
SISTEMA DE MEDICIÓN/MONITOREO, REPORTE Y VERIFICACIÓN (MRV) ASOCIADO AL BANCO MEXICANO DEL CARBONO: RASGOS PRINCIPALES

MEASUREMENT/MONITORING, REPORTING AND VERIFICATION (MRV) SYSTEM ASSOCIATED WITH THE MEXICAN CARBON BANK: MAIN FEATURES

Fernando Paz-Pellat^{1‡}

¹Programa Mexicano del Carbono y Colegio de Postgraduados, Campus Montecillo. Carretera México-Texcoco km 36.5, CP 56230, Montecillo, Texcoco, Estado de México.

[‡]Autor para correspondencia: ferpazpel@gmail.com

RESUMEN

El sistema de medición/monitoreo, reporte y verificación (MRV) es un factor crítico en la implementación de los mercados del carbono. Bajo la perspectiva de la iniciativa del Banco Mexicano del Carbono (BAMCAR) del Programa Mexicano del Carbono, el sistema MRV puede simplificarse para considerar solo la conservación de los almacenes de carbono, principalmente forestal. La estrategia de muestreo del sistema MRV de BAMCAR considera la diferencia mínima detectable en los almacenes de carbono para la implementación del diseño experimental. De igual manera, se considera la incertidumbre asociada a las estimaciones, para definir procedimientos de muestreo y verificación de los datos. En otra perspectiva, la fusión (integración) de datos duros (cuantitativos) y blandos (semicuantitativos) permite el desarrollo de estrategias de sistemas MRV que consideran a los inventarios comunitarios y profesionales en un marco común, que permite realizar estimaciones respetando las incertidumbres asociadas a los datos blandos. La estimación de la distribución de probabilidad acumulada, mediante el uso de variables indicadoras, permite obtener la caracterización completa de los errores de estimación (intervalos de confianza). La extensión de las estimaciones con un procedimiento óptimo de estimación (Kriging), permite hacer uso intensivo de los datos duros y blandos para definir las funciones indicadoras de covarianza espacial, incrementando el número de datos disponibles.

Palabras clave: diferencia mínima detectable; errores tipo I y II; distribución acumulada de probabilidad; variables indicadoras; datos duros y blandos; funciones indicadoras de covarianza.

ABSTRACT

The measurement/monitoring, reporting and verification (MRV) system is a critical factor in the implementation of carbon markets. Under the perspective of the initiative of the Mexican Carbon Bank (BAMCAR) of the Mexican Carbon Program, the MRV system can be simplified to consider only the conservation of carbon stocks, mainly in the forest sector. The sampling strategy of the BAMCAR MRV system considers the minimum detectable difference in carbon stocks for the implementation of the experimental design. Likewise, the uncertainty associated with the estimates is considered to define sampling and data verification procedures. From another perspective, the fusion (integration) of hard (quantitative) and soft (semi-quantitative) data allows the development of MRV system strategies that consider community and professional inventories in a common framework that allows estimates

to be made while respecting the uncertainties associated with the soft data. The estimation of the cumulative probability distribution using indicator variables allows to obtain the complete characterization of the estimation errors (confidence intervals). The extension of the estimates with an optimal estimation procedure (Kriging) allows intensive use of hard and soft data to define the indicator functions of spatial covariance, increasing the number of available data.

Keywords: *minimum detectable difference; type I and II errors; cumulative probability distribution; indicator variables; hard and soft data; indicator covariance functions.*

INTRODUCCIÓN

Los mecanismos de pagos de créditos o bonos de carbono, requieren que las actividades de reducción de emisiones de gases efecto invernadero (GEI) o de secuestro de carbono sean medibles y verificables por terceros, para considerarse como susceptibles de recibir incentivos financieros. En el sector forestal, por ejemplo, el mecanismo REDD+ (Reducción de Emisiones de GEI por Deforestación y Degradación forestal evitada más la conservación e incremento de los almacenes de carbono y el manejo forestal sustentable) (Angelsen *et al.*, 2021) requiere de un sistema de medición/monitoreo, reporte y verificación (MRV) que asegure (verifique) el cumplimiento de los estándares de reducción de emisiones (Hewson *et al.*, 2014). Asimismo, en otras actividades o sectores, el cumplimiento de estándares o protocolos para reducción de emisiones o secuestro de carbono para generar bonos de carbono certificados (verificados), es una actividad crítica (Climate Action Reserve, 2020; FAO, 2019, 2020; GOFC-GOLD, 2016; IPCC, 2003, 2006, 2019; VCS, 2012c, 2020). Los sistemas MRV generalmente participan en una proporción importante de los costos de implementación, por lo que es necesario reducirlos a través de enfoques metodológicos alternativos, confiables y robustos.

En la iniciativa del Banco Mexicano del Carbono (BAMCAR) del Programa Mexicano del Carbono (PMC) el sistema MRV se planteó para incorporar esquemas de muestreo con menos requerimientos y sistemas de medición/monitoreo que permitan la participación de las comunidades (McCall *et al.*, 2016; Paz *et al.*, 2012; Skutsch, 2011), en conjunto con sistemas basados en conocimiento experto de tipo profesional.

La iniciativa de BAMCAR en sector forestal está orientada, principalmente, a la conservación

(no deforestación y no degradación forestal) de los almacenes de carbono en los bosques, por lo que es importante direccionar los esquemas de muestreo y medición/monitoreo a esta actividad.

En el presente trabajo se presentan y discuten los principales rasgos del sistema MRV asociado a BAMCAR, para establecer lineamientos generales para el desarrollo de protocolos, principalmente forestales; aunque cabe señalar que el enfoque sectorial y de actividades de BAMCAR es más amplio.

Sistema MRV asociado a BAMCAR

Los principales rasgos del sistema MRV asociado a BAMCAR son el protocolo de muestreo y verificación, así como el de fusión (integración) de información de los monitoreos comunitarios con los profesionales.

Protocolo de muestreo y verificación

El diseño de muestreo para el proceso de caracterización y verificación de los cambios de los almacenes de carbono, es crítico para determinar las variaciones asociadas a los almacenes y definir sus costos. El muestreo más utilizado es el estratificado, el cual se basa en la delimitación de estratos o clases de los objetos con propiedades similares, a través del análisis de los factores o atributos que contribuyen a definir sus rasgos característicos (VCS, 2012a). Delimitados los estratos, promedios y desviaciones estándar, el siguiente paso consiste en asignar el número de muestras a cada estrato (Pearson *et al.*, 2007; UNFCCC, 2010). A diferencia del muestreo aleatorio simple (un solo estrato), el muestreo estratificado requiere de menos muestras.

En el caso de BAMCAR, el enfoque de muestreo debe estar orientado a detectar cambios en los almacenes de carbono (la hipótesis nula corresponde a no cambios), por lo que el diseño debe detectar la

diferencia mínima detectable (DMD) en sitios pareados (mismas unidades experimentales) con un tratamiento (Zar, 2010):

$$\delta \geq \left(\frac{s}{\sqrt{n}}\right) (t_{\alpha(2),v} + t_{\beta(1),v}) \quad (1)$$

donde δ es la MDD, s es la desviación estándar de las diferencias de la variable analizada, n es el número de muestras (réplicas), $v = n - 1$, son los grados de libertad de la distribución t relevante, $t_{\alpha(2)}$ el valor crítico, doble cola, de la distribución t a un nivel de significancia α (error tipo I) y $t_{\beta(1)}$ es el cuartil, una sola cola, de la distribución t correspondiente a una probabilidad β de error tipo II. El número de muestras puede determinarse de:

$$n \geq \left(\frac{s}{\delta}\right)^2 (t_{\alpha(2),v} + t_{\beta(1),v})^2 \quad (2)$$

El nivel α es la probabilidad de cometer un error tipo I (la hipótesis nula es cierta, pero es incorrectamente rechazada por la prueba) y β es una probabilidad que está asociada al error tipo II (rechazo de la hipótesis nula de no cambio cuando en realidad un cambio ha ocurrido).

Para el caso de un diseño experimental independiente (diferentes unidades experimentales), es necesario cambiar \sqrt{n} por $\sqrt{\frac{n}{2}}$ en la relación (1) y utilizar $2\left(\frac{s}{\delta}\right)^2$ en lugar de $\left(\frac{s}{\delta}\right)^2$ en la relación (2) y utilizar $v = 2(n - 1)$.

