

FUNDAMENTOS PARA EL ANÁLISIS DE RIESGO CLIMÁTICO EN ZONAS ÁRIDAS

FOUNDATIONS FOR THE ANALYSIS OF CLIMATE RISK IN DRY AREAS

Sánchez Cohen Ignacio*

Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias. CENID-RASPA
km 6.5 Canal Sacramento Zona Industrial. Durango, Dgo. MÉXICO. Tel. 52 871 7526332,
Correo-e: ignacio_sanchezcohen@hotmail.com (*Autor para correspondencia).

RESUMEN

Los sistemas productivos de zonas áridas están sujetos a la aleatoriedad climática lo que les da la categoría de sistemas bajo riesgo. El uso de modelos de simulación que consideren esta aleatoriedad, son la mejor opción para cuantificar la probabilidad de ocurrencia de eventos de lluvia y/o escurrimiento (riesgo). En el presente trabajo se analizan los fundamentos teóricos estadísticos-matemáticos necesarios para incursionar en la simulación y modelación de procesos hidrológicos en zonas áridas. También, se propone un método para cuantificar la precipitación y escurrimiento en sistemas de captación de agua de lluvia para aquellas regiones desprovistas o con poca instrumentación. De igual manera se pondera la necesidad de realizar el análisis de sensibilidad del modelo así como el proceso de calibración.

PALABRAS CLAVE: Estadística, incertidumbre, modelación, procesos, balance agua.

ABSTRACT

Rain-fed agriculture in dry areas is subject to climate uncertainty, making it a risky endeavor. Simulation models that consider this uncertainty are the best option for assessing the probability of occurrence of rainfall and/or runoff events (risk). This paper analyzes the theoretical statistical-mathematical foundations needed for modeling and simulating hydrologic processes in dry areas. A stochastic method to compute rainfall and runoff events for rainwater harvesting systems in regions with little or no instrumentation is also proposed. Moreover, the need to perform sensitivity analysis of simulation models and the calibration process is considered.

KEYWORDS: Statistics, uncertainty, modeling, processes, water balance.



Recibido: 30 de septiembre, 2013
Aceptado: 21 de mayo, 2014
<http://www.chapingo.mx/revistas>
doi: 10.5154/r.rchsza.2013.09.003

INTRODUCCIÓN

La degradación de los recursos naturales en varias partes del mundo y específicamente en las zonas sujetas a incertidumbre climática, ha adquirido proporciones seriamente alarmantes al perder gran parte de la biodiversidad y la productividad de sus suelos. Esta situación ha causado la emigración forzada por aspectos relacionados con el clima, lo que ejemplifica la vulnerabilidad inherente a nuestros recursos naturales (Oswald, 2007; Sánchez-Cohen *et al.*, 2008, 2011).

El término vulnerabilidad en el contexto de eventos hidrológicos está constituido por dos componentes principales:

- a) Riesgo a la exposición de diferentes tipos de desastres o estrés, lo que conlleva a la noción de probabilidad de ocurrencia de eventos los cuales pueden variar espacial y temporalmente.
- b) La habilidad de sobrellevar los desastres o estrés.

Una acepción más concreta del término vulnerabilidad sería: Sensibilidad a la variabilidad climática.

De lo anterior se deduce que un sistema vulnerable es un sistema bajo riesgo el cual puede ser físico o económico sin ser ambos necesariamente excluyentes. El riesgo físico se relaciona a variables como el rendimiento de los cultivos siendo la principal fuente de riesgo el climático. Sin embargo, el comportamiento físico de un cultivo es solo una apreciación parcial del riesgo al que está sujeto un productor dado que, comúnmente, los productores de zonas áridas organizan su sistema productivo de tal manera que diversifican sus actividades tratando de reducir el riesgo. Así, si fracasan en una actividad (producción de maíz por ejemplo), en otra (crianza y venta de especies menores) les puede ir mejor de tal manera que las ganancias de la segunda sobrellevan a las pérdidas de la primera (Sánchez, 2005).

El riesgo económico se relaciona a la variabilidad del ingreso con la incertidumbre de que el rendimiento de los cultivos es solo una fuente en virtud de las influencias externas ajenas a la voluntad del productor. En este contexto, acorde a Chowdhury (1992), el análisis de riesgo puede no necesariamente basarse en análisis probabilísticos considerando el amplio rango de consideraciones en que puede ser usado. Así, Fischhoff *et al.* (1984) definen al análisis de riesgo como una herramienta para la toma de decisiones que usa conocimiento base, el cual consiste de información científica y política. Luego entonces el análisis de riesgo es un subconjunto de teoría de decisiones (Sánchez *et al.*, 1995).

Cuantificación del riesgo

Acorde a Cohessen y Covello (1989), la estimación del riesgo es equivalente a la estimación de la probabilidad estadística

INTRODUCTION

Natural resource degradation in various parts of the world and particularly in areas subject to climate uncertainty has become an alarming issue due to the sizable loss of biodiversity and soil productivity. These climate-related issues have caused forced migrations, exemplifying the inherent vulnerability of our natural resources (Oswald, 2007; Sánchez-Cohen *et al.*, 2008, 2011).

The term vulnerability in the context of hydrologic events has two major components:

- a) Risk of exposure to different kinds of disasters or stresses, which leads to the probability of occurrence of events, which may vary spatially and temporally:
- b) The ability to compensate for disasters or stresses.

A more specific meaning of the term vulnerability is sensitivity to climate variability.

It follows from the above that a vulnerable system is a system at risk, where the risk may be of a physical or economic nature without the two necessarily being mutually exclusive. The physical risk is related to variables like crop yield, with the main source of risk being the weather. However, the physical behavior of a crop provides only a partial assessment of the risk to which a producer is exposed, because, usually, dryland farmers diversify their activities in an effort to reduce risk. Therefore, if producers have poor results in one activity (corn production, for example), they may fare better in another (breeding and sale of livestock), so the earnings in the second activity compensate for the losses in the first (Sánchez, 2005).

Economic risk is related to income variability, with crop yield being only one source of uncertainty due to external factors beyond the control of the producer. In this context, according to Chowdhury (1992), risk analysis may not necessarily be based on probabilistic analysis in light of the wide range of settings in which it can be used. Thus, Fischhoff *et al.* (1984) define risk analysis as a tool for decision making based on core knowledge of political and scientific information. Therefore, risk analysis is a subset of decision theory (Sánchez *et al.*, 1995).

Risk quantification

According to Cohessen and Covello (1989), estimating risk is equivalent to estimating the statistical probability of damage occurrence as a result of exposure to a risk agent. In hydrology, and specifically in agriculture, that risk agent is mainly the climate.

Agriculture systems are characterized by the complexity and interdependence of their components, as well as by the

de ocurrencia de un daño como resultado de la exposición a un agente de riesgo. En hidrología y específicamente en la agricultura ese agente de riesgo es principalmente el clima.

Los sistemas agrícolas se caracterizan por la complejidad e interdependencia de sus componentes y por la variabilidad y riesgo implícito en su manejo. En la agricultura de riego, por ejemplo, el riesgo se restringe a enfermedades, plagas y principalmente a cambios en precios y condiciones de mercado. Por otro lado, en agricultura de temporal o de subsistencia además de los factores de riesgo arriba descritos, se tiene que añadir las condiciones climáticas en términos de ocurrencia de precipitación principalmente que son mucho menos predecibles. Asimismo, en agricultura de riego el riesgo es estimado como porcentaje de pérdida basado en estadísticas (Abbaspour, 1992).

Una aproximación que comúnmente se utiliza para el análisis de riesgo consiste en la optimización de una función de rendimiento basado en restricciones al sistema (Berbel, 1993).

Otro método usado para el análisis de riesgo lo constituyen los árboles de decisión (Ang y Tang, 1984). En estos árboles de decisión las alternativas de manejo se enlistan en una matriz de decisión con sus posibles salidas. Estas matrices integran los componentes relevantes del análisis de decisión en una manera sistemática disponible para una evaluación analítica de la alternativa óptima. Después de construir la matriz se obtiene una función de utilidad.

