Determinación de los Modelos Estocásticos de Generación de las Centrales del Sistema Nacional Interconectado

V. Cárdenas D. Echeverría J. Cepeda

Operador Nacional de Electricidad, CENACE
E-mail: vcardenas@cenace.org.ec, decheverria@cenace.org.ec, jcepeda@cenace.org.ec

Resumen

El objetivo principal del presente trabajo es la determinación de los modelos estocásticos de las centrales de generación del Sistema Nacional Interconectado S.N.I. ecuatoriano. Estos modelos estocásticos servirán de entrada para implementar, posteriormente, una metodología de evaluación de la confiabilidad de generación (Generation Adequacy) que permitirá determinar adecuados márgenes de reserva considerando incertidumbres tales como la disponibilidad de recursos renovables (hídrico, eólico o solar). Para la determinación de los modelos estocásticos se propone una metodología basada en la obtención de funciones discretas de densidad de probabilidad (FDP) mensuales, utilizando como entrada los resultados de planificación energética generados por el software SDDP (Programación Dinámica Dual Estocástica), para un horizonte de un año. Siendo estas FDP funciones independientes, se propone una metodología novedosa para determinar una función de densidad "promedio" que represente a todo el año a través del concepto de convolución.

***Palabras clave*— Reserva de Energía, Despacho Económico, Planificación a Corto y Mediano Plazo, SDDP, Modelo Estocástico de Generación, Funciones de Distribución de Probabilidad**

Abstract

The main objective of this paper is to determine the stochastic models of power generation plants of the Ecuadorian National Interconnected System S.N.I. These stochastic models will be then used as input to implement a Generation Adequacy methodology that will allow determining adequate energy reserve margins considering uncertainties such as availability of renewable resources (hydric, wind, solar). In order to determine the stochastic models, a methodology based on determination of probability density functions (PDF), is proposed. This methodology uses as input the stochastic results of the software SDDP (Stochastic Dual Dynamic Programming) for a timeframe of one year. Since the obtained PDFs are independent functions, a novel methodology to compute an "average" probability density function is proposed in this paper by applying the concept of convolution.

***Index terms*— Energy Reserve, Economic Dispatch, Short-term and Long-term Planning, SDDP, Stochastic Generation Model, Probability Density Functions.**

Recibido: 22-10-2015, Aprobado tras revisión: 24-12-2015.
Forma sugerida de citación: Cárdenas, V.; Echeverría, D.; Cepeda, J. (2016). "Determinación de los Modelos Estocásticos de Generación de las Centrales del Sistema Nacional Interconectado". Revista Técnica ***"energía"***. Nº 12, Pp. 84-91.
ISSN 1390-5074.

1. INTRODUCCIÓN

Actualmente cuando se habla de energía, se destacan las energías renovables no convencionales como son la energía eólica o solar, sin embargo, en el Ecuador debido a la mayor disponibilidad del recurso y a su aprovechamiento, las centrales hidráulicas han tenido un rápido crecimiento en los últimos años, también alentado por la conciencia pública sobre el cuidado del medio ambiente permitiendo reducir las emisiones de gases de efecto invernadero asociados a la generación de la energía convencional.

Al esperar un gran potencial de energía proveniente de fuentes intermitentes, se convierte en esencial para el Operador Nacional de Electricidad la evaluación de la confiabilidad del sistema de generación de energía ya que se debe encontrar un equilibrio óptimo entre factores como la sostenibilidad ambiental, económica y la seguridad del suministro eléctrico.

En este sentido, la confiabilidad del sistema de generación de energía se divide en adecuación y seguridad [1], y su análisis se lo puede realizar utilizando la herramienta “Generation Adequacy” de PowerFactory de DIgSILENT, el cual utiliza modelos estocásticos de la capacidad de generación y carga para evaluar los índices de confiabilidad del sistema y determinar adecuados márgenes de reserva considerando incertidumbres tales como la disponibilidad de recursos renovables (hídrico, eólico o solar).