Es práctica común utilizar $\alpha = 0.05$ y $\beta = 0.2$, aunque esta regla ha sido cuestionada por Di Stefano (2003), por lo que es necesario realizar un análisis racional para determinar α y β al considerar los costos relativos de los errores tipo I y II.

Las relaciones que se muestran, son válidas para varianzas similares en el tiempo t_0 y t_1 de las unidades experimentales pareadas. Para el caso de varianzas diferentes, es necesario realizar ajustes a las relaciones utilizadas (Zar, 2010). Si $n \geq 30$, la prueba es robusta y muestra efectos resistentes a violar la hipótesis de la prueba t con $\alpha = 0.05$, a pesar de las disparidades entre σ_0^2 y σ_1^2 (Zar, 2010). Si las varianzas son iguales, la prueba t es muy robusta a la no normalidad (Zar, 2010). Si las varianzas no son iguales y n es diferente, la probabilidad de un error tipo I será diferente del α establecido.

El enfoque de muestreo propuesto está orientado a la detección de diferencias mínimas detectables de los cambios de los almacenes de carbono, por lo que el número de muestras es función de la variabilidad espacial presente.

Para el proceso de verificación de los cambios en los almacenes de carbono se puede utilizar un muestreo secuencial (Climate Action Reserve, 2012; Fairweather, 1985), donde se establecen reglas para parar el muestreo, cuando las condiciones establecidas han sido satisfechas.

Manejo de la incertidumbre en las estimaciones

Para la cuantificación del carbono no es necesario medir todos los cambios en los almacenes, a menos de que haya evidencia de las actividades que los provocan, simplificando el proceso de análisis (Hamburg, 2000).

La estimación de la incertidumbre en los cambios de los almacenes de carbono, se basan en los intervalos de confianza establecidos (IPCC, 2003), por lo que se ha propuesto la utilización de factores de descuento para el manejo de la incertidumbre (Hamburg, 2000; Schlamadinger *et al.*, 2005). La Figura 1 muestra una propuesta (Schlamadinger *et al.*, 2005) para descontar los bonos de carbono por la incertidumbre asociada, utilizando intervalos de confianza. El bono se recibe completo si se utiliza el límite inferior del intervalo de confianza y sufre descuentos progresivos al acercarse al límite superior.

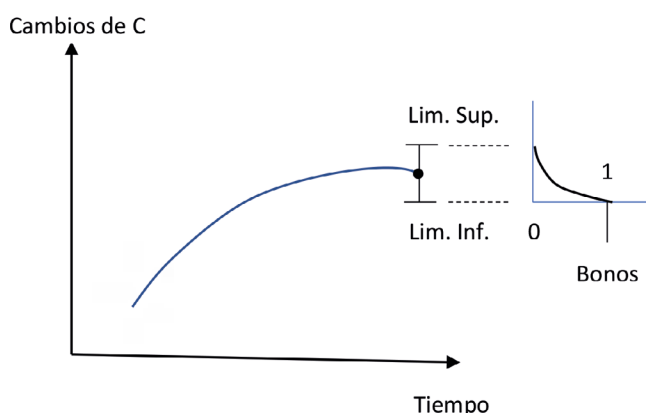


Figura 1. Descuento de bonos de carbono en función del intervalo de confianza de los cambios de los almacenes de carbono. Adaptado de Schlamadinger *et al.* (2005).

Para evitar, particularmente, sobreestimaciones se ha propuesto adoptar el principio del conservadurismo (Grassi *et al.*, 2008; Mollicone *et al.*, 2007), el cual aplica criterios conservadores en las estimaciones. Por ejemplo, si no se cuenta con todas las estimaciones de los almacenes, entonces se pueden eliminar los almacenes sin información (Grassi *et al.*, 2008).

Los reportes de emisiones de GEI o secuestro de carbono deben ser transparentes, consistentes, comparables, completos y precisos (Grassi *et al.*, 2008). Así, para reportes incompletos, el principio del conservadurismo evita las sobreestimaciones.

En la Figura 2 se muestran dos enfoques para considerar la incertidumbre en las estimaciones de los almacenes.

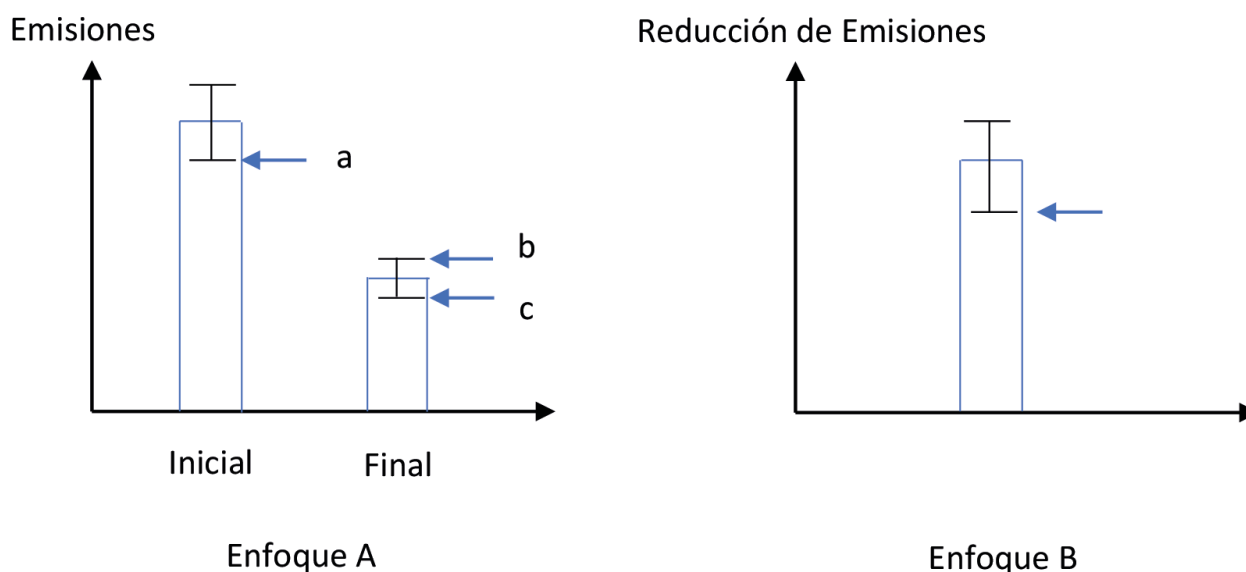


Figura 2. Perspectivas para aplicación de enfoques de conservadurismo en emisiones. Adaptado de Grassi *et al.* (2008).

En el enfoque A1 se pueden utilizar dos esquemas: $A1 = a - c$ basado en el concepto de línea base conservadora y $A2 = a - b$, basado en el estimado mínimo confiable (*reliable minimum estimate*; IPCC, 2003). En el caso del enfoque B, se usa el límite inferior del estimado del intervalo de confianza de las reducciones de emisiones. Grassi *et al.* (2008) han propuesto que el enfoque B es más adecuado para el mecanismo REDD+. No obstante, Sheng (2017) argumenta que el enfoque B no es consistente con la meta de establecer un sistema MRV confiable, por lo que se recomienda el enfoque A basado en el estimado mínimo confiable.

La estimación de los bonos de carbono puede establecerse en función del intervalo de confianza, definiendo un valor crítico en donde no se aplican descuentos y, posteriormente, definir descuentos en forma proporcional al error de estimación, hasta un umbral en donde el muestreo no mejora el error y se rechaza la estimación aplicable al límite impuesto (Climate Action Reserve, 2020).

Estimados de cambios en el carbono orgánico de los suelos

Para ejemplificar las aplicaciones de la diferencia mínima detectable (DMD), en esta sección se analiza el caso del carbono orgánico de los suelos. Pueden revisarse los protocolos para estimar los almacenes (VCS, 2012b), así como los asociados a estimar los cambios de los almacenes de carbono (VCS, 2012c), para tener un contexto de metodologías aceptadas; aunque diferentes a la propuesta.

La detección de cambios en el carbono orgánico de los suelos (COS) forestales y de diferencias entre los tratamientos, es importante para entender las alteraciones en el secuestro de carbono (Conen *et al.*, 2003; Homann *et al.*, 2001; Post *et al.*, 2001). La DMD en los suelos forestales es típicamente grande (Conant *et al.*, 2003; Homann *et al.*, 2001; Yanai *et al.*, 2003). Los suelos forestales no perturbados tienen almacenes del COS con valores altos (Conant *et al.*, 2003; Yanai *et al.*, 2003), por lo que los métodos deben considerar la variabilidad espacial en el caso de resolver los cambios

con relación a almacenes de carbono grandes en los suelos (Post *et al.*, 2001).