El uso de índices es también usado para la cuantificación de riesgo como: (Fischhoff, 1984)

$$R = \sum_{j=1}^n W_j Y_j \quad (1)$$

Donde:

Y_j es la utilidad esperada para el atributo “ j ” y W_j es un factor de ponderación expresando la importancia relativa.

Aproximación determinística versus aproximación estocástica

Usualmente en hidrología, manejo de cuencas y en ramas de la ciencia afines, el éxito de una determinada obra se mide en términos del comportamiento del sistema diseñado. Por ejemplo en sistemas de captación de agua de lluvia el éxito se evalúa como función del almacenamiento de humedad en el suelo u otro tipo de almacenamiento. En este criterio la oscilación de las variables de entrada al sistema (proceso aleatorio) no es considerada es decir, si ninguna variable involucrada en el sistema sigue una distribución probabilística se dice entonces que el modelo que describe a ese sistema es determinístico.

Si aceptamos que nuestro conocimiento relativo al comportamiento de diversos sistemas no es perfecto y considerando

variability and risk inherent in their management. In irrigated agriculture, for example, risk is restricted to diseases, plagues, and mainly to changes in prices and market conditions. By contrast, in rain-fed or subsistence agriculture, besides the above-mentioned risk factors, weather conditions in terms of rainfall occurrence that are far less predictable must be considered. Also, in irrigation agriculture the risk is expressed in terms of statistically-based percentage loss of total crop production (Abbaspour, 1992).

A common approach to risk analysis is the optimization of a yield function based on restrictions to the system (Berbel, 1993).

Another approach used in risk analysis is the decision tree method (Ang and Tang, 1984). In this approach, management alternatives are listed in a decision matrix with their possible outcomes. These matrices integrate the components relevant for the decision analysis in a systematic manner, allowing an analytical assessment of the best alternative. A utility function is obtained after the matrix is built.

Indexes are also used in risk quantification as follows (Fischhoff, 1984):

$$R = \sum_{j=1}^n W_j Y_j \quad (1)$$

Where:

Y_j is the utility expected for the attribute “ j ” and W_j is a weighting factor expressing its relative importance.

Deterministic approach versus stochastic approach

In hydrology, watershed management and related branches of science, the success of a given work is usually measured in terms of the behavior of the designed system. For example, in rainwater collection systems success is measured as a function of moisture storage in the soil or another type of storage. According to this criterion, the oscillation of variables (random process) inputted into the system is not considered; that is, if no variable in the system shows a probabilistic distribution, then it can be said that the model describing this system is deterministic.

If we accept that our knowledge of the behavior of various systems is not perfect, and considering the uncertainty involved in some of their parameters, it can be concluded that there are severe limitations in the deterministic approaches to risk analysis. These approaches do not allow the analysis of credibility and risk under uncertain conditions.

Stochastic simulation (also known as the Monte Carlo method) uses mathematical models to study systems characterized by the occurrence of discrete random events, represented by random variables. The randomness found in real systems can be synthesized. This approach allows the

la incertidumbre asociada con algunos de sus parámetros, se puede concluir que existen enormes limitaciones en las aproximaciones determinísticas en el análisis de riesgo. Estas aproximaciones no permiten el análisis de credibilidad y riesgo bajo condiciones de incertidumbre.

La simulación estocástica (citada también como método Monte Carlo) utiliza modelos matemáticos para el estudio de sistemas que se caracterizan por la ocurrencia de eventos discretos aleatorios los cuales son representados por variables aleatorias. La aleatoriedad encontrada en un sistema real puede ser sintetizada. Este tipo de aproximación permite la cuantificación del comportamiento esperado del sistema y la cantidad de la variación aleatoria lo que constituye un indicativo del grado de riesgo asociado con el sistema (Gottfried, 1984).

Sin embargo, acorde a Linsley (1976), los métodos estocásticos presentan la desventaja que las variables generadas estocásticamente son tan creíbles como lo sean los parámetros de las funciones de distribución de donde fueron generadas. Esto pone de manifiesto que la magnitud del record histórico o base de datos tiene un efecto en la incertidumbre de los parámetros a ser estudiados. El gran problema en el análisis de riesgo estriba en la predicción y control de variables aleatorias como el caso de eventos extremos de precipitación y temperaturas. Esto enfatiza el estrecho vínculo entre el riesgo y la productividad.

Análisis multivariado

Normalmente en estudios hidrológicos se asume que existe independencia entre los parámetros que definen el comportamiento de algún fenómeno. Inclusive técnicas avanzadas de análisis estocástico como el método Monte Carlo sobreestiman la posible correlación inherente a no pocos parámetros hidrológicos (Díaz *et al.*, 2008). El hecho de incluir en la generación aleatoria de valores de parámetros la correlación estadística existente tiene dos objetivos principales: (Tiscareño *et al.*, 1993).

- Evitar combinaciones de parámetros no reales que pudieran arrojar salidas absurdas de los modelos de simulación y
- Mantener la variabilidad natural del sistema durante la generación de los parámetros del modelo.

En este proceso, se requiere del conocimiento de la media, desviación estándar y la correlación entre variables (si se consideran solo dos variables correlacionadas) o la matriz de covarianza (si se consideran más de dos variables correlacionadas), Díaz *et al.*, 2011.

La distribución normal y la generación multivariada: Numerosa literatura asienta que cualquier distribución puede ser reducida (estandarizada) a la distribución normal; las

quantification of the system's expected behavior and the amount of random variation, which is indicative of the degree of risk associated with the system (Gottfried, 1984).

However, according to Linsley (1976), stochastic methods share as a drawback the fact that the variables thus generated are only as reliable as the parameters in the distribution function from which those variables were generated. This shows that the size of the historical record or database has an impact on the uncertainty of the parameters under study. The major problem in risk analysis lies in the prediction and control of random variables, as in the case of extreme rainfall and temperature events. This fact emphasizes the close link between risk and productivity.

Multivariate analysis

In hydrology studies it is generally assumed that the parameters that define the behavior of a given phenomenon are independent. Even advanced stochastic analysis techniques, like the Monte Carlo method, overestimate the possible correlation inherent to several hydrological parameters (Díaz *et al.*, 2008). The inclusion of the existing statistical correlation in the random generation of parameter values has two major objectives (Tiscareño *et al.*, 1993):

- Avoid non-real parameter combinations that may yield absurd outcomes in the simulation models, and
- Keep the natural variability of the system during the generation of model parameters.

This process requires knowing the mean, standard deviation, and correlation between variables (if only two correlated variables are considered) or the covariance matrix (if more than two correlated variables are considered), Díaz *et al.*, 2011.

Normal distribution and Multivariate generation. Many sources state that any distribution may be reduced (standardized) to the normal distribution. The advantage in using normal distribution lies in the fact that it is very "manageable" for statistical purposes, which is why it is often used as a distribution "model" for many hydrological phenomena. Additionally, several multivariate phenomena approach this distribution regardless of the original distribution due to the central limit theorem.

The function of multivariate normal density is a generalization of the univariate normal density function and is obtained by changing the exponent of the following equation:

$$f(x) = \frac{1}{2\pi} \exp \left[-\frac{(x - \mu)^2}{2\sigma^2} \right] - \infty \leq z \leq \infty \quad (2)$$

as:

$$\frac{x - m}{\sigma^2} = (x - \mu)(\sigma^2)^{-1}(x - \mu) \quad (3)$$

ventajas en el uso de la distribución normal estriban en que es muy “manejable” en términos estadísticos por lo que es bastante usada como distribución “modelo” para muchos fenómenos hidrológicos. Además, varios fenómenos multivariados se aproximan a esta distribución independientemente de la distribución original debido al teorema del límite central.

