

Aproximación al modelado de los aportes hidráulicos a las represas del Uruguay teniendo en cuenta el índice Niño 3.4.

R. Chaer, R. Terra, A. Díaz, A. Brandino.

Resumen— Este trabajo expone una primera aproximación a un modelo de series de aportes hidráulicos a las centrales de generación hidroeléctrica del Uruguay, considerando su relación con el fenómeno ENOS a través de la incorporación del índice Niño 3.4. Se presenta una metodología de evaluación de los potenciales beneficios logrados por la mejora en los modelos de aportes hidráulicos a las represas. Se aplica esta metodología al modelo rústico presentado y se exponen los resultados. Se entiende que estos resultados son conservadores y que en base a los mismos se comprueba la necesidad de profundizar en la incorporación de la información climatológica en los modelos de aportes hidráulicos a las represas.

Index Terms— ENSO, El Niño, La Niña, Hydroelectric-thermal power generation, Hydrology, Meteorology, Power generation dispatch.

I. INTRODUCCIÓN

La operación óptima del sistema de generación de hidroeléctrico, parte de utilizar una herramienta de optimización que permite calcular una “Política de Operación”. Esta PO, no es otra cosa que la valorización de los recursos almacenables del sistema, de forma de poder evaluar en todo momento, la conveniencia o no de usar cada recurso. En el caso Uruguayo, el recurso almacenable de mayor importancia es al agua en las represas de las centrales hidráulicas. La PO se expresa entonces en nuestro caso en una valorización del agua de los embalses en función del estado del sistema. En la determinación de una PO es determinante el modelado que se realice de los procesos estocásticos considerados. En nuestro caso, la mayor fuente de incertidumbre la constituyen los aportes hidráulicos a las represas, la posibilidad de recibir energía de nuestros vecinos y la disponibilidad de las máquinas térmicas de nuestro sistema. La obtención de una política de operación se lleva a

cabo mediante una optimización dinámica estocástica [1] en la que el objetivo es minimizar el valor esperado del Costo Futuro (CF) de operar el sistema. En forma simplificada, podemos escribir CF cómo:

$$CF(x, U_k, R_k, k) = CE(x, u_k, r_k, k) + q \cdot CF(x', U_{k+1}, R_{k+1}, k+1) \quad (1)$$

$$U_k = \{u_k, u_{k+1}, \dots\} \quad y \quad R_k = \{r_k, r_{k+1}, \dots\}$$

Siendo r_k , la realización de las entradas aleatorias en la etapa k y u_k el valor de las variables de control que aplicamos en la etapa k . Típicamente, las variables de control son las potencias despachadas en las diferentes centrales térmicas y los caudales turbinados y vertidos en las hidráulicas. El costo incurrido en forma directa en la etapa k es $CE(x, u_k, r_k, k)$. El factor q es el encargado de tener en cuenta la tasa de descuento aplicable a un paso de tiempo. El valor del estado del sistema al inicio de la etapa k es x , evolucionando durante dicha etapa hasta el valor x' .

La evolución del estado del sistema durante la etapa k es consecuencia de la estructura propia del sistema y de la aplicación de las variables de control u_k y de las entradas aleatorias r_k . La evolución del estado se modela mediante una función como la siguiente:

$$x' = f(x, u_k, r_k, k) \quad (2)$$

La ecuación (1) expresada en palabras dice: “El Costo Futuro desde el inicio de la etapa k , partiendo del estado x es el costo incurrido en la etapa k más el Costo Futuro desde el inicio de la etapa $(k+1)$ multiplicado por el actualizador q ”. Con esta formulación, una PO es una forma de tener las variables de control en función del estado del sistema para cada etapa y se puede escribir como:

$$u_k = PO(x, k) \quad (3)$$

Dada una PO es posible evaluar CF usando (1) y (2) sobre un horizonte de tiempo y para un conjunto dado de realización de las variables aleatorias. Así es posible buscar la PO óptima, como aquella que minimiza el valor esperado de CF. La herramienta de optimización utilizada en nuestro caso es SimSEE [2].

Álvaro Díaz (adiaz@fing.edu.uy) y Rafael Terra (rterra@fing.edu.uy), Instituto de Mecánica de los Fluidos e Ingeniería Ambiental (IMFIA) de la Facultad de Ingeniería (FING) de la Universidad de la República Oriental del Uruguay (UDELAR).