Las DMD pueden reducirse al seleccionar diseños experimentales ventajosos (Conant *et al.*, 2003; Homann *et al.*, 2001; Yanai *et al.*, 2003). Por ejemplo, se ha observado una disminución considerable en las DMD en muestreos pareados con relación a muestreos independientes (Ellert *et al.*, 2002; Yanai *et al.*, 2003); aunque Conant *et al.* (2003) solo observó estas diferencias en tres de cuatro sitios, atribuyendo las diferencias a la variabilidad espacial observada.

El uso de modelos para analizar cambios en los almacenes del COS, se ha utilizado para predecir los cambios a futuro después de la primera medición (Conen *et al.*, 2003; Nécipalová *et al.*, 2014; Smith, 2004). Los modelos de simple parametrización como el RothC (Coleman y Jenkinson, 1996) pueden ser útiles en la consecución de este objetivo.

El uso de técnicas geoestadísticas (Govaerts, 1997) para reducir los errores de estimación, es recomendable, ya que considera la variabilidad espacial del COS, (Allen *et al.*, 2010; Kirwan *et al.*, 2005; Mooney *et al.*, 2007).

La detección de la DMD se ha usado en tratamientos únicos (Ellert, 2002; Kravchenko y Robertson, 2011; Maillard *et al.*, 2017; Yanai *et al.*, 2003) y múltiples (Conant *et al.*, 2003; Garten y Wullschleger, 1999; Homann *et al.*, 2001, 2008).

Para estimar la DMD puede utilizarse el coeficiente de variación ($CV = s/m$. desviación estándar entre el promedio) para el caso de muestreos independientes (Conant *et al.*, 2003; Maillard *et al.*, 2017):

$$\Delta \geq \left(\frac{CV}{\sqrt{\frac{n}{2}}} \right) (t_{\alpha(2),v} + t_{\beta(1),v}) \quad (3)$$

donde Δ es la DMD (en % de la media de la primera medición), CV es el coeficiente de variación de la primera medición (%).

El almacén del COS se estima de (Poeplau *et al.*, 2017):

$$COS = CCO \times DAP_{ff} \times (1 - FG_v) \times P \times 0.1 \quad (4)$$

donde COS ($Mg\ C\ ha^{-1}$) es el almacén de carbono, CCO es la concentración de carbono orgánico del suelo ($mg\ C\ g^{-1}$ suelo fino), DAP_{ff} es la densidad aparente del suelo fino ($\leq 2mm$) ($g\ suelo\ cm^{-3}$ suelo fino), FG_v es la

fracción de fragmentos grueso ($> 2mm$) por volumen y P es la profundidad del suelo (cm).

La variabilidad del COS es dependiente de la escala (Vanguelova *et al.*, 2016) y está asociada a diversos factores (FAO, 2019), tales como el clima, el tipo de suelo, la hidrología, la topografía, el uso del suelo, su manejo e historia de uso. Vanguelova *et al.* (2016) revisa las fuentes de error e incertidumbres, así como los métodos de medición de las variables que intervienen en la estimación del almacén del COS, relación (4), desde la perspectiva de la escala de muestras, parcela, paisaje, región y país.

Vandenbygaart y Angers (2006) discuten las barreras para realizar mediciones precisas de las variables que intervienen en la estimación del COS, relación (4). Estos autores presentan sugerencias para reducir los errores tipo II. Uno de los procesos más críticos para la estimación del COS, es el uso de la masa equivalente del suelo (MES), compensación de cambios en la densidad aparente del suelo (Ellert y Bettany, 1995). Otro factor a considerar es si el COS se encuentra en estado estacionario (máximo o mínimo valor), ya que, de ser así, no se esperan cambios de estado. Los análisis de la densidad aparente del suelo, la concentración del carbono orgánico y el almacén del COS, ha sido analizada por Chaudhuri *et al.* (2011) con relación a diferentes usos del suelo, concluyendo que los cambios no están relacionados con el uso del suelo y dependen de factores específicos a los sitios.

Fusión (integración) de información

El uso de información semicuantitativa (cualitativa) en la medición/monitoreo de los almacenes de carbono ha sido propuesto por Paz *et al.* (2012), como un medio para la fusión (integración) de información multi-fuente (Paz y de Jong, 2012). De esta manera se utiliza el concepto de capacidades diferenciadas en las mediciones/monitoreos de los almacenes de carbono, con estimaciones indirectas, usando monitoreo comunitario y mediciones convencionales, profesionales. Se han establecido protocolos para las mediciones semicuantitativas (PMC, 2011c, 2015), así como aquellos relacionados con los muestreos cuantitativos o convencionales (PMC, 2011b), diseñados en función de los lineamientos establecidos por la Comisión Nacional Forestal (CONAFOR) en el Inventario Nacional Forestal y de Suelos (INFyS) (CONAFOR, 2009). También se han establecido los lineamientos para los muestreos cuantitativos y semicuantitativos (PMC, 2011a).

El uso de información indirecta (imprecisa) requiere de la noción de calidad de los datos, la cual es un criterio legítimo para su clasificación. El procedimiento utilizado para la integración de información “blanda” o indirecta se fundamenta en el Teorema de Bayes. En lo siguiente se presenta una discusión de la integración de información blanda y dura (mediciones convencionales), con base en los desarrollos de Alabert (1987), documentados también en Wingle y Poeter (1998).

Teorema de Bayes. Se utilizará la convención de denotar a la variable aleatoria dura como \hat{z} y a la variable aleatoria z como blanda.

El Teorema de Bayes, a nivel de distribuciones de probabilidad, puede plantearse como:

$$f(z|\hat{z}) = \frac{f(\hat{z}|z) \times f_z(z)}{f_{\hat{z}}(\hat{z})} \quad (5)$$

donde:

$f_z(z)$ es la función densidad de probabilidad marginal de la variable aleatoria Z

$f_{\hat{z}}(\hat{z})$ es la función densidad de probabilidad marginal de la variable aleatoria \hat{Z}

$f(z|\hat{z})$ es la función densidad de probabilidad la variable aleatoria Z dado $\hat{Z} = \hat{z}$

$f(\hat{z}|z)$ es la función densidad de probabilidad la variable aleatoria \hat{Z} dado $Z = z$

En la relación (5) el término $f_{\hat{z}}(\hat{z})$ es una constante, por lo que la función de verosimilitud $f(\hat{z}|z)$ determina la actualización de la densidad de probabilidad *a priori* $f_z(z)$ a la densidad de probabilidad *a posteriori* $f(z|\hat{z})$.

La Figura 3 muestra un ejemplo del uso del Teorema de Bayes para la actualización de las probabilidades con base en la función de verosimilitud $f(\hat{z}|z)$.

