



**Nota orientativa sobre la estimación de la incertidumbre
de las reducciones de emisiones mediante la simulación
de Monte Carlo**

Versión 1.0
Septiembre 2021

Índice

Paso 1. Identificar las fuentes de los valores utilizados en las estimaciones de reducción de emisiones y si son independientes o compartidas.....	2
Paso 2. Reconocer la incertidumbre asociada con cada una de estas variables.	5
Paso 3. Difundir las incertidumbres sobre la estimación de las reducciones de emisiones mediante la simulación de Monte Carlo	8
Paso 4. Evaluar la contribución de cada fuente a la incertidumbre general	16
Anexo 1. Ejemplo de Monte Carlo en Excel.....	21
Anexo 2. Ejemplo de Monte Carlo en R	28

Nota orientativa sobre la estimación de la incertidumbre de las reducciones de emisiones mediante la simulación de Monte Carlo

Esta nota orientativa ha sido preparada por el proyecto QUERCA (Cuantificación de estimaciones de incertidumbre y riesgo para la contabilidad de carbono) en el SUNY College of Environmental Science and Forestry con fondos del FCPF

El Criterio 9 del Marco metodológico del FCPF requiere que la incertidumbre de la estimación de las reducciones de emisiones se cuantifique utilizando los métodos de Monte Carlo. Las Directrices del FCPF sobre el análisis de la incertidumbre de las reducciones de emisiones describen las fuentes de incertidumbre que hay que propagar y proporcionan orientación para realizar simulaciones de Monte Carlo.

Los programas de ER se diferencian tanto en las actividades que realizan como en los métodos con los que calculan los factores de emisión y los datos de actividad. Por ello, las fuentes de incertidumbre también difieren y los cálculos para combinarlas correctamente también serán diferentes. En este documento se describe el enfoque general y se ofrece un ejemplo sencillo para ilustrar ese enfoque. El enfoque general descrito aquí incluye los siguientes pasos:

- Paso 1. Identificar las fuentes de los valores utilizados en las estimaciones de reducción de emisiones y si son independientes o compartidas
- Paso 2. Reconocer la incertidumbre asociada con cada una de estas variables
- Paso 3. Difundir las incertidumbres sobre la estimación de las reducciones de emisiones mediante la simulación de Monte Carlo
- Paso 4. Evaluar la contribución de cada fuente a la incertidumbre general

El ejemplo sencillo se ha proporcionado en Excel y en R para ayudar a los usuarios a comprender esta guía y cada uno de los pasos. Cada situación es única y los ejemplos que se dan tendrán que adaptarse a los programas en cuestión, pero los principios subyacentes son universales. En el Anexo 1 se proporcionan más detalles sobre el ejemplo.

Esta nota orientativa complementa las Directrices del FCPF sobre el análisis de la incertidumbre.

Paso 1. Identificar las fuentes de los valores utilizados en las estimaciones de reducción de emisiones y si son independientes o compartidas.

Siguiendo el proceso mediante el cual los programas de ER estiman las reducciones de emisiones, los programas deben identificar todas las variables utilizadas en la estimación de emisiones y absorciones. [En el cuadro 1](#) de las Directrices del FCPF sobre el análisis de la incertidumbre figura una lista de las principales fuentes de incertidumbre que, como mínimo, deben evaluarse. En la simulación de Monte Carlo, las incertidumbres en estas variables se combinarán mediante el muestreo de las posibles distribuciones de sus valores, según se determina en el Paso 2 siguiente.

Para combinar correctamente las incertidumbres de varias variables, es necesario comprender qué variables se utilizan de forma independiente y cuáles se comparten en varios cálculos.

Las variables y sus fuentes de incertidumbre asociadas contribuyen de forma independiente a un cálculo determinado si se derivan de forma independiente y no se utilizan para ninguna otra variable. Por ejemplo, los datos del inventario de árboles se recogen generalmente de forma

independiente para cada estrato o tipo de cubierta de tierra y no se utilizan en los cálculos para otros estratos o tipos de cubierta de tierra (mostrados en azul en la Figura 1.1).

Otras variables y sus incertidumbres asociadas se comparten en múltiples cálculos, por ejemplo, la fracción de carbono (CF), la relación entre raíz y brotes (R:S) y las variables de alometría de árboles pueden utilizarse en múltiples tipos de bosques (se muestra en rojo en la Figura 1.1). En ese caso, las densidades de carbono se calculan mediante una combinación de fuentes independientes y compartidas y, por lo tanto, están parcialmente correlacionadas (se muestran en color morado en la Figura 1.1) y es importante representar estas correlaciones correctamente al combinarlas en la propagación de errores.




Figura 1.1 Al calcular las densidades de carbono, los datos de inventario recogidos en cuatro tipos de cubierta terrestre son independientes (azul). Si se utilizan los mismos valores de fracción de carbono (CF), relación entre raíz y brotes (R:S) y alometría de árboles en varios tipos de bosques, se comparten (rojo). Las incertidumbres calculadas a partir de una combinación de fuentes independientes y compartidas se correlacionarán parcialmente (morado), con coeficientes de correlación intermedios entre 0 (totalmente independientes) y 1 (totalmente compartidos).

El hecho de que una fuente de incertidumbre se trate como compartida o independiente dependerá de cómo se recopiló y de cómo se utiliza en el cálculo. Algunos programas recopilan datos de alometría de árboles de forma independiente para cada tipo de cubierta terrestre. En ese caso, las incertidumbres en la alometría de árboles serían independientes para cada tipo de cubierta (Figura 1.2). Teóricamente, la fracción de carbono y las relaciones entre raíz y brotes se podrían determinar de forma independiente para cada tipo de cubierta, o se podría utilizar un único valor entre los tipos de bosque. La conversión del carbono a CO₂ se trata como una constante sin incertidumbre, ya que la variabilidad en las relaciones isotópicas del carbono y el oxígeno es insignificante.




Figura 1 2. El hecho de que una variable sea independiente o compartida depende de cómo se recopilaron los datos. Si las ecuaciones alométricas son específicas para cada tipo de cubierta, son independientes. La fracción de carbono y la relación entre raíz y brotes se pueden determinar por separado para cada tipo de bosque, pero si no, se comparten.

Dado que las reducciones de las emisiones se estiman como la diferencia entre el Nivel de referencia de las emisiones y las emisiones efectivamente controladas, también es pertinente la correlación entre las dos estimaciones. Por ejemplo, si los programas utilizan los mismos factores de emisión en los períodos de referencia y control, deben tratarse como compartidos (como se muestra en la Figura 1.3). Por el contrario, si los datos de inventario se recopilan independientemente para cada período, los factores de emisión para los dos períodos se consideran más independientes.

