

## Generación de Árboles de Escenarios en forma Analítica, para Modelar Recursos Energéticos Renovables

R. Barreto

*Centre d'Innovació en Convertidors Estàtics i Accionaments (CITCEA-UPC), E.T.S. Enginyeria Industrial Barcelona, Universitat Politècnica Catalunya*  
*Universidad Nacional de Loja*  
*E-mail: rbarreto@eerssa.com*

### Resumen

El presente artículo propone la implementación de un algoritmo para generar árboles de escenarios a partir de series de datos estadísticos, el algoritmo es válido para procesar información proveniente de resultados de experimentos aleatorios o de simulaciones a partir de funciones de distribución de probabilidad conocidas.

El Árbol de Escenarios es un instrumento adecuado que permite tratar los parámetros aleatorios para la solución de problemas de optimización estocástica en el campo de los recursos naturales renovables.

La metodología propuesta es aplicada a un caso de estudio para tratar la información aleatoria de recursos de generación eléctrica de tipo hidráulica y eólica, así como la demanda eléctrica (incluyendo la carga de cocinas de inducción), de un sistema de distribución aislado, en base a series de datos de mediciones históricas reales.

**Palabras clave**— Árboles de Escenarios, Generación Renovable, Método Neural Gas, Programación Estocástica.

### Abstract

This paper proposes the implementation of an algorithm for generating scenarios trees from a series of statistical data; the algorithm is valid to process information from results of randomized experiments or simulations from known distribution functions of probability.

The scenarios tree is an appropriate instrument to deal with random parameters allows for solving stochastic optimization problems in the field of renewable natural resources.

The proposed methodology is applied to a study case to treat random information resource power generation wind and hydraulic, as well as electricity demand (including loading of induction cookers), a system of isolated distribution, based on data sets real history measurements.

**Index terms**— Neural Gas Method, Renewable Generation, Scenarios Tree, Stochastic Programming.

Recibido: 30-08-2016, Aprobado tras revisión: 09-12-2016

Forma sugerida de citación: Barreto R. (2017). "Generación de Árboles de Escenarios en forma Analítica, para Modelar Recursos naturales Renovables". Revista Técnica "energía". No. 13, Pp. 196-205  
ISSN 1390-5074.

## 1. INTRODUCCIÓN

### 1.1. Relevancia de la Programación Estocástica en Modelación de Generación Renovable

El aprovechamiento de las fuentes de energía renovable es considerado como un pilar fundamental para cumplir con el objetivo de abastecer adecuadamente la demanda de energía eléctrica en el Ecuador, con calidad y seguridad <sup>[1]</sup>.

En este ámbito las políticas en materia energética que se aplican en el país no solamente promueven la expansión del parque generador en la búsqueda de cambiar la matriz energética nacional, mediante el uso de recursos energéticos renovables en sustitución de combustibles fósiles para la producción de electricidad, con el consiguiente beneficio económico y ambiental, sino también el uso de nuevas cargas eléctricas especiales como cocinas de inducción o vehículos eléctricos en sustitución de los artefactos tradicionales que utilizan combustibles fósiles.

Sin embargo, el aprovechamiento de fuentes de energía renovables como la hidráulica, eólica o fotovoltaica implican variabilidad del potencial energético que sumado a las fluctuaciones de la demanda eléctrica, tornan complejo el modelamiento de los sistemas eléctricos.

La estocasticidad o incertidumbre que está presente en la disponibilidad de los elementos de generación renovable y la magnitud de la demanda eléctrica, pueden ser modelados y tratados aplicando técnicas avanzadas de programación matemática, que combinadas con algoritmos de optimización lineal, no lineal, entera, entera mixta o dinámica, constituyen una nueva disciplina denominada Programación Estocástica vía Análisis de Escenarios <sup>[2]</sup>.

El instrumento adecuado que permite tratar los parámetros aleatorios para la solución del problema de optimización estocástica, es el Árbol de Decisión o de Escenarios (AE), por lo que el presente artículo propone la implementación de un algoritmo para generar estos árboles a partir de series de datos conocidos (establecidos a partir de mediciones reales), también el algoritmo es válido para procesar información proveniente de resultados de experimentos aleatorios o de simulaciones a partir de funciones de distribución de probabilidad conocidas.

### 1.2. Aplicación de Árboles de Escenarios en Sistema Eléctricos

La estocasticidad está presente en todos los sistemas, pudiendo deberse a carencia de datos fiables, errores de medida o puede tratarse de parámetros que representan información sobre el futuro <sup>[2]</sup>, estos aspectos están presentes en la resolución de los

denominados problemas basados en el flujo óptimo de potencia, tales como despacho económico, unit commitment, flujo óptimo de potencia y planificación de expansión de sistemas eléctricos, en los cuales una de las más comunes técnicas utilizadas para modelar la incertidumbre es la representación en escenarios <sup>[3]</sup>

Debido a la complejidad matemática que supone la Programación Estocástica, es habitual que para simplificar el tratamiento del problema, se asuma mediante aproximaciones y estimaciones, que los parámetros son conocidos con certeza (normalmente a su valor medio); con lo cual se obtienen soluciones deterministas que posiblemente se alejen del objetivo buscado o que no se pueden aplicar con resultados satisfactorios, ya que se podría estar asumiendo el cumplimiento de hipótesis que podrían ser violadas en la realidad <sup>[2]</sup>, por lo que la programación estocástica brinda una alternativa adecuada para obtener *soluciones robustas* con resultados que son óptimos para casi todos los escenarios posibles.