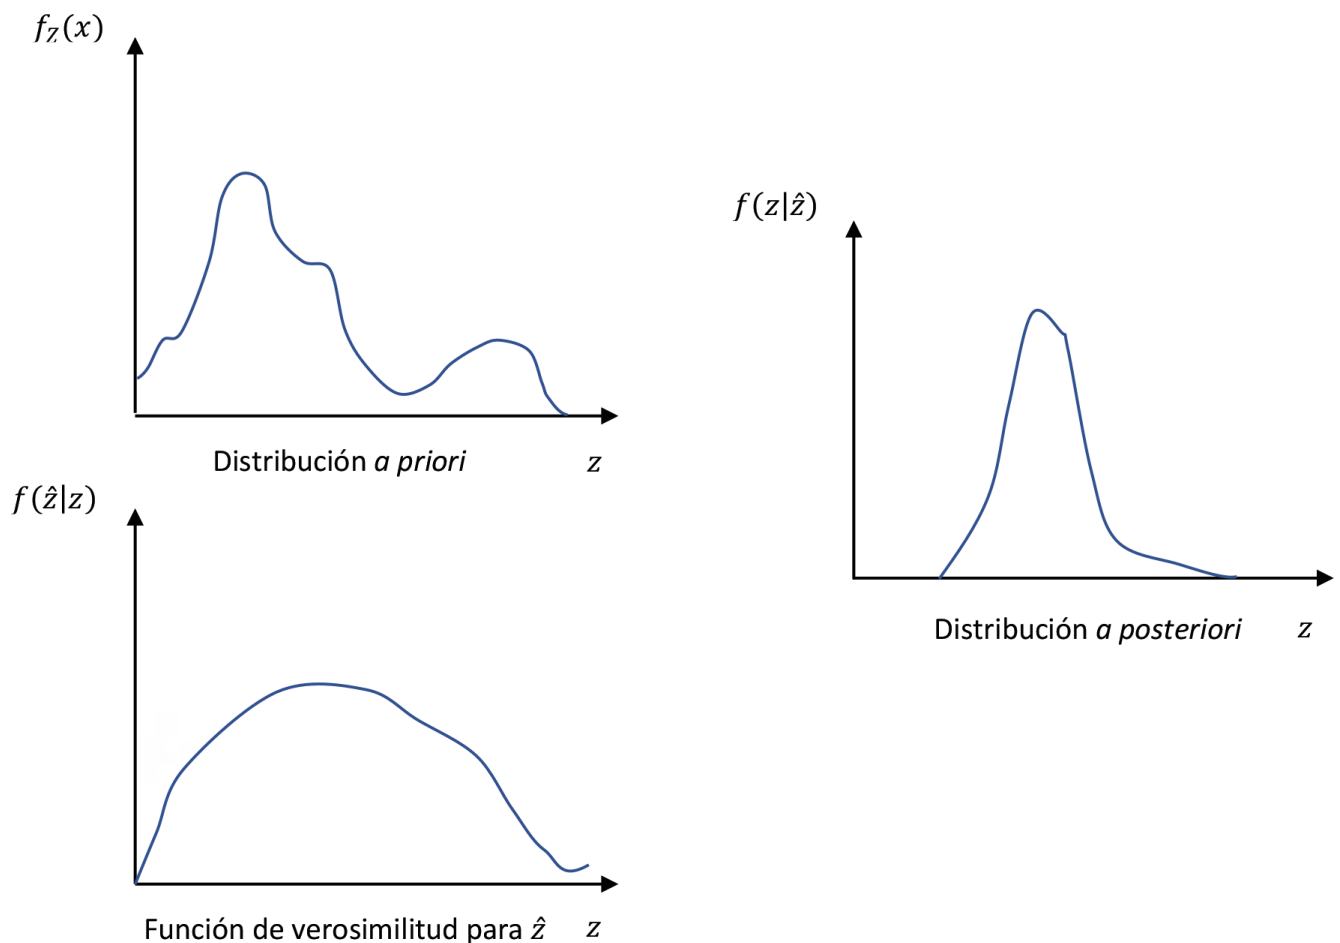


Figura 3. Actualización de probabilidades con el uso de la función de verosimilitud.

En el caso de datos duros (sin error), la Figura 4 muestra el uso del Teorema de Bayes que expone que

la función de verosimilitud genera estimaciones de datos duros.

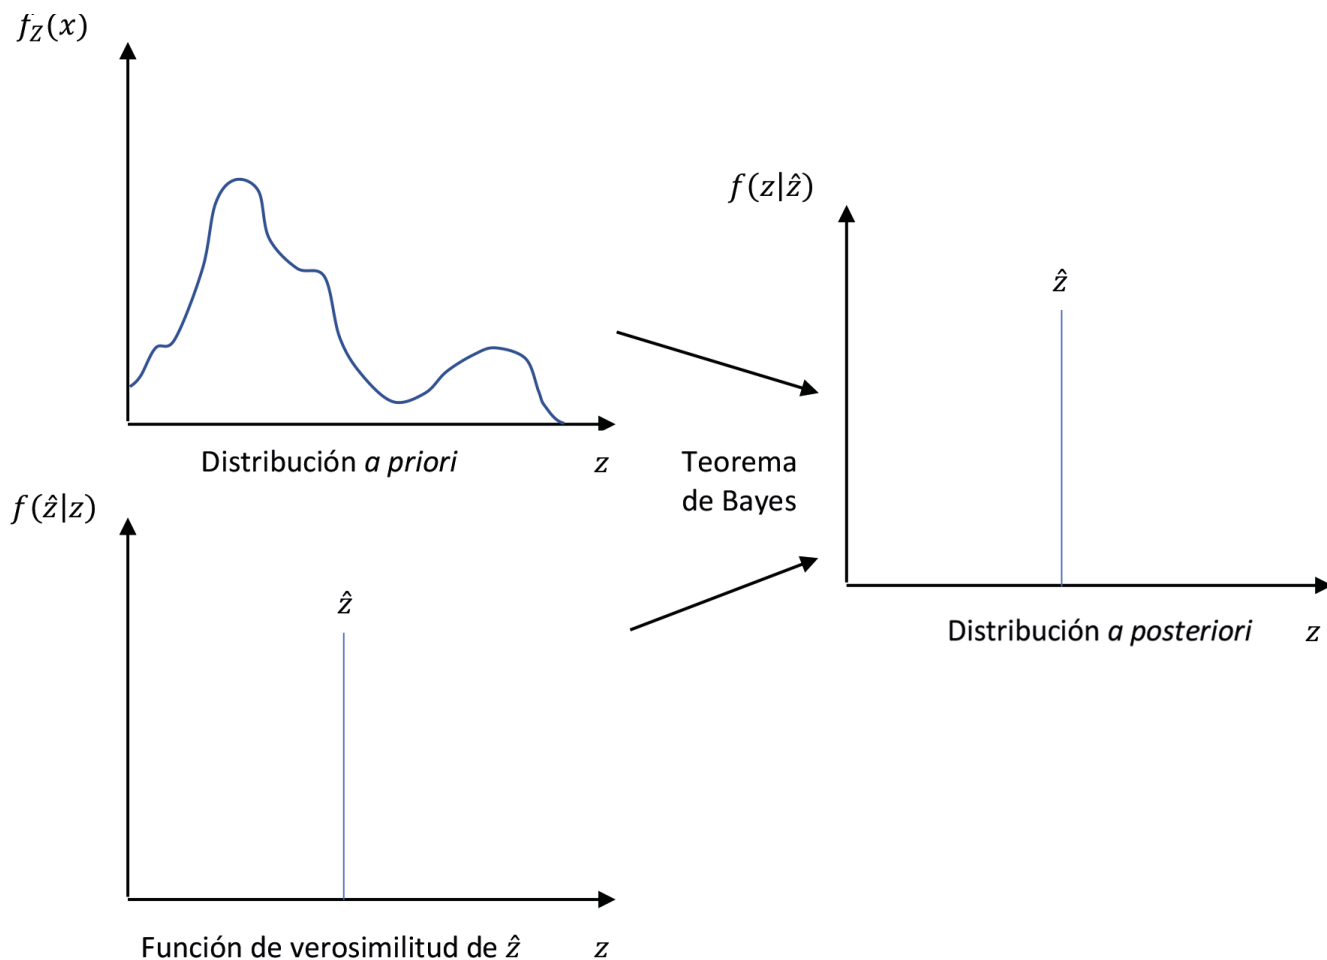


Figura 4. Actualización de probabilidades para datos duros.

El caso, en el que la función de verosimilitud no aporta información (tipo distribución de probabilidad uniforme), se muestra en la Figura 5, mediante la aplicación del Teorema de Bayes.

Variables indicadoras. Para codificar información de la función acumulada de probabilidad, es posible el uso de variables indicadoras:

$$I(x; z_c) = P(Z(x) \leq z_c | Z(x)) = \begin{cases} 1, & Z(x) \leq z_c \\ 0, & Z(x) > z_c \end{cases} \quad (6)$$

El momento de orden uno de la variable indicadora es:

$$E[I(x; z_c)] = P[Z(x) \leq z_c] = F(z_c) \quad (7)$$

donde $F(z_c)$ es la distribución de probabilidad acumulada.