El modelo estocástico de la capacidad de generación se utiliza para definir los estados de disponibilidad de un generador, es decir, que para cada estado, se debe especificar la capacidad de generación total disponible como un porcentaje de la producción máxima, junto con su probabilidad de ocurrencia, cabe recalcar que la sumatoria de la probabilidad de ocurrencia está limitada automáticamente por el 100% [2].

Bajo este contexto, el enfoque principal de este artículo es desarrollar una metodología de identificación de modelos estocásticos de generación que permita disponer de funciones de distribución de probabilidad de generación para cada una de las unidades del Sistema Nacional Interconectado (S.N.I.) a partir de las series estocásticas que entrega el Programa SDDP -Programación Dinámica Dual Estocástica-, cuyo análisis se lo realizará utilizando el software de MATLAB [3].

2. MODELOS ESTOCÁSTICOS DE GENERACIÓN DE ENERGÍA ELÉCTRICA

El objetivo de la presente metodología es obtener una función de densidad de probabilidad de la energía disponible de una central de generación, la cual cuantificará el riesgo de no cubrir la demanda esperada. Esta función representa la contribución probabilística final de toda la generación de la central durante las horas de demanda pico.

Se utilizan los valores de las series estocásticas del Programa SDDP para construir la función de probabilidad asociada a cada central de generación. En este sentido, a continuación se describen los conceptos de funciones de probabilidad y el modelo de programación dinámica dual estocástica del SDDP [4].

2.1. Series Estocásticas del SDDP

El Programa SDDP (Programación Dinámica Dual Estocástica) determina la política operativa más económica para los embalses, teniendo en cuenta las incertidumbres en las afluencias futuras; simula la operación del sistema a lo largo del período de planificación, para distintos escenarios de secuencias hidrológicas; calcula índices de desempeño tales como el promedio de los costos operativos, y determina la operación óptima de corto plazo [4].

La programación dinámica dual estocástica parte de una representación estocástica de las series temporales hidrológicas pertinentes. La versión del SDDP utilizada permite representar los aportes hidrológicos mensuales por medio de sus medias, desviaciones típicas, coeficientes de asimetría, estructura de correlación temporal y la estructura de la correlación espacial. Esta representación permite utilizar los parámetros para una generación de secuencias hidrológicas igualmente probables, las cuales preservan las características de la serie original. Dichas secuencias permiten simular el sistema hidrotérmico y observar su comportamiento para cada una de ellas. Dado que ellas son igualmente probables, de los resultados de las simulaciones es posible inferir acerca del comportamiento probabilístico de diversas variables producto de la operación del sistema [4].

2.2. Función de densidad de probabilidad.

Para caracterizar un proceso estocástico, dado por el Programa SDDP, debe conocerse la función de distribución conjunta de las variables aleatorias para todos los posibles resultados.

En este sentido, la función de densidad de probabilidad es un modelo teórico que describe la forma en que varían los resultados de un experimento aleatorio, es decir, nos da todas las probabilidades de todos los posibles resultados que podrían obtenerse cuando se realiza un experimento aleatorio [5]. Se clasifican como discretas o continuas.

En el caso de las series estocásticas obtenidas del Programa SDDP, la variable aleatoria a analizar será considerada como discreta. Se dice que una variable aleatoria es discreta, si los números asignados a los sucesos elementales son puntos aislados. Sus posibles valores constituyen un conjunto finito numerable [5].

2.2.1 Definición matemática de función de densidad de probabilidad (FDP) discreta

Sea un espacio probabilístico y sea X una variable aleatoria discreta que toma como posibles valores x_1, x_2...x_n, se define la *densidad de probabilidad de X* como el conjunto de pares (x_i, p_i) que a cada valor de la variable le asocia una probabilidad, donde [5]:

