}$ ), para la radiación solar ( $\alpha_{4,3}$ ) es *Alto* ( $\lambda_{3,4}$ ), para la velocidad del viento ( $\alpha_{4,4}$ ) es *Nulo* ( $\lambda_{4,3}$ ), y para la evapotranspiración ( $\alpha_{4,5}$ ) es *Apenas Alto* ( $\lambda_{5,4}$ ).

De acuerdo con (31) y (32) usando la fila  $n = 41$  de las matrices  $H^L = (h_{n,e}^L)_{N \times E}$  y  $S^L = (s_{n,i}^L)_{N \times I}$ , la regla  $n = 41$  para la salida  $\alpha_{4,1}$  se evalúa como en (44). El resultado de la regla  $\tau_{41,4}^1$  para la salida ( $\alpha_{4,1}$ ), se asigna a la función de pertenencia de salida  $\lambda_{1,4}$ . El mismo proceso es aplicable para las reglas  $N$ , así como para las salidas  $I$ :

$$\tau_{41,4}^1 = \min(\tilde{\phi}_{1,3}^4, \tilde{\phi}_{2,2}^4, \tilde{\phi}_{3,2}^4, \tilde{\phi}_{4,2}^4, \tilde{\phi}_{5,2}^4) \\ = \min(0.2670, 0.9615, 0.9615, 1, 0.5827) \\ = 0.267. \quad (44)$$

La agregación se realiza de acuerdo con (33). La función resultante  $T^i$  se defuzifica utilizando el método de centroide descrito en (21). Cuando las

**Tabla 11.** Comparación de condiciones meteorológicas en el punto de control  $P^4$ 

Condición meteorológica		Punto $P^0$	Punto $P^4$	
		Medidas $C_i^0$	Ajustadas $Ca_i^4$	Medidas $Cm_i^4$
$i = 1$	Temperatura ( $^{\circ}C$ )	18.1	19.9878	19
$i = 2$	Lluvia ( $mm$ )	0	0	0
$i = 3$	Radiación solar ( $W/m^2$ )	890	982.8276	916
$i = 4$	Velocidad del viento ( $km/hr$ )	16	15.9935	18.2
$i = 5$	Et ( $mm/d$ )	5	5.249	5.2

salidas  $i = 1, 2, \dots, I$  están defuzificadas, el vector de factor de ajuste constante  $A_4$  se conforma como en (34).

El vector de factor de ajuste constante  $A_4$ , derivado del análisis anterior, se muestra en (45):

$$A_4 = [0.0544, 0.0544, 0.0544, -0.004, 0.5249]. \quad (45)$$

Posteriormente, se calcula la certeza de las condiciones meteorológicas  $\eta_{i=1,2,\dots,I}$  en función de la fecha. La fecha no influye en la certeza  $\eta_1$  (Temperatura), por lo que siempre se considera como  $\eta_1 = 1$ . Las certezas  $\eta_{i=2,3,4,5}$  se obtienen con (35). Utilizando los parámetros definidos en la sección 4.1.3, las certezas de las condiciones meteorológicas  $\eta_{i=2,3,4,5}$  durante el mes de agosto, un mes de la temporada de lluvias, se muestran en (46) y (47):

$$\eta_2 = \eta_3 = \eta_5 = e^{\frac{-(8-7)^2}{2(3)^2}} = 0.9460, \quad (46)$$

$$\eta_4 = e^{\frac{-(8-10)^2}{2(1)^2}} = 0.1353. \quad (47)$$

El ajuste debido a las condiciones meteorológicas es un proceso similar al utilizado en el Ajuste debido al paisaje. Sin embargo, en este ajuste, las entradas son las condiciones meteorológicas difusas  $\tilde{C}_i^0(v_i)$ , las cuales son ponderadas utilizando la certeza de las condiciones meteorológicas  $\eta_{i=1,2,\dots,I}$ .

El resultado es el vector de factores de ajuste variable mostrado en (48):

$$B = [0.0499, 0.009, 0.0499, 0, 0.5249]. \quad (48)$$

Después de obtener los vectores  $A_i$  y  $B$ , se utiliza (37)(37) para obtener el ajuste final de las condiciones ambientales. Por ejemplo, en (49), se

muestran las condiciones meteorológicas derivadas del análisis realizado.

De acuerdo a la Tabla 11, el valor medido de la temperatura es  $C_1^0 = 18.1$ , los factores de ajuste son  $\alpha_{4,1} = 0.0544$  y  $\beta_1 = 0.0499$  contenidos en  $A_4$  mostrado en (45) y en  $B$  mostrado en (48). En este caso,  $C_1^0 = 18.1$  es modificado por un ajuste combinado de  $(0.0544 + 0.0499)$ , el cual puede ser interpretado como un incremento de  $5.44\% + 4.99\% = 10.43\%$  del valor medido. Por lo tanto, el valor ajustado de la temperatura es  $Ca_1^4 = 19.98$  como se muestra en (49):

$$\begin{aligned} Ca_1^4 &= (C_1^0)(1 + \alpha_{4,1} + \beta_1) \\ &= (18.1)(1 + 0.0544 \\ &\quad + 0.0499) = 19.98. \end{aligned} \quad (49)$$

En la Tabla 11 se comparan las condiciones meteorológicas  $Ca_{i=1,2,\dots,I}^4$  obtenidas con *IWeCASF* y las condiciones meteorológicas medidas  $C_{i=1,2,\dots,I}^4$  en el punto de control  $P^4$ . Esta comparación solo es ejecutada durante la etapa de diseño para validar los resultados y no es requerida durante la implementación de *IWeCASF*.

### 4.3 Discusión de resultados

La región que se utiliza en este trabajo para realizar el ajuste de las condiciones meteorológicas no es tierra de cultivo, esto permite probar el modelo *IWeCASF* en una región más compleja con diferentes características de paisaje bajo condiciones controladas. Además, en un terreno puramente agrícola, es muy frecuente que no haya muchas características naturales o no naturales del paisaje que afecten las condiciones meteorológicas, necesarias para validar este modelo.

**Tabla 12.** Comparación de condición meteorológica (Temperatura) ajustada  $Ca_1^4$ , medida  $Cm_1^4$ , e interpolada  $CI_1^4$ 

Prueba	$Ca_1^4$ ( $^{\circ}C$ )	$Cm_1^4$ ( $^{\circ}C$ )	$CI_1^4$ ( $^{\circ}C$ )
A	10.61	11	10.89
B	14.43	12.9	13.8
C	15.81	14.7	14.5
D	19.07	21	21.1
E	18.97	18.5	19.97
F	17.32	17	15.4
G	27.4	27.8	27.77
H	17.76	18	18.25
I	18.99	20	20.96
J	16.92	17.6	16.2
K	12.9	12.7	13.03
L	14.36	14.2	14.47
M	13.5	12.8	11.83
N	19.05	20.1	19.95
O	20.77	21	20.88
P	30	29.5	29.4

El análisis experimental preliminar consiste en evaluar el rendimiento de IWeCASF para determinar los parámetros iniciales. El tamaño del sector con mejores resultados es utilizado en este documento  $40 \times 40 \text{ m}$  ( $E_{RMS} = 0.0412$ ). Los sectores  $s(x, y)$  con tamaño inferior a  $40 \times 40 \text{ m}$ , como  $20 \times 20 \text{ m}$  o  $15 \times 15 \text{ m}$ , no disminuyen mucho el error ( $E_{RMS} = 0.041$ ,  $E_{RMS} = 0.0408$ ) pero sí aumentan el costo computacional de IWeCASF debido al aumento del número de sectores. La resolución utilizada en este artículo  $1450 \times 1247$ , es decir,  $1 \text{ pixel} \cong 1.9 \text{ m}^2$ ; conlleva a un error  $E_{RMS} = 0.0412$ .