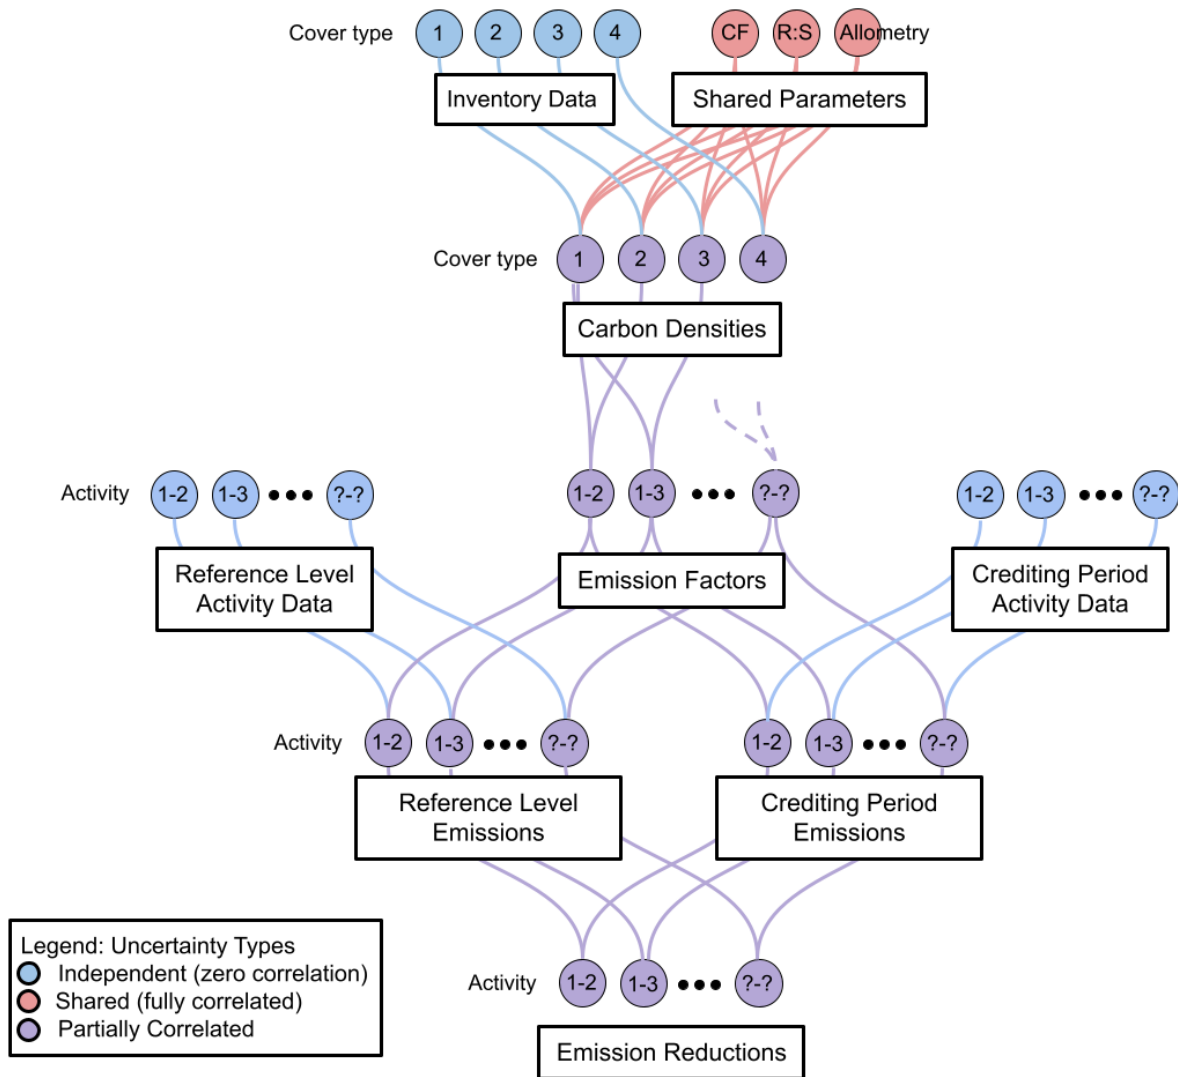


Figura 1 3. Los factores de emisión se derivan de las densidades de carbono de las categorías de cubierta terrestre en transición. Muchas de estas transiciones son posibles y el número y grado de la correlación de tales actividades variará según el programa, dependiendo del diseño. Los factores de emisión pueden compartirse entre el nivel de referencia y el período de control, como se muestra aquí. Al estimar la incertidumbre en las reducciones de las emisiones, las fuentes compartidas de incertidumbre tendrán en común un valor muestreado aleatoriamente en cada iteración de la simulación de Monte Carlo. Las incertidumbres asociadas con los resultados basados tanto en fuentes compartidas como independientes estarán parcialmente correlacionadas (se muestran en morado).

El grado de correlación parcial (es decir, el valor del coeficiente de correlación) que surge de la combinación de una mezcla de fuentes de incertidumbre compartidas e independientes puede estimarse analíticamente (no se cubre en esta guía) o examinando los resultados de la simulación de Monte Carlo. No es importante conocer el coeficiente de correlación de las variables intermedias en el cálculo. Sin embargo, si el cálculo comenzara con entradas parcialmente correlacionadas, tales como densidades de carbono, habría que estimar los coeficientes de correlación para propagarlos correctamente (ver Sección 3.2.3).

Posibles riesgos

Tratar las fuentes de incertidumbre como independientes cuando son compartidas subestimaría la verdadera incertidumbre combinada. En el ejemplo sencillo que figura en el Anexo 1, la incertidumbre en la ER debería ser del 416%. Si los factores de emisión se tratan como independientes entre el nivel de referencia y el período de control, en lugar de como compartidos, se obtiene un valor del 403%, que es incorrecto.

Paso 2. Reconocer la incertidumbre asociada con cada una de estas variables.

El uso del enfoque de Monte Carlo para la propagación de errores requiere definir las distribuciones de las variables utilizadas en el cálculo. Hay dos formas de generar muestras aleatorias que imiten la distribución probable de una variable. La primera es tomar muestras de una distribución definida (una función de la densidad de probabilidad o PDF). El segundo es muestrear aleatoriamente los valores de la variable de un conjunto de datos (bootstrapping).

2.1 Decidir entre PDF y bootstrapping

Es más fácil muestrear de una distribución definida que muestrear de un conjunto de datos, especialmente en Excel. El muestreo de un conjunto de datos tiene la ventaja de que no se requieren hipótesis sobre la naturaleza de la distribución. Si la distribución no es normal, entonces el bootstrapping sería más preciso, a menos que los datos no sean representativos. La siguiente figura proporciona un árbol sencillo de decisiones para decidir entre PDF y bootstrapping para generar muestras aleatorias que imiten la distribución probable de una variable.

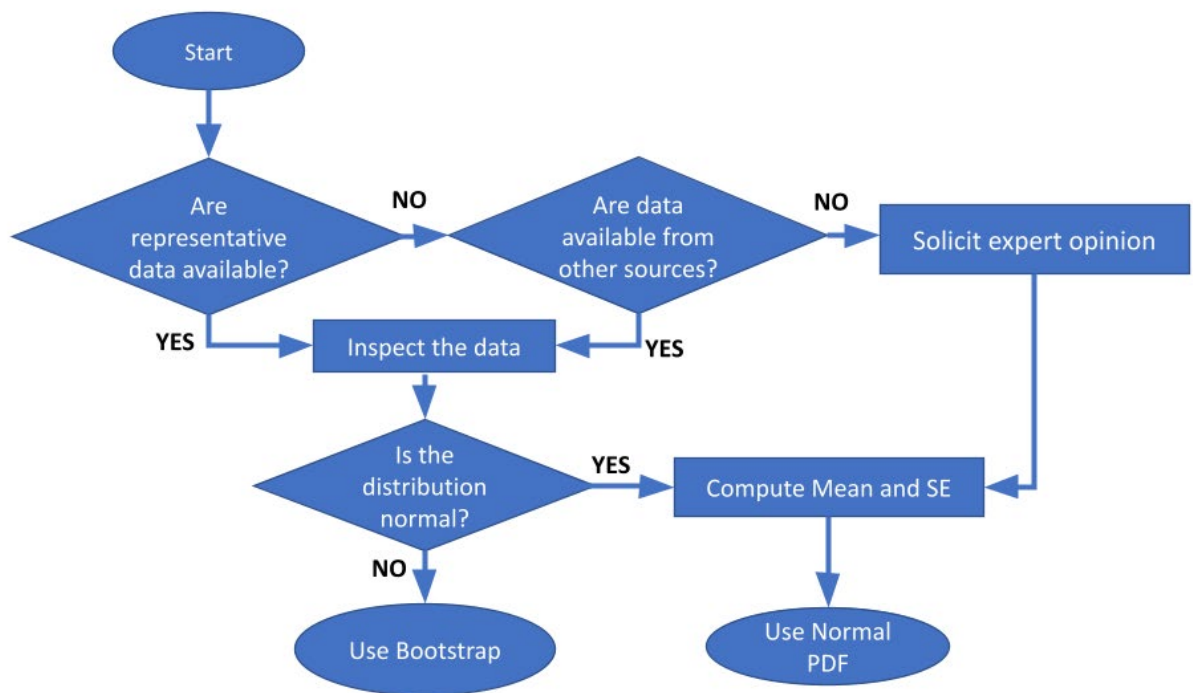


Figura 2.1. Árbol de decisiones para elegir si muestrear a partir de datos o PDF.

2.2 Descripción de la incertidumbre con una función de la densidad de probabilidad (PDF)

Se puede utilizar una función matemática para describir la distribución de los posibles valores de una variable. Normalmente, en ausencia de información en contrario, se utilizan distribuciones normales. Se puede seleccionar una distribución distinta de una normal si los valores posibles no se distribuyen normalmente. Para algunas aplicaciones, las distribuciones beta, binomiales, gamma, de Weibull o lognormales describen mejor la distribución de las observaciones. Sin embargo, si hay suficientes datos para determinar que la distribución no es normal, entonces el bootstrapping también es una opción.