Como un ejemplo de aplicación de los conceptos expuestos, se realizará la generación de un árbol de escenarios considerando la aleatoriedad proveniente de fuentes de energía renovables como la hidráulica y eólica; y, de la demanda eléctrica con inclusión de cocinas de inducción.

El algoritmo propuesto puede ser utilizado para desarrollar modelos de planificación óptima de la operación y planificación óptima de la expansión tanto de transmisión como de distribución, planificación de la expansión de la generación, programación óptima de inversiones en el sistema eléctrico, análisis de riesgo, logística y planificación de comunicaciones, problemas de localización óptima de plantas de generación o de subestaciones de distribución, planificación de mercados energéticos, etc.; con los cuales se puede encontrar una política de decisión que maximice la esperanza matemática de alguna función sobre las decisiones y las variables aleatorias, mediante un proceso analítico <sup>[2]</sup>.

En la generación de los árboles de escenarios se propone utilizar el método de agrupamiento o clustering denominado Neural Gas, con el cual se genera árboles de escenarios a partir de información aleatoria agrupada en series de datos.

Para tratar de entender los conceptos involucrados en este trabajo, en una primera instancia se expone la formulación matemática utilizada en programación estocástica y se introducen los conceptos básicos de análisis de escenarios bietapa y multietapa, se establece el concepto de árboles de escenarios y se profundiza en la formulación matemática del algoritmo Neural Gas.

## 2. PROGRAMACION ESTOCASTICA

### 2.1. Programación Lineal

Para facilitar el entendimiento de programación estocástica, iniciaremos analizando los conceptos de la programa lineal determinista clásica, cuya forma estándar consiste en elegir valores de las variables  $x_1, x_2, \dots, x_n$  para maximizar o minimizar una función objetivo que normalmente se representa por  $Z$ , por lo general el planteamiento del problemas se refiere a una función de minimización como la siguiente:

$$\text{minimizar } Z = (c_1 x_1 + c_2 x_2 + \dots + c_n x_n)$$

En ese caso la función objetivo puede buscar por ejemplo minimizar los costos de un proyecto, las pérdidas de energía, las caídas de tensión, el flujo de potencia en líneas o transformadores, etc.

Como se observa la función objetivo se forma mediante la aplicación de  $n$  parámetros  $c_i$ .

La realización del problema de optimización, para que sea factible de ejecutar debe estar sujeto a  $m$  restricciones:

$$\begin{aligned} a_{11} x_1 + a_{12} x_2 + \dots + a_{1n} x_n &\leq b_1 \\ a_{21} x_1 + a_{22} x_2 + \dots + a_{2n} x_n &\leq b_2 \\ &\vdots \\ &\vdots \\ a_{m1} x_1 + a_{m2} x_2 + \dots + a_{mn} x_n &\leq b_m \end{aligned}$$

y,

$$x_1 \geq 0, x_2 \geq 0, \dots, x_n \geq 0$$

En estas ecuaciones  $a_{ij}$  y  $b_j$ , también son parámetros del modelo implementado.

En programación lineal determinista, los parámetros  $c$ ,  $A$  y  $b$ , son constantes y en forma condensada el problema de optimización lineal determinista puede ser expresado, utilizando una representación matricial, de la siguiente manera:

$$\text{minimizar } Z = cx \quad (1)$$

Sujeta a:

$$\begin{aligned} Ax &= b \\ x &\geq 0 \end{aligned}$$

En donde:

$Z$  función objetivo del problema de optimización

$c$  coeficientes de la función objetivo lineal

$x$  conjunto de variables de decisión  $x=\{x_i\}$

$A$  coeficientes de las restricciones

$b$  términos independientes de las restricciones

En tanto que los problemas lineales estocásticos son problemas de optimización lineal en los que algunos de los parámetros  $c$ ,  $A$  o  $b$  del modelo se consideran inciertos, por lo que pueden ser representados por variables aleatorias, las cuales pueden ser tratadas mediante una descripción probabilística bajo la forma de distribuciones, densidades o medidas de probabilidad [2].

La técnica que modeliza adecuadamente la incertidumbre es el denominado análisis de escenarios, el cual se fundamenta en conocer un número finito de valores de los parámetros estocásticos, que representan al conjunto de todos los valores posibles.

Las variables aleatorias se determinan en base al experimento aleatorio cuyo resultado se representa por  $\omega$  (sucesos elementales) y al conjunto de posibles resultados del experimento por  $\Omega$ .