IWeCASF puede soportar resoluciones más grandes tal como  $2000 \times 1720$ ; es decir,  $1 \text{ pixel} \cong 1 \text{ m}^2$ , con un error  $E_{RMS} = 0.0408$  pero estas resoluciones pueden requerir métodos complejos de adquisición de imágenes. Cuando el porcentaje de píxeles no asignados es  $\%NAP < 1.5$ , IWeCASF funciona mejor ( $E_{RMS} = 0.0408$ ) que con mayores porcentajes. Es posible lograr un  $\%NAP = 0$ , pero en algunos casos este  $\%NAP$  requería procesar una imagen con una resolución mayor a  $1450 \times 1247$ .

Se implementó un conjunto de suites de sensores integrados (ISS) para registrar las mediciones de las condiciones meteorológicas en diferentes puntos de control. IDW, un método de interpolación de la literatura [3, 4], y las mediciones de las condiciones meteorológicas realizadas con las ISS, se emplearon para validar las condiciones meteorológicas ajustadas  $Ca_i^4$  obtenidas con IWeCASF.

El error cuadrático medio normalizado ( $E_{RMS}$ ) también se utiliza para evaluar el rendimiento de la interpolación.

En la Tabla 12 se muestra una comparación de los resultados obtenidos, estos valores corresponden a las condiciones meteorológicas en el punto de control  $P^4$ .

En el caso de la temperatura,  $Ca_1^4$  presenta un  $E_{RMS} = 0.0435$  que es casi igual a  $E_{RMS} = 0.0418$  que corresponde a la interpolación ( $CI_1^4$ ). Se presentan resultados más precisos cuando se ajustan valores de temperatura superiores a  $18 \text{ }^{\circ}C$ . El error  $E_{RMS}$  de  $CI_1^4$  o de  $Ca_1^4$  no es un problema para la estimación puntual de la humedad del suelo utilizando FEADM.

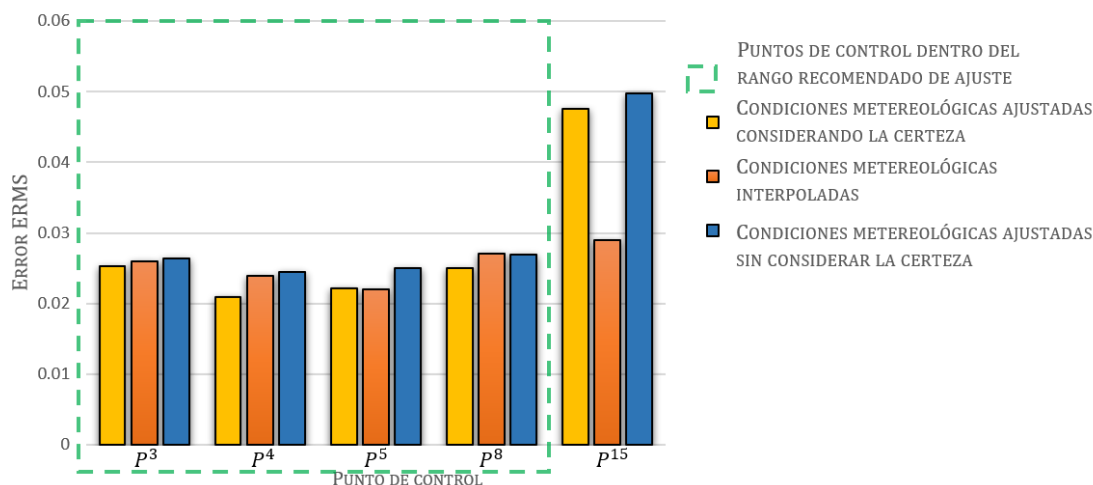


Fig. 14. Comparación de errores  $E_{RMS}$  para la condición climatológica  $C_2^r$  en los puntos de control  $P^{r=3,4,5,8,15}$

Con referencia a la lluvia,  $Ca_2^4$  con un  $E_{RMS} = 0.0209$  es más precisas que  $CI_2^4$  con un  $E_{RMS} = 0.0239$ . Los mejores ajustes se realizaron con lluvias inferiores a 1 mm. Sin embargo, la resolución del pluviómetro agrega incertidumbres para determinar si IWeCASF o IDW se desempeñan mejor en algunas pruebas donde el error de ambos modelos es menor que la resolución del medidor de lluvia (0.2 mm).

La Fig. 14 muestra el rendimiento de los ajustes para  $Ca_{i=2}^r$  en los puntos de control  $P^3, P^4, P^5, P^8$  y  $P^{15}$  considerando la certeza de las condiciones meteorológicas  $\eta_2$ , en el punto de control  $P^8$  el error sin certeza  $\eta_2$  es  $E_{RMS} = 0.0269$ , que es similar al error obtenido mediante el método de interpolación ( $E_{RMS} = 0.0271$ ), mientras que el error considerando la certeza  $\eta_2$  ( $E_{RMS} = 0.025$ ) es menor que ambos. Los beneficios de incluir la certeza de las condiciones meteorológicas  $\eta_i$  son más evidentes en el caso de la lluvia  $C_2^r$ .

La radiación solar ajustada  $Ca_3^4$  presenta un  $E_{RMS} = 0.0135$ , mientras que la radiación solar interpolada  $CI_1^4$  presenta un  $E_{RMS} = 0.0130$ . Ambos errores son extremadamente similares porque la radiación solar denota una menor dependencia de la variabilidad de las condiciones meteorológicas en una región estrecha.

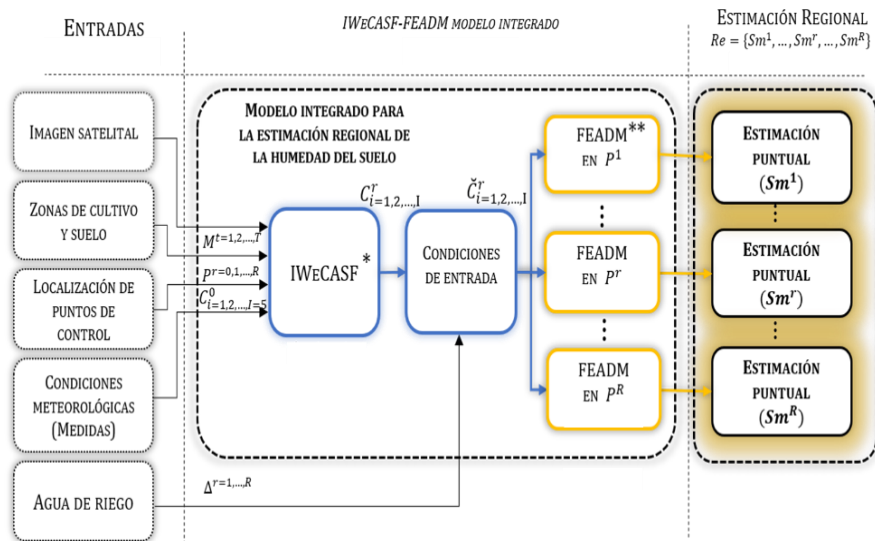
El error de  $Ca_4^4$  es  $E_{RMS} = 0.0536$  y el error de  $CI_1^4$  es  $E_{RMS} = 0.0600$ . El ajuste de la velocidad del

viento es extremadamente complejo debido a sus condiciones cambiantes, así como a la presencia de barreras naturales o no naturales. Esto normalmente no se considera con algunos modelos de interpolación, que pueden afectar la estimación puntual de la humedad del suelo.