En la contabilidad de carbono REDD+, a veces se han utilizado distribuciones uniformes para describir los posibles valores de la fracción de carbono ([IPCC 2006 Tabla 4.3](#)) y la relación entre raíz y brotes ([IPCC 2019 Ajuste de la Tabla de 2006 4.4](#)). Por esta razón, ofrecemos orientación sobre cómo utilizar un PDF uniforme. Sin embargo, parece inverosímil que haya una probabilidad cero de un valor fuera de estos rangos. En su lugar, recomendamos utilizar el error medio y estándar de los datos disponibles para definir una distribución normal. Como alternativa, los valores se pueden muestrear mediante bootstrapping.

A falta de datos fiables, se puede utilizar el criterio de expertos para definir un PDF. Las Directrices del FCPF sobre el análisis de la incertidumbre de las reducciones de emisiones recomiendan consultar independientemente al menos a tres expertos cuando la estimación del parámetro no esté disponible o no sea representativa (por ejemplo, basada en parcelas de investigación). El error medio y estándar de la media de las opiniones de los expertos debe utilizarse para definir una distribución normal. El uso del rango sería sensible a valores extremos, y duplicar el rango (como se recomienda actualmente en las Directrices) inflaría la incertidumbre de las reducciones de emisiones. Como alternativa, los valores se pueden muestrear mediante bootstrapping.

2.3 Uso de la distribución de los datos (bootstrapping)

Una alternativa a la representación analítica de la distribución de las entradas es volver a muestrear los datos, un procedimiento conocido como bootstrapping (Ephron y Tibshirani 1994) que se ilustra en la Figura 2.2. Los valores se extraen aleatoriamente de los datos para crear posibles conjuntos de datos alternativos con distribuciones similares y el mismo número de observaciones. Cada muestra aleatoria se extrae de todas las muestras posibles (esto se denomina “muestreo con reemplazo”) porque el muestreo sin reemplazo, si se dibuja el número de observaciones en el conjunto de datos, devolvería el conjunto de datos original todas las veces. Este enfoque no requiere la asunción de una distribución y, por lo tanto, es más cierto para la población medida. El bootstrapping es especialmente ventajoso cuando la distribución resulta difícil de definir. El inconveniente de este enfoque es que la representación de la población es tan buena como los datos y si el conjunto de datos es pequeño, puede que no capture con precisión el rango de valores potenciales.




Figura 2.2. Muestreo aleatorio de valores a partir de un conjunto de datos. El conjunto de datos tiene 7 valores, que se pueden muestrear aleatoriamente (con sustitución) para crear posibles conjuntos de datos alternativos.

Posibles riesgos

El muestreo del tipo bootstrapping debe configurarse para que coincida con el diseño del muestreo. Por ejemplo, si se estratifica el diseño del muestreo, sería necesario realizar un bootstrapping por separado para cada estrato y producir las estimaciones globales combinando la información de cada estrato. Podría haber problemas similares para el muestreo por grupos.

A menudo, los datos no son representativos, debido al acceso a los lugares de muestreo (cerca de carreteras o bordes de bosques) o a la facilidad de medición (excavación de raíces de árboles pequeños). Este es un posible peligro tanto para caracterizar los datos con un PDF como para el bootstrapping. En estos casos, se debe utilizar el juicio de expertos para corregir el sesgo en los datos.

Paso 3. Difundir las incertidumbres sobre la estimación de las reducciones de emisiones mediante la simulación de Monte Carlo

El FCPF requiere el uso de la simulación de Monte Carlo para cuantificar los efectos de entradas inciertas sobre la incertidumbre de las reducciones de las emisiones de carbono. Utilizando este enfoque, el cálculo de las reducciones de las emisiones se repite cientos o miles de veces, con entradas que varían aleatoriamente para imitar las incertidumbres en los valores de todas las variables que entraron en el cálculo tanto del Nivel de referencia como de las emisiones y absorciones monitorizadas. Como se ha descrito anteriormente en el Paso 2, las muestras aleatorias que imitan la distribución probable de una variable se pueden generar utilizando una distribución definida (un PDF) o muestreando aleatoriamente los valores de la variable a partir de un conjunto de datos (bootstrapping). La distribución de los cientos o miles de resultados refleja los efectos netos de las incertidumbres en las entradas.

3.1 Cómo realizar una muestra aleatoria de una distribución o un conjunto de datos

3.1.1 Muestreo a partir de una distribución

Para simular la incertidumbre en una entrada utilizando una distribución definida, se utilizan los parámetros que describen la distribución para generar las muestras aleatorias.

Distribución	Fórmulas de hojas de cálculo	Código R
Uniforme	<p>RAND() genera números aleatorios distribuidos uniformemente entre 0 y 1.</p> <p>Generar números aleatorios uniformes entre los valores de A1 y A2 utilizando:</p> <p>= (\$A\$1 + RAND())*(\$A\$2-\$A\$1))</p>	<p>Generar n números aleatorios uniformes entre A1 y A2 utilizando:</p> <p>runif(n, min = a1, max = a2)</p>
Normal	<p>NORM.INV(probabilidad, media, sd) da una inversa de la distribución acumulativa normal, con una probabilidad, media y desviación estándar (sd) especificadas.</p> <p>La combinación de RAND y NORM.INV proporciona una muestra aleatoria de una distribución con una media y una desviación estándar especificadas. Si la media y la sd están en las celdas B1 y B2, utilizar:</p> <p>=NORM.INV(RAND(), \$B\$1, \$B\$2)</p>	<p>Teniendo en cuenta la media y la desviación estándar (de) de la distribución, generar n muestras aleatorias utilizando:</p> <p>rnorm(n, mean, sd)</p>

3.1.2 Muestreo a partir de un conjunto de datos (bootstrapping)

Para simular la incertidumbre en una aportación mediante bootstrapping, cada muestra aleatoria se selecciona del conjunto de datos de posibles entradas.

Fórmula de hojas de cálculo	Código R
<p>Si hay 10 puntos de datos en las celdas A1:A10, puede muestrear aleatoriamente 1 de ellos utilizando:</p> <pre>=INDEX(\$A\$1:\$A\$10,ROWS(\$A\$1:\$A\$10)*RAND()+1,COLUMNS(\$A\$1:\$A\$10)*RAND()+1)</pre> <p>Puesto que esta fórmula extrae un único valor al azar del conjunto de datos especificado, debe copiarlo muchas veces para generar un ejemplo de bootstrapping. Copiar esta fórmula para muestrear muchas observaciones y copiarla para tantas iteraciones como sea necesario.</p>	<p>Con una muestra de tamaño n: (c1,c2,c3,...,cn), se puede generar un vector:</p> <pre>SampleC<-c(c1,c2,c3,...,cn)</pre> <p>Al definir una serie de simulaciones (NS), se pueden generar muestras de bootstrapping (BootstrapSam) generando muestras de NS de tamaño n muestreadas del vector "SampleC" con sustitución:</p> <pre>BootstrapSam <- replicate(NS, sample(SampleC, replace = T))</pre>

3.2 Cómo muestrear múltiples fuentes de incertidumbre

Para tener en cuenta correctamente las fuentes de incertidumbre independientes frente a las compartidas (identificadas en el Paso 1 anterior), es necesario asignar las muestras aleatorias de los valores de las entradas de forma independiente, en el caso de las muestras independientes (3.2.1), o asignar el mismo valor aleatorio en todos los cálculos que comparten ese valor, en el caso de fuentes compartidas (3.2.3), en cada iteración de la simulación de Monte Carlo.

3.2.1 Cómo asignar valores aleatorios independientes

En el caso de variables de entradas independientes, los valores aleatorios se seleccionarán independientemente para cada variable para representar la incertidumbre en esas variables. Por ejemplo, los datos de actividad se recopilan de forma independiente en cada punto temporal.

Fórmula de hojas de cálculo	Código R
-----------------------------	----------

<p>Para fuentes independientes, las celdas a las que se hace referencia para los parámetros (por ejemplo, media y sd en el caso de una fuente normalmente distribuida) no son las mismas:</p> <p>SourceA: A3=NORM.INV(RANDARRAY(1,n),\$A\$1,\$A\$2)</p> <p>SourceB: B3=NORM.INV(RANDARRAY(1,n),\$B\$1,\$B\$2)</p> <p>La celda A4 tendría un número aleatorio diferente al que harían referencia todos los cálculos de la fila 4 y así sucesivamente para todas las filas de la simulación.</p>	<p>Para las fuentes independientes (SourceA y SourceB), los números aleatorios de una distribución específica se pueden generar de forma independiente.</p> <p>Considerando dos fuentes distribuidas de forma normal: SourceA tiene mean=mSA y sd=sdSA y SourceB tiene mean=mSB y sd=sdSB.</p> <p>Se pueden generar n números aleatorios de SourceA (SimNumSA) y SourceB (SimNumSB) independientemente de la siguiente manera:</p> <p>SimNumSA<-rnorm(n, mSA, sdSA) SimNumSB<-rnorm(n, mSB, sdSB)</p>
--	---

3.2.2 Cómo asignar valores aleatorios compartidos

Hay casos en los que la misma variable de una entrada se utiliza varias veces en un cálculo y, en estos casos, esa variable de la aportación debe tener sólo un valor aleatorio para cada iteración. Por ejemplo, si se utiliza una relación entre raíz y brotes común en varios tipos de bosque, se selecciona una muestra aleatoria de una posible R:S en cada iteración y cada tipo de bosque que requiera un valor R:S utiliza el mismo valor en esa iteración.