Álvaro Brandino (abrandino@adme.com.uy) está en la Administración del Mercado Eléctrico (ADME) del Uruguay.

Ruben Chaer (rch@todo.com.uy) está en el Instituto de Ingeniería Eléctrica (IIE) – FING-UDELAR y en ADME.

Observar que en este procedimiento interviene la realización de las variables aleatorias. Conocido el valor de las variables aleatorias en la etapa k dependiendo de los procesos aleatorios la realización en la etapa $(k+1)$ resulta con más o menos incertidumbre. Gráficamente, decimos que tenemos un “cono de incertidumbre” hacia el futuro, que comienza con el valor que conocemos y se agranda en la medida en que nos alejamos hacia el futuro hasta alcanzar la varianza del proceso observado como si los valores fueran independientes. A modo de ejemplo, los caudales medios semanales al lago de Rincón del Bonete son de 567 m³/s en valor esperado y descartando el 20% de los valores menores y el 20% de los valores mayores, podemos decir que el 60% está entre 54.4 m³/s y 973 m³/s.

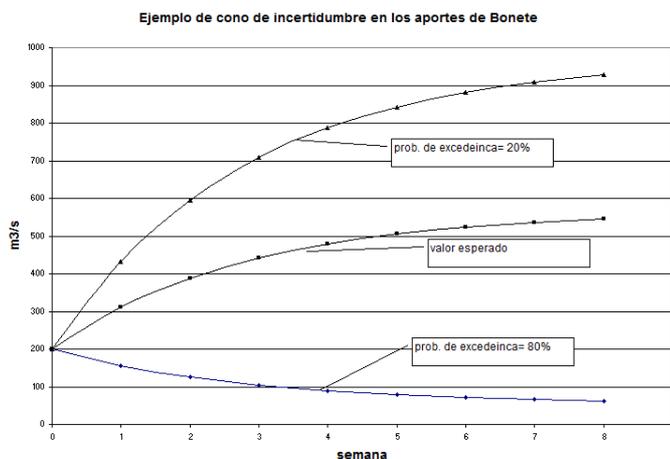


Figura 1. Ejemplo de cono de incertidumbre.

En la Fig. 1 se muestra un ejemplo, del cono de incertidumbre del caudal de aportes al lago de Rincón de Bonete, sabiendo que el valor de la semana anterior fue de 200 m³/s. Mirando la Fig. 1 es claro que no es lo mismo conocer el aporte de la semana anterior que suponer que es absolutamente desconocido. Cuanta más información se incorpora al modelado de los procesos estocásticos considerados, más agudos serán los conos de incertidumbre y más precisa será la PO que se obtenga. Cuanto menos información incorpore el modelo de lo los procesos aleatorios más obtusos serán los conos de incertidumbre y la PO que se obtenga será menos precisa.

En la sección II se describe en forma resumida la información disponible sobre el fenómeno de El Niño Oscilación Sur (ENOS), los eventos extremos conocidos como “El Niño” y “La Niña” y su influencia sobre las precipitaciones en Uruguay. En la sección III se describe la forma rústica de incluir esta información en el modelo de aportes hidráulicos. En la sección IV se muestra la metodología que se utilizó para evaluar los beneficios de incluir esta información y en la V se presentan los resultados numéricos obtenidos.

II. EL FENÓMENO ENOS, EL NIÑO, LA NIÑA Y LAS LLUVIAS EN URUGUAY.

Son bien conocidas las relaciones existentes entre las anomalías de temperatura de superficie del mar (TSM) en el Océano Pacífico ecuatorial y las anomalías de precipitaciones en la región sudeste de América del Sur que, en particular, en las cuencas del río Uruguay y Negro [3, 4]. Dichas relaciones estadísticas son particularmente significativas durante las fases extremas de ENOS (El Niño y la Niña), conociéndose también los mecanismos físicos que las causan.

Para algunas épocas del año, las anomalías de índices construidos a partir de la TSM en el Pacífico pueden ser buenos predictores de anomalías de precipitaciones (y por tanto de aportes) en nuestra región con varios meses de anticipación. Un ejemplo de tal índice es el Niño 3.4 (N3.4), que es el promedio de la TSM en una región del Pacífico ecuatorial central, y está disponible públicamente. Asimismo, existen varios modelos que pronostican exitosamente las TSM hasta con un año de anticipación. De este modo, es posible construir predictores de aportes utilizando anomalías de TSM observadas o pronosticadas.