$$p_i = P(X = x_i) \tag{1}$$

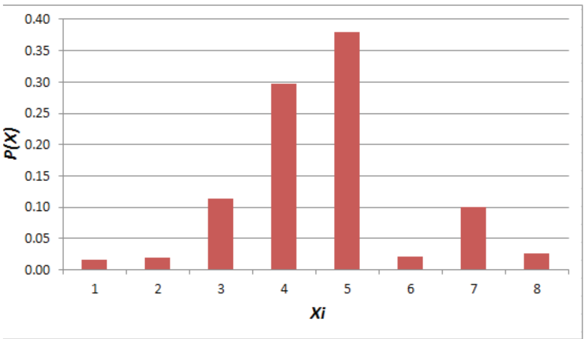

Figura 1: Función de densidad de probabilidad

La Fig. 1, representa el comportamiento de un proceso estocástico, por ejemplo, la función de densidad de probabilidad de generación de energía de un mes determinado, dado por las series estocásticas del Programa SDDP.

Ahora, para caracterizar dos o más procesos estocásticos, debe conocerse la función de distribución conjunta de las variables correspondientes.

En este sentido, existe un procedimiento matemático denominado convolución, el cual permite transformar dos funciones en una tercera función, que en cierto sentido representa la magnitud en la que se superponen las dos funciones.

2.3. Convolución de funciones de densidad de probabilidad discretas.

Una convolución es un operador matemático que transforma dos funciones f_1 y f_2 en una tercera función f_3, que en cierto sentido representa la magnitud en la que se superponen f_1 y una versión trasladada e invertida de f_2. Una convolución es un tipo muy general de media móvil [5].

2.3.1 Definición matemática de convolución discreta

Sean X e Y dos variables aleatorias independientes que tienen un número finito de valores enteros. Se desea conocer la distribución de la suma $X+Y$.

Usando independencia, se tiene [5]:

$$f_{X+Y}(k) = P(X+Y=k) \tag{2}$$

$$f_{X+Y}(k) = \sum_i P(X=i, Y=k-i) \tag{3}$$

$$f_{X+Y}(k) = \sum_i P(X=i)P(Y=k-i) \tag{4}$$

$$f_{X+Y}(k) = \sum_i f_X(i) f_Y(k-i) \tag{5}$$

Entonces, la función de convolución $f_X * f_Y$ está definida por:

$$f_X(k) * f_Y(k) = \sum_i f_X(i) f_Y(k-i) \tag{6}$$

La ecuación es denominada como la convolución de f_X y f_Y.

3. METODOLOGÍA PROPUESTA

Los resultados de una simulación del SDDP, de interés para este trabajo, están constituidos por 50 series estocásticas correspondientes a la energía producida por cada planta de generación en el período de la curva de duración mensual correspondiente a la demanda pico, la cual comprende un periodo de 2.87% del total de las horas del mes (t_{pico}). En este sentido, se obtendrán

50 valores de producción por cada mes, dentro de un periodo de tiempo total de n cantidad de años de análisis (en el caso de estudio se selecciona el periodo de un año, sin embargo el periodo de estudio total puede ser de varios años). Así, se obtendrá un total de 12 conjuntos de 50 datos cada uno. Usando estos resultados, es posible determinar las funciones de densidad de probabilidad de producción de energía para cada uno de los meses que hayan formado parte de la simulación. Cada una de estas funciones de densidad representa la probabilidad de producción mensual de la planta, la cual constituye una variable aleatoria independiente para cada mes (esto puesto que la probabilidad de generación mensual depende del resultado del proceso estocástico del SDDP en función de la programación estocástica de las variables involucradas tales como la hidrología y éstas presentan independencia entre los diferentes meses).

Por otro lado, la funcionalidad de *Generation Adequacy* de PowerFactory requiere como entrada la función de densidad de probabilidad discreta de potencia disponible de generación de cada planta para un año. Sobre la base de este requerimiento, es necesario definir una metodología que permita realizar lo siguiente:

a) Determinar, a partir de las 12 funciones de densidad de probabilidad independientes de producción de energía mensual (f_k; k=1, 2,…,12, con variables X_k) obtenidas a partir de los resultados del SDDP, una función de densidad "promedio" que represente el comportamiento promedio de producción de cada planta para todo el año.

b) Transformar la función de densidad "promedio" de producción a una función de densidad "promedio" de potencia disponible.