Los ajustes de IWeCASF  $Ca_5^4$  presentan un error  $E_{RMS} = 0.0301$ ; mientras tanto, los resultados de interpolación  $CI_5^4$  presentan un error  $E_{RMS} = 0.0322$ . Todos estos errores son aceptables para el segundo objetivo de IWeCASF que es proporcionar a FEADM las condiciones meteorológicas para realizar una estimación de la humedad del suelo.

Las diferencias existentes entre las mediciones de las condiciones meteorológicas ( $Cm_i^4$ ) y las condiciones meteorológicas ajustadas ( $Ca_i^4$ ) no comprometen la precisión de la estimación de la humedad del suelo. De hecho, hay algunas incertidumbres o errores instrumentales en algunas pruebas en las cuales se puede considerar un  $E_{RMS} = 0$  debido a que la desviación entre el resultado de IWeCASF  $Ca_1^4$  y la condición meteorológica medida  $Cm_1^4$  es inferior a la precisión de la ISS.

IWeCASF presenta dos ventajas claras sobre un método de interpolación para determinar las condiciones meteorológicas y lograr una estimación regional de la humedad del suelo. La primera es un mejor rendimiento al ajustar una



**Fig. 15.** Esquema de una estimación regional basada en estimaciones puntuales

variable inconsistente como la lluvia. La certeza de la condición climática  $\eta_2$  es la responsable de este resultado. La segunda es que IWeCASF no requiere desplegar más de una estación de medición cuando se está ejecutando, a diferencia de los métodos de interpolación que sí requieren más de un punto de medición para realizar la interpolación.

La distancia desde el punto de control  $P^0$  y las diferentes características del paisaje reverbera en la precisión de los resultados. Los errores normalizados  $E_{RMS}$  en el punto de control  $P^{15}$  son los siguientes:

- $E_{RMS} = 0.0467$  para la temperatura.
- $E_{RMS} = 0.0475$  para la lluvia.
- $E_{RMS} = 0.0187$  para la radiación solar.
- $E_{RMS} = 0.1182$  para la velocidad del viento.
- $E_{RMS} = 0.0386$  para la evapotranspiración.

En el caso de  $Ca_{i=1,3,5}^{15}$  (temperatura, radiación solar y evapotranspiración), los errores permanecen extremadamente similares a los obtenidos en el punto de control  $P^4$ , el aumento máximo en estos errores es 0.0085. Para  $Ca_{i=2}^{15}$  (lluvia), el aumento en el error es 0.0266. Ambos aumentos de error muestran que los ajustes de las condiciones meteorológicas están influenciados

por la distancia entre el punto de control primario  $P^0$  y el punto de control donde se realiza el ajuste  $P^r$ .

El caso de  $Ca_4^{11}$  (velocidad del viento) muestra un notable incremento de 0.0646 en el error. Este aumento es causado no solo por el problema de la distancia, sino también por las condiciones cambiantes del comportamiento del viento en una región con una cantidad sustancial de barreras naturales o no naturales.

Sin embargo, en las tierras de cultivo, no es habitual encontrar barreras dispersas a lo largo de la región de interés. El rango de ajuste recomendado de IWeCASF es de 1.4 km medido desde  $P^0$ . Este rango se define en función del error de las condiciones meteorológicas ajustadas.

No todos los ajustes de las condiciones meteorológicas más allá de esta distancia presentan un error significativo; por ejemplo, el error de  $Ca_1^{15}$  (temperatura) es  $E_{RMS} = 0.0447$  en el punto de control  $P^{15} \cong 1.5$  desde  $P^0$ , sin embargo, si se proporciona una condición meteorológica con un error importante ( $E_{RMS} \geq 0.1$ ); por ejemplo, el error de  $Ca_4^{15}$  (velocidad del viento) es  $E_{RMS} = 0.1182$  en el punto de control  $P^{15}$ ; a un modelo para estimar la humedad del suelo como se describe en la Sección 3.1, se podría obtener una estimación errónea de la humedad del suelo.



## Modelo integrado para la estimación regional

### 5.1 Modelo integrado IWeCASF-FEADM

El esquema de un modelo de estimación regional de la humedad del suelo basado en FEADM - IWeCASF se presenta en la Fig. 15.

#### 5.1.1. Entradas

Las entradas requeridas por el modelo integrado son las mismas descritas en las secciones 3.1.1 y 4.1.1. Aunadas a éstas, se encuentra el agua de riego, la cual es una matriz  $\Delta = (\delta_{x_r, y_r})_{XXY}$  conformada a partir de una base de datos geográfica que contiene el registro de la cantidad de agua de riego suministrada en cada sector  $s(x, y)$  de la región de riego.

#### 5.1.2. Modelo integrado

El modelo integrado IWeCASF-FEADM está conformado por IWeCASF, cuyos resultados son complementados con el registro de agua de riego para luego ser suministrados como entradas a FEADM, el cual determina la estimación puntual de la humedad del suelo en cada punto de control. El resultado es una estimación regional de la humedad del suelo a partir de un conjunto de estimaciones puntuales.

IWeCASF (descrito detalladamente en la sección 4), determina las condiciones climáticas dentro de una región permitiendo el uso de un modelo de estimación puntual de la humedad del suelo como FEADM (sección 3).

Los valores suministrados como entradas a FEADM, son las condiciones meteorológicas reales  $\check{C}_i^r$  definidas en (50). El valor de cada condición meteorológica  $C_i^r$  es el obtenido con IWeCASF, a excepción de  $C_{i=2}^r$  (lluvia), el cual es complementado con el registro de agua de riego  $\delta_{x_r, y_r} \in \Delta = (\delta_{x_r, y_r})_{XXY}$  en el punto de control  $P^r$ . El objetivo es determinar la cantidad real de agua que es suministrada en el sector  $s(x_r, y_r)$ . Si la región de estimación es una zona de irrigación y esta información no es suministrada al modelo integrado, el resultado de la estimación puntual puede no ser muy preciso.

FEADM (sección 3) recibe como entrada las condiciones meteorológicas reales  $\check{C}_{i=1,2,\dots,I}^r$  mostradas en (50):

$$\check{C}_i^r = \begin{cases} C_i^r + \delta_{x_r, y_r} & i = 2, \\ C_i^r & i \neq 2. \end{cases} \quad (50)$$

Estas son procesadas para obtener el nivel de humedad del suelo (estimación puntual de la humedad del suelo  $Sm^r$ ), en un área delimitada (punto de control  $P^r$ ).