La función de densidad normal multivariada es una generalización de la función de densidad normal univariada y se obtiene modificando el exponente de esta ecuación :

$$f(x) = \frac{1}{2\pi} \exp \left[-\frac{(x - \mu)^2}{2\sigma^2} \right] - \infty \leq z \leq \infty \quad (2)$$

como:

$$\frac{x - m}{\sigma^2} = (x - \mu)(\sigma^2)^{-1}(x - \mu) \quad (3)$$

el cual mide la distancia al cuadrado de “x” a μ en términos de número de desviaciones estándar, por:

$$(x - \mu)' \Sigma^{-1}(x - \mu) \quad (4)$$

Donde:

μ representa el valor esperado del vector aleatorio “X”, y Σ^{-1} es la matriz de covarianza (Banks, 1998). Asimismo la constante univariada normalizada :

$$\sqrt{2\pi\sigma^2} \quad (5)$$

debe ser cambiada por una constante general que fuerza al área bajo la curva de densidad multivariada a ser la unidad para cualquier longitud de vector. Esta constante es:

$$(2\pi)^{-\frac{p}{2}} |\Sigma|^{-\frac{1}{2}} \quad (6)$$

Por lo tanto, la función de densidad normal p-dimensional para el vector aleatorio $X = [X1, X2, \dots, Xp]$ estará dada por:

$$f(x) = \frac{1}{(2\pi)^{\frac{p}{2}} |\Sigma|^{-\frac{1}{2}}} e^{-\frac{(x - \mu)' \Sigma^{-1}(x - \mu)}{2}} \quad (7)$$

La función de densidad normal bivariada: La función de densidad normal bivariada ($p = 2$), puede ser evaluada en función de los parámetros de las dos variables correlacionadas: $\mu_1 = E(X1)$, $\mu_2 = E(X2)$, $\sigma_{11} = \text{Var}(X1)$, $\sigma_{22} = \text{Var}(X2)$ y $\rho_{12} = \rho_{21} / [(\sigma_{11})^{1/2} (\sigma_{22})^{1/2}]$, el cual es la correlación entre las dos variables, nótese que los subíndices indican la variable 1 y 2.

Para fines prácticos, es necesario substituir los subíndices “1 y 2” por las variables “x” y “y” respectivamente, así entonces, substituyendo el inverso de la matriz de covarianza Σ^{-1} e introduciendo el coeficiente de correlación, la ecuación 7 se expresará como:

which measures the square distance from “x” to μ in terms of the number of standard deviations by:

$$(x - \mu)' \Sigma^{-1}(x - \mu) \quad (4)$$

Where:

μ is the expected value of the random vector “X”, and Σ^{-1} is the covariance matrix (Banks, 1996). Likewise, the normalized univariate constant:

$$\sqrt{2\pi\sigma^2} \quad (5)$$

must be changed by a general constant that forces the area under the multivariate density curve to become the unit for any vector length: This constant is:

$$(2\pi)^{-\frac{p}{2}} |\Sigma|^{-\frac{1}{2}} \quad (6)$$

Therefore, the function of p-dimensional normal density for the random vector $X = [X1, X2, \dots, Xp]$ is given by:

$$f(x) = \frac{1}{(2\pi)^{\frac{p}{2}} |\Sigma|^{-\frac{1}{2}}} e^{-\frac{(x - \mu)' \Sigma^{-1}(x - \mu)}{2}} \quad (7)$$

The function of normal bivariate density. The function of normal bivariate density ($p = 2$) may be evaluated according to the parameters of the two correlated variables: $\mu_1 = E(X1)$, $\mu_2 = E(X2)$, $\sigma_{11} = \text{Var}(X1)$, $\sigma_{22} = \text{Var}(X2)$ and $\rho_{12} = \rho_{21} / [(\sigma_{11})^{1/2} (\sigma_{22})^{1/2}]$, which is the correlation between both variables; note that subscripts indicate variables 1 and 2.

For practical purposes, it is required to substitute the subscripts “1” and “2” for the variables “x” and “y” respectively. Therefore, by substituting the inverse of the covariance matrix Σ^{-1} and introducing the correlation coefficient, equation 7 will become:

$$f_{x,y}(x,y) = f_{y|x}(y|x) f_x(x) \quad (8)$$

Where:

the first factor in the right side of the equality is:

$$f_{y|x}(y|x) = \frac{1}{\sqrt{2\pi\sigma_y} \sqrt{1 - \rho^2}} e^{-\frac{1}{2} \frac{(y - \mu_y - \rho_{xy} \frac{\sigma_y}{\sigma_x})(x - \mu_x)}{\sigma_y \sqrt{1 - \rho^2_{xy}}}} \quad (9)$$

and the second factor is given by:

$$f_x(x) = \frac{1}{\sqrt{2\pi\sigma_x}} e^{-\frac{1}{2} \frac{(x - \mu_x)^2}{\sigma_x^2}} \quad (10)$$

The conditional parameters of the equation 8 are, for the mean:

$$E(y | x) = \mu_y + \rho_{xy} \frac{\sigma_y}{\sigma_x} (x - \mu_x) \quad (11)$$

$$f_{x,y}(x,y) = f_{y|x}(y|x)f_x(x) \quad (8)$$

Donde:

el primer factor al lado derecho de la igualdad es:

$$f_{y|x}(y|x) = \frac{1}{\sqrt{2\pi}\sigma_y \sqrt{1-\rho^2}} e^{-\frac{1}{2}(y-\mu_y - \rho_{xy}(\frac{\sigma_y}{\sigma_x})(x-\mu_x)) \frac{1}{\sigma_y \sqrt{1-\rho_{xy}^2}}} \quad (9)$$

y el segundo factor está dado por:

$$f_x(x) = \frac{1}{\sqrt{2\pi}\sigma_x} e^{-\frac{1}{2}(\frac{x-\mu_x}{\sigma_x})^2} \quad (10)$$

Los parámetros condicionales de la ecuación 8 son, para la media:

$$E(y|x) = \mu_y + \rho_{xy} \frac{\sigma_y}{\sigma_x} (x - \mu_x) \quad (11)$$

y para la desviación estándar:

$$\sigma_y | x = \sigma_y \sqrt{1 - \rho^2} \quad (12)$$

El proceso para el uso de la ecuación 8 consiste en generar un número normalizado "x" para la variable "X" acorde a la ecuación:

$$x = \mu + \sigma Z \quad (13)$$

Donde $Z = \sum_{i=1}^{12} U_i - 6$.

Esta ecuación constituye la base para la obtención de valores estándar normalmente distribuidos partiendo de un número aleatorio de la distribución uniforme con U[0,1]. Esta ecuación establece que se tiene que generar 12 números uniformemente distribuidos y sumarlos, al resultado se le deberá restar un valor de 6 para obtener el valor deseado normalmente distribuido; (se supone que la variable de la cual se generará el número aleatorio tiene una media μ_x y una desviación estándar σ_x). El número así generado se deberá sustituir en las ecuaciones 9 y 10; el producto de estas ecuaciones será la función probabilística de densidad condicionada "y" dado "x".

Método Montecarlo y el Teorema de Bayes

La aplicación del método Monte-Carlo en conjunción con la teoría Bayesiana, es útil cuando se requieren predecir valores en las entradas a los modelos. Es decir, se acepta de antemano que existe "incertidumbre" en los valores que un determinado parámetro o variable de entrada a los modelos pueda tomar. Así, el método propone la obtención de funciones de distribución anteriores como entradas al modelo para obtener funciones de distribución del(os) parámetro(os) de las salidas del modelo pudiendo actualizar, con la información así generada, los parámetros de las funciones de entrada al modelo.

and for the standard deviation:

$$\sigma_y | x = \sigma_y \sqrt{1 - \rho^2} \quad (12)$$

The process for the use of equation 8 is to generate a normalized number "x" for variable "X" according to the equation:

$$x = \mu + \sigma Z \quad (13)$$

Where: $Z = \sum_{i=1}^{12} U_i - 6$.