Sobre la base de lo mencionado, y usando un símil con el concepto de promedio aritmético, se define la función de densidad "promedio" f_M (con variable aleatoria X_M) como una función que permita satisfacer la siguiente ecuación:

$$f_{12*X_M}\left(k\right) = f_{X_1+X_2+\text{K}\ X_{12}}\left(k\right) \qquad (7)$$

Así, la convolución de las 12 funciones de densidad independientes (función de densidad conjunta de las 12 funciones $f_{DC} = f_{X1+X2+\ldots+X12}$) debe ser igual a la función de densidad conjunta obtenida de convolucionar 12 veces la función de densidad "promedio" f_M, a la cual se puede denominar como la función de densidad conjunta objetivo: $f_{DCO} = f_{12*XM}$.

Basado en esta definición, es posible determinar la f_M identificando cada uno de los pares discretos (x_{Mi}, p_{Mi}) que conforman la f_M.

Debido a la complejidad matemática causada por la no linealidad de las operaciones de convolución sucesiva, es necesario utilizar un optimizador heurístico que permita identificar los pares discretos (x_{Mi}, p_{Mi}) óptimos que estructuren la f_M óptima que mejor satisfaga la ecuación . En este sentido, se debe especificar una función objetivo apropiada que permita ejecutar la identificación paramétrica detallada.

Con este propósito, se ha planteado como función objetivo la minimización de los errores cuadrados entre los pares discretos de las funciones f_{DC} (x_{DCi}, p_{DCi}) y la f_{DCO} (x_{DCOi}, p_{DCOi}). Considerando que los rangos discretos de amabas funciones son los mismos ($x_{DCi} = x_{DCOi}$), la función objetivo a minimizar puede ser definida de acuerdo a , siendo la restricción fundamental que los parámetros a identificarse p_{Mi} cumplan la condición de representar una función de densidad de probabilidad discreta .

$$\min OF = \alpha \cdot \sum_{i=1}^{n}\left(p_{DCO_i} - p_{DC_i}\right)^2 \qquad (8)$$

Siendo α un peso para atenuar el efecto de los valores pequeños de los p_{DCOi} y de los $p_{DCi,}$ que en este caso se define como 10 000. El proceso de optimización de está sujeto a la siguiente restricción.

$$\sum_{i=1}^{n} p_{M_i} = 1 \qquad (9)$$

En este sentido, el algoritmo de optimización heurístico será el encargado de identificar los parámetros óptimos p_{Mi}. Sobre la base de los resultados registrados en la literatura, en la solución exitosa de problemas de optimización altamente no lineales, este trabajo ha seleccionado como optimizador a la versión enjambre del algoritmo de optimización de mapeo media-varianza ($MVMO^S$) [7], el cual será explicado brevemente en la sección 3.1.

Una vez determinados los parámetros óptimos p_{Mi}, la función f_M queda identifica, representando la función de densidad "promedio" de producción anual de energía de la planta. Esta f_M luego deberá ser transformada a la función de densidad "promedio" de potencia disponible f_{Mp} para lo cual aplicará la ecuación que permite relacionar la energía con la duración de la demanda pico.

$$x_{Mp_i} = \frac{x_{M_i}}{t_{pico}} \tag{10}$$

La Fig. 2 presenta un diagrama de flujo que esquematiza la metodología propuesta.