Fórmula de hojas de cálculo	Código R
<p>Para las fuentes compartidas, se pone en común la muestra aleatoria de una entrada de incertidumbre:</p> <p>SourceA: A3=NORM.INV(RANDARRAY(1,n),\$A\$1,\$A\$2)</p> <p>SourceB: B3=\$A\$3</p> <p>En este ejemplo, las iteraciones están en las filas y cada columna de una fila que utilice esta fuente haría referencia a la celda A3 para un valor aleatorio de esta fuente.</p>	<p>Para las fuentes (SourceA y SourceB) que se comparten, ambas fuentes compartirán la muestra aleatoria de la entrada para cada iteración de la simulación de Monte Carlo.</p> <p>Considerando un origen compartido distribuido normalmente: SourceA tiene media=mA y sd=sdA</p> <p>Se pueden generar n números aleatorios de SourceA de la siguiente manera:</p> <p>SimNumA<- rnorm(n, mA, sdA)</p> <p>Cada fuente que se comparta con SourceA hará referencia al número aleatorio extraído para esa iteración</p>

	SimNumB <- SimNumA
--	--------------------

3.2.3 Cómo asignar valores aleatorios parcialmente correlacionados

Las variables de las entradas de un cálculo no pueden ser ni compartidas ni independientes, sino que deben estar parcialmente correlacionadas, si estas variables se calculan a partir de una combinación de fuentes compartidas e independientes. Es más fácil realizar una simulación de Monte Carlo comenzando con las entradas que son completamente independientes y totalmente compartidas, y esto es lo que recomendamos. Sin embargo, si se inicia un cálculo con variables parcialmente correlacionadas como entradas, como factores de emisiones basados en el inventario forestal independiente pero con las relaciones entre raíces y brotes compartidas, la simulación de Monte Carlo requerirá muestras aleatorias parcialmente correlacionadas para estas variables.

Crear una matriz con más de dos variables en Excel es posible pero difícil (Zaiontz 2020).

Fórmula de hojas de cálculo	Código R
------------------------------------	-----------------

1. Para la covarianza entre dos vectores X (A1:A30) e Y (B1:B30), se necesitará una matriz de varianza-covarianza de 2 x 2.

Matriz A

	X	Y
X	=VAR.S(A1:A30)	=COVARIANCE.S(A1:A30,B1:B30)
Y	=COVARIANCE.S(B1:B30,A1:A30)	=VAR.S(B1:B30)

2. Calcular la media de ambas variables con:

Matriz B

X	=AVERAGE(A1:A30)
Y	=AVERAGE(B1:B30)

3. Calcular una descomposición de Cholesky de la matriz de covarianza (Pistilli 2019). También será una matriz de 2 x 2.

Matriz C

	X	Y
X	=SQRT(A ₁₁)	=0
Y	=COVARIANCE.S(A ₂₁ /C ₁₁)	=SQRT(A ₂₂ - C ₂₁ ²)

4. Calcular un vector normal bivariado aleatorio. Para n iteraciones de números aleatorios, sería una matriz

Cargar el paquete MASS, que puede desarrollar números aleatorios normales multivariante:

library(MASS)

En primer lugar, generar una matriz de varianza-covarianza de 2 x 2 entre los vectores X e Y.

A<-cov(cbind(X,Y))

Generar n pares de valores aleatorios de X e Y con la varianza-covarianza especificada en A:

mvrnorm(n,c(mean(X),mean(Y)), A)

<p>de 2 x n con la misma fórmula en cada celda. Resaltar las celdas para formar una matriz de 2 x n, escribir la fórmula:</p> <p>=MMULT(C NORM.INV(RANDARRAY(2,n))+B</p> <p>Después de escribir la fórmula, al pulsar ctrl + mayús + Intro en el teclado se rellenarán todas las celdas de la matriz con la función.</p> <p>Cada celda del vector normal bivariado aleatorio es la media de esa variable más un residual aleatorio con la correlación deseada.</p>	
---	--

3.3 Cómo iterar

El muestreo aleatorio, ya sea a partir de PDF o de datos, puede repetirse muchas veces para generar una distribución de estimaciones a partir de las cuales se puede evaluar la incertidumbre.

Fórmula de hojas de cálculo	Código R
<p>Cada cálculo se repite en las filas (o columnas).</p> <p>Excel 365 tiene una función RANDARRAY que facilita este proceso.</p> <p>La fórmula RANDARRAY se utiliza en combinación con la fórmula utilizada para muestrear a partir de los datos.</p> <p style="text-align: center;">RANDARRAY(R,C)</p> <p>Donde R es el número de filas especificado y C es el número de columnas especificado. Por ejemplo, si se están realizando iteraciones en las filas, R hace referencia al número de iteraciones y C es 1.</p> <p>Por ejemplo, si se toma un muestreo de una distribución normal con media en la celda A1, sd en la celda A2 y el número de iteraciones en la celda A3,</p> <p style="text-align: center;">= NORM.INV(RANDARRAY(\$A\$3,1), \$A\$1, \$A\$2)</p> <p>La ventaja de RANDARRAY es que la fórmula se representa sólo una vez, en vez de por separado en cada iteración. Tener miles de fórmulas hace que el archivo sea enorme y que la ejecución sea</p>	<p>En el caso de una distribución normal con una media (media) y una desviación estándar (sd) especificadas, se puede generar un número aleatorio de la siguiente manera:</p> <p style="text-align: center;">rnorm(1,mean,sd)</p> <p>R utiliza matrices y conjuntos para almacenar datos. Los cálculos repetidos se gestionan según el número de elementos en el conjunto (n). Para generar n números aleatorios, indicar n:</p> <p style="text-align: center;">rnorm(n,mean,sd)</p>

lenta. Se recomienda invertir en Office 365 para hacer Monte Carlo en Excel.

El signo # se puede utilizar en lugar de =NORM.INV(RANDARRAY) en fórmulas simples que no muestrean a partir de una distribución. # copia la fórmula para rellenar el conjunto. Esto es útil para los cálculos que no requieren muestreo aleatorio.

Esto es efectivamente lo mismo que la ventaja de RANDARRAY, la fórmula sólo necesita ser escrita en la primera celda y se autorellena para cada iteración.

Posibles riesgos

Si se convierte a una hoja de Google, todas las fórmulas que utilicen # tendrán el mensaje de error ANCHOR ARRAY.

Usar muy pocas iteraciones de Monte Carlo puede proporcionar estimaciones imprecisas de la incertidumbre. Para el cálculo de la reducción de emisiones, se puede determinar el número de iteraciones de Monte Carlo necesarias para lograr la confianza deseada en las estimaciones de la incertidumbre. En este ejemplo (basado en el ejemplo sencillo del Anexo 1), las estimaciones de la incertidumbre son exactas sólo en torno al 20% de la reducción de las emisiones incluso después de 2.000 iteraciones, pero se acercan al 10% con 10.000 iteraciones (Figura 3.3).




Figura 3.3. La similitud de las estimaciones de Monte Carlo depende del número de iteraciones.

- Mediana de las estimaciones de Monte Carlo de las reducciones de emisiones, calculada para hasta 10.000 iteraciones para 5 series independientes de Monte Carlo.
- (b) La mitad de la amplitud del IC del 90% de las iteraciones de Monte Carlo dividida por la mediana de ER para las mismas 5 series de Monte Carlo.
- La desviación estándar de las 5 estimaciones de las reducciones de emisiones de Monte Carlo.
- La desviación estándar de las 5 estimaciones de la incertidumbre de Monte Carlo.

3.4 Cómo interpretar el resultado de la simulación de Monte Carlo

El resultado de la simulación de Monte Carlo puede analizarse para caracterizar la incertidumbre en los resultados del cálculo.