Un escenario es una particular realización de los parámetros inciertos  $\omega = (c^\omega, A^\omega, b^\omega)$  a los que se consideran como variables aleatorias discretas en donde  $\omega \in \Omega$  [2].

### 2.2. Árboles de Escenarios

Al conjunto de escenarios se los puede representar mediante el árbol de escenarios, cuyos niveles corresponden a las etapas del horizonte de planificación, en los cuales debemos tomar alguna decisión y que se presentan mediante nodos, existiendo un nodo de partida o nodo raíz y a los nodos de la etapa final denominamos ramas.

En cuyo caso un escenario es cada trayectoria desde el nodo raíz a cualquier rama. Fig. 1.

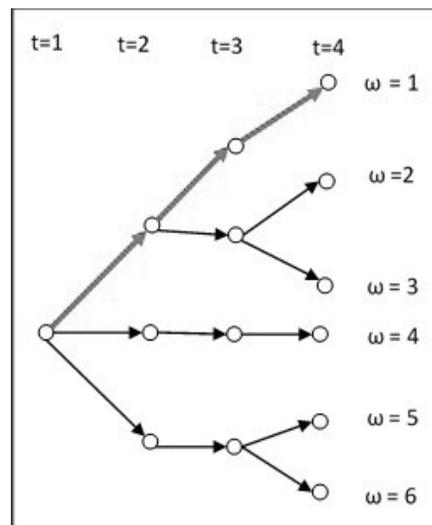


Figura 1: Árbol de Escenarios

### 2.3. Programación Lineal Estocástica

Contando con el árbol de escenarios, se modela el problema estocástico considerando la información proveniente del árbol según la siguiente expresión:

$$\min Z^\omega = c^\omega x^\omega \quad (2)$$

Sujeto a:

$$\begin{aligned} A^\omega x^\omega &= b^\omega \\ x^\omega &\geq 0 \end{aligned}$$

En donde:

- Z función objetivo del problema de optimización
- c coeficientes de la función objetivo lineal
- x conjunto de variables de decisión  $x = \{x_t\}$  para todas las etapas  $t=1, 2, \dots, T$ .
- A coeficientes de las restricciones
- b términos independientes de las restricciones
- $\omega$  realización del proceso aleatorio

La metodología así planteada proporciona soluciones factibles bajo cada escenario, sin subordinarse a ninguno de ellos, el valor esperado de la función objetivo es siempre mejor para todos los escenarios, a través de optimizar una combinación lineal de las funciones objetivo bajo cada escenario y replicando las restricciones en cada uno de ellos, conformando el denominado Modelo Determinista Equivalente (MDE) que para un modelo bietapa sería:

$$Z = \min c_1 x_1 + E_p(\min c_2^\omega x_2^\omega P(\omega)) \quad (3)$$

Sujeto a:

$$\begin{aligned} A_1 x_1 &= b_1 \\ A_2^\omega x_1 + A_2 x_2^\omega &= b_2^\omega \\ x_1 \geq 0 \in NA, x_2^\omega &\geq 0 \end{aligned}$$

En donde NA, constituyen las condiciones de no anticipatividad, lo que significa que si dos escenarios son idénticos desde la etapa inicial hasta una etapa  $t$  incluida, las decisiones a tomar bajo esos escenarios deben ser las mismas hasta la etapa  $t$  y  $E_p$  representa la esperanza matemática para la función de probabilidad  $P(\omega)$  [2].

En este modelo en la primera etapa, se toma la decisión ( $x_1$ ), luego ocurre la realización del proceso estocástico  $\omega$  y posteriormente a que dicho proceso ocurre se toma una nueva decisión ( $x_2$ ), en este caso se requiere implementar un árbol de escenarios de dos etapas.

En [4] y [5], se desarrollan modelos de programación estocástica bietapa para resolver problemas de caracterización de la incertidumbre para compañías de distribución eléctrica; y, en [6] se desarrolla un modelo bietapa para diseño óptimo de sistemas con generación distribuida.

En planificación de la expansión de sistemas eléctricos, se pueden también desarrollar modelos más complejos de programación estocástica multianual como en [7].

## 3. CASO DE ESTUDIO

### 3.1. Generación de Árboles de Escenarios

Para aplicar los modelos de Programación Estocástica, la generación de árboles de escenarios es una parte fundamental ya que de ellos depende la calidad de las soluciones obtenidas.

El tratamiento de la información estocástica para generar los árboles de escenarios puede resultar en algunos casos incluso más complejo que el problema estocástico en sí, por lo que el presente artículo propone un algoritmo para efectuar procesamiento.

Se pueden encontrar en la literatura sobre esta temática varias metodologías para la generación de los árboles de escenarios, una de las alternativas existentes es efectuar una realización del proceso estocástico en cada etapa del árbol conservando las propiedades estadísticas del proceso aleatorio (por ejemplo los momentos estadísticos) y establecer las probabilidades de transición condicionales del árbol.