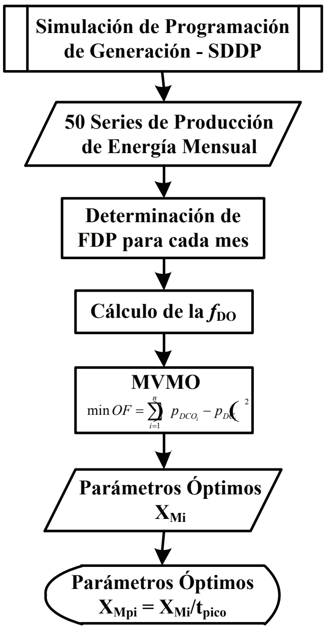

Figura 2: Metodología Propuesta

3.1. Optimización de Mapeo Media-Varianza

El procedimiento general del $MVMO^S$ se muestra en la Fig. 3. Este algoritmo constituye una nueva herramienta de optimización metaheurística que combina las propiedades del MVMO original [8] con la teoría de inteligencia de enjambre. Inicialmente, se definen los parámetros del algoritmo y un conjunto de soluciones candidatas, normalizadas entre [0, 1], rango en el cual se realizan las operaciones subsiguientes, garantizando así una búsqueda del óptimo con las variables de control dentro de sus límites [min, max]. En contraste con el MVMO, el $MVMO^S$ realiza una búsqueda simultánea con *np* partículas, cada una caracterizada por su propia memoria, representada por su correspondiente archivo de almacenamiento dinámico de mejores soluciones y una función de mapeo.

En la etapa inicial de búsqueda, cada partícula realiza, individualmente, *m* evaluaciones de la función objetivo para recolectar un conjunto de posibles soluciones. Posteriormente, se produce un intercambio de información entre las búsquedas individuales, tanto para determinar la solución óptima global, como para suprimir las partículas próximas a esta (criterio de distancia euclidiana). Nuevas soluciones candidatas (descendencia) se definen heredando (cruce) algunas dimensiones del óptimo local en cada partícula, mientras que el mapeo de las dimensiones restantes (mutación) considera la media y la varianza del óptimo global.

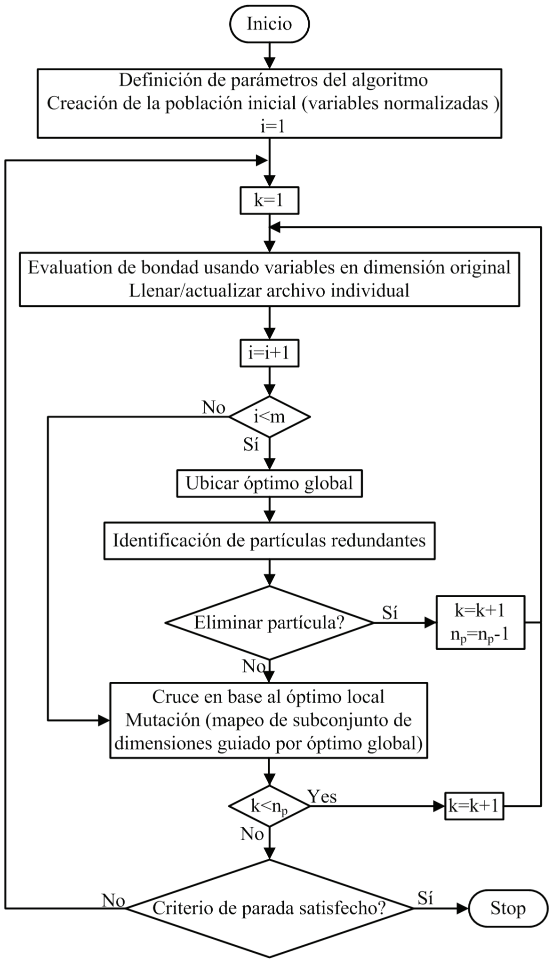

Figura 3: Procedimiento de MVMOS (i, k, m, y np denotan al contador evaluaciones de la función objetivo, contador de partículas, número máximo de corridas independientes, y número total de partículas, respectivamente)

4. CASO DE ESTUDIO

A continuación se presenta los resultados de análisis de los procesos estocásticos del Programa SDDP, lo cual permite encontrar las funciones de densidad de probabilidad de generación de energía, a partir de las 50 series estocásticas simuladas por el Programa SDDP para cada mes.