This equation is the basis for obtaining standard values normally distributed starting from a random number of the uniform distribution with U[0,1]. This equation means that 12 uniformly distributed numbers must be generated and added up. A value of 6 must be deducted from the result to get the desired value normally distributed (it is assumed that the variable from which the random number will be generated has a mean μ_x and a standard deviation σ_x). The number thus generated will be substituted in equations 9 and 10; the product of these equations will be the probabilistic function of conditioned density "y" given "x".

The Monte-Carlo Method and the Bayes theorem

The application of the Monte-Carlo method conjointly with the Bayesian theory is useful when it is necessary to predict values for the model inputs. That is, it is accepted beforehand that there is "uncertainty" in the values that a given parameter or variable inputted to the models may take. Thus, the method proposes obtaining previous distribution functions as inputs for the model to acquire distribution functions for the model's output parameter(s). This, with the information so generated, allows updating the parameters of the model's input functions.

Figure 1 displays the method algorithm, which can be summarized in the following steps (modified from Tiscareño *et al.*, 1993).

- 1) Obtain the probabilistic density functions from the relevant databases for the several variables involved in the simulation model in question.
- 2) Derive the relevant conditioned distribution function(s).
- 3) Generate the inputs to the model according to the function parameters described in steps 1 and 2.
- 4) Obtain the distribution function(s) for the model outputs.
- 5) When relevant, compare the output distribution functions with the input distribution functions, and modify the parameters of the latter to obtain better output estimates. At this point, it is necessary to establish a criterion

La Figura 1 señala de manera gráfica el algoritmo del método el cual puede ser resumido en los siguientes pasos (modificado de Tiscareño *et al.*, 1993):

- 1) Obtener las funciones de densidad probabilísticas de las bases de datos pertinentes para las diferentes variables que involucraría el modelo de simulación en cuestión.
- 2) Derivar la(s) función(es) de distribución condicionada pertinentes.
- 3) Generar las entradas al modelo acorde a los parámetros de las funciones descritas en los pasos 1 y 2.
- 4) Obtener la(s) función(es) de distribución de las salidas del modelo.
- 5) Cuando sea pertinente, comparar las funciones de distribución de salidas con las de entradas y modificar los parámetros de estas últimas para obtener mejores estimaciones en las salidas. En este punto, es necesario el establecer un criterio de selección de aquellas salidas que se considera mejorarán los parámetros de las funciones de entrada en términos de una mejor predicción

for selecting those outputs that may improve the predictive power of the input function parameters.

- 6) Repeat the steps until the input density functions stabilize.

The algorithm shown in Figure 1 has been used to obtain Irrigation Guides based on a hydrological simulation model. In this algorithm, the random variation in the soil infiltration function parameters (sorptivity and saturated hydraulic conductivity) was taken into account, considering the joint probability that a given value occurs because these values are correlated. With this information and some fixed data in the model (design parameters of the surface irrigation), the simulation model was used, considering as viable options those parameter combinations yielding an efficiency of 85 % or more in the application of irrigation water and a uniformity coefficient of 85 % or more.

Approach to quantification of runoff in watersheds with little instrumentation

The variable that defines the vulnerability of a production system is the rainfall; therefore, daily rainfall is a simple example in meteorological terms of a binary random event (it

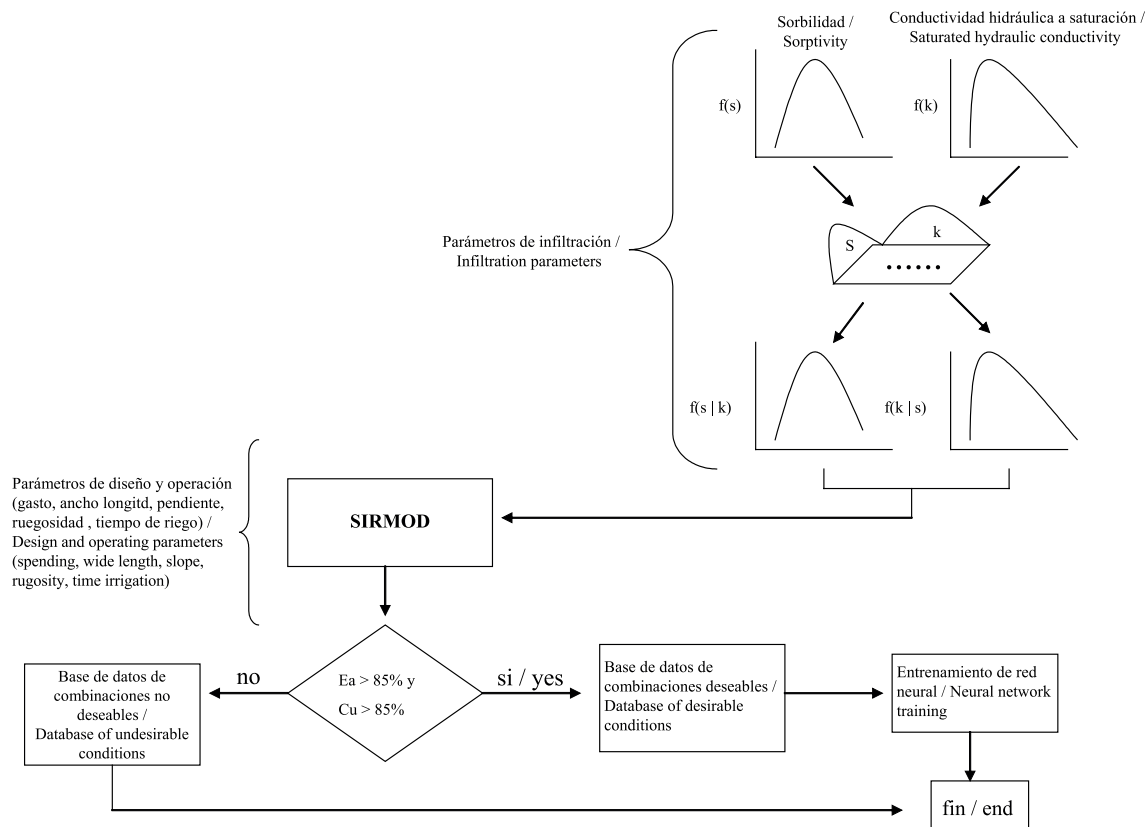


FIGURA 1. El concepto del método Monte Carlo aplicado a la obtención de Guías de Riego (modificado de Tiscareño *et al.*, 1993).
 FIGURE 1. Application of the Monte-Carlo method to the formulation of Irrigation Guides (modified from Tiscareño *et al.*, 1993).

- 6) Repetir los pasos hasta que las funciones de densidad de entrada adquieran estabilidad.

El algoritmo mostrado en la Figura 1 ha sido utilizado para la obtención de Guías de Riego basadas en un modelo de simulación hidrológico. En este, se consideró la variación aleatoria de los parámetros de las funciones de infiltración de los suelos (sorbilidad y conductividad hidráulica a saturación), considerando la probabilidad conjunta de que un determinado valor ocurra en virtud de que estos valores están correlacionados. Con esta información y algunos datos fijos en el modelo (parámetros de diseño del riego superficial) se hizo uso del modelo de simulación considerando como opciones viables a aquellas combinaciones de parámetros que resultaran en una eficiencia de aplicación del agua de riego mayor o igual a 85 % y un coeficiente de uniformidad mayor o igual a 85 %.