La estacionalidad de la señal que relaciona el estado de ENOS con el clima en nuestra región ha sido analizado en numerosos estudios, bien buscando establecer las relaciones estadísticas como también para encontrar los mecanismos físicos subyacentes. Muchos de los estudios estadísticos han sido realizados con la precipitación o con series mensuales de caudal. La base de datos de aportes semanales plantea nuevas oportunidades. Además, los análisis estadísticos de sesgo se han hecho generalmente para medianas, terciles o cuartiles pues es infrecuente contar con aplicaciones o usuarios que sean capaces de distinguir y tomar decisiones en virtud del conocimiento de cambios en toda la distribución de probabilidad del predictando, en este caso los aportes. El modelo que se describe en este trabajo tiene ese mérito y plantea por este motivo nuevas necesidades de análisis de la estacionalidad de la señal entre ENOS (representado por el índice N3.4) y los aportes a los embalses.

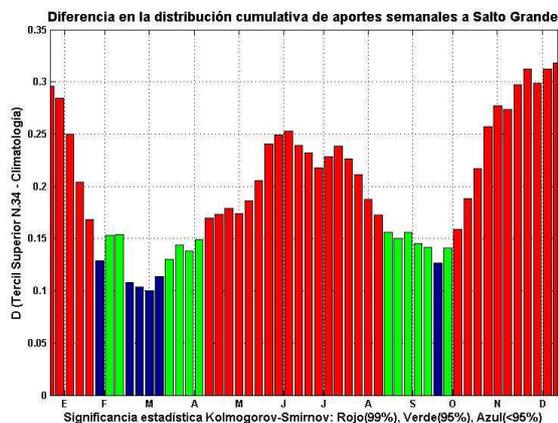


Figura 2. Estacionalidad de la predictibilidad del aporte a Salto Grande en función del índice N3.4. (Ver texto)

Se construyó el histograma de aportes para cada una de las 52 semanas del año (incluyendo en cada caso también las dos anteriores y las dos posteriores) considerando por un lado todo el período de datos y por otro solo aquellos años en que el N3.4 se encontraba en el tercil superior durante el período del predictor. Como período del predictor se tomaron 24 casos: los 9 meses individuales anteriores a la semana en turno (que se tomó como cota superior de la antecedencia en la señal) y los 8 bimestres y 7 trimestres consecutivos contenido en los mismos 9 meses. A estos dos conjuntos de aportes semanales se le aplicó el test de Kolmogorov-Smirnov que apunta a distinguir si dichas poblaciones están tomadas de una misma distribución. El test está basado en el estadístico D que es la máxima distancia entre las distribución cumulativas de ambas poblaciones. La Figura 2 muestra el máximo valor semanal de D para todas las posibilidades del período predictor –a mayor valor de D mayor diferencia entre las poblaciones- y la significancia estadística resultante. Dos tercios de las semanas del año muestran un sesgo significativo (al 99%, barras rojas) en la distribución de aportes al condicionar por el tercil superior del N3.4 en algún período del predictor que esta gráfica no indica. Los períodos de mayor predictibilidad (entendidos como los que presentan un D mayor) se concentran sobre el fin de la primavera y el principio del verano y sobre el final del otoño y el invierno, corroborando los resultados existentes sobre la estacionalidad de la señal.