Para este análisis se han considerado las siguientes hipótesis:

- Período de análisis: oct 2015-sep 2016.
- Proyección de demanda.
- Plan de mantenimientos de generación y transmisión.
- Plan bianual de operación del Sistema Nacional Interconectado, CENACE.
- Centrales para el análisis: Paute y Agoyán.

Dado que se realizará un análisis probabilístico de confiabilidad, basado en los criterios de "Generation Adequacy", se han considerado las series estocásticas de generación de las centrales hidroeléctricas para el periodo de punta, es decir, para las horas de demanda pico del sistema. En este sentido, se ha considerado alrededor de 20 horas de generación en demanda punta por mes.

4.1. Resultados Central Hidroeléctrica Paute

A continuación, se presentan los resultados de analizar las 50 series estocásticas para la generación en demanda punta de la central hidroeléctrica Paute.

En la Fig. 4, se presenta la función de densidad de probabilidad para los meses de diciembre 2015, mayo 2016 y septiembre 2016.

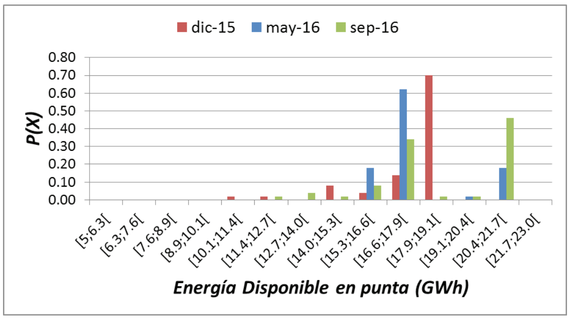

Figura 4. Función de densidad de probabilidad de producción de energía mensual

En este sentido, se presenta el comportamiento estocástico de la producción de energía mensual en punta de la central hidroeléctrica Paute.

Usando las 12 funciones de densidad de probabilidad, se calcula la función de densidad conjunta de las 12 funciones, la cual se muestra en la Fig. 5.

En la Fig. 5, se observa que la función de densidad conjunta no representa el comportamiento probabilístico real de la producción anual de energía en punta de la central hidroeléctrica Paute, dado que matemáticamente está representando la superposición de las funciones de densidad de probabilidad, y lo que en realidad se requiere es una función de densidad promedio de producción de energía, tal y como se demuestra en el método propuesto en este trabajo.

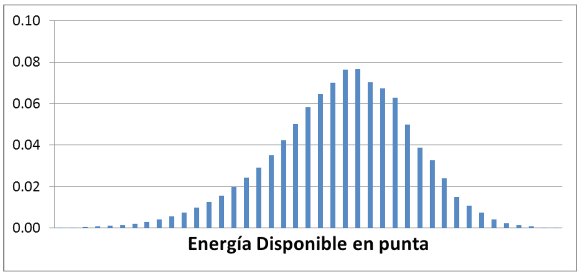

Figura 5: Función de densidad conjunta de las 12 funciones

Ahora, utilizando la metodología propuesta, la Fig. 6, muestra la función de densidad "promedio" f_M de la central hidroeléctrica Paute, lo que permite tener una visión probabilística de la producción de energía en punta de la central para todo el año.

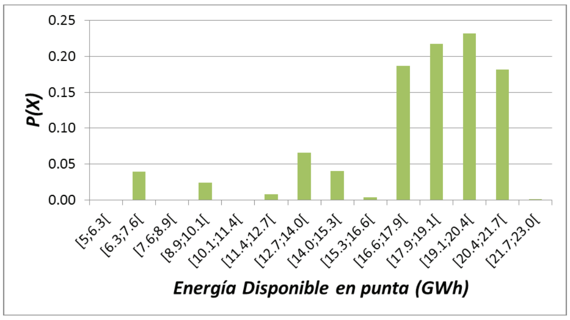

Figura 6: Función de densidad "promedio" f_M de producción de energía para el año de análisis – Central Paute

Dado que se necesita la potencia disponible en punta de la central hidroeléctrica, la Fig. 7 presenta los resultados de la función de densidad "promedio" de potencia disponible f_{Mp} en punta de la central Paute. En este sentido, se aprecia que las mayores probabilidades de producción en punta (alrededor de 0.2) se da entre las potencias de 789 MW a 1034 MW. Esto permite tener el modelo estocástico de producción en punta de la central y puede ser utilizada para cualquier tipo de tecnología.