Un modelo menos complejo puede ser desarrollado, combinando criterios objetivos y subjetivos, en el que las probabilidades condicionales de transición se estiman a priori en base a criterios de expertos, y las realizaciones estocásticas se calculan a partir de un modelo matemático que busca minimizar las diferencias entre las propiedades estadísticas de los escenarios del árbol y las del proceso estocástico observado en la realidad, por medio de un modelo de mínimos cuadrados que minimiza el error cuadrático medio.

### 3.2. Método Neural Gas

Sin embargo, existen varios modelos en el área de aprendizaje competitivo, cuyo propósito es distribuir un cierto número de vectores en un espacio n-dimensional, reflejando la distribución de probabilidad de este ordenamiento, existiendo en la literatura modelos de aprendizaje competitivo duro o aprendizaje competitivo suave, entre estos últimos se encuentra el método Neural Gas <sup>[9]</sup>, que puede ser utilizado en la generación de árboles de escenarios.

Neural Gas en forma general es un método de agrupamiento o clustering que obtiene los centroides que mejor representan a un conjunto de datos, por medio de un proceso iterativo de adaptación de dichos centroides, dependiendo de su distancia a las series de datos que se van escogiendo en forma aleatoria en el proceso iterativo.

Debiendo recalcar que Clustering es un método que es utilizado en minería de datos, en los cuales un centroide puede ser definido como el punto equidistante a los objetos que pertenecen al cluster.

Según la literatura especializada que se puede encontrar sobre este tema se puede tener la siguiente descripción del Método Neural Gas:

Para determinar la proximidad de las series de datos se puede utilizar la expresión:

$$d(\omega, \omega') = \|\omega - \omega'\|^2 \quad (4)$$

Con lo cual la distancia entre una serie de datos  $\omega$  a un escenario del árbol  $\omega^k$ , es calculada como la mínima distancia de la serie a alguno de los escenarios del árbol.

$$d(\omega, \{\omega^k\}) = \min_{k=1,2,\dots,K} d(\omega, \omega^k) \quad (5)$$

Para evaluar el error que se produce en la aproximación entre el conjunto de series de datos a modelar  $\{\omega^i\}$  y la representación mediante el árbol de escenarios  $\{\omega^k\}$ , se utiliza la expresión:

$$d(\{\omega^i\}, \{\omega^k\}) = \frac{1}{I} \sum_{i=1}^I \min_{k=1,2,\dots,K} d(\omega^i, \omega^k) \quad (6)$$

En tanto que el algoritmo de generación del árbol de escenarios tiene los siguientes pasos <sup>[8]</sup>:

- 1) Inicialización: Se escoge de manera aleatoria los escenarios iniciales que pasan a formar parte del árbol  $\{\omega^k\}$  para  $k=1,2,\dots,K$ .

- 2) Selección de nuevas series: Se escoge una serie  $\omega$  en forma aleatoria de entre el conjunto de datos a modelar y calculamos la distancia a cada uno de los escenarios del árbol.

$$d(\omega, \omega^k) \text{ para } k = 1, 2, \dots, K \quad (7)$$

Luego se ordenan los escenarios de acuerdo a la distancia  $d$  en un vector  $O^k$ .

- 3) Adaptación: Se modifican los valores de cada escenario del árbol en función del orden  $O^k$ , de tal forma que los escenarios más cercanos experimentan el mayor cambio, según la expresión:

$$\Delta \omega_t^k = \epsilon(j) \cdot \frac{\sum_{k'=1,2,\dots,K/\omega_t^k \in \omega^{k'}} h_\lambda(O^{k'}) \cdot (\omega - \omega^{k'})}{\sum_{k'=1,2,\dots,K/\omega_t^k \in \omega^{k'}} \mathbf{1}}$$

Que constituye la ecuación (8), y en donde:

$j$  es el contador de iteraciones, que varía desde 1 hasta  $j_{\max}$ .

$\epsilon(j)$  es una función exponencial que controla el tamaño del cambio global en los escenarios y está dado por:

$$\epsilon(j) = \epsilon_0 \cdot \left(\epsilon_f / \epsilon_0\right)^{j/j_{\max}} \quad (9)$$

$h_\lambda(O)$  es una función que establece el ajuste que se aplica a cada escenario dependiendo de la distancia a la serie de datos  $\omega$ .

$$h_\lambda(O) = -\exp\left(-\frac{O}{\lambda(j)}\right) \quad (10)$$

$\lambda(j)$  también es una función exponencial que controla el tamaño de los cambios individuales de cada escenario

$$\lambda(j) = \lambda_0 \cdot \left(\lambda_f / \lambda_0\right)^{j/j_{\max}} \quad (11)$$

- 4) Criterio de Parada: El algoritmo concluye cuando se alcanza el límite de iteraciones, caso contrario pasa al punto 2.