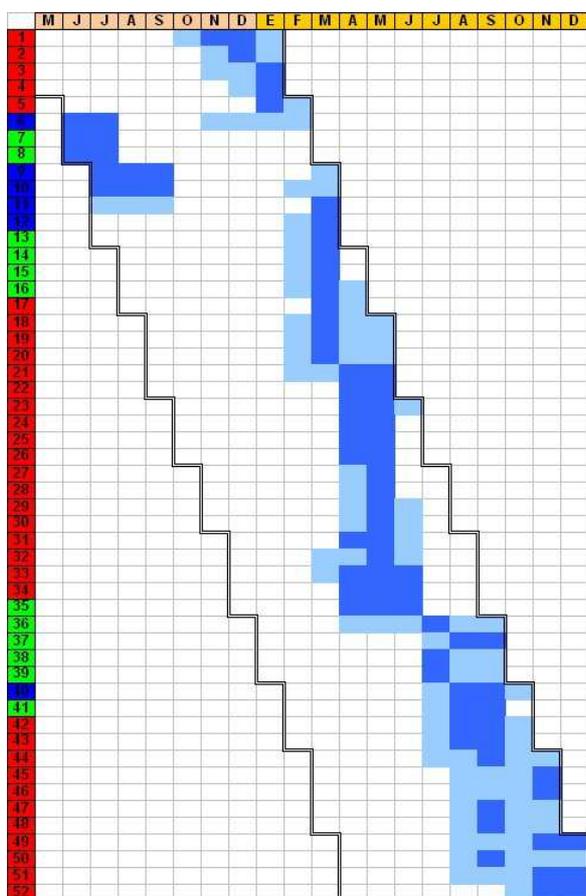


Figura 3. Estacionalidad de la antecedencia del periodo predictor óptimo (en N3.4) respecto del aporte a Salto Grande para cada semana del año.

La Figura 3 nos muestra en azul oscuro el período del predictor que generó en cada semana el sesgo máximo (según el estadístico D) y en celeste aquellos meses, bimestres o trimestres cuyo D asociado es mayor o igual al 90% del D máximo. Se verifica también que la antecedencia óptima del predictor también varía con la estación.

Se repetirá este trabajo sistemáticamente para otras condiciones del N3.4 y para los otros embalses. La experiencia previa sugiere que los períodos de máxima señal y de antecedencia óptima varían según el caso. Es necesario analizar estos y otros aspectos para desarrollar el modelo del que aquí se presenta una primera aproximación en su máximo potencial.

III. MODELO RUSTICO

Parece razonable que la incorporación de la información del clima que se describió en la sección anterior a los modelos de procesos estocásticos asociados a los aportes hidráulicos a las represas de Uruguay debe reducir la incertidumbre sobre el futuro inmediato y por lo tanto lograr POs más precisas. En este trabajo presentamos una primera aproximación al problema que consiste en incorporar la información de la serie Niño 3.4 y darle el tratamiento genérico que se utilizó en SimSEE para realizar el modelo de aportes hidráulicos a las represas [5]. Decimos que esto es “rústico” pues supone dejar que el identificador busque un modelo con una estructura genérica e infiera los parámetros en base a la serie histórica de datos sin agregarle nada del conocimiento de la física del sistema climatológico ni de las relaciones estadísticas inferidas por los investigadores en estos temas, algunas de las cuales se describieron en la sección II. Es de esperar por lo tanto que el modelo no esté utilizando al máximo la información contenida en la serie Niño 3.4 y que queda trabajo por hacer para mejorarlo. Se eligió este camino para tener una primera evaluación de los eventuales beneficios con las herramientas de que se disponía.

El modelo [5] consiste en construir un conjunto de funciones de deformación que transforman las series de datos (en este caso los aportes a Bonete, Palmar, Salto y la serie Niño 3.4) en series normales (gaussianas de valor medio cero y varianza unidad). Estas funciones de deformación son no-lineales e invertibles. Debemos pensar en estas funciones como “lentes” que nos deforman las amplitudes de las series originales y nos permiten verlas como series normales. En nuestro caso tenemos cuatro juegos de lentes (uno para cada serie) y en cada juego de lentes tenemos uno para cada semana del año. De esta forma, la estacionalidad anual de las series queda capturada en los lentes. Si hacemos el espectro de potencia de las series transformadas, no se aprecian barras que sobresalgan del resto y entonces las series son representables como las salidas de un filtro lineal que es atacado por ruido blanco gaussiano. Los coeficientes del filtro se calculan por mínimos

cuadrados garantizando que se mantienen los coeficientes de correlación entre las series entre si y con su pasado. En nuestro caso se probó con filtros de diferente orden y para este trabajo se decidió usar un filtro de orden 1 siendo el resultado de la identificación:

$$\begin{bmatrix} b \\ p \\ s \\ n34 \end{bmatrix}_{k+1} = \begin{bmatrix} 0.664 & 0.039 & 0.106 & 0.047 \\ 0.119 & 0.659 & 0.016 & 0.007 \\ 0.095 & -0.025 & 0.765 & 0.036 \\ 0.008 & -0.004 & 0.012 & 0.977 \end{bmatrix} \cdot \begin{bmatrix} b \\ p \\ s \\ n34 \end{bmatrix}_k + R_k \quad (4)$$

La ecuación (4) muestra la matriz que correlaciona los valores de las series normales de aportes a Bonete (b), Palmar (p), Salto (s) y la del índice Niño 34 ($n34$) en el paso ($k+1$) con los valores del paso (k) de las mismas series más un vector de ruido blanco R_k .