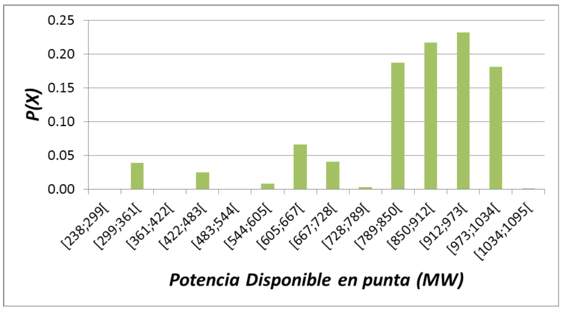

Figura 7: Función de densidad "promedio" de potencia disponible f_{Mp} para el año de análisis – Central Paute

4.2. Resultados Central Hidroeléctrica Agoyán

Utilizando la metodología propuesta, la Fig. 8, muestra la función de densidad "promedio" f_M de la central hidroeléctrica Agoyán, lo que permite tener una visión probabilística de la producción de energía de la central.

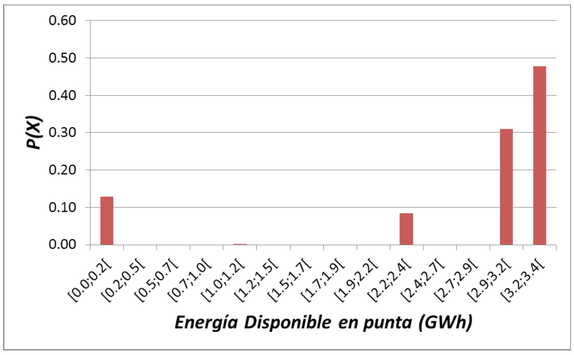

Figura 8: Función de densidad "promedio" f_M de producción de energía para el año de análisis – Central Agoyán

Dado que se necesita la potencia disponible en punta de la central hidroeléctrica, la Fig. 9 presenta los resultados de la función de densidad "promedio" de potencia disponible f_{Mp} en punta de la central Agoyán.

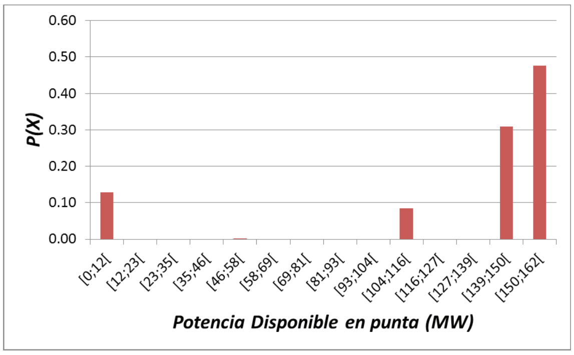

Figura 9: Función de densidad "promedio" de potencia disponible f_{Mp} para el año de análisis – Central Agoyán

Se aprecia que las mayores probabilidades de producción en punta (alrededor de 0.45) se da entre las potencias de 139 MW a 156 MW.

5. CONCLUSIONES Y RECOMENDACIONES

Los análisis de la producción y reserva del sistema tradicionalmente han sido analizados a través de criterios deterministas. Sin embargo, la aleatoriedad de las variables de control, como la generación y la demanda, hace que estos criterios sean inadecuados. En el Ecuador, esto se agrava cuando se incorporan grandes fuentes de energía hidroeléctrica, puesto que éstas presentan mucha mayor probabilidad de fluctuación que las fuentes de generación convencionales. En este contexto, se debe diseñar y aplicar herramientas más flexibles (como las probabilísticas) para analizar la planificación del sistema de potencia.