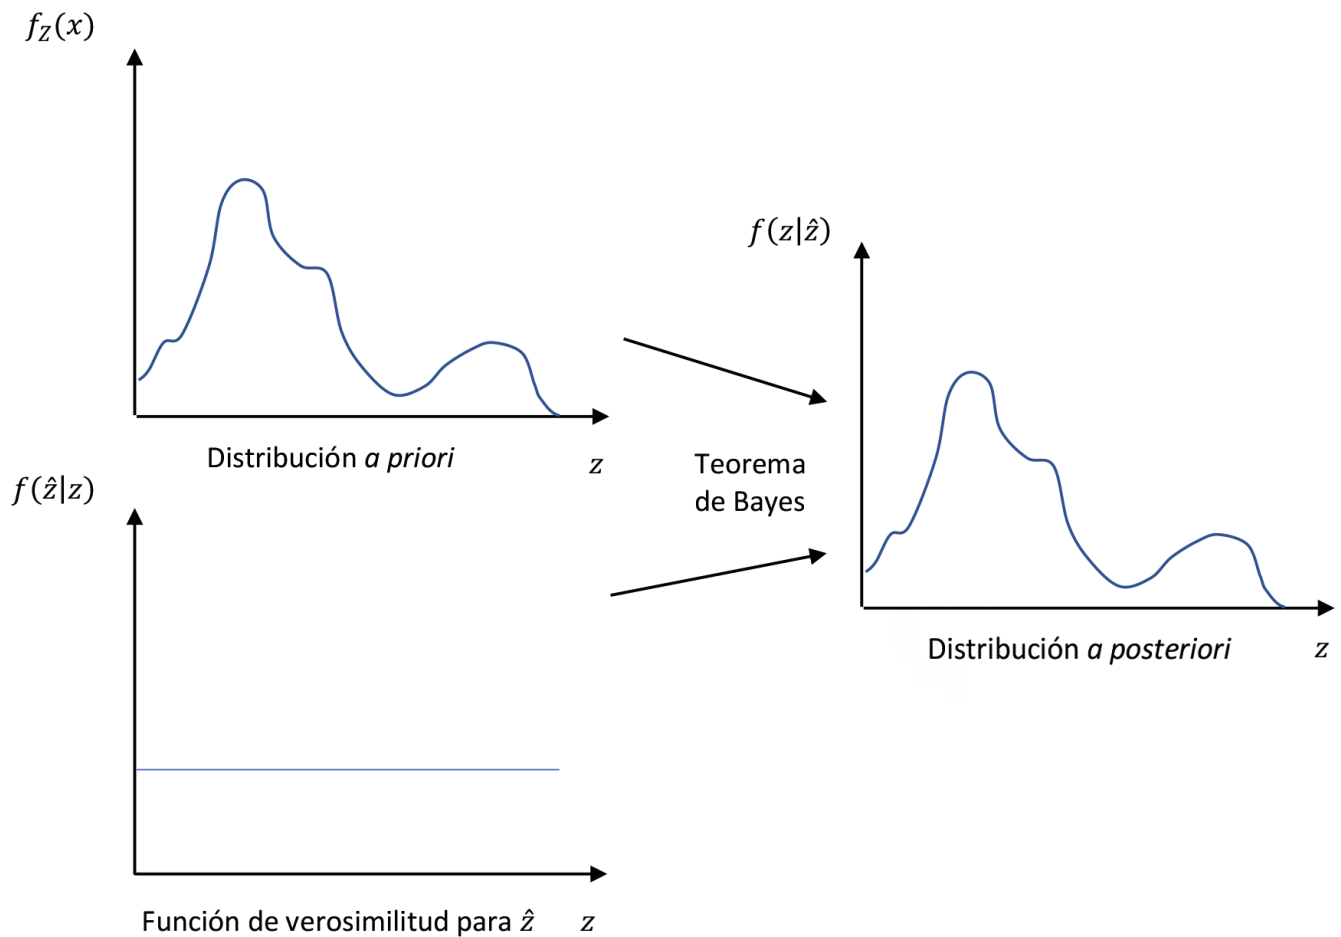


Figura 5. Actualización de probabilidades para el caso de no información.

El momento de orden dos está definido por:

$$E[I(x; z_c)I(x + h; z_c)] = P[Z(x) \leq z_c, Z(x + h) \leq z_c] = K_I(h; z_c) \quad (8)$$

que es la función de covarianza indicador no centrada.

La función de covarianza indicadora centrada está dada por:

$$C_I(h; z_c) = K_I(h; z_c) - F^2(z_c) \quad (9)$$

Función indicadora de verosimilitud. Para definir la calidad de la variable indirecta \hat{z} es necesario definir las métricas del error de una mala clasificación:

$$p_1 = P(\hat{Z}(x) \leq z_c | Z(x) \leq z_c) \quad (10)$$

$$p_2 = P(\hat{Z}(x) \leq z_c | Z(x) > z_c) \quad (11)$$

Una variable indirecta \hat{z} se considera de buena calidad si $p_1 \rightarrow 1, p_2 \rightarrow 0$. En el caso de $p_1 = p_2$ la variable \hat{z} no contiene información.

La función indicadora de verosimilitud está caracterizada completamente por:

$$L_{kk}(\hat{i}, i) = P(\hat{i}(x; z_k) | i(x; z_k)) \quad (12)$$

$$L_{kk}(1,1) = p_1(z_k)$$

$$L_{kk}(1,0) = p_2(z_k)$$

$$L_{kk}(0,1) = 1 - p_1(z_k)$$

$$L_{kk}(0,0) = 1 - p_2(z_k)$$

Para una prueba de hipótesis, la función indicadora de verosimilitud define toda la información requerida para la hipótesis nula H_0 (Cuadro 1).

Cuadro 1. Prueba de hipótesis.

	H_0 cierta	H_0 falsa
Aceptar H_0	Decisión correcta p_1	Error tipo II p_2
Rechazar H_0	Error tipo I $1 - p_2$	Decisión correcta $1 - p_2$

Las probabilidades de mala clasificación pueden estimarse usando datos de calibración entre variables duras y blandas (Figura 6), lo que permite establecer métricas de incertidumbre para la fusión de información.

La estimación de las probabilidades de la función indicador de verosimilitud está definida por el número

de puntos que caen dentro de cada región:

$$p_1(z_c) = \frac{A}{A+D} \tag{13}$$

$$p_2(z_c) = \frac{B}{B+C} \tag{14}$$




Figura 6. Relación entre la variable dura y la blanda para estimar las probabilidades de mala clasificación.

La estimación de la función indicadora de verosimilitud no es equivalente al conocimiento de la función de verosimilitud completa $f(\hat{z}|z)$, pero es suficiente para el proceso de estimación (Alabert, 1987).

Para el caso de clases o tipos de variables blandas, podemos definir la variable indicadora:

$$I(x; c_i) = \begin{cases} 1, & \text{si } Z(x) = c_i \\ 0, & \text{si } Z(x) \neq c_i \end{cases} \tag{15}$$

definida para las diferentes clases c_i .

Las clases c_i están dadas por:

$$c_i = \begin{cases} 1, & Z(x) \leq z_1 \\ 2, & z_1 < Z(x) \leq z_2 \\ \dots & \dots \\ K, & z_{K-1} < Z(x) \leq z_K \\ K + 1, & Z(x) > z_K \end{cases} \tag{16}$$

La Figura 7 muestra la relación entre la variable dura y la blanda para el caso del uso de clases.




Figura 7. Relación entre la variable dura y la blanda, caso de clases.

Las probabilidades de mala clasificación están dadas por el número de puntos en las diferentes regiones de la Figura 7:

$$p_1 = \frac{E}{D + E + F} \tag{17}$$

$$p_2 = \frac{B+H}{A+B+C+G+H+I} \tag{18}$$

Codificación de información dura y blanda. Los tipos de datos, sus formas y medidas de incertidumbre se muestran en el Cuadro 2. En el caso del intervalo, se desconocen sus valores dentro del mismo, lo cual no es equivalente a una distribución de probabilidad uniforme. El uso de valores arriba o debajo de un umbral permite establecer las condiciones a cumplir por las estimaciones de datos. El uso de métricas de incertidumbre de los datos indirectos establece criterios de la calidad de la información. Finalmente, el uso de distribuciones de probabilidad permite utilizar el conocimiento *a priori* de la información.

Cuadro 2. Tipos de datos, su formato y medidas de incertidumbre.

Tipo de Datos	Categoría Datos	Formato	Medida de incertidumbre
Duro		Valor único de $z(x)$	Sin incertidumbre en $z(x)$
	Tipo A	Valor único impreciso $\hat{z}(x)$	Índice de calidad
	Tipo B1	$[z_{min}, z_{max}]$ $z_{min} \leq z(x) \leq z_{max}$	Anchura del intervalo
Blando	Tipo B2	$z(x) \leq z_{max}$	Límite superior
	Tipo B3	$z(x) \geq z_{min}$	Límite inferior
	Tipo C	Distribución de probabilidad	Distribución de probabilidad

La codificación de los datos duros y blandos sigue reglas simples de cumplimiento de los límites establecidos (Alabert, 1987; Govaerts, 1997; Wingle *et al.*, 1998; Zhu and Journel, 1993).

Un primer paso consiste en definir los intervalos de la variable para poder codificar (vector de información) los diferentes tipos de datos en $N_c + 1$ intervalos. La Figura 8 muestra la codificación de los distintos tipos de datos definidos en el Cuadro 1.