La diagonal de la matriz en (4) contiene los coeficientes de mayor valor y son los que muestran la dependencia de un valor de cada serie con su propio pasado. Cuanto más próximo sea a la unidad este valor mayor será “la memoria” del proceso estocástico asociado a la serie. Como se puede apreciar las series de aportes semanales tienen este coeficiente en el entorno de 0.7 mientras que el de la serie $n34$ es 0.977 indicando que los cambios en la temperatura de la superficie del Pacífico son más lentos que en los aportes a los embalses.

Los coeficientes de la última columna en (4) son la influencia que tiene sobre las series b , p y s el valor del índice $n34$. Como se puede apreciar estos valores son muy pequeños en comparación con los valores de la diagonal de la matriz, pero esto no necesariamente quiere decir que el efecto es despreciable. Dado que la serie $n34$ tiene una memoria superior a las demás, aunque los coeficientes que tienen en cuenta su participación en la predicción de los valores de las demás series sean bajos, actúan en escalas temporales mayores.

Con un argumento simétrico, los coeficientes de la última fila son los coeficientes de participación de b , p y s en la determinación del valor del índice $n34$. Dicha influencia es un resultado de la metodología que carece de sentido físico pero que no afecta significativamente los resultados: Como b , p y s tienen menos memoria que $n34$ estos coeficientes de participación resultan menos significativos pues las series b , p y s cambiarán de signo antes de causar movimientos significativos de $n34$ y compensarán los aportes inyectados previamente. Para dar una idea del impacto que puede tener el comportamiento del índice $n34$ en la predicción de los aportes elegimos mostrar cómo varían los valores esperados de los aportes para una realización posible de $n34$. La siguiente figura muestra el resultado de considerar una realización cualquiera del algoritmo (4) de 25 años de duración, anulando en R_k las tres primeras componentes. La serie b resultante se antitransformó con uno de los lentes del conjunto de lentes asociados a la serie. Se usó uno fijo (correspondiente a la última semana del año) para no introducir la estacionalidad anual en la figura.

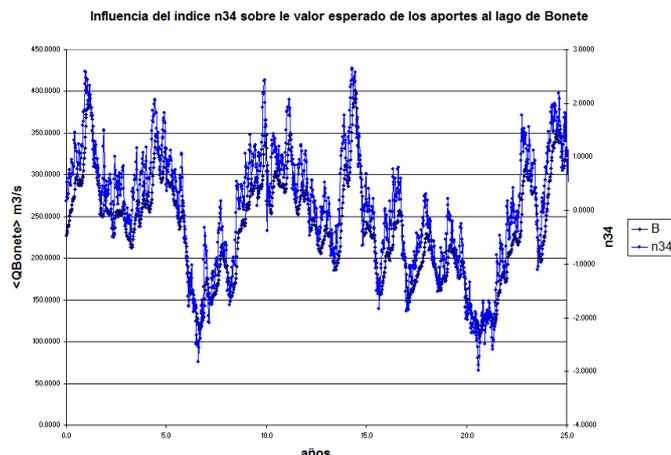


Fig. 4 Influencia de la serie $n34$ sobre los aportes esperados en Bonete.

La Fig. 4 es un ejemplo, pero sirve para mostrar cómo el efecto de la serie $n34$ puede ocasionar que el valor esperado de los aportes a Bonete para la siguiente semana, tenga apartamientos importantes respecto del valor esperado de largo plazo y que estos apartamientos son prolongados en el tiempo por la inercia de la serie $n34$.

Luego de estas consideraciones cualitativas sobre las relaciones entre las series impuestas por (4), veremos en la siguiente sección una metodología para evaluar los beneficios de incorporar la serie $n34$ en el modelo de aportes.

IV. METODOLOGIA DE EVALUACION DE BENEFICIOS

En la sección I se introdujo el concepto de Costo Futuro (CF) y de Política de Operación (PO), en esta sección se mostrará como evaluar los beneficios que se podrían obtener en valor esperado por una mejora en el modelado de los procesos estocásticos que nos permita obtener una política de operación más precisa.