Para la ejecución del ejemplo numérico desarrollado se consideraron los parámetros recomendados en [4]:

$$\begin{aligned} \lambda_0 &= 10 \\ \lambda_f &= 0,01 \\ \epsilon_0 &= 0,5 \\ \epsilon_f &= 0,005 \\ j_{\max} &= 40\ 000 \end{aligned}$$

Para el desarrollo del algoritmo se utilizó el programa MATrix LABoratory –MATLAB [10].

Con la finalidad de que se pueda visualizar los resultados que se obtienen con la aplicación del algoritmo indicado, se realizará la generación de un árbol de decisión bietapa, con 48 escenarios.

El primer conjunto de datos que se representará mediante el árbol de escenarios corresponde a la curva de carga diaria de un sistema eléctrico aislado para los 365 días del año, en donde se incluye la carga de las cocinas de inducción, Fig. 2.:

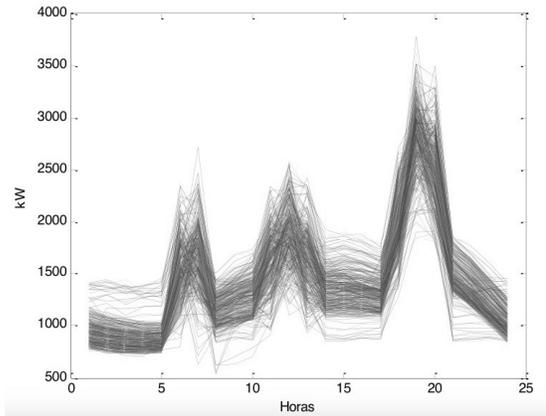


Figura 2: Series de datos de la demanda eléctrica

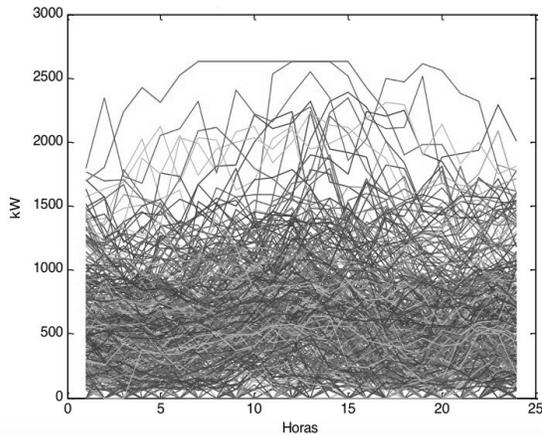


Figura 3: Series históricas de la producción eólica

El tercer conjunto de datos utilizados, corresponden a la producción disponible en el mismo período de una central hidroeléctrica de pasada de 2.4 MW de potencia instalada, la cual es función del caudal disponible en el aprovechamiento hidráulico y que también tiene carácter estocástico. Fig. 4.

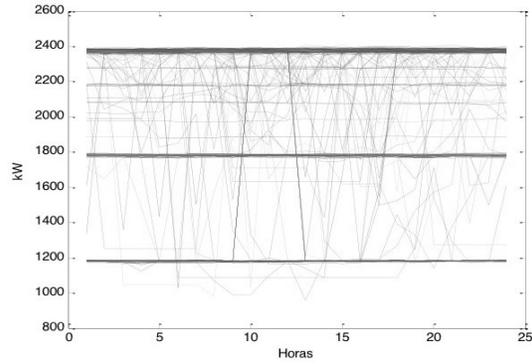


Figura 4: Series históricas de la producción hidroeléctrica

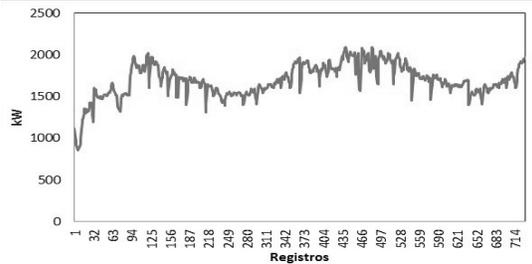


Figura 5: Serie Temporal de la demanda para las 19:00

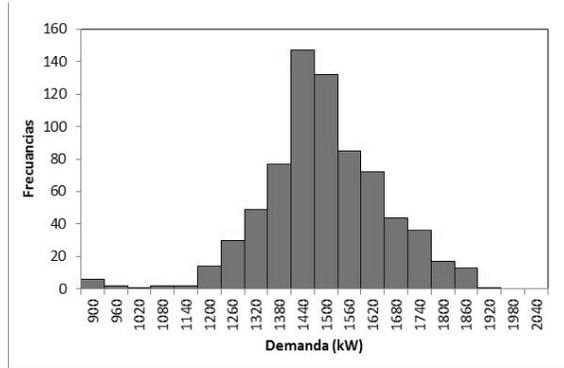


Figura 6: Distribución de Frecuencia para la demanda

En el caso del recurso eólico, la serie temporal del potencial eólico muestra su comportamiento estacional. Fig. 7.