#### 5.1.3. Estimación regional

La humedad del suelo en cada punto de control  $P^r$  de la región debe ser determinada para obtener una estimación regional. Como consecuencia, FEADM se implementa  $R$  veces, una vez por cada punto de control  $P^{r=1,2,\dots,R}$  dando como resultado  $R$  estimaciones puntuales de la humedad del suelo  $Sm^{r=1,2,\dots,R}$ . El conjunto de estimaciones puntuales de la humedad del suelo  $Sm^{r=1,2,\dots,R}$  se denomina estimación regional de la humedad del suelo  $Re = \{Sm^1, Sm^2, \dots, Sm^R\}$ .

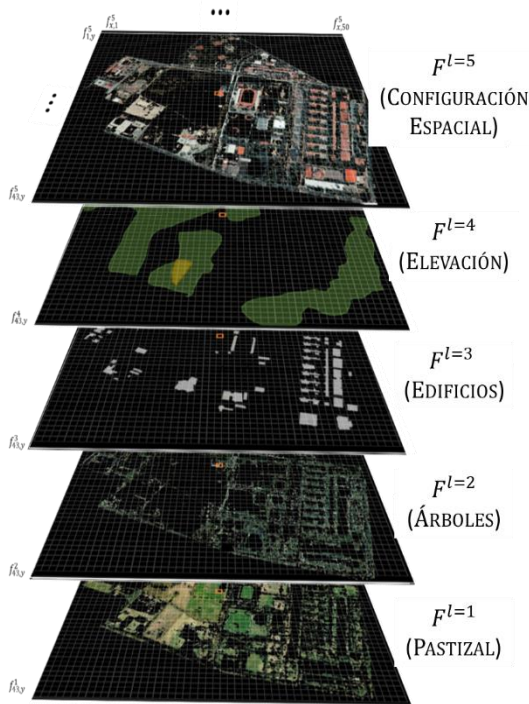
## 5.2 Experimentos

Las imágenes satelitales de la región de estimación se dividen en  $S = 2150$  sectores  $s(x, y)$ , como se describe en la sección 3.1.1. El total  $S = 2150$  de sectores  $s(x, y)$ , la extensión de cada sector  $s(x, y)$  ( $40 \times 40$  m), y la resolución de la imagen ( $1450 \times 1247$ ) están determinadas por las pruebas preliminares. La imagen satelital de la Fig. 11, muestra la región de interés, la ubicación  $s(x_r, y_r)$  de algunos puntos de control  $P^r$  y la matriz de características  $M^2$  (tipo de cultivo).

La profundidad de la estimación es de 30 cm y es mantenida constante durante todas las evaluaciones.

En este experimento, cada sector  $s(x, y)$  se considera un punto de control. Los valores  $v_{i=1,2,\dots,I}$  utilizados son presentados en la Tabla 14; éstos corresponden a las condiciones climáticas medidas  $C_{i=1,2,\dots,I}^0$  en el punto de control primario  $P^0$  (mostrado en la Fig. 11).

Las características del paisaje  $F^{l=1,2,\dots,L}$  se extraen de las imágenes satelitales mediante los procedimientos descritos en la sección 4.1.2. La imagen original se separa en  $L = 5$  matrices de



$$\tilde{\Phi}^r = \begin{bmatrix} 0 & 0.7668 & 0 \\ 0 & 0.8554 & 0 \\ 0 & 0.93 & 0 \\ 0 & 1 & 0 \\ 0.0807 & 0.0708 & 0 \end{bmatrix} \quad (53)$$

Los Sistemas de Inferencia Difusa (FIS, por sus siglas en inglés), utilizados para determinar los valores de ajuste  $\Lambda_r$  y  $B$  se describen en la sección 4.2. Después de evaluar las reglas  $N = 245$  el resultado del factor de ajuste constante  $\alpha_{r,i}$ , se muestra en (54):

$$\Lambda_r = [-0.0288, -0.003, -0.0499, -0.225, -0.28]. \quad (54)$$

La certeza  $\eta_{i=1,2,\dots,I}$  calculada en (46) y (47) es utilizada en el FIS de ajuste variable. El factor de ajuste variable  $B$  es único para toda la región de estimación. En (55), se presenta el factor de ajuste  $B$ , resultante del ajuste variable de las condiciones climáticas  $C_{i=1,2,\dots,I}^0$ :

$$B = [0, -0.0167, -0.0498, -0.0498, -0.021]. \quad (55)$$

Al final, IWeCASF determina las condiciones meteorológicas en cada punto de control  $P^r$  utilizando (37), los ajustes constantes  $(\alpha_{r,i})_{1,I}$  (54) y el ajuste variable  $B$  obtenidos en (55). Sin embargo, las condiciones climáticas ajustadas  $C_{i=2}^r$  se complementan utilizando el registro de agua de riego  $\delta_{x_r,y_r}$  como se muestra en (50). En este experimento, el registro de agua de riego  $\delta_{x_r,y_r}$  en el punto de control  $P^r = s(22,22)$  es  $\delta_{x_r,y_r} = 4.12$ .

Por lo tanto, las condiciones climáticas reales  $\check{C}_{i=1,3,4,5}^r$  son las condiciones climáticas que se muestran en (56) y (58)-(60), mientras que las condiciones meteorológicas reales  $\check{C}_{i=2}^r$  se calculan en (57):

$$\check{C}_{i=1}^r = C_1^r = 18.93, \quad (56)$$

$$\check{C}_{i=2}^r = C_2^r + \delta_{x_r,y_r} = 5.8 + 4.12 = 9.92, \quad (57)$$

$$\check{C}_{i=3}^r = C_3^r = 238.57, \quad (58)$$

$$\check{C}_{i=4}^r = C_4^r = 9.42, \quad (59)$$

$$\check{C}_{i=5}^r = C_5^r = 2.62. \quad (60)$$

Fig. 16. Matrices de características del paisaje  $F^{l=1,2,\dots,5}$

características del paisaje  $F^{l=1,2,\dots,L}$ . En la Fig. 16, se ilustran todas las matrices  $F^{l=1,2,\dots,L}$  de la región y el punto de control  $P^r = s(22,22)$ , el cual es utilizado en este experimento para ejemplificar el proceso.

Utilizando (27) y (28) el vector de características particulares  $\Phi^r(F^l, M^l, P^r)$  del punto  $P^r = s(22,22)$  se muestra en (51):

$$\Phi^r(F^l, M^l, P^r) = [94.172, 3.613, 1.7482, (100/A), 45.99, (100/I), (100/1), (100/1)]. \quad (51)$$

Usando (29), se realiza la comparación  $\Phi^{0,r}$ , el resultado se muestra en (52):

$$\Phi^{0,r} = [5.828, -3.613, -1.7482, (0/A), -23.23, (0/I), (0/1), (0/1)]. \quad (52)$$

La fuzificación de  $\Phi^{0,r}$  (52), la matriz de características particulares difusas  $\tilde{\Phi}^r$  de (30) se presenta en (53):