Aproximación para cuantificación de escurrimiento en cuencas poco instrumentadas

La variable que define la vulnerabilidad de un sistema productivo es la precipitación pluvial; así, la ocurrencia de precipitación diaria es un ejemplo meteorológico simple de un evento aleatorio binario (ocurre o no ocurre, lo que se considera dos estados de esa variable), por lo que una secuencia de estos eventos constituye una serie de tiempo de esta variable. Un modelo estocástico muy comúnmente usado para el análisis de información de este tipo, son las Cadenas de Markov de primer orden para dos estados de la naturaleza. Estas cadenas tienen la propiedad de que la probabilidad de transición que gobierna cada observación en la serie de tiempo, depende solo del valor del dato anterior (Wilkes, 1995; Banks 1988, Haan, 1982). En esta aproximación, para cada valor en la serie de tiempo de la lluvia, el proceso estocástico se encuentra en el estado 0 (no lluvia, $X_t = 0$) o 1 (lluvia $X_t = 1$). En cada paso, el estado puede permanecer inmóvil o bien cambiar a otro estado; es decir, si hoy llueve puede suceder que mañana también llueva o que no ocurra lluvia. De esta manera, son posibles cuatro transiciones:

- Día sin lluvia seguido de día sin lluvia (p00)
- Día con lluvia seguido de día sin lluvia (p10)
- Día sin lluvia seguido de día con lluvia (p01)
- Día con lluvia seguido de día con lluvia (p11)

Las probabilidades de transición son condicionales para el estado futuro $t + 1$, es decir, si ocurrirá precipitación mañana, dado el estado al tiempo t , es decir, si ocurrió precipitación hoy. En forma matemática esto es (Sánchez, *et al.*, 2011):

$$\begin{aligned} p00 &= \Pr\{X_{t+1} = 0 | X_t = 0\} & 14a \\ p01 &= \Pr\{X_{t+1} = 1 | X_t = 0\} & 14b \\ p10 &= \Pr\{X_{t+1} = 0 | X_t = 1\} & 14c \\ p11 &= \Pr\{X_{t+1} = 1 | X_t = 1\} & 14d \end{aligned}$$

occurs or not, which are two states of that variable). Therefore, a sequence of these events constitutes a time series of this variable. A stochastic model very often used to analyze this kind of information is the first order Markov chains for two states of nature. These chains are characterized by the fact that the probability of transition that governs each observation in the time series is subject only to the value of the previous datum (Wilkes, 1995; Banks, 1988; Haan, 1982). In this approach, for each value in the rainfall time series the stochastic process is found in the state 0 (no rain, $X_t = 0$) or 1 (rain, $X_t = 1$). In every step, the state may remain as it is or change to another state; that is, if it rains today, tomorrow it may also rain or it may not. Thus, there are four possible transitions:

- Day without rain, followed by day without rain (p00)
- Day with rain, followed by day without rain (p10)
- Day without rain, followed by day with rain (p01)
- Day with rain, followed by with rain (p11)

The probabilities of transition are conditional for the future state $t + 1$; that is, if it will rain tomorrow, given the state at the time t , that is, if it rained today. In mathematical terms this is (Sánchez *et al.*, 2011)

$$p00 = \Pr\{X_{t+1} = 0 | X_t = 0\} \quad 14a$$

$$p01 = \Pr\{X_{t+1} = 1 | X_t = 0\} \quad 14b$$

$$p10 = \Pr\{X_{t+1} = 0 | X_t = 1\} \quad 14c$$

$$p11 = \Pr\{X_{t+1} = 1 | X_t = 1\} \quad 14d$$

The climate parameter p00 is the one that should be included in the mapping of climate variability, because this parameter is closely linked to the average length of the dry period, which, in turn, is associated with the variation in rainfall in the short and long term. Also, p00 provides a robust statistical determination.

Assuming that rainfall in a given region follows an exponential distribution, its cumulative function is:

$$F_x(X) = 1 - e^{-\lambda x} \quad (15)$$

Where:

λ is the inverse of the mean of daily rainfall, “ e ” is the base of the natural logarithms and F_x indicates the cumulative distribution function of “ X ”. For runoff simulation (Ru), the transformation of an exponential distribution is used as follows:

$$Ru = \frac{1}{-\theta} \ln\left[1 - \left[\frac{U - a}{1 - a}\right]\right] \quad (16)$$

Where:

θ is the inverse of the average daily runoff, “ U ” is a random number and “ a ” is the probability that no runoff occurs.

El parámetro climático $p00$, es el que debiera incluirse en el mapeo de la variabilidad climática en virtud de que este parámetro está estrechamente relacionado con la duración media del periodo seco, el cual a su vez se asocia con la variación de la precipitación en el corto y largo plazo. Asimismo, la $p00$, ofrece una determinación estadística robusta.

Si se asume que la precipitación pluvial en una región determinada sigue una distribución exponencial, su función acumulada es:

$$F_x(X) = 1 - e^{-\lambda x} \quad (15)$$

donde, λ es el inverso de la media de la precipitación diaria, “ e ” es la base de los logaritmos naturales y F_x denota la función de distribución acumulada de “ X ”. Para la simulación de escurrimiento (Ru) se utiliza la transformación de una distribución exponencial como:

$$Ru = \frac{1}{-\theta} \ln[1 - [\frac{U - a}{1 - a}]] \quad (16)$$

Donde:

θ es el inverso del escurrimiento medio diario, “ U ” es un número aleatorio y “ a ” es la probabilidad de que no ocurra escurrimiento.

Para la obtención del parámetro “ a ” bajo condiciones limitadas de disponibilidad de información, se pueden utilizar funciones fronteras que cuantifiquen la cantidad necesaria de humedad en el suelo (Th) para iniciar escurrimiento dado cierto contenido de humedad. Por ejemplo Sánchez (1994) obtuvo tres funciones frontera para el mismo número de suelos las cuales cuantifican lo arriba asentado. Aunque las funciones fronteras fueron obtenidas en condiciones controladas con un simulador de lluvia (véase Figura 2), éstas pueden ser utilizadas en estudios preliminares en cualquier tipo de suelo. Las funciones son:

para suelos ligeros:

$$Th = 4.138 e^{(-0.038)^{\beta_{t-1}}} R^2 = 0.68 \quad (17)$$

para suelos medios

$$Th = 3.961 e^{(-0.041)^{\beta_{t-1}}} R^2 = 0.69 \quad (18)$$

y para suelos pesados:

$$Th = 2.720 e^{(-0.031)^{\beta_{t-1}}} R^2 = 0.79 \quad (19)$$

Donde:

β es el contenido final de humedad en el día anterior ($t-1$) en milímetros.

Acorde a estas funciones, el contenido mínimo inicial de humedad en el suelo para iniciar el escurrimiento es de 4.1,

To obtain the parameter “ a ” under conditions of limited information availability, frontier functions may be used to quantify the required amount of moisture in the soil (Th) to begin runoff given a certain moisture content. For example, Sánchez (1994) obtained three frontier functions for the same number of soils, which quantify the above assertion. Although the frontier functions were obtained in controlled conditions with a rainfall simulator (see Figure 2), they can be used for preliminary studies in any type of soil. The functions are:

for light soils:

$$Th = 4.138 e^{(-0.038)^{\beta_{t-1}}} R^2 = 0.68 \quad (17)$$

for medium soils:

$$Th = 3.961 e^{(-0.041)^{\beta_{t-1}}} R^2 = 0.69 \quad (18)$$

and for heavy soils:

$$Th = 2.720 e^{(-0.031)^{\beta_{t-1}}} R^2 = 0.79 \quad (19)$$

Where:

β is the final moisture content on the previous day ($t-1$) in millimeters.

According to these functions, the minimum initial moisture content in the soil to begin runoff is 4.1, 3.5 and 2 mm for light, medium, and heavy soils respectively. Given that we want to know the potential for runoff in dry conditions, the initial moisture content for the different soils should be considered as equal to 0.

The parameter θ is calculated by stochastically generating rainfall according to equation 3, considering that there will be runoff on those days in which the difference between the generated rainfall and the respective “ Th ” is positive.