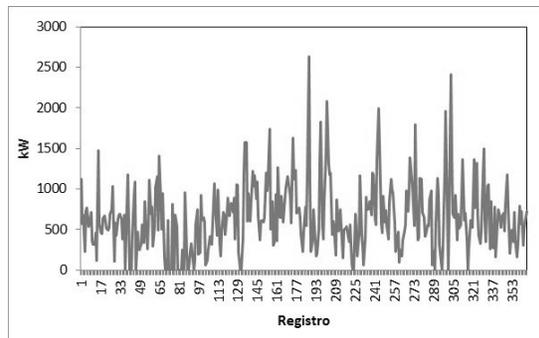


Figura 7: Serie temporal del potencial eólico para las 09:00

En tanto que la distribución de frecuencias de los datos tiene un gráfico sesgado, propio de la velocidad del viento. Fig. 8.

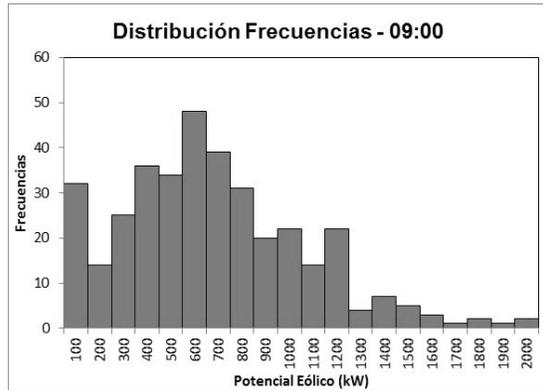


Figura 8: Distribución de frecuencias del potencial eólico para las 09:00

En lo que respecta a la generación hidroeléctrica, al tratarse de una central de pasada opera al máximo de potencia que se puede alcanzar en función de la disponibilidad de los caudales, el diseño de la central normalmente se realiza para un caudal de persistencia del 90%. En este caso la serie histórica de la producción eléctrica se puede observar a continuación. Fig. 9.

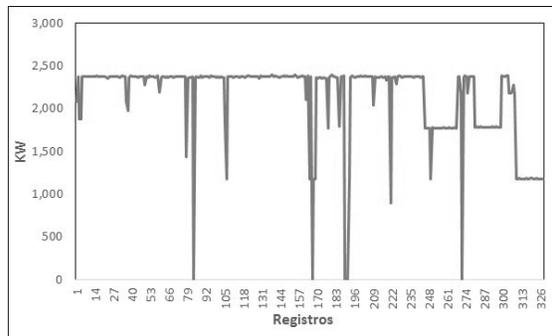


Figura 9: Serie temporal de la producción hidráulica

## 4. RESULTADOS

### 4.1. Árbol de Escenarios Generado.

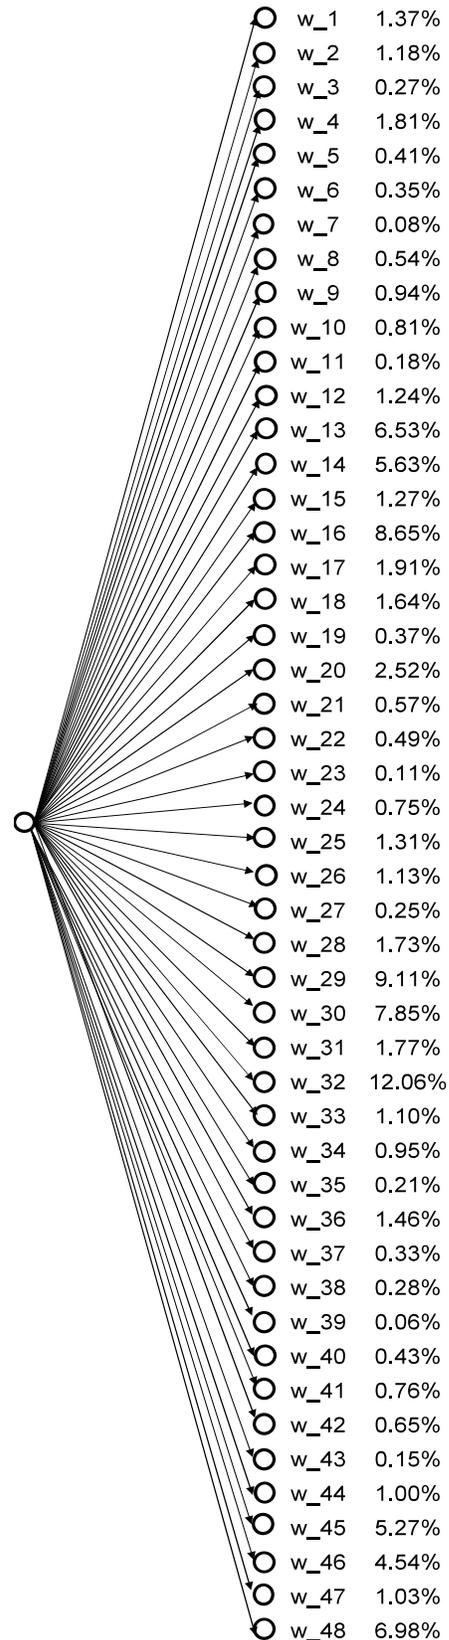


Figura 10: Árbol de Escenarios Bietapa

Con los antecedentes expuestos, se genera el árbol de escenarios bietapa representado en la Fig. 10, la primera etapa del árbol estaría constituida únicamente por variables deterministas, según el modelo de optimización que se desarrolle.