- Encontrar la mediana (percentil 50) de los resultados de Monte Carlo
- Encontrar el percentil 5 de los resultados
- Encontrar el percentil 95 de los resultados
- Calcular la mitad de la amplitud del intervalo de confianza del 90%.
- Convertir esto a un porcentaje de la mediana.

Fórmula de hojas de cálculo	Código R
<p>Donde el resultado de Monte Carlo está en las celdas B1:B10000</p> <p>A1 =MEDIAN(B1:B10000) A2 =PERCENTILE(B1:B10000, 0.05) A3 =PERCENTILE(B1:B10000, 0.95) A4 =(A3-A2)/2 A5 =A4/A1*100</p>	<p>Considerando un vector de números simulados SimNumC (c1,c2,c3,...,cn):</p> <p>A1<- median(SimNumC) A2<- quantile(SimNumC , 0.05) A3<- quantile(SimNumC , 0.95) A4<- (A3-A2)/2 A5<- abs(A4/A1)*100</p>

Posibles riesgos

Un error común al interpretar los resultados de Monte Carlo es informar de la incertidumbre en la media o mediana de la distribución de las estimaciones. Este error es de los grandes, por lo general subinforma sobre la incertidumbre por un factor de 100, porque calcular la incertidumbre en la tendencia central (por ejemplo, el error estándar de la media) implica dividir la desviación estándar por la raíz cuadrada del número de “observaciones”, que normalmente son 10.000 ensayos. La confianza en la media podría hacerse arbitrariamente pequeña aumentando el número de iteraciones de Monte Carlo, pero el intervalo de confianza del 90% de un mayor número de estimaciones seguiría siendo igual de amplio. El aumento del número de iteraciones mejora la precisión de la estimación de la incertidumbre, pero si se interpreta correctamente, no reduce la incertidumbre.

Paso 4. Evaluar la contribución de cada fuente a la incertidumbre general

Comprender cuánta incertidumbre contribuye cada fuente ayudará a identificar oportunidades para reducir las incertidumbres. Evaluar la incertidumbre global con diferentes entradas que se supone que son perfectamente conocidas es una forma de evaluar la sensibilidad de la incertidumbre global a la incertidumbre en cada entrada.

La realización de un análisis de sensibilidad se facilita mediante interruptores para cada entrada que activan o desactivan la incertidumbre asociada. La incertidumbre general se puede calcular con diferentes combinaciones de interruptores activados, en lugar de cambiar las fórmulas en el archivo Excel o el código en R.

Fórmula de hojas de cálculo	Código R
<p>Esto se logra con una fórmula “IF” que haga referencia a una celda utilizada para activar o desactivar una fuente para el análisis de sensibilidad.</p>	<p>El código relevante para una fuente de incertidumbre se puede activar utilizando “if”.</p>

Por ejemplo, si la celda A5 de la página de resultados tiene el valor "on" u "off", y la celda B5 de la página de entradas tiene

IF('resultspage'A5="on", 1, 0.0000000001)

Cada iteración de una extracción aleatoria para la fuente se multiplica por la celda B5. Si la fuente de la incertidumbre está desactivada, se utiliza 0,0000000001 en lugar de 0 para evitar errores en la función NORM.INV.

La comparación de la importancia de la incertidumbre en las diversas entradas se puede lograr evaluando cada una por separado, con todas las demás incertidumbres desactivadas, o quitando cada una, con todas las demás fuentes activadas. Desde el punto de vista de la evaluación del beneficio de reducir una fuente determinada en el contexto de todas las demás, es más importante informar de cuánta incertidumbre se reduce eliminando esa fuente que informar de cuánto contribuye esa fuente por sí sola, y este es el enfoque recomendado en las Directrices del FCPF sobre la aplicación del marco metodológico. Sin embargo, es más fácil entender los resultados de considerar una fuente a la vez. Y si hay una necesidad de revisar una fuente,

En el siguiente cuadro se muestran los resultados de un análisis de sensibilidad del ejemplo sencillo que figura en el Anexo.

Fuentes incluidas	Incertidumbre (Megatoneladas C/año)			Incertidumbre (% de emisiones)		
	Nivel de referencia	Acreditación Período	RE	Nivel de referencia	Acreditación Período	RE
R:S	2,80	2,50	0,29	17	17	17
CF	0,58	0,52	0,07	4	4	4
Incertidumbre de muestreo en los EF	3,29	2,95	0,36	21	21	21
Factores de emisión (de las 3 fuentes anteriores)	4,44	3,98	0,46	27	27	27

Datos de actividad	4,10	7,20	8,07	25	49	472
Todas las fuentes	6,09	8,54	8,46	37	58	492

En este ejemplo, las incertidumbres son elevadas en relación con la reducción de las emisiones. Esto se debe a que en este ejemplo la reducción de las emisiones era pequeña (1,7 megatoneladas C/año, véase la Fig. 4.1 para una explicación gráfica).




Figura 4.1. (a) Las incertidumbres representan el 37% de las emisiones del nivel de referencia y el 57% de las emisiones del período de control. (b) Debido a que la reducción de las emisiones es pequeña, la incertidumbre combinada es una gran fracción de la reducción de las emisiones (>400%).

Como se muestra en la figura 4.2, las incertidumbres relativas a la reducción de las emisiones se harán más pequeñas con el tiempo si la reducción de las emisiones aumenta con el tiempo, suponiendo que las incertidumbres que contribuyan sean relativamente constantes con el tiempo (Neeff 2021).




Figura 4.2. Incertidumbre en la estimación de las reducciones de las emisiones por escenarios de eficacia en la reducción de las emisiones por debajo del nivel de referencia y por incertidumbre en la medición de las emisiones (de Neff (2021), modificado de FAO 2019)

Posibles riesgos

Si las estimaciones de la incertidumbre no son muy precisas (basadas en un número pequeño de iteraciones de Monte Carlo), entonces por variación aleatoria, la incertidumbre con una fuente desactivada puede ser ligeramente superior a la incertidumbre con la fuente activada. Notificar cada fuente activada, en lugar de cada fuente desactivada, evitará este problema. El aumento del número de iteraciones de Monte Carlo hace que las estimaciones de la incertidumbre sean más precisas (Figura 3,3).

Literatura citada

- Efron, B., Tibshirani, R. J. 1994. An introduction to the bootstrap. *CRC press*.
- FCPF 2016. Carbon fund methodological framework. *Forest Carbon Partnership Fund Report*.
- Disponible en: https://www.forestcarbonpartnership.org/system/files/documents/FCPF%20Carbon%20Fund%20Methodological%20Framework%20revised%202016_1.pdf
- FCPF 2020. Guidelines on the application of the Methodological Framework Number 4 On Uncertainty Analysis of Emission Reductions. Forest Carbon Partnership Fund. Forest Carbon Partnership Facility Report. Disponible en: https://www.forestcarbonpartnership.org/sites/fcp/files/FCPF%20Guidelines%20on%20Uncertainty%20Analysis_2020_0.pdf
- IPCC 2006. IPCC guidelines for national greenhouse gas inventories. vol. 4 agriculture, forestry and other land use. *Elaboración por el National Greenhouse Gas Inventories Programme*. S Eggleston, L Buendia, K Miwa, T Ngaraand K Tanabe. Institute for Global Environmental Strategies, Hayama, Japan. Disponible en: <https://www.ipcc-nggip.iges.or.jp/public/2006gl/vol4.html>
- IPCC 2019. Refinement to the 2006 IPCC guidelines for national greenhouse gas inventories. *Elaboración por el National Greenhouse Gas Inventories Programme*. G. Domke, A. Brandon, R, Diaz-Lasco, S. Federici, E. Garcia-Apaza, G. Grassi, et al. Institute for Global Environmental Strategies, Hayama, Japan. Disponible en: <https://www.ipcc-nggip.iges.or.jp/public/2019rf/vol4.html>
- Neeff, T. What is the risk of overestimating emission reductions from forests – and what can be done about it?. *Climatic Change* 166, 26 (2021). <https://doi.org/10.1007/s10584-021-03079-z>
- Pistilli, Tony. “Behind the models: cholesky decomposition.” Medium, Towards Data Science, 23 de mayo de 2019, towardsdatascience.com/behind-the-models-cholesky-decomposition-b61ef17a65fb.
- Zaiontz, C. 2020. “Cholesky Decomposition”. Real Statistics Using Excel, www.real-statistics.com/linear-algebra-matrix-topics/cholesky-decomposition/.