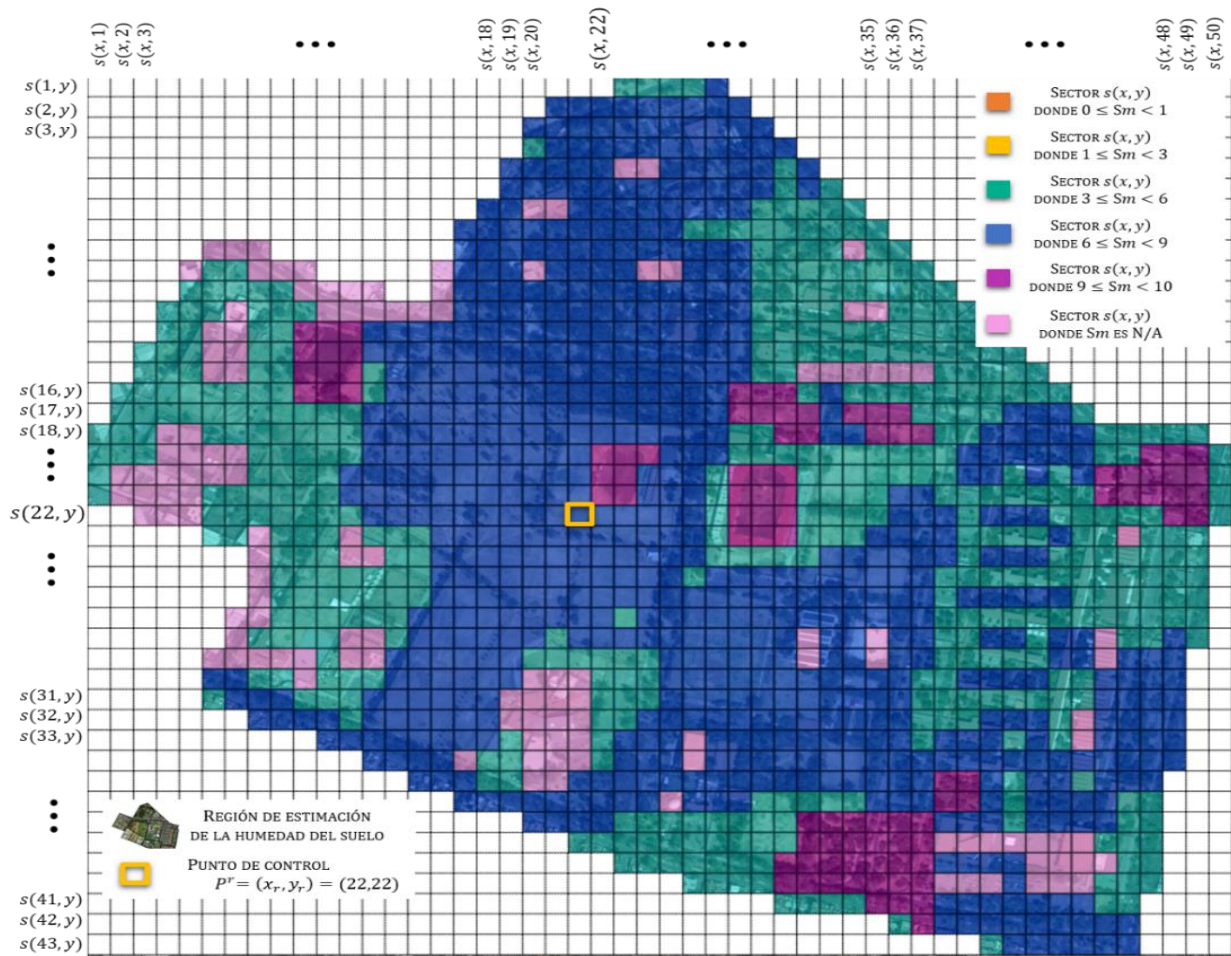


Fig. 17. Estimación regional de la humedad del suelo  $Re = \{Sm^1, Sm^2, \dots, Sm^R\}$

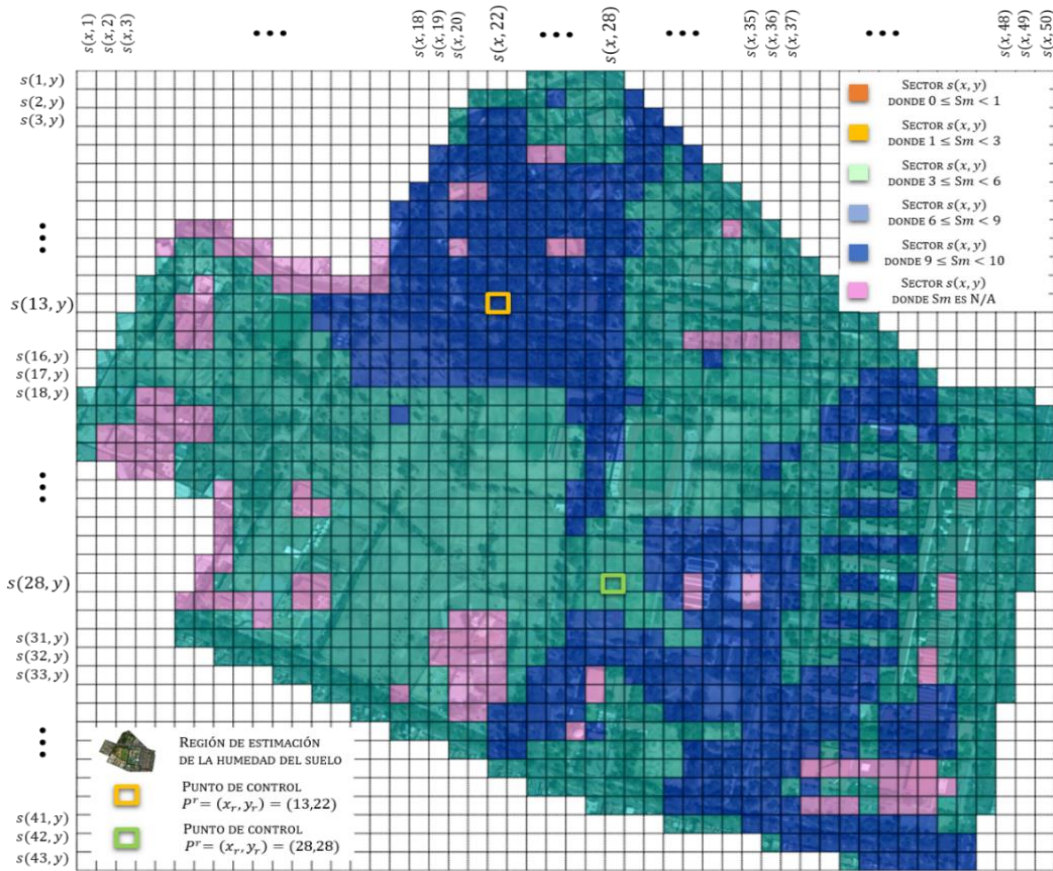
Las condiciones meteorológicas reales  $\check{C}_i^r$  son introducidas a FEADM, el cual, se ejecuta una vez por cada punto de control  $P^r$ , a diferencia de IWeCASF que se realiza solo una vez para cada estimación regional  $Re$ . Las condiciones meteorológicas reales  $\check{C}_{i=1,2,\dots,l}^{r=s(22,22)}$  son consideradas como criterios de evaluación  $C_{i=1,2,\dots,l}$ , conforme a lo establecido en la Tabla 3.