En tanto que en la etapa dos, se incorpora la estocasticidad de las variables, que para el presente trabajo estará representada por 48 escenarios ( $w$ ) con su correspondiente probabilidad de ocurrencia  $P(w)$ .

En este artículo cada escenario está constituido por 24 valores horarios de la demanda eléctrica y de los potenciales eólico e hidráulico disponibles, expresados en kW, con lo cual se puede establecer un modelo de programación estocástica diaria y cuyo detalle se pueden observar en el Apéndice 1, en donde se expresa también la probabilidad de ocurrencia de cada escenario.

#### 4.2. Análisis de los Resultados.

Con la finalidad de analizar la información y la importancia que representan los escenarios, se ha creído conveniente indicar en forma gráfica el escenario 32, por ser el que representa la mayor probabilidad de ocurrencia (12,06%).

En este escenario se registra un alto potencial hidroeléctrico y a pesar de existir un bajo potencial eólico, el sistema eléctrico aislado podría bajo este escenario cubrir la demanda eléctrica en el período de 24 horas. Fig. 11.

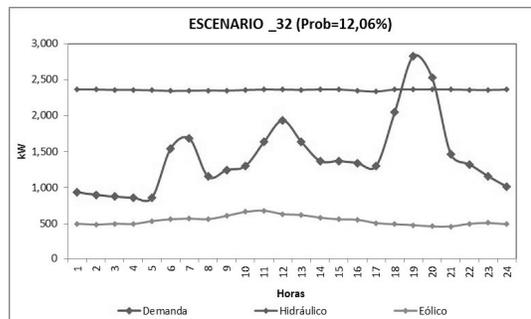


Figura 11: Variables Estocásticas en el Escenario 32

Sin embargo existen escenarios como el 44, en los cuales se registran altos valores horarios de la demanda eléctrica y bajo potencial de generación eólica e hidroeléctrica. Fig. 12.

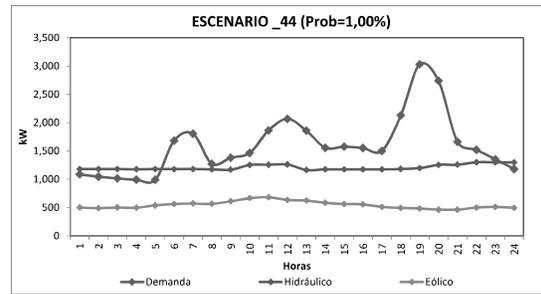


Figura 12: Variables Estocásticas en el Escenario 44

En estos escenarios el potencial eólico e hidroeléctrico no sería suficiente para cubrir la demanda eléctrica, por lo que se requiere la participación de otros tipos de generación convencional para el abastecimiento, lo cual incide en la planificación operativa o de expansión del sistema eléctrico aislado y que posiblemente no hubieran sido considerados al utilizar un modelo de planificación en un entorno determinista.

También se pueden observar escenarios con alto potencial eólico, superior incluso al potencial hidroeléctrico como el que se observa en el escenario 27, aunque su probabilidad de ocurrencia es muy baja, que también deben ser considerados en los problemas de optimización estocástica. Fig. 13.

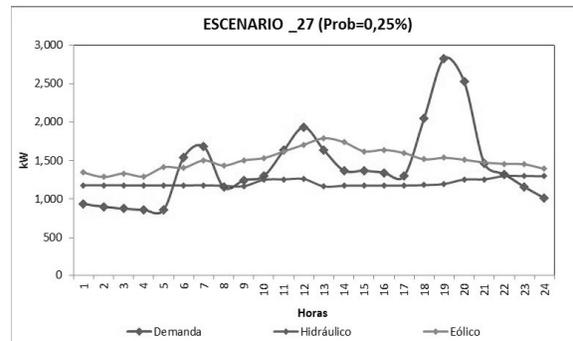


Figura 13: Evolución de las Variables Estocásticas en el Escenario 27

Es importante señalar que el Método Neural Gas puede ser adaptado en forma natural para generar árboles de escenarios multietapas y multivariables, de así requerirse para el modelo de optimización estocástica que se esté desarrollando, como ejemplo en este artículo y utilizando la misma información estadística de la demanda y de la producción eólica e hidroeléctrica, se generó un árbol de escenarios de 4 etapas, que se presenta en forma gráfica a continuación. Fig. 14.