Anexo 1. Ejemplo de Monte Carlo en Excel

El ejemplo sencillo en Excel tiene dos versiones, una con un período de acreditación de 2 años y otra con un período de acreditación de 4 años, lo que ilustra la alta incertidumbre asociada con un período de acreditación corto.

En el ejemplo sencillo se incluyen dos tipos de bosques, y la deforestación es la única transición del uso de la tierra. El ejemplo ilustra una tasa de deforestación del 3% anual en ambos tipos de bosques.

Introducción

La primera hoja del libro de Excel describe las funciones de las hojas siguientes.

This workbook provides an example of Monte Carlo error propagation for estimating the uncertainty in emission reductions for REDD+. The data are not for a real country; the example is simple to make it easy to understand.

Input Variables sheet:

Ten years of Activity data are used for this example: The reference period is composed of two periods of 7 and 3 years. The crediting period is 2 years. There are three land-cover types: two forest types (FT1 and FT2) and non-forest (NF).

The parameters for emission factors are the aboveground biomass per unit area, which are specific for each forest type, and the root:shoot ratio and carbon fraction, which are shared for the two forest types.

For each uncertainty source in the AD and EF sheet, the standard error (SE) is back-calculated as: $SE = \text{mean} * \text{uncertainty} (90\% \text{ CI}) / 100 / 1.96$

AD sheet: Monte Carlo iterations for Activity Data.

EF sheet: Monte Carlo iterations for Emission Factors

The number of simulations is 10,000. Of these, 9,990 rows are hidden for ease in navigating the spreadsheet.

ER and Sensitivity Analysis sheet:

The AD and EF iterations are combined to estimate the Emission Reduction.

Conduct a sensitivity analysis by turning uncertainty sources on or off using switches, updating the Monte Carlo sampling, and copying the results into the table.

Variables de entrada

La hoja de Variables de entrada contiene todos los datos necesarios para el cálculo de las reducciones de las emisiones. La tabla 1 son los datos de actividad, o la superficie de tierra convertida de bosque tipo 1 a no bosque (FT1-NF) y la superficie de tierra convertida de bosque tipo 2 a no bosque (FT2-NF) para el período total de 10 años: siete años de período de referencia y tres años de período de control. La tabla 2 tiene los factores de emisión incluyendo la fracción de carbono (CF), la relación entre raíz y brotes (R:S) y la biomasa sobre el suelo (AGB).

Las incertidumbres se dan como la mitad de la amplitud del IC del 90%. La SE se calcula a partir de la incertidumbre y el valor de la estimación, aunque reconocemos que en realidad la incertidumbre se calcula a partir de la SE.

	A	B	C	D	E	F	G	H	I	J	K	L	M
1													
2													
3		Table 1. Activity Data and associated uncertainties					Table 2. Carbon Densities, Carbon Fraction, R:S and associated uncertainties						
4		Period	Conversion	AD	U			Value	U				
5		1	FT1-NF	739,643	34			CF	0.47	4			
6		(7 years)	FT2-NF	248,302	46			R:S	0.321	67			
7		2	FT1-NF	232,293	49			AGB_FT1	263	20			
8		(3 years)	FT2-NF	70,935	60			AGB_FT2	150	38			
9		3	FT1-NF	174,937	55			AGB_NF	26	29			
10		(2 years)	FT2-NF	54757	67								
11													
12													
13													
14													
15													
16													
17													
18													
19													

Datos de actividad (AD)

En la hoja de Datos de actividad, los datos de transición de los bosques para cada período de tiempo se simulan utilizando la Simulación de Monte Carlo como: =NORM.INV(RAND(), B\$5, B\$7*B\$1)

NORM.INV(probabilidad, media, sd) da una inversa de la distribución acumulativa normal, con la probabilidad, media y desviación estándar (sd) especificadas.

RAND() genera valores normales aleatorios uniformes entre 0-1.

B\$5 es la media del valor.

B\$7 es el error estándar.

B\$1 es un multiplicador controlado por un interruptor en la hoja de ER y análisis de sensibilidad.

	A	B	C	D	E	F	G	H
1	Multiplier	1	1	1	1	1	1	
2		Period 1 (7 years)		Period 2 (3 years)		Period 3 (2 years)		
3		Deforestation		Deforestation		Deforestation		
4		FT1-NF	FT2-NF	FT1-NF	FT2-NF	FT1-NF	FT2-NF	
5	AD (ha)	739,643	248,302	232,293	70,935	174,937	54757	
6	U (%)	34	46	49	60	55	67	
7	SE	128305	58275	58073	21715	49090	18718	
8	Iterations							
9	1	839422	270794	222858	91907	102908	37920	
10	2	717687	306853	183361	61983	72253	52898	
11	3	548353	204995	243763	56959	126084	71099	
12	4	697787	196958	264925	80956	181057	91994	
13	5	663700	233860	134214	55382	122318	37432	
14	6	673559	229470	151467	98678	150497	46524	
10005	9997	713932	293956	205358	79225	156485	61649	
10006	9998	686580	157331	211198	44622	93772	66896	
10007	9999	718346	267479	271383	110406	212800	48783	
10008	10000	633855	227603	184761	62645	157602	56779	
10009								

Factores de emisión (EF)

En la hoja de Factores de emisión, los valores de R:S, CF y AGB de cada tipo de bosque se simulan mediante la simulación de Monte Carlo.

La biomasa por debajo del suelo (BGB) se calcula multiplicando cada valor de AGB simulado por el valor de R:S simulado.

El carbono total de cada tipo de cubierta terrestre se calcula como la suma de AGB y BGB.

Los factores de emisión (EF) se calculan como la diferencia en el carbono total entre los tipos de cubierta terrestre. La columna M muestra la transición del tipo de bosque 1 (FT1) a no bosque (NF). El proceso se repite para FT2-NF en la columna N.

Las celdas debajo de la fila 10 son valores simulados para cada variable de entrada. Los multiplicadores de la fila 8 se controlan mediante interruptores en la hoja de ER y análisis de sensibilidad.

B11 : X ✓ fx =NORM.INV(RAND(),\$B\$3,\$D\$3*\$B\$8)

	A	B	C	D	E	F	G	H	I	J	K	L	M	N
1		Value	U (%)	SE										
2	CF	0.47	4	0.01										
3	R:S	0.321	67	0.11										
4	AGB_FT1 (ton/ha)	263	20	26.84										
5	AGB_FT2 (ton/ha)	150	38	29.08										
6	AGB_NF (ton/ha)	26	29	3.85										
7		R:S Uncertainty	CF Uncertainty	Sampling Uncertainty			Sampling Uncertainty			Sampling Uncertainty				
8	Multiplier	1	1	1			1			1				
9		Parameters		Simulated Carbon Densities: Forest			Simulated Carbon Densities:			Simulated Carbon Densities:			FE: FT1-NF	FE: FT2-NF
10	Iterations	R:S	CF	AGB	BGB	Total C (AGB+BGB)	AGB	BGB	Total C (AGB+BGB)	AGB	BGB	Total C (AGB+BGB)	C (AGB+BGB)	C (AGB+BGB)
11	1	0.32	0.48	256	82	162	92	30	58	18	6	11	151	47
12	2	0.41	0.46	261	106	170	138	56	90	28	11	18	151	72
13	3	0.18	0.46	167	30	90	128	23	69	27	5	15	75	54
14	4	0.32	0.48	295	94	186	198	63	125	28	9	18	168	107
15	5	0.14	0.48	290	42	159	155	22	85	20	3	11	148	74

ER y simulación

Las emisiones para cada transición forestal se calculan multiplicando los datos de actividad (AD) de la hoja de AD por los factores de emisión (EF) de la hoja de EF.