FEADM comienza con la comparación de criterios  $C_i$ , la obtención de la matriz de juicio  $\check{P}$  y del vector  $W$  mostrado en (23). La matriz de criterios difusos  $\check{C}$  de (10) en  $P^r = s(22,26)$  se muestra en (61), mientras que la matriz ponderada  $\check{C}^w$  de (12) se presenta en (62):

$$\check{C} = \begin{bmatrix} 0 & 0 & 0.986 & 0 & 0 \\ 0 & 0 & 0 & 0.52 & 0 \\ 0 & 0.0238 & 0.1032 & 0 & 0 \\ 0 & 0.6450 & 0 & 0 & 0 \\ 0 & 0 & 0.32 & 0 & 0 \end{bmatrix}, \quad (61)$$

$$\check{C}^w = \begin{bmatrix} 0 & 0 & 0.1808 & 0 & 0 \\ 0 & 0 & 0 & 0.1979 & 0 \\ 0 & 0.0061 & 0.0264 & 0 & 0 \\ 0 & 0.051 & 0 & 0 & 0 \\ 0 & 0 & 0.0325 & 0 & 0 \end{bmatrix}. \quad (62)$$

Las matrices  $D_n^k$  de (14) están determinadas por los elementos  $m_1, m_2, m_3$  de  $\Phi^r(F^l, M^t, P^r)$ , los cuales indican el tipo de suelo y de cultivo, en el punto de control  $P^r$  donde se realiza la evaluación



**Fig.18.** Estimación regional de la humedad del suelo  $Re = \{Sm^1, Sm^2, \dots, Sm^R\}$  sin considerar registro de agua de riego  $\Delta$

$e_n^k$ . Un ejemplo de los conjuntos de evaluaciones  $E^k$  es  $E^4 = \{.0264, .0061, e_n^5 = 0 \mid n = 3,4,5, \dots, 40 \}$  que corresponden al conjunto  $E^4$  de la alternativa Alta ( $A_4$ ).

La mejor evaluación  $\alpha_k$  de cada conjunto de evaluación  $E^k$  se determina utilizando (17). El conjunto de mejores evaluaciones  $\alpha_k$  resultante es  $[0,0,0,0.0264,0.0061]^T$ . De acuerdo con (18), la mejor alternativa evaluada  $\hat{A}$  es Alta ( $A_4$ ).

Finalmente, la estimación p de la humedad del suelo  $Sm^r$  se realiza con (20) para la agregación difusa y (21) para la defuzificación.

La humedad del suelo estimada  $Sm^r$  en el punto de control  $P^r = s(22,22)$  se muestra en (63), mientras que el valor de la humedad del suelo  $Sm_m^r$  medida en el mismo punto se presenta en

(64). Esta medición es realizada solo para fines comparativos  $Sm_m^r$ :

$$Sm^r = 8.84, \tag{63}$$

$$Sm_m^r = 8.55. \tag{64}$$

El análisis previo debe desarrollarse para cada punto de control  $P^r$ . El resultado es una estimación puntual de la humedad del suelo en cada sector  $s(x,y)$ . La Fig. 17 ilustra la estimación regional  $Re = \{Sm^1, Sm^2, \dots, Sm^R\}$  del área de interés. El agua de riego  $\delta_{x_r, y_r}$  aumenta el contenido de agua del suelo. Por esta razón en algunos sectores  $s(x,y)$ , los niveles de humedad del suelo son muy elevados. Además, hay áreas en las que la estimación de humedad del suelo  $Sm$

no está disponible (N/A) debido a la existencia de edificios.

### 5.3 Discusión de resultados

En el modelo integrado los resultados de IWeCASF se complementaron con la adición del registro de agua de riego. Sin embargo, si no se considera el registro de agua de riego y se aplica FEADM como se propone, los resultados serían como se muestran en la Fig. 18.

En este caso, la humedad del suelo  $Sm^r$  es mayor en los puntos de control cubiertos de árboles, por ejemplo,  $P^r = s(13,22)$  con  $Sm^r = 6.32$ , que en los puntos de control de pastizales  $Sm^r = 5.09$  como  $P^r = s(28,28)$ . Las áreas de árboles preservan mejor la humedad del suelo. El modelo integrado puede funcionar sin considerar el registro de agua de riego.

Este modelo también es adecuado para determinar la humedad del suelo en regiones de siembra por temporal.

En la Fig. 17 y la Fig. 18, cada  $s(x,y)$  es un punto de control  $P^r$  y la estimación regional  $Re = \{Sm^1, Sm^2, \dots, Sm^R\}$  está compuesta de  $R = 1366$  estimaciones puntuales  $Sm^{r=1,2,\dots,1366}$ . Un total de 921 condiciones meteorológicas medidas  $C_{i=1,2,\dots,5}^0$  se utilizan para evaluar el modelo integrado IWeCASF-FEADM.

Los errores de estimación de cuatro puntos de control  $P^r$  de la región son comparados para explicar el desempeño del modelo integrado con respecto a la distancia en la cual se realiza una estimación puntual.

Los gráficos corresponden a los puntos de control  $P^r = (17,8)$ ,  $P^r = (22,26)$ ,  $P^r = (14,35)$ ,  $P^r = (33,47)$ . Las estimaciones en el punto de control  $P^r = (17,8)$  son las más precisas, el error normalizado  $E_{RMS}$  para este punto es  $E_{RMS} = 0.0361$ , mientras el error para el  $P^r = (22,26)$  es  $E_{RMS} = 0.0479$ , para punto  $P^r = (14,35)$  el error es  $E_{RMS} = 0.0519$  y para el punto de control  $P^r = (33,47)$  el error es  $E_{RMS} = 0.0544$ .

De acuerdo con estos resultados, y al recordar la ubicación del punto de control primario  $P^0 = (18,6)$ , el desempeño del modelo integrado depende de la distancia entre el punto de control  $P^r$  y el punto de control primario  $P^0$ ; es decir, la estimación puntual de la humedad del suelo es

más precisa cuando se obtiene más cerca del punto de control donde se miden las condiciones climáticas  $C_{i=1,2,\dots,I}^0$ .

Sin embargo, los resultados obtenidos en los puntos de control dentro del rango de estimación (1.5 km), presentan un error normalizado que no implica una limitación para obtener la humedad del suelo para determinar el suministro de agua de riego. Para los puntos de control fuera de este rango, se recomienda establecer otro punto de control primario para realizar otra estimación regional.

## 6 Conclusiones

En este trabajo se desarrolló un modelo de estimación regional de la humedad del suelo con base en estimaciones puntuales.

Está compuesto por tres modelos, el primero realiza una estimación difusa basada en la toma de decisiones (FEADM) el cual permite obtener la estimación puntual de la humedad del suelo; el segundo modelo desarrollado es el ajuste inteligente de las condiciones meteorológicas basado en las características espaciales (IWeCASF), que hace posible que FEADM pueda ser usado para la estimación regional; este modelo determina las condiciones meteorológicas en cualquier punto de control, a partir de su medición en el punto primario.

El tercer modelo es la integración de los dos anteriores IWeCASF-FEADM que permite una estimación regional de la humedad del suelo a partir de un conjunto de estimaciones puntuales. En todos se consideran el tipo de cultivo, el tipo de suelo, las condiciones meteorológicas y las características del terreno como factores importantes para estimar la humedad. Mediante pruebas experimentales se verificaron los resultados los cuales fueron satisfactorios.