In a work of rainwater collection, if the total amount of water received in a growing area is considered as a decision variable, it is possible to categorize the farmer’s behavior toward the risk, which in a mathematical form is defined as (Sánchez Cohen *et al.*, 1997):

$$E(Re | P) = \max + [P\beta_1 + (1 - P)\beta_2] \quad (20)$$

Where:

$E(Re | P)$ is the expected net income (Re) given a certain probability (P) of having a total amount of water (rainfall + runoff) of a given magnitude; β_1 , β_2 are income if the total amount of water is located above or under the frontier condition. Usually, for a risk-neutral farmer, the objective is to maximize income. For a risk-adverse farmer, the objective is to maximize the return associated with agricultural

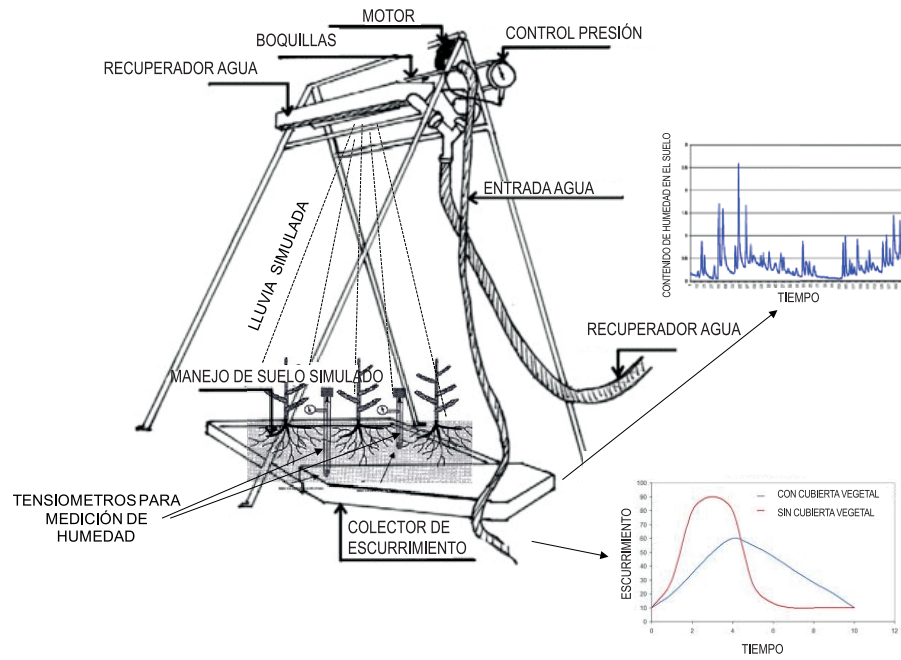


FIGURA 2. Simulador de lluvia para la obtención de las funciones frontera de escurrimiento.

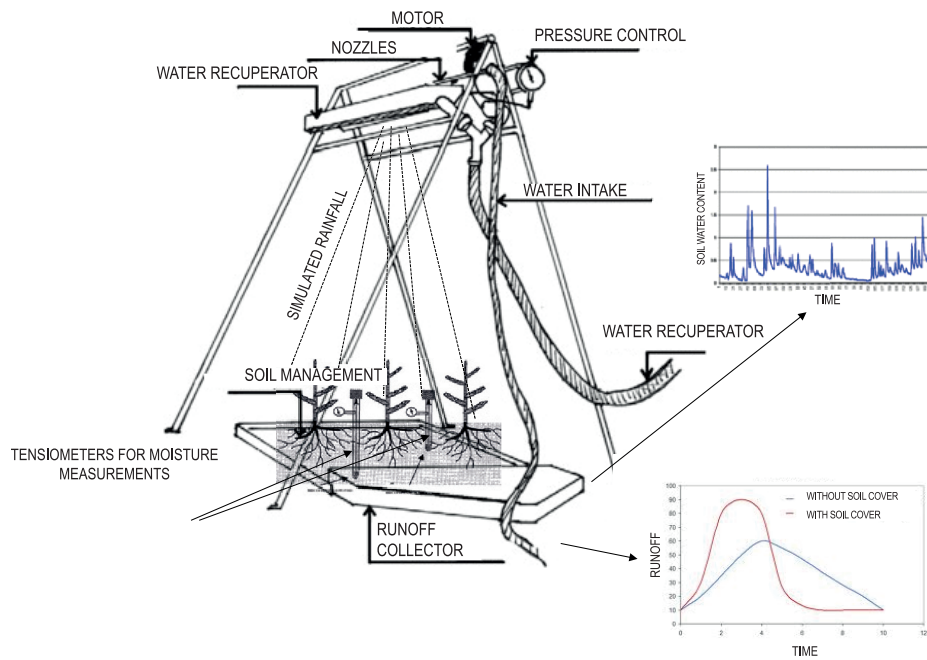


FIGURE 2. Rainfall simulator for obtaining runoff frontier functions.

3.5 y 2 mm para suelos ligeros medios y pesados respectivamente. En virtud de que se desea conocer la potencialidad de escurrimiento bajo condiciones secas, se debe considerar el contenido inicial de humedad para los diferentes suelos igual a 0.

La obtención del parámetro θ consiste en generar estocásticamente precipitación pluvial acorde a la ecuación 3 considerando que se producirá escurrimiento en aquellos días en los que la diferencia entre la precipitación generada y el respectivo “ Th ” sea positiva.

En una obra de captación de agua de lluvia, si se considera como variable de decisión a la cantidad total de agua que se recibe en área de cultivo, se puede categorizar el comportamiento del agricultor al riesgo lo que matemáticamente se define como (Sánchez Cohen, *et al.*, 1997)

$$E(Re | P) = \max [P\beta_1 + (1 - P)\beta_2] \quad (20)$$

Donde:

$E(Re | P)$ es el ingreso neto esperado (Re) dada cierta probabilidad (P) de tener una cantidad total de agua (precipitación + escurrimiento) de cierta magnitud; β_1, β_2 son ingresos si la cantidad total de agua se ubica arriba o abajo de la condición frontera. Comúnmente, para un agricultor neutro al riesgo, el objetivo es maximizar los ingresos. Para un agricultor adverso al riesgo, el objetivo es maximizar la utilidad asociada con las actividades agrícolas y los recursos. En términos de riesgo (probabilidad de falla) la cantidad de escurrimiento, es analizado acorde a :

$$R = (1 - \frac{1}{Tr})^n \quad (21)$$

Donde:

R es el riesgo, Tr = periodo de retorno del evento y n es el intervalo de tiempo considerado.

Los parámetros de los modelos de simulación siempre contienen incertidumbre en algún grado; esta condición se refiere a la falta de “seguridad” en el valor que se asigna a algún parámetro con fundamento en la variabilidad espacial del mismo, la dificultad en otorgar un valor preciso, o el pleno desconocimiento de los valores base del parámetro. Una vez asignado el o los valores de los parámetros, el modelo debe ser calibrado con cierto criterio, considerando datos observados del parámetro. Este proceso implica que el modelador o usuario del modelo tenga un claro conocimiento de todos los parámetros de entrada del modelo así como de los procesos representados en el mismo. Así, aquellos parámetros que no son bien conocidos, en el proceso de calibración, se deben dejar como fijos aún si presentan cierta sensibilidad o son ajustados a valores poco probables. El desconocimiento de la sensibilidad de los parámetros, dificulta el proceso de calibración ya que se puede perder demasiado tiempo

activities and resources. In risk terms (probability of failure), the amount of runoff is analyzed according to:

$$R = (1 - \frac{1}{Tr})^n \quad (21)$$

Where:

R is the risk, Tr = event return time, and n is the time interval considered.

Parameters in simulation models always include a certain degree of uncertainty. This condition means lack of “certainty” in the value assigned to a parameter due to its spatial variability, the difficulty in assigning a precise value, or a total lack of knowledge of the parameter’s base values. Once the value(s) for the parameters are assigned, the model must be calibrated with a certain criterion, considering the parameter data observed. This process requires that the modeler or model user have a clear understanding of all the model input parameters, as well as the processes represented therein. Thus, those parameters that are not well known in the calibration process should be left as fixed even if they show certain sensitivity or are adjusted to unlikely values. The lack of knowledge of the parameters’ sensitivity hinders the calibration process because too much time may be lost adjusting parameters showing little or null variation when input data change. The focus must be on the model’s sensitive parameters, as this conveys a better understanding and estimate of their values, thus reducing uncertainty.