B4 : X ✓ fx =AD!B8*EF!M11

	A	B	C
1	E		
2		Period 1	
3	Id Sim	FT1-NF	FT2-NF
4	1	16904942	2507280
5	2	9276812	1012690
6	3	18355428	1141584
7	4	14278623	1788756
8	5	15418026	2178583
9	6	14756366	2966326
10000	9997	10967077	1086876
10001	9998	15375514	2164624
10002	9999	11635320	1090530
10003	10000	15471274	1333783
10004			
10005			
10006	Median	13463090.5	1716809.5
10007	Percentile 5%	9143658.75	968009.35
10008	Percentile 95%	18660940.4	2709561.9
10009	Half of confidence interval	4758640.825	870776.275

1. En la fila 10006, la mediana de todas las simulaciones de cada tipo de bosque se calcula como

$$=MEDIAN(B4:B10003)$$

- En la fila 10007, el percentil del 5% de todas las simulaciones de cada tipo de bosque se calcula como

=PERCENTILE(B4:B10003, 0.05)

- En la fila 10008, el percentil del 95% de todas las simulaciones de cada tipo de bosque se calcula como

=PERCENTILE(B4:B10003, 0.95)

- En la fila 10009, la mitad de la amplitud del intervalo de confianza del 90% se calcula de la siguiente manera: (Percentil 95-percentil 5)/2

Es decir, (B10008-B10007)/2

- Por último, en la fila 10010, la incertidumbre se calcula de la siguiente manera: (mitad del intervalo de confianza del 90%/mediana)*100

Es decir, (B10009/B10006)*100

	A	B	C	D	E	F	
1	E						
2		Period 1		Period 2		Pe	
3	Id Sim	FT1-NF	FT2-NF	FT1-NF	FT2-NF	FT1-NF	
4		1	12579300	2145060	19711800	5966694	718
5		2	11624181	2053586	18192807	5124254	708
6		3	12199296	799607	14862848	2329076	493
7		4	15251342	1491441	14820434	4445804	845
8		5	12930120	1401435	16500603	3238515	951
9		6	11422763	1956069	15082771	4544586	821
10000		9997	14190176	913164	20319442	1728174	745
10001		9998	17154368	1587364	22550704	3345243	744
10002		9999	12808888	1970360	17565880	3586100	959
10003		10000	11801514	1840880	15995044	3159120	773
10004							
10005							
10006	Median		13427966	1717174.5	17394955	4132576.5	823
10007	Percentile 5%		9187692.6	962025.2	11866981.5	2331686.6	56404
10008	Percentile 95%		18695230.75	2662617.65	23989526.25	6419677.6	114040
10009	Half of confidence interval		4753769.075	850296.225	6061272.375	2043995.5	288179
10010	Uncertainty		35.4	49.52	34.85	49.46	3
10011							

Interruptores

En la imagen siguiente, la incertidumbre final de las Reducciones de emisiones (celda X10009) se resalta en azul. Cuando los interruptores de las celdas D10012:D10017 están activados, los multiplicadores relacionados se establecen en 1. Cuando los interruptores están desactivados, los multiplicadores se establecen en 0 (o 1E-10, que está cerca de 0, y esto evita errores en la fórmula de Excel). Las incertidumbres cambian ligeramente cada vez que se actualiza el libro y se vuelven a muestrear los valores aleatorios.

	A	B	C	D	E	F	G	H	I	J
10009	Uncertainty (%)	38	58	48	67	53	74	31	47	414.55
10011			Parameter	Switches						
10012			R:S Uncertainty	on						
10013			CF Uncertainty	on						
10014			Sampling Uncertainty (AGB)							
10015			AGB of Forests	on						
10016			Activity Data Uncertainty							
10017			Activity Data	on						
10019	Sensitivity analysis									
10020		Uncertainty (%)	Parameter	Uncertainty with one turned off (%)	Change from all Parameters	Uncertainty with one turned on (%)				
10021	All on	417.94	R:S Uncertainty	413.74	4.2	13.58				
10022	All off	0	CF Uncertainty	414.59	3.35	3.49				
10023			Sampling uncertainty	393.27	24.67	17.11				
10024			Emission Factor uncertainty	395.47	22.47	22.38				
10025			Activity Data	22.38	395.56	395.47				

Esta imagen muestra lo que ocurre cuando la incertidumbre de R:S está desactivada en la pestaña de EF.

	A	B	C	D	E	F	G
6	AGB_NF (t/ha)	26	3.8	29		BGB_NF (ton/ha)	8.346
7		R:S Uncertainty CF Uncertainty Sampling Uncertainty					Sampling
8	Switch	1E-10	1	1			1
9		Parameters			Simulated Carbon Densities: Forest Type 1		Simulat
10	Iterations	R:S	CF	AGB	BGB	Total C (AGB+BGB)	AGB
11	1	0.32	0.47	272	87	169	140
12	2	0.32	0.47	269	86	167	135
13	3	0.32	0.47	278	89	172	144
14	4	0.32	0.49	253	81	164	168
15	5	0.32	0.48	270	86	171	137
16	6	0.32	0.46	274	88	167	148
10007	9997	0.32	0.47	241	77	149	122
10008	9998	0.32	0.47	250	80	155	105
10009	9999	0.32	0.48	257	82	163	202
10010	10000	0.32	0.46	201	64	122	178

La contribución de cada fuente a la incertidumbre global puede determinarse comenzando con todas las fuentes activadas y desactivando cada fuente una a una, o comenzando con todas las fuentes desactivadas y activando cada fuente una a una. La tabla del análisis de sensibilidad se rellena con los valores copiados de la celda J1009 con diferentes combinaciones de interruptores activados o desactivados.

	A	B	C	D	E	F
10011			Parameter	Switches		
10012			R:S Uncertainty	on		
10013			CF Uncertainty	on off		
10014			Sampling Uncertainty (AGB)			
10015			AGB of Forests	on		
10016			Activity Data Uncertainty			
10017			Activity Data	on		
10018						
10019	Sensitivity analysis					
10020		Uncertainty (%)	Parameter	Uncertainty with one turned off (%)	Change from all Parameters	Uncertainty with one turned on (%)
10021	All on	417.94	R:S Uncertainty	413.74	4.2	13.58
10022	All off	0	CF Uncertainty	414.59	3.35	3.49
10023			Sampling uncertainty	393.27	24.67	17.11
10024			Emission Factor uncertainty	395.47	22.47	22.38
10025			Activity Data	22.38	395.56	395.47

Anexo 2. Ejemplo de Monte Carlo en R

https://github.com/mark78b/MCS_in_R/

El ejemplo sencillo en R es el mismo que en Excel, mostrando tasas de deforestación de dos tipos de bosques.

1. Cargando biblioteca

Para ejecutar el código R actual, cargue las siguientes bibliotecas:

```
library(matrixStats)
library(gridExtra)
library(reshape)
```

2. Lectura de entradas por tipo de bosque y período

Leer los valores específicos de AD y EF (e incertidumbres asociadas) por tipo de bosque (FT) y período (P). Leer las tablas csv de AD y EF de la siguiente manera:

```
rm(list=ls(all=TRUE))
```

```
### Dirección para leer las entradas
setwd("C:/Desktop/Inputs")
```

```
### Lectura de entradas
```

```
# Entradas de AD
```

```
BaseAD <- read.csv("1_Activity_Data.csv")
dim(BaseAD)
```

```
BaseAD_4yr <- read.csv("1_Activity_Data_4yr.csv")
dim(BaseAD_4yr)
```

```
# Entradas de EF
```

```
BaseEF <- read.csv("2_Emission_Factors.csv")
dim(BaseEF)
```

3. Simulaciones de números aleatorios de AD y EF

Un paso clave del MCS es la generación de números aleatorios de AD y EF. Para generar números aleatorios es necesario: (i) el estimador de AD y EF y (ii) el error estándar (SE) de los

estimadores de AD y EF. Sin embargo, en la mayoría de los casos, sólo se informa de las incertidumbres de AD y EF. Por lo tanto, es necesario calcular el SE de AD y EF de la siguiente manera:

$$U = \frac{1/2 IC}{\hat{\theta}} \times 100 \quad \Rightarrow \quad U = \frac{1.96 \times \sigma}{\hat{\theta}} \times 100 \quad \Rightarrow \quad \sigma = \frac{U \times \hat{\theta}}{1.96 \times 100}$$

$$U = \frac{1/2 IC}{\hat{\theta}} \times 100 = \frac{1.96 \times \sigma}{\hat{\theta}} \times 100 \Rightarrow \sigma = \frac{U \times \hat{\theta}}{100}$$

U = Incertidumbre

IC = Intervalo de confianza

θ = Estimador de AD o EF

σ = Desviación estándar

Una vez que se han calculado los SE de AD y EF, es posible (i) generar vectores de números aleatorios de AD y EF por FT-P, (ii) estimar las emisiones por FT, y (iii) guardar vectores de emisiones simuladas por FT en formato de matriz.