Figura 8. Codificación de los distintos tipos de datos. La posición de la flecha define el valor o valores umbral utilizados.

Estimación de la distribución de probabilidad acumulada

De las definiciones del promedio de variables indicadores duras y blandas se tiene:

$$P[Z(x) \leq z_k] = E[I(x; z_k)] = F(z_k) \quad (19)$$

$$P[\hat{Z}(x) \leq z_k] = E[\hat{I}(x; z_k)] = \hat{F}(z_k) \quad (20)$$

Bajo la hipótesis de estacionariedad de las funciones indicadoras y las probabilidades de mala clasificación es posible obtener:

$$\hat{F}(z_k) = p_1(z_k)x F(z_k) + p_2(z_k)z[1 - F(z_k)] \quad (21)$$

por lo que para $p_1(z_k) \neq p_2(z_k)$ la relación (21) puede ser puesta como:

$$F(z_k) = \frac{\hat{F}(z_k) - p_2(z_k)}{p_1(z_k) - p_2(z_k)} \quad (22)$$

Con el uso de datos duros (N_h) y datos blandos (N_s), la estimación de $F(z_k)$ puede realizarse (el superíndice * se utiliza para connotar estimaciones) de:

$$F^*(z_k) = \omega \left[\sum_{\alpha=1}^{N_h} v_\alpha i(x_\alpha; z_k) \right] + (1 - \omega) \left[\sum_{\beta=1}^{N_s} \lambda_\beta \frac{\hat{i}(x_\beta; z_k) - p_2^*(x_\beta; z_k)}{p_1^*(x_\beta; z_k) - p_2^*(x_\beta; z_k)} \right] \quad (23)$$

con:

$$\omega = \frac{N_h}{N_h + N_s} \quad (24)$$

Los pesos v_α y λ_β pueden establecerse como equivalentes a $\frac{1}{N_h}$ y $\frac{1}{N_s}$, respectivamente. Para el caso donde los datos están agrupados espacialmente,

es necesario utilizar técnicas que reduzcan su influencia, por lo que se puede utilizar la técnica de desagrupamiento de celdas (Journel, 1983).

Estimaciones óptimas de variables espaciales

Para la incorporación de la información espacial, en el proceso de estimación se utiliza la función covariograma que permite realizar un proceso de estimación denominado Kriging (Govaerts, 1987;

Isaaks y Srivastava, 1989). El uso de variables indicadoras plantea covariogramas indicadores para la estimación de distribuciones espaciales usando el Kriging indicador (Journel, 1983). Para el caso del uso de datos duros y blandos, el Kriging blando permite realizar estimaciones en el marco de variables indicadoras.

La integración de información dura y blanda para estimar el covariograma indicador duro puede establecerse al plantear un par de hipótesis.

Una primera hipótesis se plantea para las variables indicadoras $I(x; z_k)$ en la localización x e $\hat{I}(y; z_k)$ en la localización y :

$$P(Z(x) \leq z_k | Z(y) \leq z_k, Z(y) \leq z_k) = P(Z(x) \leq z_k | Z(y) \leq z_k) \quad (25)$$

$$P(Z(x) \leq z_k | Z(y) > z_k, Z(y) \leq z_k) = P(Z(x) \leq z_k | Z(y) > z_k) \quad (26)$$

que plantea que la información en $Z(x)$ contenida en $\hat{Z}(y)$ es despreciable comparada con la información contenida en $Z(x)$. Es razonable suponer que la información combinada $\hat{Z}(y)$ y $Z(x)$ no es más informativa que el valor verdadero de solo $Z(y)$. Bajo la hipótesis planteada, la relación entre los covariogramas se establece para el covariograma cruzado:

$$C_{I\hat{I}}(h; z_k) = [p_1(z_k) - p_2(z_k)]C_I(h; z_k) \quad (27)$$

Una segunda hipótesis puede plantearse para las variables indicadoras $\hat{I}(x; z_k)$ en la localización x e $\hat{I}(y; z_k)$ en la localización y :

$$P(\hat{Z}(x) \leq z_k | Z(y) \leq z_k, \hat{Z}(x) \leq z_k) = P(\hat{Z}(x) \leq z_k | Z(y) \leq z_k) \quad (28)$$

$$P(\hat{Z}(x) \leq z_k | Z(y) > z_k, \hat{Z}(x) \leq z_k) = P(\hat{Z}(x) \leq z_k | Z(y) > z_k) \quad (29)$$

que plantea que la información en $\hat{Z}(x)$ contenida en $\hat{Z}(y)$ es despreciable comparada con la información contenida en el valor verdadero $Z(y)$. Bajo esta hipótesis el covariograma indicador de $\hat{Z}(x)$ está relacionado con el duro:

$$C_{I\hat{I}}(h; z_k) = [p_1(z_k) - p_2(z_k)]^2 C_I(h; z_k) \quad (30)$$

Las dos hipótesis son más conocidas como hipótesis de Markov-Bayes (Almeida y Journel, 1996; Journel, 1999; Shmaryan y Journel, 1999; Zhu y Journel, 1993).

De la consideración de las hipótesis de Markov-Bayes, donde un dato duro siempre prevalece sobre cualquier dato blando co-colocado, la integración de datos duros y blandos para estimar la función indicadora del covariograma dura estará dada por:

$$C_I^*(h; z_k) = \omega_1 [C_I^*(h; z_k)] + \omega_2 \left[\frac{C_{I\hat{I}}^*(h; z_k)}{p_1^*(z_k) - p_2^*(z_k)} \right] + \omega_3 \left[\frac{C_I^*}{\{p_1^*(z_k) - p_2^*(z_k)\}^2} \right] \quad (31)$$

Con:

$$\omega_1 = \frac{Nh}{N_{tot}} \quad (32)$$

$$\omega_2 = \frac{Ns}{N_{tot}} \quad (33)$$

$$\omega_3 = 1 - (\omega_1 + \omega_2) \quad (34)$$

El número de pares de la relación (31) está dado por: $N_h^2 + N_h N_s + N_s^2$.

Estimadores tipo E

La metodología de integración de datos duros y blandos se planteó para estimar la distribución probabilidad acumulada $F(z)$, por lo que permite la estimación directa, no paramétrica, del intervalo de confianza de la estimación.

El valor promedio de estimación (tipo E) puede determinarse directamente de la distribución de probabilidad $F(z)$. Para esto se pueden usar modelos que permitan interpolar datos para una mejor caracterización de la función, o para extrapolarse para determinar los límites asociados a la distribución de probabilidad acumulada (Deutsch y Journel, 1998; Govaerts, 1987).

El software para realizar estimaciones con el Kriging está generalmente disponible en diferentes sistemas (Deutsch y Journel, 1998; Wingle *et al.*, 1999).

Una alternativa empírica para las estimaciones espaciales es el uso de interpoladores basados en el inverso ponderado de la distancia (Burrough, 1986):

$$\alpha_{\beta} = \frac{\sum_{\beta=1}^N \left(\frac{x_{\beta}}{d^{\beta}} \right)}{\sum_{\beta=1}^N \left(\frac{1}{d^{\beta}} \right)} \quad (35)$$

donde d es la distancia Euclidiana entre el punto a interpolar y el resto de los datos espaciales, p es la potencia de la distancia, generalmente $p = 2$.

COMENTARIOS FINALES

Los métodos planteados para el diseño experimental y la integración de datos duros y blandos, definen el camino para su uso conjunto en el sistema de medición/monitoreo, reporte y verificación, dada la dependencia con los errores tipo I y II.

La integración (fusión) de información dura y blanda permite el acoplamiento de sistemas de monitoreo comunitario con el profesional, definiendo la equivalencia de la información contenida en ambos tipos de datos: datos semicuantitativos o blandos para el monitoreo comunitario y datos cuantitativos o duros para el profesional.

El uso de datos blandos permite contar con datos complementarios a los duros, los cuales generalmente son escasos, por lo que pueden realizarse estimaciones en el contexto de relativamente pocos datos duros.