Este trabajo presenta una nueva metodología para la caracterización probabilística de la producción de energía y disponibilidad de potencia de una central de generación. Es decir, se determinan los modelos estocásticos de las centrales de generación.

La función de densidad "promedio" de energía y potencia disponible, proporciona gran información para el planificador del sistema con respecto a los posibles comportamientos de la central de generación.

Estos resultados son la base para realizar un análisis de confiabilidad de la generación (adecuación) del sistema de potencia, lo que permitirá calcular márgenes de reserva probabilísticos del sistema, así como también contar con una herramienta de decisión para el planificador.

REFERENCIAS BIBLIOGRÁFICAS

[1] P. Hee Yau, "Generation System Reliability Evaluations with Intermittent Renewables," M.S. thesis, University of Strathcly, United Kingdom, 2006.

[2] R. Billinton, R. Karki, A. Kumar, "Reliability and Risk Evaluation of Wind Integrated Power Systems", Springer, 2013.

[3] MATLAB, Math Works, Inc., Natick, MA, USA. www.mathworks.com

[4] SDDP, Manual de Usuario, http://www.psr-inc.com/

[5] H. Morris, DeGroot and Mark, J. Schervish, “Probability and Statistics”, Pearson, Cuarta Edición, 2011.

[6] NERC, “Methods to Model and Calculate Capacity Contributions of Variable Generation for Resource Adequacy Planning”, U.S.A., March 2011.

[7] J. Cepeda, “Evaluación de la Vulnerabilidad del Sistema Eléctrico de Potencia en Tiempo Real usando Tecnología de Medición Sincrofasorial”, Tesis Doctoral, Universidad Nacional de San Juan, Argentina, Diciembre 2013.

[8] Erlich I., Venayagamoorthy G. & Nakawiro W. (2010). “A mean variance optimization algorithm”. IEEE World Congress on Computational Intelligence, Barcelona, Spain.

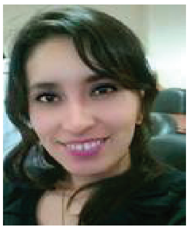

Verónica Cárdenas Ulloa.- Recibió su título de Ingeniera Eléctrica en la Escuela Politécnica Nacional en el 2011. En el año 2014 egresó de la Maestría en Energías Renovables realizada en la Universidad de las Fuerzas Armadas ESPE. Actualmente trabaja en la Dirección de Planeamiento de la Corporación Centro Nacional de Control de Energía CENACE. Sus áreas de interés son: Energías Renovales No Convencionales, Confiabilidad de Sistemas de Generación y Planificación de la Operación.

Diego Echeverría Jurado.- Recibió su título de Ingeniero Eléctrico de la Escuela Politécnica Nacional de Quito, en 2006. Se encuentra realizando sus estudios de Doctorado en Ingeniería Eléctrica en el Instituto de Energía Eléctrica (IEE), de la Universidad Nacional de San Juan. Actualmente trabaja en el Operador Nacional de Electricidad CENACE de Ecuador en el Área de Investigación y Desarrollo. Sus áreas de interés son: Estabilidad de Sistemas de Potencia en Tiempo Real, Sistemas de medición sincrofasoriales PMU’s y Control de Emergencia de Sistemas de Potencia.

Jaime Cristóbal Cepeda.- Recibió el título de Ingeniero Eléctrico en la Escuela Politécnica Nacional en 2005 y el de Doctor en Ingeniería Eléctrica en la Universidad Nacional de San Juan en 2013. Entre 2005 y 2009 trabajó en Schlumberger y en el CONELEC. Colaboró como investigador en el Instituto de Energía Eléctrica, Universidad Nacional de San Juan, Argentina y en el Instituto de Sistemas Eléctricos de Potencia, Universidad Duisburg-Essen, Alemania entre 2009 y 2013. Actualmente se desempeña como jefe de investigación y Desarrollo del CENACE. Sus áreas de interés incluyen la evaluación de vulnerabilidad en tiempo real y el desarrollo de Smart Grids.