Los modelos desarrollados para la estimación permiten describir la variabilidad espacial de la humedad en una región de tamaño moderado. Además, consideran las interacciones entre la humedad del suelo, las condiciones meteorológicas, las características del suelo y del cultivo. Los resultados, derivados de la validación de cada uno de los modelos creados, determinan que el error de estimación obtenido es adecuado y

permite determinar el nivel de humedad minimizando las mediciones. El rango de estimación, en este trabajo, es de 1,5 km desde el punto de control primario.

## Referencias

1. **Moradkhani, H. (2008).** Hydrologic remote sensing and land surface data assimilation. *Sensors*, Vol. 8, No. 5, pp. 2986–3004. DOI: 10.3390/s8052986.
2. **Romero, R., Muriel, J.L., García, I., & Muñoz de la Peña, D. (2012).** Research on automatic irrigation control: State of the art and recent results. *Agricultural Water Management*, Vol. 114, pp. 59–66. DOI: 10.1016/j.agwat.2012.06.026.
3. **Jing, Minggang & Wu, Jitao (2013).** Fast image interpolation using directional inverse distance weighting for real-time applications. *Optics Communications*, Vol. 286, pp. 111–116. DOI: 10.1016/j.optcom.2012.09.011.
4. **Zhang, Yanjun, Xian, Cuiling, Chen, Huajin, Grieneisen, M.L., Liu, Jiaming, & Zhang, Minghua (2016).** Spatial interpolation of river channel topography using the shortest temporal distance. *Journal of Hydrology*, Vol. 542, pp. 450–462. DOI: 10.1016/j.jhydrol.2016.09.022.
5. **Gasch, C.K., Hengl, T., Graler, B., Meyer, H., Magney T.S., & Brown, D.J. (2015).** Spatio-temporal interpolation of soil water, temperature, and electrical conductivity in 3D + T: The Cook Agronomy Farm data set. *Spatial Statistics*, Vol. 14, Part A, pp. 70–90. DOI: 10.1016/j.spasta.2015.04.001.
6. **Plouffe, C.C.F., Robertson, C. & Chandrapala, L. (2015).** Comparing interpolation techniques for monthly rainfall mapping using multiple evaluation criteria and auxiliary data sources: A case study of Sri Lanka. *Environmental Modelling & Software*, Vol. 67, pp. 57–71. DOI: 10.1016/j.envsoft.2015.01.011.
7. **Shtiliyanova, A., Bellocchi, G., Borrás, D., Eza, U., Martín, R., & Carre, P. (2017).** Kriging-based approach to predict missing air temperature data. *Computers and Electronics in Agriculture*, Vol. 142 Part A, pp. 440–449. DOI: 10.1016/j.compag.2017.09.033.
8. **Ohmer, M., Liesch, T., Goeppert, N., & Goldscheider, N. (2017).** On the optimal selection of interpolation methods for groundwater contouring: An example of propagation of uncertainty regarding inter-aquifer exchange. *Advances in Water Resources*, Vol. 109 Supplement C, pp. 121–132. DOI: 10.1016/j.advwatres.2017.08.016.
9. **Ahmad, S., Kalra, A., & Stephen, H. (2010).** Estimating soil moisture using remote sensing data: A machine learning approach. *Advances in Water Resources*, Vol. 33, No. 1, pp. 69–80. DOI: 10.1016/j.advwatres.2009.10.008.
10. **Clark, M.P., Rupp, D.E., Woods, R.A., Zheng, X., Ibbitt, R.P., Slater, A.G., Shmidt, J., & Uddstrom, M.J. (2008).** Hydrological data assimilation with the ensemble Kalman filter: Use of streamflow observations to update states in a distributed hydrological model. *Advances in Water Resources*, Vol. 31, No. 10, pp. 1309–1324. DOI: 10.1016/j.advwatres.2008.06.005.
11. **Goumopoulos, C., O'Flynn, B., & Kameas, A. (2014).** Automated zone-specific irrigation with wireless sensor/actuator network and adaptable decision support. *Computers and Electronics in Agriculture*, Vol. 105, pp. 20–33. DOI: 10.1016/j.compag.2014.03.012.
12. **Flores-Carrillo, D.A., Sánchez-Fernández, L.P., Sánchez-Pérez, L.A., & Carbajal-Hernández, J.J. (2017).** Soil moisture Fuzzy Estimation Approach based on Decision-Making. *Environmental Modelling and Software*, Vol. 91, pp. 223–240. DOI: 10.1016/j.envsoft.2017.01.018.
13. **Zanetti, S.S., Cecílio, R.A., Alves, E.G., Silva, V.H., & Fernandes-Sousa, E. (2015).** Estimation of the moisture content of tropical soils using colour images and artificial neural networks. *CATENA*, Vol. 135, pp. 100–106. DOI: 10.1016/j.catena.2015.07.015.
14. **Zou, L., Wang, L., Lin, A., Zhu, H., Peng, Y., & Zhao, Z. (2016).** Estimation of global solar radiation using an artificial neural network based on an interpolation technique in Southeast China. *Journal of Atmospheric and Solar-Terrestrial Physics*, Vol. 146, pp. 110–122. DOI: 10.1016/j.jastp.2016.05.013.
15. **Kashif-Gill, M., Kemblowski, M.W., & McKee, M. (2007).** Soil moisture data assimilation using support vector machines and ensemble Kalman filter. *Journal of the American Water Resources Association*, Vol. 43, No. 4, pp. 1004–1015. DOI: 10.1111/j.1752-1688.2007.00082.x.
16. **Kumar, S.V., Peters-Lidard, C.D., Eastman J.L., & Tao, W.K. (2008).** An integrated high-resolution hydrometeorological modeling testbed using LIS and WRF. *Environmental Modelling & Software*, Vol. 23, No. 2, pp. 169–181. DOI: 10.1016/j.envsoft.2007.05.012.
17. **Liu, D., Yu, Z.-b., & L, H.-s. (2010).** Data assimilation using support vector machines and