RECONOCIMIENTO

El autor agradece al Consejo Nacional de Ciencia y Tecnología (CONACyT) por el apoyo a través del FORDECYT-PRONACES para realizar este trabajo mediante el financiamiento al proyecto 319069 “Resiliencia y estabilidad socioecológica de la cafecultura mexicana bajo sombra: hacia nuevos paradigmas”

LITERATURA CITADA

- Alabert, F. 1987. Stochastic Imaging of Spatial Distributions using Hard and Soft Information. M.Sc. Thesis. Stanford University. Stanford, CA. 416 p.
- Allen, D. E., M. J. Pringle, K. L. Page and R. C. Dalal. 2010. A review of sampling designs for the measurement of soil organic carbon in Australian grazing lands. *The Rangeland Journal* 32:227-246.
- Almeida, A. S. and A. G. Journel. 1996. Joint simulation of multiple variables with Markov-type coregionalization model. *Mathematical Geology* 26:565-588.
- Angelsen, A., C. Martius, V. De Sy, A. E. Duchelle, A. M. Larson y P. T. Thuy. 2021. REDD+: La Transformación. Lecciones y Nuevas Direcciones. CIFOR. Bogor, Indonesia. 338 p.
- Burrough, P. A. 1986. Principles of Geographical Information for Land Resource Assessment. Monographs on Soil and Resources Survey No. 12. Oxford Science Publications – Clarendon Press. Oxford, UK. 220 p.
- Chaudhuri, S., E. M. Pena-Yewtukhiw, L. M. McDonald, J. Skoulsen and M. Sperow. 2011. Land use effects on sample size requirements for soil organic carbon stock estimations. *Soil Science* 176:110-114.
- Climate Action Reserve. 2012. Updated Guidance for Verification of Sampled Pools for forest Projects. Supplemental Verification Methodology. <https://www.climateactionreserve.org/wp-content/uploads/2009/03/Supplemental-Verification-Methodology-Sequential-Sampling-11.pdf> (Consulta: septiembre 18, 2021).
- Climate Action Reserve. 2020. Protocolo Forestal para México. Versión 2.0. México. https://www.climateactionreserve.org/wp-content/uploads/2020/08/Mexico_Forest_Protocol_V2.0_Espanol_Package_080420.pdf (Consulta: octubre 10, 2021).
- Coleman, K. and S. D. Jenkinson. 1996. RothC-26.3: a model of the turnover of carbon in soil. pp. 237-246. *In*: Powlson, D. S., P. Smith and J. U. Smith (eds.). Evaluation of Soil Organic Matter Models using Existing Long-term Datasets. Springer-Verlag. Berlin.
- CONAFOR. 2009. Manual y Procedimientos para el Muestreo de Campo (Re-Muestreo 2009). Inventario Nacional Forestal y de Suelos. Comisión Nacional Forestal. Guadalajara, Jalisco, México. 140 p.
- Conant, R. T., G. R. Smith and K. Paustian. 2003. Spatial variability of soil carbon in forested and cultivated sites: implications for change detection. *Journal of Environmental Quality* 32:278-286.
- Conen, F., M. V. Yakutin and A. D. Sambuu. 2003. Potential for detecting changes in soil organic carbon concentrations resulting from climate change. *Global Change Biology* 9:1515-1520.

- Deutsch, C. V. and A. G. Journel. 1998. *GSLIB, Geostatistical Software Library and User's Guide*. Second Edition. Oxford University Press. New York, U.S.A. 375 p.
- Di Stefano, J. 2003. How much power is enough? Against the development of an arbitrary convention for statistical power calculations. *Functional Ecology* 17:707-709.
- Ellert, B. H. and J. R. Bettany. 1995. Calculation of organic matter and nutrients stored in soils under contrasting managements regimes. *Canadian Journal of Soil Science* 75:529-538.
- Ellert, B. H., H. H. Janzen and T. Entz. 2002. Assessment of a method to measure temporal change in soil carbon storage. *Soil Science Society of America Journal* 66:1687-1695.
- Fairweather, S. E. 1985. Sequential sampling for assessment of stocking adequacy. *Northern Journal of Applied Forestry* 2:5-8.
- FAO. 2019. *Measuring and modelling soil carbon stocks and stock changes in livestock production systems. Guidelines for assessment*. Rome, Italy. 145 p.
- FAO. 2020. *A protocol for measurement, monitoring, reporting and verification of soil organic carbon in agricultural landscapes. GSOC-MRV Protocol*. Rome, Italy. 140 p.
- Garten, C. T. and S. D. Wulldchleger. 1999. Soil carbon inventories under a bioenergy crop (switchgrass): measurement limitations. *Journal of Environmental Quality* 28:1359-1365.
- GOFC-GOLD. 2016. *A Sourcebook of Methods and Procedures for Monitoring and Reporting Anthropogenic Greenhouse Gas Emissions and Removals Associated with Deforestation, Gains and Losses of Carbon Stocks in Forests Remaining Forests, and Forestation*. GOFC-GOLD Report version COP22-1. GOFC-GOLD Land Cover Project Office. Wageningen University, The Netherlands. 268 p.
- Govaerts, P. 1997. *Geostatistics for Natural Resources Evaluation*. Oxford University Press. New York, U.S.A. 483 p.
- Grassi, G., S. Monni, S. Federici, F. Achard and D. Mollicone. 2008. Applying the conservativeness principle to REDD to deal with the uncertainties of the estimates. *Environmental Research Letters* 3:1-12. DOI:10.1088/1748-9326/3/3/035005
- Hamburg, S. P. 2000. Simple rules for measuring change in ecosystem carbon in forestry-offset projects. *Mitigation and Adaptation Strategies for Global Change* 5:27-37.
- Hewson, M., K. Steininger y S. Pasmajoglou. 2014. *Manual de Medición, Reporte y Verificación (MRV) de REDD+ Versión 2.0*. Programa de Carbono Forestal, Mercados y Comunidades financiado por USAID. Washington, D.C., U.S.A. 43 p.
- Homann, P. S., B. T. Bormann and J. R. Boye. 2001. Detecting treatment differences in soil carbon and nitrogen resulting from forest manipulations. *Soil Science Society of America Journal* 65:463-469.
- Homann, P. S., B. T. Bormann, J. R. Boyle, R. L. Darbyshire and R. Bigley. 2008. Soil C and N minimum detectable changes and treatment differences in a multi-treatment forest experiment. *Forest Ecology and Management* 255:1724-1734.
- IPCC. 2003. *Good Practice Guidance for Land Use, Land-Use Change and Forestry*. Institute for Global Environmental Strategies (IGES) for the IPCC. Hayama, Japan. 590 p.
- IPCC. 2006. *Agriculture, forestry and other land use IPCC Guidelines for National Greenhouse Gas Inventories*. National Greenhouse Gas Inventories Programme. Institute for Global Environmental Strategies. Hayama, Japan.
- IPCC. 2019. *2019 Refinement to the 2006 IPCC Guidelines for National Greenhouse Gas Inventories*. Switzerland. 15 p.
- Isaaks, E. H. and R. M. Srivastava. 1989. *Applied Geostatistics*. Oxford University Press. New York, U.S.A. 592 p.
- Journel, A. G. 1983. Nonparametric estimation of spatial distributions. *Mathematical Geology* 15:445-468.
- Journel, A. G. 1986. Constrained interpolation and qualitative information – the soft kriging approach. *Mathematical Geology* 18:269-286.
- Journel, A. G. 1999. Markov models for cross-covariances. *Mathematical Geology* 31:955-964.
- Kirwan, N., M. A. Oliver, A. J. Moffati and G. W. Morgan. 2005. Sampling the soil in long-term forest plots: the implications of spatial variation. *Environmental Monitoring and Assessment* 111:149-172.
- Kravchenko, A. N. and G. P. Robertson. 2011. Whole-profile soil carbon stocks: the danger of assuming too much from analyses of too little. *Soil Science Society of America Journal* 75:235-240.
- Maillard, E., B. G. McConkey and D. A. Angers. 2017. Increased uncertainty in soil carbon stock measurement with spatial scale and sampling profile depth in world grasslands: a systematic analysis. *Agriculture, Ecosystems and Environment* 236:268-276.
- McCall, M. K., N. Chutz and M. Skutsch. 2016. Moving from measuring, reporting, verification (MRV) of forest carbon to community mapping, measuring, monitoring (MMM): perspectives from Mexico. *Plos One* 11: e014603. DOI: 10.1371/journal.pone.0146038.
- Mollicone, D., A. Freibauer, E. D. Schulze, S. Braatz, G. Grassi and S. Federici. 2007. Elements for the expected mechanisms on 'reduced emissions from deforestation and degradation, REDD' under UNFCCC. *Environmental Research Letters* 16: 3582-3588. DOI:10.1088/1748-9326/2/4/045024.
- Mooney, S., K. Gerow, J. Antle, S. Capalbo and K. Paustian. 2007. Reducing standard errors by incorporating spatial autocorrelation into a measurement scheme for soil carbon credits. *Climate Change* 80:55-72.
- Necpálová, M., R. P. Anex, A. N. Kravchenko, L. J. Abedndroth, S. J. del Grosso, W. A. Dick, M. J. Helmers, D. Hetzmann, J. G. Lauer, E. D. Nafziger, J. E. Sawyer, P. C. Scharf, J. S. Strock