Therefore, sensitivity analysis in process simulation models is an instrument for the quantification of input parameters as regards their impact on model outputs, and it is useful not only for model development, but also for validation and uncertainty reduction (Lenhart *et al.*, 2002).

In mathematical terms, the dependence of a variable “ y ” on a parameter “ x ” is expressed by the partial derivative. This expression is numerically approximated by a finite difference; thus, let y_0 be a model output resulting from an initial value x_0 for the parameter “ x ” (Figure 3). This initial parameter is varied by $\pm\Delta x$ yielding $x_1 = x_0 - \Delta x$ and $x_2 = x_0 + \Delta x$ with the corresponding values.

of y_1 and y_2 . Thus, the finite approximation of the partial derivative is:

$$S' = \frac{y_2 - y_1}{(x_0 + \Delta x) - (x_0 - \Delta x)} = \frac{y_2 - y_1}{2\Delta x} \quad (22)$$

To obtain a dimensionless index, the previous equation must be normalized as:

$$S = \frac{\frac{y_2 - y_1}{y_0}}{\frac{x_2 - x_1}{x_0}} \quad (23)$$

ajustando parámetros que presentan poca o nula variación cuando los datos de entrada son cambiados. La focalización debe ser hacia los parámetros sensibles del modelo ya que esto conduce a un mejor entendimiento y mejor estimación de sus valores reduciendo la incertidumbre.

Así entonces, el análisis de sensibilidad en los modelos de simulación de procesos es un instrumento para la cuantificación de parámetros de entrada con respecto a su impacto en las salidas del modelo y es útil no solo para el desarrollo del modelo sino también para la validación y reducción de la incertidumbre (Lenhart *et al.*, 2002).




FIGURA 3. Relación entre una variable de salida del modelo “y” y un parámetro “x”.

FIGURE 3. Relationship between a model output variable “y” and a parameter “x”.

Matemáticamente la dependencia de una variable “y” de un parámetro “x” es expresado por la derivada parcial. Esta expresión es aproximada numéricamente por una diferencia finita; así, sea y_0 una salida del modelo resultado de un valor inicial x_0 del parámetro “x” (Figura 3). Este parámetro inicial es variado por $\pm\Delta x$ arrojando $x_1 = x_0 - \Delta x$ y $x_2 = x_0 + \Delta x$ con los valores correspondientes de y_1 y y_2 . Así, la aproximación finita de la derivada parcial es:

$$S' = \frac{Y_2 - Y_1}{(x_0 + \Delta x) - (x_0 - \Delta x)} = \frac{Y_2 - Y_1}{2\Delta x} \quad (22)$$

Para obtener un índice adimensional, la anterior ecuación necesita ser normalizada como:

$$S = \frac{\frac{Y_2 - Y_1}{Y_0}}{\frac{x_2 - x_1}{x_0}} \quad (23)$$

Mientras más grande sea el valor de S, la sensibilidad del valor de salida al parámetro de entrada es mayor. Una vez que

The larger the S value, the more sensitive the output value is to the input parameter. Once the most sensitive parameters are known, then the parameters to be calibrated will be defined.

Calibration

Calibration is the process whereby the simulated and observed values are optimally adjusted. Under this approach, calibration will focus on minimizing the differences among these data (Cabrera, 2012). In another definition (Bonaldi *et al.*, 2011), calibration is the procedure of assigning values to the parameters in search of the maximum coherence between the planned objective and the instrument to be used.

There are several efficiency criteria to assess a simulation model. For example, the determination coefficient, the Nash-Sutcliffe efficiency index, the Nash-Sutcliffe efficiency index with logarithmic values, the congruence index, and so on (Krause *et al.*, 2005). In this paper, the determination coefficient, the Nash-Sutcliffe efficiency index and PBIAS are described. BIAS measures the drift of the mean of the simulated data to be greater or less than the homologous observed data (Moriassi *et al.*, 2007). The equations are as follows:

The determination coefficient:

$$r^2 = \left(\frac{\sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2} \sqrt{\sum_{i=1}^n (P_i - \bar{P})^2}} \right)^2 \quad (24)$$

Where:

r^2 is the determination coefficient, O_i is each of the i observations, P_i is each of the simulated data, \bar{O} is the mean of the observed data, \bar{P} is the mean of the simulated data and n is the total number of observations.

$$\text{NASH} = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (25)$$

Where:

NASH is the Nash-Sutcliffe index (dimensionless); the other parameters are as previously defined.

$$\text{PBIAS} = \left[\frac{\sum_{i=1}^n (Y_i \text{obs} - Y_i \text{sim}) * (100)}{\sum_{i=1}^n (Y_i \text{obs})} \right] \quad (26)$$

Where:

PBIAS is the deviation of the evaluated data (%), $Y_i \text{obs}$ are the observed values, $Y_i \text{sim}$ are the simulated values y n is the total number of observations.

se conozcan los parámetros que presentan la mayor sensibilidad, se definirá entonces los parámetros a calibrar.

Calibración

La calibración es el proceso con el que se ajustan de manera óptima los valores simulados y los observados, bajo esta idea general, la calibración se centrará en minimizar las diferencias entre estos datos (Cabrera, 2012). Otra definición, según Bonaldi *et al.* (2011) es el procedimiento de asignar valores a los parámetros en la búsqueda de la máxima coherencia entre el objetivo planteado y la herramienta que se utilizará.

Los criterios de eficiencia para valorar a un modelo de simulación son varios, por ejemplo, el coeficiente de determinación, índice de eficiencia de Nash-Sutcliffe, índice de eficiencia de Nash-Sutcliffe con valores logarítmicos, índice de congruencia, etc. (Krause *et al.*, 2005). En este documento, se describe el coeficiente de determinación, índice de eficiencia de Nash-Sutcliffe y PBIAS, este último mide la tendencia de la media de los datos simulados a ser mayores o menores que los datos homólogos observados (Moriasi *et al.*, 2007). Las ecuaciones se presentan a continuación:

$$r^2 = \left(\frac{\sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2} \sqrt{\sum_{i=1}^n (P_i - \bar{P})^2}} \right)^2 \tag{24}$$

Donde:

r^2 es el coeficiente de determinación, O_i es cada una de las i observaciones, P_i es cada uno de los i datos simulados, \bar{O} es la media de los datos observados, es la media de los datos simulados y n es el número total de observaciones.

$$NASH = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \tag{25}$$

Donde:

$NASH$ es el índice de Nash-Sutcliffe (adimensional); los demás parámetros son como se definió anteriormente.

$$PBIAS = \left[\frac{\sum_{i=1}^n (Y_i \text{obs} - Y_i \text{sim}) * (100)}{\sum_{i=1}^n (Y_i \text{obs})} \right] \tag{26}$$

Donde:

$PBIAS$ es la desviación de los datos evaluados (%), $Y_i \text{obs}$ son los valores observados, $Y_i \text{sim}$ son los valores simulados y n es el número total de observaciones.

CONCLUSIONS

Process simulation is an activity with which the user can draw conclusions regarding the behavior of a given system, through the application of a model whose cause-effect relationship is the same (or similar) to the one in the original system. Thus, simulation is restricted to the development and use of models which realistically describe a system’s behavior.

The action of “modeling” and “simulating” any event in nature began to blossom during the Second World War and has boomed in the last decade with the advent of supercomputers. In this time, there have been efforts to mathematically represent (modeling) natural phenomena in which, if the relationships that shape the phenomenon are simple, mathematical methods are used to solve the problem, with this approach being called an analytical solution. However, the majority of the systems usually found in nature are too complex to be evaluated analytically; hence, simulation techniques provide a better option, namely the numerical solution.

Rain-fed farming systems are subject to climate randomness, so they are systems under risk. This risk should be quantified through an *ex ante* analysis to be able to prevent losses or design mitigation mechanisms. Simulation models that include climate randomness (stochastic) are the best option to carry out this quantification. However, it is necessary to use robust models with minimal information requirements, making it necessary to know the sensitivity of the model to variations in its parameters in order to be able to discern, based on the available information, which model is the most suitable. On the other hand, the full use of hydrological simulation requires minimal knowledge of statistics and computer programming to be able to systematize the algorithms, since it is necessary to “replicate” climate scenarios to quantify the impact of changes in variables on the hydrological cycle.