Sean entonces dos modelos M1 y M2. Supongamos que M2 es mejor que M1 en el sentido de que genera conos de incertidumbre más ajustados a la realidad que el M1. Utilizando SimSEE calculamos las correspondientes políticas de operación PO1 y PO2. Ahora para evaluar el beneficio de considerar (M2, PO2) en lugar de (M1, PO1) vamos a realizar dos simulaciones del sistema, las dos usando M2 para que las realizaciones de los procesos estocásticos se comporten como pensamos que los tenemos mejor modelados. En una de las simulaciones operaremos con PO1 y en la otra con PO2.

Para comparar el costo de operar con PO2 con el de operar con PO1, consideraremos los costos acumulados, incurridos desde el inicio de la simulación hasta el paso k más el costo futuro $CF2(x1,k+1)$ y $CF2(x2,k+1)$ en que nos deja una y otra de las simulaciones al final del paso k . Esto es, sumamos al costo incurrido hasta el paso k con el Costo Futuro desde el estado en que quedó el sistema al final del paso k . Esto lo hacemos para cada una de las simulaciones, pero

consideremos en ambos casos la función $CF_2(x)$ correspondiente a la optimización con que se determinó PO2. Si llamamos CO_1 y CO_2 a las sumas de costos así obtenidas para cada una de las simulaciones, podemos escribir:

$$CO_1(k, R_h) = \sum_{j=1}^{j=k} CE(x_j, r_j, u_j^1, k) + q \cdot CF_2(x_{k+1}, k+1) \quad (5)$$

y

$$CO_2(k, R_h) = \sum_{j=1}^{j=k} CE(x_j, r_j, u_j^2, k) + q \cdot CF_2(x_{k+1}, k+1) \quad (6)$$

En donde:

- $R_h = \{r_1^h, r_2^h, \dots\}$ es una realización posible de los procesos estocásticos.
- u_j^1 y u_j^2 son las variables de control resultantes de la aplicación del PO1 y PO2 respectivamente.
- CF_2 es el valor esperado de operar el sistema con el modelo M2 y la PO2.

Comparar CO_1 y CO_2 para una realización dada R_k carece de sentido. Puede darse el caso que para esa realización particular, por azar, sea mucho mejor usar la PO1 en lugar de la PO2, pero se supone que la PO2 es más precisa que la PO1 y que en valor esperado deber llevar a menores costos de operación. Para obtener los valores esperados, consideramos muchas realizaciones de los procesos estocásticos y calculamos los valores esperados de CO_1 y CO_2 promediando los valores obtenidos al considerar el conjunto de realizaciones en (5) y (6) respectivamente. En la siguiente sección se muestran la evaluación de los beneficios que se podrían obtener en un año de aplicación del modelo mejorado.

V. RESULTADOS Y CONCLUSIONES

Para la evaluación de los beneficios de incorporar la información de la serie Niño3.4 como se mostró en la sección III utilizando la metodología desarrollada en IV se eligió realizar la simulación del año en curso (2008). Los detalles del sistema uruguayo pueden verse en [6].

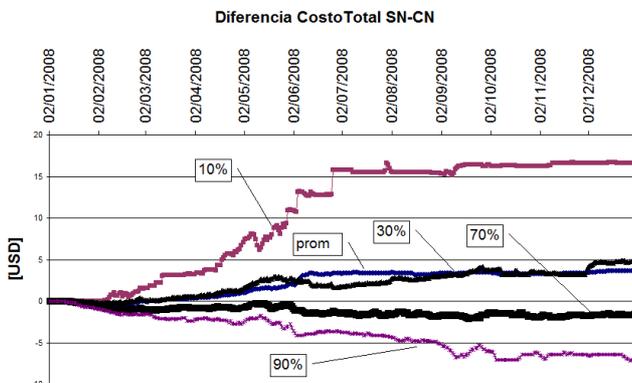


Fig. 5. Diferencia CO1-CO2 para el año 2008.

La Fig. 5 muestra la diferencia $CO_1 - CO_2$ en valor esperado y para diferentes probabilidades de excedencia. Como se puede apreciar es posible esperar una economía de unos 3.5MUSD (tres y medio millones de dólares). También se observa que dicha economía se produce desde febrero hasta septiembre lo que es consistente con la realidad del sistema en cuanto a que lo crítico es el uso del agua antes y durante el invierno y la llegada de la primavera alivia el sistema, baja los costos y por lo tanto bajan las posibles economías a realizar.