A continuación se muestra cómo simular números aleatorios (de distribución normal, mediante error medio y estándar) de AD independiente y EF parcialmente correlacionado:

1. Simulación de datos de actividad

Computación de SD de AD

```
BaseAD$DesEstDA<-abs((BaseAD$U_AD_per*BaseAD$AD_ha)/(1.65*100))
```

Número de simulaciones

```
n<-1000000
```

```
MatrizDef<-seq(1:n)
```

Interruptor para AD si es 1 incorpora MC y si es 0 entonces se usa el valor sencillo

```
SWITCH_AD =1
```

Simulaciones de AD por período y conversiones

para (i en 1:length(BaseAD\$Code))

```
{
```

```
  DAsim<-rnorm(n,mean=BaseAD$AD_ha[i], sd=BaseAD$DesEstDA[i]*SWITCH_AD)
```

```
  MatrizDef<-cbind(MatrizDef,DAsim)
```

```
}
```

Conversión de matriz de AD a DataFrame

```

Matrix_AD<-as.data.frame(MatrizDef)

### Nombres de columna correctos de AD-Dataframe por periodo y transición
colnames(Matrix_AD) = c("Id_sim_AD",
                        "AD_P1_FT1_NF","AD_P1_FT2_NF",
                        "AD_P2_FT1_NF","AD_P2_FT2_NF",
                        "AD_P3_FT1_NF","AD_P3_FT2_NF")

##### 2. Simulación de factores de emisión #####

### Simulaciones y CF, R:S y AGB por tipo de bosque y transición
### Matriz para guardar valores simulados de CF, R:S y AGB
MatrizEF_Def <-seq(1:n)
### Interruptores para EF
SWITCH_EF =1

### Simulaciones de CF, R:S y AGB
para (i en 1:length(BaseEF$value))
{
  EF_Sim<-rnorm(n,mean=BaseEF$value[i], sd=BaseEF$SE[i]*SWITCH_EF)
  MatrizEF_Def<-cbind(MatrizEF_Def,EF_Sim)
}

### Conversión de la matriz CF, R:S y AGB a DataFrame
Matrix_EF<-as.data.frame(MatrizEF_Def)

### Nombres de columna correctos de CF, R:S y AGB en DataFrame
colnames(Matrix_EF) = c("Id_sim_EF","CF","Root_S","AGB_FT1","AGB_FT2","AGB_NF")

#####

### Simulación de BGB, densidades de carbono y EF por transición

### Simulación de BGB por estrato
Matrix_EF$BGB_FT1 <- Matrix_EF$AGB_FT1 * Matrix_EF$Root_S
Matrix_EF$BGB_FT2 <- Matrix_EF$AGB_FT2 * Matrix_EF$Root_S
Matrix_EF$BGB_NF <- Matrix_EF$AGB_NF * Matrix_EF$Root_S

### Simulación de densidades de carbono por estrato
Matrix_EF$C_FT1 <- (Matrix_EF$AGB_FT1 + Matrix_EF$BGB_FT1 ) * Matrix_EF$CF

```

```
Matrix_EF$C_FT2 <- (Matrix_EF$AGB_FT2 + Matrix_EF$BGB_FT2 ) * Matrix_EF$CF
Matrix_EF$C_NF <- (Matrix_EF$AGB_NF + Matrix_EF$BGB_NF ) * Matrix_EF$CF
```

```
### Simulación de EF por transición
```

```
Matrix_EF$EF_FT1_NF <- Matrix_EF$C_FT1 - Matrix_EF$C_NF
```

```
Matrix_EF$EF_FT2_NF <- Matrix_EF$C_FT2 - Matrix_EF$C_NF
```

```
### Filtración de EF simulado por transición
```

```
Matrix_EF1<-data.frame(Id_sim_EF =Matrix_EF$Id_sim_EF,
```

```
EF_FT1_NF =Matrix_EF$EF_FT1_NF,
```

```
EF_FT2_NF =Matrix_EF$EF_FT2_NF)
```

```
length(Matrix_EF1$Id_sim_EF)
```

4. Estimación de emisiones simuladas

Al usar los valores de AD y EF simulados, se calculan las emisiones por transición del uso de la tierra y periodo:

```
### Fusión de AD-Dataframe y EF-Dataframe
```

```
Table_Emi<- merge(Matrix_AD, Matrix_EF1, by.x = "Id_sim_AD", by.y = "Id_sim_EF",all=T)
```

```
### Estimación de emisiones por período y transición anualizadas
```

```
yearP1=7
```

```
yearP2=3
```

```
yearP3=2
```

```
Table_Emi$Emi_P1_FT1_NF <- Table_Emi$AD_P1_FT1_NF * Table_Emi$EF_FT1_NF
```

```
Table_Emi$Emi_P1_FT2_NF <- Table_Emi$AD_P1_FT2_NF * Table_Emi$EF_FT2_NF
```

```
Table_Emi$Emi_P2_FT1_NF <- Table_Emi$AD_P2_FT1_NF * Table_Emi$EF_FT1_NF
```

```
Table_Emi$Emi_P2_FT2_NF <- Table_Emi$AD_P2_FT2_NF * Table_Emi$EF_FT2_NF
```

```
Table_Emi$Emi_P3_FT1_NF <- Table_Emi$AD_P3_FT1_NF * Table_Emi$EF_FT1_NF
```

```
Table_Emi$Emi_P3_FT2_NF <- Table_Emi$AD_P3_FT2_NF * Table_Emi$EF_FT2_NF
```

```
dim(Table_Emi)
```

```
#####
```

```
##### 3.1 Simulación de emisiones de la línea basal (2 períodos, 7 y 3 años) #####
```

```
### Selección de emisiones para el período de línea basal
```

```
Table_Emi_FREL<- Table_Emi[, c(1,10:13)]
```

```
Table_Emi_FREL$FREL<- ( rowSums(Table_Emi_FREL[,c(2:5)]) ) / (yearP1+yearP2)
```


5. Estimación de cuantiles e incertidumbres

Utilizando vectores de emisiones simuladas, es posible estimar las incertidumbres superiores/inferiores asociadas de la siguiente manera:

$$U_{inf} = \frac{|Q(0.025) - \hat{E}|}{\hat{E}} \times 100 \quad \text{and} \quad U_{sup} = \frac{|Q(0.975) - \hat{E}|}{\hat{E}} \times 100$$

U_{inf} = Incertidumbre en el lado izquierdo de las emisiones simuladas

U_{sup} = Incertidumbre en el lado derecho de las emisiones simuladas

$Q(0,025)$ = cuantil 0,025 de las emisiones simuladas

$Q(0,975)$ = cuantil 0,975 de las emisiones simuladas

E = Emisiones simuladas de Monte Carlo

(i) Por lo tanto, los cuantiles inferiores/superiores de las emisiones de la línea basal pueden estimarse como:

```
Q_05_FREL <-quantile(Table_Emi_FREL$FREL,0.05)[[1]]
```

```
Q_95_FREL <-quantile(Table_Emi_FREL$FREL,0.95)[[1]]
```

(ii) Además, las incertidumbres inferiores/superiores de la línea basal de las emisiones pueden estimarse como:

```
half_CI <- (Q_95_FREL - Q_05_FREL)/2
```

```
U_FREL<-abs( half_CI / median(Table_Emi_FREL$FREL))*100
```

6. Guardado de cuantiles e incertidumbres

Se guardan cantidades e incertidumbres de emisiones por período y emisión mediana:

```
### Guardado de emisiones de la línea basal y cuantiles e incertidumbres asociadas
```

```
Table_FREL<-data.frame(Period = "FREL",  
                        Emisión = median(Table_Emi_FREL$FREL),  
                        Q_05 = round(Q_05_FREL , digits = 3),  
                        Q_95 = round(Q_95_FREL , digits = 3),  
                        Incertidumbre = round(U_FREL, digits = 2))
```

7. Función de densidad de probabilidad de emisiones por período y línea basal

Por último, se trazan las funciones de densidad de probabilidad (PDF) de las emisiones por período y emisiones medianas:

```
### Guardado de PDF de emisiones de la línea basal
setwd("C:/Users/Invited/Outputs")

pdf("1_Emissions_Uncertainty_FREL.pdf")
par(mfrow=c(2,1))
hist(Table_Emi_FREL$FREL,
      main="Histogram of FREL",
      xlab="Average annual emissions from deforestation (Ton of CO2e)",
      cex.lab=1, cex.axis=0.8, cex.main=1,
      #border="blue",
      col="green",
      las=1,
      breaks = 200,
      prob = TRUE)
lines(density(Table_Emi_FREL$FREL ))
dev.off()
```

Una versión preliminar del código R mostrado arriba está disponible en el siguiente enlace:
https://github.com/mark78b/MCS_in_R/

Información del documento

Versión	Fecha	Descripción
1.0	21 de septiembre de 2021	Versión inicial