- ensemble Kalman filter for multi-layer soil moisture prediction. *Water Science and Engineering*, Vol. 3, No. 4, pp. 361–377.
18. **Munro, R.K., Lyons W.F., Shao, Y., Wood, M.S., Hood, L.M., & Leslie L.M. (1998).** Modelling land surface–atmosphere interactions over the Australian continent with an emphasis on the role of soil moisture. *Environmental Modelling & Software*, Vol. 13, No. 3-4, pp. 333–339. DOI: 10.1016/S1364-8152(98)00038-3.
  19. **Chang, D.Y. (1996).** Applications of the extent analysis method on fuzzy AHP. *European Journal of Operational Research*, Vol. 95, No. 3, pp. 649–655. DOI: 10.1016/0377-2217(95)00300-2.
  20. **Wang, Y.M., Luo, Y., & Hua, Z. (2008).** On the extent analysis method for fuzzy AHP and its applications. *European Journal of Operational Research*, pp. 735–747. DOI: 10.1016/j.ejor.2007.01.050.
  21. **Sen, C.G. & Cinar, G. (2010).** Evaluation and pre-allocation of operators with multiple skills: A combined fuzzy AHP and max–min approach. *Expert Systems with Applications*, pp. 2043–2053. DOI: 10.1016/j.eswa.2009.06.075.
  22. **Zadeh, L.A. (1965).** *Information and control*. University of California. Berkley, California, pp. 338–353.
  23. **Flores-Carrillo, D.A, et al. (2017).** Soil moisture fuzzy estimation approach based on decision-making. Vol. 91, pp. 223–240.
  24. **Liou, T.S. & Wang, J.M. (1992).** Ranking fuzzy numbers with integral value. *Fuzzy Sets and Systems*, pp. 247–255. DOI: 10.1016/0165-0114(92)90223-Q.
  25. **Elshorbagy, A. & Parasuraman, K. (2008).** On the relevance of using artificial neural networks for estimating soil moisture content. *Journal of Hydrology*, Vol. 362, No. 1-2, pp. 1–18. DOI: 10.1016/j.jhydrol.2008.08.012.
  26. **Hwang, C.L. & Yoon, K. (1981).** *Multiple attributes decision making methods and applications*. Berlin: Springer.
  27. **Behzadian, M., Khanmohammadi-Otaghsarab, S., Yazdanib, M., & Ignatiuscet, J. (2012).** A state of the art survey of TOPSIS applications. *Expert Systems with Applications*, pp. 13051–13069. DOI: 10.1016/j.eswa.2012.05.056.
  28. **Deng, H., Yeh, C.-H. & Willis, R.J. (2000).** Inter-company comparison using modified TOPSIS with objective weights. *Computers & Operations Research*, pp. 963–973. DOI: 10.1016/S0305-0548(99)00069-6.
  29. **Cheng, S., Chan, C.W., & Huang, G.H. (2003).** An integrated multi-criteria decision analysis and inexact mixed integer linear programming approach for solid waste management. *Engineering Applications of Artificial Intelligence*, pp. 543–554. DOI: 10.1016/S0952-1976(03)00069-1.
  30. **Vahdani, B., Mousavi, S.M., & Tavakkoli-Moghaddam, R. (2011).** Group decision making based on novel fuzzy modified TOPSIS method. *Applied Mathematical Modelling*, pp. 4257–4269. DOI: 10.1016/j.apm.2011.02.040.
  31. **Yei, F. & Li, Y. (2014).** An extended TOPSIS model based on the possibility theory under fuzzy environment. *Knowledge-Based Systems*, pp. 263–269. DOI: 10.1016/j.knosys.2014.04.046.
  32. **FAO (2010).** World Programme for the Census of Agriculture 2010. Rome, pp. 142–146.
  33. **Narasimhan, B. & Srinivasan, R. (2005).** Development and evaluation of Soil Moisture Deficit Index (SMDI) and Evapotranspiration Deficit Index (ETDI) for agricultural drought monitoring. *Agricultural and Forest Meteorology*, Vol. 133, No. 1-4, pp. 69–88. DOI: 10.1016/j.agrformet.2005.07.012.
  34. **Flores-Carrillo, D.A., Sánchez-Fernández, L.P., Sánchez-Pérez, L.A., Carbajal-Hernández, J.J. (2017).** Soil moisture fuzzy estimation approach based on decision-making. *Environmental Modelling & Software*, Vol. 91, pp. 223–240. DOI: 10.1016/j.envsoft.2017.01.018.
  35. **Sheeren, D., Ouin, A., Bastin, N., & Ladet, S. (2009).** Discriminating small wooded elements in rural landscape from aerial photography: A hybrid pixel/object-based analysis approach. *International Journal of Remote Sensing*, Vol. 30, No. 19, pp. 4979–4990. DOI: 10.1080/01431160903022928.
  36. **Aksoy, S., Akçay, H.G., & Wassenaar, T. (2010).** Automatic mapping of linear woody vegetation features in agricultural landscapes using very high resolution imagery. *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 48, No. 1, pp. 511–522. DOI: 10.1109/TGRS.2009.2027702.
  37. **Eckert, S., Tesfay-Ghebremicael, S., Hurni, H., & Kohler, T. (2017).** Identification and classification of structural soil conservation measures based on very high resolution stereo satellite data. *Journal of Environmental Management*, Vol. 193, pp. 592–606. DOI: 10.1016/j.jenman.2017.02.061.
  38. **Chianucci, F., Disperatib, L., Guzzi, D., Bianchini, D., Nardino, V., Lastrì, C., Rindinella, A., & Corona, P. (2016).** Estimation of canopy attributes in beech forests using true colour digital images from a small fixed-wing UAV. *International Journal of Applied Earth Observation and*

*Geoinformation*, Vol. 47, pp. 60–68. DOI: 10.1016/j.jag.2015.12.005.

39. **Sadeghi, M., Jones, S.B., & Philpot, W.D. (2015).** A linear physically-based model for remote sensing of soil moisture using short wave infrared bands. *Remote Sensing of Environment*, Vol. 164, pp. 66–76. DOI: 10.1016/j.rse.2015.04.007.
40. **Mora, M., Avila, F., Carrasco-Benavides, M., Maldonado, G., Olguín-Cáceres, J., & Fuentes, S. (2016).** Automated computation of leaf area index from fruit trees using improved image processing algorithms applied to canopy cover digital photographs. *Computers and Electronics in Agriculture*, Vol. 123, pp. 195–202. DOI: 10.1016/j.compag.2016.02.011.
41. **Persson, M. (2005).** Estimating surface soil moisture from soil color using image analysis. *Vadose Zone Journal*, Vol. 4, No.4, pp. 1119–1122. DOI: 10.2136/vzj2005.0023.
42. **Macfarlane, C., Hoffman, M., Eamus, D., Kerp, N., Higginson, S., McMurtrie, R., & Adams, M. (2007).** Estimation of leaf area index in eucalypt forest using digital photography. *Agricultural and Forest Meteorology*, Vol. 143, No. 3, pp. 176–188. DOI: 10.1016/j.agrformet.2006.10.013.
43. **Mokhtarzade, M. & Valadan-Zoej, M.J. (2007).** Road detection from high-resolution satellite images using artificial neural networks. *International Journal of Applied Earth Observation and Geoinformation*, Vol. 9, No. 1, pp. 32–40. DOI: 10.1016/j.jag.2006.05.001.
44. **Niu, X. (2006).** A semi-automatic framework for highway extraction and vehicle detection based on a geometric deformable model. *ISPRS Journal of Photogrammetry and Remote Sensing*, Vol. 61, No. 3, pp. 170–186. DOI: 10.1016/j.isprsjprs.2006.08.004.
45. **Gillespie, A.R., Kahle, A.B., & Walker, R.E. (1986).** Color enhancement of highly correlated images. I. Decorrelation and HSI contrast stretches. *Remote Sensing of Environment*, Vol. 20, No. 3, pp. 209–235. DOI: 10.1016/0034-4257(86)90044-1.
46. **Gillespie, A.R. (1992).** Enhancement of multispectral thermal infrared images: Decorrelation contrast stretching. *Remote Sensing of Environment*, Vol. 42, No. 2, pp. 147–155. DOI: 10.1016/0034-4257(92)90098-5.
47. **Giorgio, G.A., Ragosta, M., & Telesca, V. (2017).** Application of a multivariate statistical index on series of weather measurements at local scale. *Measurement*, Vol. 112 Supplement C, pp. 61–66. DOI: 10.1016/j.measurement.2017.08.005.

*Article received on 12/08/2019; accepted on 25/11/2019.  
Corresponding author is Luis Pastor Sánchez Fernández.*