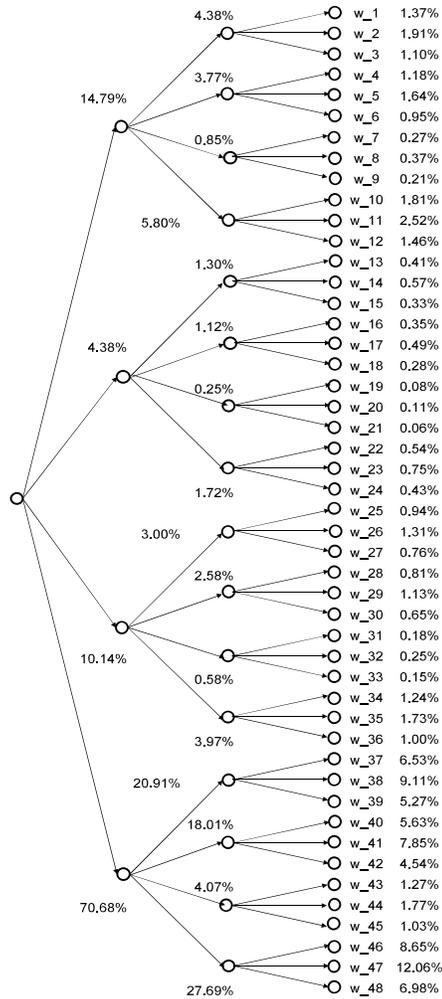


Figura 14: Árbol de Escenarios Multietapas

## 5- CONCLUSIONES Y RECOMENDACIONES

### 5.1. Conclusiones

El algoritmo Neural Gas, permite tratar la incertidumbre existen en la disponibilidad de recursos naturales renovables y en la demanda eléctrica, de manera adecuada, a través de la generación de árboles de escenarios, lo cual posibilita el planteamiento de problemas de optimización estocástica.

El algoritmo desarrollado permite generar árboles de escenarios bietapas o multietapas.

La generación de árboles de escenarios mediante el algoritmo Neural Gas, abren la posibilidad de desarrollar modelos de planificación estocástica, que permitan la toma de decisiones adecuada, en sustitución de los modelos de planificación determinista tradicionalmente utilizados

### 5.2. Recomendaciones

Se debe continuar las investigaciones relacionadas con el tratamiento de variables aleatorias especialmente relacionadas con la generación renovable, de tal manera que contribuya con el objetivo nacional de cambio de la matriz energética.

### REFERENCIAS BIBLIOGRAFICA

- [1] Conelec, “Plan Maestro de Electrificación 2013-2022”, Advantlogic Ecuador S.A.
- [2] A. Ramos, A. Alonso-Ayuso. G. Pérez, “Optimización Bajo Incertidumbre”. 2011. Universidad Pontificia Comillas.
- [3] A. Amru, A. Etemadi, A. Khodaei. “Treatment of uncertainty for next generation power systems: State-of-the-art in stochastic optimization”, Electric Power Systems Research, 141 (2016) 233-245.
- [4] A. Ahmadi, M. Charwand, P. Siano, A. Nexhad, D. Sarno, M. Gitizandeh, F. Raesi. “A novel two-stage stochastic programming model for uncertainty characterization in short-term optimal strategy for a distribution company”, Energy 117 (2016) 1-9.
- [5] Y. Huang, J.Wu, Y Hsu. “Two-stage stochastic programming model for the regional-scale electricity planning under demand uncertainty”. Energy 116 (2016) 1145-1157.
- [6] Y. Yang, S.Zhang, Y. Xiao. “Optimal desing of distributed energy resource systems based on two-stage stochastic programming. Applied Thermal Enegineering 110 (2017) 1358-1370.
- [7] H. Park, R. Baldick. “Multi-year stochastic generation capacity expansion planning under environmental energy policy”. Applied Energy 183 (2016) 737-745.
- [8] J.Latorre, S. Cerisola, A. Ramos. “Clustering Algorithms for Scenario Tree Generation. Application to Natural HydroInflows”. Instituto de Investigaciones Tecnológicas, ICAI, Universidad Pontificia Comillas.
- [9] B. Fritzke, “Some Competitive Learning Methods”, 1997, Systems Biophysics Institute for Neural Computation Ruhr-Universität Bochum.
- [10] J Garcia, J. Rodríguez, J. Vidal, “Aprenda Matlab 7.0”, 2005, Universidad Politécnica de Madrid.

[11] J. Birge, F. Louveaux, "Introduction to Stochastic Programming", 1997, Springer-Verlag New York, Inc.



**Raúl Barreto Calle.**-Nació en Biblián, provincia del Cañar, Ecuador en 1969. Recibió su título de Ingeniero Eléctrico de la Universidad de Cuenca en 1995; de Magister en Administración de Empresas de la Universidad Nacional de Loja, Ecuador en 2008, de

Master en Ingeniería en Energía de la Universidad Politécnica de Cataluña y Universidad de Barcelona, España en 2013. Actualmente realiza sus estudios de Doctorado en la Universidad Politécnica de Cataluña y su campo de investigación se encuentra relacionado con Planificación Óptima de Sistemas Eléctricos de Potencia.