End of English Version

CONCLUSIÓN

La simulación de procesos es una actividad con la cual el usuario puede obtener conclusiones relativas al comportamiento de un sistema dado por medio del estudio de un modelo cuya relación causa-efecto es la misma (o similar) a la del sistema original. Así entonces, la simulación se circunscribe al desarrollo y uso de modelos que describen realísticamente el comportamiento de un sistema.

La acción de “simular” y “modelar” cualquier evento que ocurra en la naturaleza es una herramienta que prácticamente empezó su auge durante la Segunda Guerra Mundial, y ha alcanzado su máxima expresión durante la última década con el advenimiento de las supercomputadoras. En este periodo se ha tratado de representar matemáticamente (modelación) fenómenos naturales en los que, si las relaciones que componen al fenómeno son simples, se usan métodos matemáticos para la solución al problema planteado a lo que se denomina “solución analítica”. Sin embargo, la mayoría de los sistemas encontrados comúnmente en la naturaleza son demasiado complejos para poder evaluarse analíticamente, por lo que las técnicas de simulación ofrecen como mejor opción la solución numérica.

Los sistemas agropecuarios en zonas de temporal están sujetos a la aleatoriedad climática, por lo que son sistemas bajo riesgo. La cuantificación de este riesgo debiera realizarse en un análisis *ex ante* para estar en posibilidades de prevenir o diseñar mecanismos de mitigación. Los modelos de simulación que consideran la aleatoriedad climática (estocásticos) son la mejor opción para llevar a cabo esta cuantificación. Sin embargo, es necesario utilizar modelos robustos con mínimo requerimiento de información por lo que es necesario conocer la sensibilidad del modelo a las variaciones en sus parámetros para poder discernir, con base en la información disponible, qué modelo es el más conveniente. Por otro lado, el uso pleno de simulación hidrológica requiere del conocimiento mínimo de estadística y programación computacional en aras de sistematizar los algoritmos dado que se requiere de “reproducir” escenarios climáticos para cuantificar el impacto de alteraciones de variables en el ciclo hidrológico.

LITERATURA CITADA

- Abbaspaour, K. C. 1992. A yield model for use in determining crop insurance premiums. *Agricultural and Forest Meteorology*, 60: 33 – 51.
- Ang, A. H.; Tang, W. H. 1984. *Probability Concepts in Engineering Planning and Design*. Vol I and II. J. Wiley and Sons Inc. New York.
- Banks, J. 1998. *Handbook of Simulation. Principles, Methodology, Advances, Applications and Practice*. Engineering and Management Press. 847 pp.
- Berbel, J. 1993. Risk programming in agricultural systems: a multiple criteria analysis. *Agricultural Systems*, 41: 275 – 278.
- Bonaldi, P.; Prada, J. D.; González, A.; Rodríguez, D.; Rojas, L. E. 2011. Método numérico para la calibración de un modelo DSGE. *Revista Desarrollo y Sociedad*. Vol. 68. pp 119-156.
- Cabrera, J. 2012. Calibración de modelos hidrológicos. Universidad Nacional de Ingeniería. Facultad de Ingeniería Civil. Fecha de consulta: 16/04/2013 http://www.imefen.uni.edu.pe/Temas_interes/modhidro_2.pdf
- Chowdhury, R. N. 1992. Probabilistic risk analysis in geomechanics and water engineering in environmental management. Chap. 2 pp 37 – 70.
- Coheseen, J. J.; Covello, V. T. 1989. *Risk Analysis: A Guide to Principles and Methods for Analysing Health and Environmental Risk*. Executive Office of the President of the United States.
- Díaz Padilla, G.; Sánchez Cohen, I.; Quiroz, R.; Garatuza, J.; Watts, C.; Cruz, R. 2008. Interpolación espacial de la precipitación pluvial en la zona de barlovento y sotavento en la zona del Golfo de México. *Agricultura Técnica en México*. Vo. 34 num. 3 pp 279 – 287.
- Díaz Padilla G.; Sánchez Cohen, I.; Guajardo Panes, R. A. 2011. Análisis de Series de Tiempo de Clima para Tomar decisiones en México. *Retos de la Investigación en Agua en México*. Universidad Nacional Autónoma de México. pp 45 – 59.
- Fischhoff, B.; Watson, S. R.; Hope, C. 1984. *Defining Risk, Policy Sciences*, 17: 123 – 139.
- Gottfried, B. S. 1984. *Elements of stochastic process simulation*. Prentice-Hall Inc. 99 8-10.
- Haan, C. T. 1982. *Statistical Methods in Hydrology*. The Iowa State University Press. 378 pp.
- Krause, P.; Boyle, D. P.; Båse, F. 2005. Comparison of different efficiency criteria for hydrological model assessment. *Advances in Geosciences*, 5, 89-97
- Lenhart, T.; Eckhardt, K.; Fohrer, N.; Frede, H. G. 2002. Comparison of two different approaches of sensitivity analysis. *Physics and Chemistry of the Earth* 27 (2002) 645–654
- Linsley, K. R. 1976. *Rainfall – Runoff models. Systems approach to water management*. McGraw-Hill. pp 17 – 56.
- Moriasi, D. N.; Arnold, J. G.; Van Liew, M. W.; Bingner, R. L.; Harmel, R. D.; Veith, T. L. 2007. Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. *American Society of Agricultural and Biological Engineers*. Vol. 50(3):885-900
- Oswald Spring, U. 2007. Key elements of environmentally induced migration: A Mesoamerican and Mexican Vision. Fecha de consulta: 20/03/2013 http://www.afes-press.de/html/body_download_oswald.html.
- Sánchez Cohen, I. 2005. *Manejo Integral del Agua. Una aproximación a la simulación de Procesos*. Libro Científico No. 2. INIFAP CENID RASPA, Gómez Palacio Dgo. Mexico. 272 pp.
- Sánchez Cohen, I.; Lopes, V. L.; Slack D., C.; Hernández, C. 1995. Assessing Risk for Water Harvesting Systems in Arid Ecosystems. *J. Soil and Water Cons.* 50(5) 446 – 449.
- Sánchez Cohen, I.; Díaz Padilla, G.; Tereza Cavasos P., M.; Rebeca Granados R., G.; Reyes Gómez, E. 2011. *Elementos para entender el cambio climático y sus impactos*. Ed. Porrúa. México. 167 pp.
- Sánchez Cohen, I. 1994. *Evaluating strip farming systems for arid ecosystems. A stochastic Approach*. PhD. Dissertation. The University of Arizona. 111 pp.

- Sánchez Cohen, I.; Lopez, V. L.; Slack, D. S.; Fogel, M. M. 1997. Water Balance Model for Small **Scale** Water Harvesting Systems. *Journal of Irrigation and Drainage Engineering*. Vol. 123, No. 2 Pp 123 – 128.
- Sánchez Cohen, I.; Díaz Padilla, G.; Chebhouni, G.; Orona Castillo, I.; Villanueva Díaz, J.; González Barrios, J.L.; González Cervantes, G. 2008. Variabilidad Climática en México: Algunos impactos hidrológicos, sociales y económicos. *Ingeniería Hidráulica en México*, vol. XXIII, núm. 4. pp 5 – 24.
- Tiscareño, M.; López, V. L.; Stone, J. J.; Lane, L. J. 1993. Sensitivity Analysis of the WEPP Watershed Model for Rangeland Applications: I Hillslope Processes. *Transactions of the ASAE*. Vol. 36, No. 6. pp 1659 – 1672.
- Wilkes, D. S. 1995. *Statistical Methods in the Atmospheric Sciences*. Department of Soil Crop and Atmospheric Sciences. Academic Press. Ithaca New York. 467 pp.