- and M. B. Villamil. 2014. What does it take to detect a change in soil carbon stock? A regional comparison of minimum detectable difference and experiment duration in the north central United States. *Journal of Soil and Water Conservation* 69:517-531.
- Paz, F. y B. de Jong. 2012. Desarrollo de una estrategia de mapeo del carbono en ecosistemas terrestres usando fusión de información cuantitativa y semicuantitativa en campo bajo el principio de conservación de la incertidumbre. pp. 275-280. En: Paz, F. y R. Cuevas (eds.). *Estado Actual del Conocimiento del Ciclo del Carbono y sus Interacciones en México: Síntesis a 2011. Serie Síntesis Nacionales. Programa Mexicano del Carbono*. Texcoco, Estado de México, México.
- Paz, F., B. de Jong., S. Covalada, M. G. Morales, I. Amezcua, J. C. Gómez, M. M. Torres y A. Vargas. 2012. Monitoreo forestal comunitario en la Sierra Madre de Chiapas. pp. 759-766. En: Paz, F. y R. Cuevas (eds.). *Estado actual del conocimiento del ciclo del carbono y sus interacciones en México: Síntesis a 2011. Serie Síntesis Nacionales. Programa Mexicano del Carbono*. Texcoco, Estado de México, México.
- Pearson, T. R. H., S. L. Brown and R. A. Birdsey. 2007. *Measurement Guidelines for the Sequestration of Forest Carbon*. General Technical Report NRS-18. Northern Research Station. Forest Service. 42 p.
- PMC. 2011a. Manual de criterios para la selección de las parcelas de muestreo cuantitativas y semicuantitativas (Versión 1.31). Coordinación: F. Paz, Colaboradores: M. Casiano, C. O. Cruz, J. Argumedo, B. de Jong, R. Flores y S. Ochoa. Texcoco, Estado de México, México. 60 p. <http://pmcarbono.org/pmc/publicaciones/manuales.php> (Consulta: diciembre 08, 2021).
- PMC. 2011b. Manual de campo para el Inventario Forestal Estatal Cuantitativo (Versión 2.11). Coordinación: F. Paz, Colaboradores: M. Casiano, C. O. Cruz, J. Argumedo, B. de Jong, R. Flores y S. Ochoa. Texcoco, Estado de México, México. 129 p. <http://pmcarbono.org/pmc/publicaciones/manuales.php> (Consulta: diciembre 13, 2021).
- PMC. 2011c. Muestreo semicuantitativo. Inventario Forestal Estatal Cuantitativo, Bosques y Selvas. Manual de Referencia (Versión 2.1). Coordinación: Fernando Paz, Colaboradores: Marcos Casiano, Carlos O. Cruz, Jesús Argumedo, Ben de Jong, R. Flores y S. Ochoa. Texcoco, Estado de México, México. 49 p. <http://pmcarbono.org/pmc/publicaciones/manuales.php> (Consulta: diciembre 12, 2021).
- PMC. 2015. Manual de procedimientos inventario semicuantitativo de carbono+. Estudio de factibilidad Técnica para el pago de bonos de carbono en el Estado de México (RETUS con BASES EDOMEX). Coordinación: Fernando Paz, Colaboradores: Fabiola Rojas-García y Julio Cesar Wong. Texcoco, Estado de México, México. 58 p. <http://pmcarbono.org/pmc/publicaciones/manuales.php> (Consulta: diciembre 08, 2021).
- Poeplau, C., C. Vos and A. Don. 2017. Soil organic carbon stocks are systematically overestimated by misuse of the parameters bulk density and rock fragment content. *Soil* 3:61-66.
- Post, W. M., R. C. Izaurralde, L. K. Mann and N. Bliss. 2001. Monitoring and verifying changes of organic carbon in soil. *Climate Change* 51:73-99.
- Schlamadinger, B., L. Ciccacese, M. Dutschke, P. M. Fearnside, S. Brown and D. Murdiyarso. 2005. Should we include avoidance of deforestation in the international response to climate change? pp. 26-41. In: D. Mudiyarso and H. Herawati (eds.). *Carbon Forestry: Who Will Benefit? Proceedings of Workshop on Carbon Sequestration and Sustainable Livelihoods*. Center for International Forestry Research (CIFOR), Bogor, Indonesia.
- Sheng, J. 2017. Effect of uncertainties in estimated carbon reduction from deforestation and forest degradation on required incentive payments in developing countries. *Sustainability* 9:1608. DOI:10.3390/su9091608
- Shmaryan, L. E. and A. G. Journel. 1999. Two Markov models and their application. *Mathematical Geology* 31:965-988.
- Skutsch, M. 2011. *Community Forest Monitoring: Opportunities for the Carbon Market*. Earthscan. London, UK. 208 p.
- Smith, P. 2004. How long before a change in soil organic carbon can be detected? *Global Change Biology* 10:1878-1883.
- UNFCCC. 2010. Calculation of the Number of Sample Plots for Measuring within A/R CDM Project Activities. A/R Methodological Tool. EB 58 Report Annex 15. <https://cdm.unfccc.int/methodologies/ARmethodologies/tools/ar-am-tool-03-v2.1.0.pdf> (Consulta: septiembre 28, 2021).
- Vandenbygaart, A. J. and D. A. Angers. 2006. Towards accurate measurements of soil organic carbon stock change in agroecosystems. *Canadian Journal of Soil Science* 86:465-471.
- Vangelova, E. I., E. Bonifacio, D. De Vos, M. R. Hoosbeck, T. W. Berger, L. Vesterdal, K. Armolaitis, L. Celi, L. Dinca, O. J. Kjonaas, P. Pavienda, J. Pumpanen, Ü. Püttsepp, B. Reidy, P. Simoncic, B. Tobin and M. Zhiyanski. 2016. Source of errors and uncertainties in the assessment of forest soil carbon stock at different scales – review and recommendations. *Environmental Monitoring and Assessment* 188:630. DOI:10.1007/S10661-016-5608-5.
- VCS. 2012a. VCS Module VMD0018, Methods to Determine Stratification. Version 1.0. Sectoral Scope 14. Document prepared by The Earth Partners LLC. 10 p.
- VCS. 2012b. Approved VCS Methodology VM0021. Soil Carbon quantification Methodology. Version 1.0, Sectoral Scope 14. Document prepared by The Earth Partners LLC. 30 p.
- VCS. 2012c. VCS Module VMD0021. Estimation of Stocks in the Soil Carbon Pool. Version 1.0. sectoral Scope 14. Document prepared by The Earth Partners LLC. 33 p.
- VCS. 2020. VCS Methodology VM0042. Methodology for Improved Agricultural Land Management. Version 1.0, Sectoral Scope 14. Document prepared by TerraCarbob LLC. 113 p.

- Wingle, W. L. and E. P. Poeter. 1998. Classes vs. thresholds: A modification to traditional indicator simulation, *Advances in Geostatistics*, 1998 AAPG Annual Meeting. http://www.uncert.com/wwingle/pubs/aapg_98/class.pdf (Consulta: septiembre 03, 2021).
- Wingle, W. L., E. P. Poeter and S. A. McKenna. 1998. *UNCERT User's Guide (Version 1.16 ±)*. Department of Geology and Geological Engineering. Colorado School of Mines. Golden, CO. 461 p.
- Wingle, W. L., E. P. Poeter and S. A. McKenna. 1999. *UNCERT: Geostatistics, uncertainty analysis and visualization software applied to groundwater flow and contaminant transport modeling*. *Computers and Geosciences* 25:365-376.
- Yanai, R. D., S. V. Stehman, M. A. Arthur, C. E. Prescott, A. J. Friedland, T.G. Siccama and D. Binkley. 2003. Detecting change in forest floor carbon. *Soil Science Society of America Journal* 67:1583-1593.
- Zar, J. H. 2010. *Biostatistical Analysis*. Fifth Edition. Prentice Hall. 255 p.
- Zhu H. and A. G. Journel. 1993. Formatting and integrating soft data: stochastic imaging via the Markov-Bayes algorithm. *In*: Soares A. (ed.). *Geostatistics Tróia '92*. Quantitative Geology and Geostatistics, Vol 5. Springer, Dordrecht.