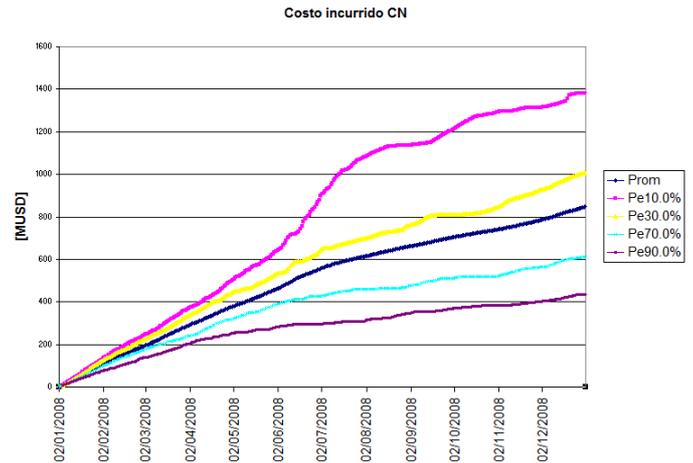


Fig. 6. Costos térmicos y de falla.

La Fig. 6 muestra el costo incurrido en la operación del sistema con diferentes probabilidades de excedencia. La economía de 3.5 MSD puede no parecer relevante cuando se compara con el costo de operación esperado para el año 2008 que anda en el entorno de los 800 MUS (contabilizando los costos de falla a valores consistentes con la operación realizada, ver Fig. 6). Pero mucho menos relevante es la inversión necesaria para mantener una línea de investigación aplicada para llevar adelante una mejora del modelo que capitalice estos beneficios económicos para el país.

Es de esperar que la economía que se logre sea algo superior al usar un modelo que aproveche el conocimiento sobre la física del sistema en lugar de la aproximación muy rústica que se utilizó para realizar esta evaluación. En particular es necesario reflejar en el modelo la estacionalidad y antecedencia de la relación entre ENOS y los aportes y la no linealidad de la misma.

Además de la reducción de costos en valor esperado, es de esperar beneficios adicionales en cuanto a la reducción del "riesgo". La implantación de medidas de ahorro, o restricciones obligatorias (como se llegó a aplicar en el año 2008) no es inmediata y por lo tanto, poder prever su necesidad con uno o dos meses de antelación es sin duda un valor importante, adicional a la reducción de costos que se pueda estimar usando la metodología propuesta.

VI. REFERENCES

- [1] Bellman, R. Dynamic Programming, Princeton University Press, 1957.
- [2] Sitio del simulador SimSEE. (<http://ie.fing.edu.uy/simsee/>)
- [3] Pisciotano, G., A. Díaz, G. Cazes, y C. R. Mechoso, 1994: El Niño–Southern Oscillation impact on rainfall in Uruguay. *J. Climate*, 7, 1286–1302.
- [4] Montecinos, A., Díaz. A., y P. Aceituno, 2000: Seasonal diagnostic and predictability of rainfall in subtropical South America based on tropical Pacific SST. *J. Climate*, 13, 746-758.
- [5] Ruben. Chaer y Raúl Zeballos, Modelo Simplificado de Central con Embalse con fines didácticos. *IEEE LATIN AMERICA TRANSACTIONS*, VOL. 4, NO. 3, MAY 2006.
- [6] UTE, Programación estacional noviembre 2007 – abril 2008, publicada en el sitio <http://www.dncu.gub.uy>

VII. BIOGRAFÍAS



Ruben Chaer was born in Tacuarembó, in 1962. He received the degrees in Electrical Engineering in 1991 from the Universidad de la República, Uruguay. He is currently an Adjoint Professor of the Instituto de Electrical Engineering and consultor of the ADME (Administrator of the Electrical Market). He works in planning and operation of power systems.



Rafael Terra graduated as a Hydraulic and Environmental Engineer from Universidad de la República and obtained his M.Sc. and Ph.D. degrees in Atmospheric Sciences from the University of California at Los Angeles (UCLA). His expertise is in numerical modeling of the atmosphere and climate risk assessment.



Alvaro Díaz graduated as a Mechanical Engineering and obtained his M. Sc. degree in Universidad de la República. His main areas of interest are climate anomalies in southeastern South America, with special emphasis on applications to water resources, energy and crop production.



Álvaro Brandino graduated in Electrical Engineering from the Universidad de la República, Uruguay, in 1980. He works in ADME (The Electrical Market Administrator), and has also worked in the fields of operation and short term planning