

Mejora en las simulaciones de un modelo hidrogeológico de base física mediante corrección complementaria de sus errores

Improvement of the physically-based groundwater model simulations through complementary correction of its errors

Reyes Alcalde, J. M.

Magíster en Ciencias de la Ingeniería, mención Recursos y Medio Ambiente Hídrico, Universidad de Chile. Ingeniero Civil y Licenciado en Ciencias de la Ingeniería, Universidad Católica del Norte. Ingeniero de Proyectos, Aguas Andinas, Chile.
E-mail: jreyesalcalde@gmail.com

Recibido: 02/07/2017

Aceptado: 13/04/2017

Publicado: 28/04/2017

Citar como: Reyes Alcalde, J. M. 2017. Improvement of the physically-based groundwater model simulations through complementary correction of its errors. *Ingeniería del agua*, 21(2), 119-134. <https://doi.org/10.4995/la.2017.7066>

RESUMEN

Los Modelos hidrogeológicos de Base Física (MBF), como MODFLOW, se utilizan como herramienta de evaluación de recursos hídricos subterráneos considerando que las diferencias producidas entre lo simulado y lo observado (residuos o errores) corresponden a ruido blanco. Sin embargo, en la práctica las simulaciones numéricas presentan normalmente errores no sólo aleatorios sino también sistemáticos. En este trabajo se ha desarrollado un procedimiento numérico para tratar con los errores sistemáticos de los MBF, estudiando su estructura para modelar su comportamiento y corregir los resultados de forma externa y complementaria mediante un esquema denominado Modelo de Corrección Complementaria (MCC). La aplicación del MCC al MBF muestra disminución en las desviaciones locales, mejor distribución de los errores y reducciones en las correlaciones temporales y espaciales de los residuos, con una reducción de un 73% en el RMSN global respecto del MBF original. Esta metodología se observa como una interesante posibilidad de actualizar un MBF evitando el trabajo y los costos de intervenir su estructura interna.

Palabras clave | modelación; Hidrogeología; corrección complementaria; Geoestadística; redes neuronales artificiales.

ABSTRACT

Physically-Based groundwater Models (PBM), such MODFLOW, are used as groundwater resources evaluation tools supposing that the produced differences (residuals or errors) are white noise. However, in the facts these numerical simulations usually show not only random errors but also systematic errors. For this work it has been developed a numerical procedure to deal with PBM systematic errors, studying its structure in order to model its behavior and correct the results by external and complementary means, trough a framework called Complementary Correction Model (CCM). The application of CCM to PBM shows a decrease in local biases, better distribution of errors and reductions in its temporal and spatial correlations, with 73% of reduction in global RMSN over an original PBM. This methodology seems an interesting chance to update a PBM avoiding the work and costs of interfere its internal structure.

Key words | modeling; Hydrogeology; complementary correction; Geostatistic; artificial neural networks.

INTRODUCCIÓN

La modelación hidrogeológica en la actualidad es esencialmente determinística al utilizar códigos informáticos que resuelven, mediante aproximaciones numéricas, las ecuaciones tradicionales de flujo subterráneo basadas en la ecuación de conservación de la masa y en la fórmula de Darcy (Harbaugh y McDonald, 1988). Estos códigos de base física, como MODFLOW, se han utilizado desde hace décadas como herramienta de evaluación de recursos hídricos subterráneos. La elaboración de un Modelo de Base Física (MBF) requiere variados estudios preliminares de carácter geológico, hidrológico e hidrogeológico, mediante los cuales se genera un modelo conceptual sobre el cual se construye el modelo numérico (SEA, 2012).

Sin embargo, es frecuente encontrar disparidad entre lo simulado y la realidad, no tanto por dificultades numéricas como por la falta de concordancia entre el sistema real y el modelo, dada usualmente por la escasa información en general disponible y por la inherente heterogeneidad de los medios reales (Dagan, 2002). El modelador se enfrenta a la necesidad de estimar los parámetros hidráulicos del MBF dados niveles observados (problema inverso), intentando ajustar los niveles calculados a los medidos, en un proceso denominado calibración, proceso en el cual, aun siendo exitoso, subsisten errores no sólo aleatorios sino también sistemáticos (Demissie *et al.*, 2008, Xu, 2013), situación que limita la representatividad de los MBF y obliga a recurrir a otras herramientas si se quiere mejorar la calidad de la modelación subterránea.

En este trabajo se estudian procedimientos numéricos para tratar con los errores sistemáticos de un MBF, estudiando su estructura temporal y espacial para modelar su comportamiento y corregir los resultados de forma externa y complementaria. El enfoque determinístico tradicional con que se estudia la hidrogeología es complementado con el enfoque estocástico (Renard, 2007; Barra, 2010) de las herramientas utilizadas en el presente trabajo, aprovechando las potencialidades de ambos esquemas, donde las ventajas de uno compensan las limitaciones del otro.

ZONA DE ESTUDIO

El sector escogido en este estudio se ubica en la zona central de Chile (Figura 1), específicamente en el acuífero superior del valle de Santiago, sector denominado Mapocho Alto (DGA SDT n°133, 2002).

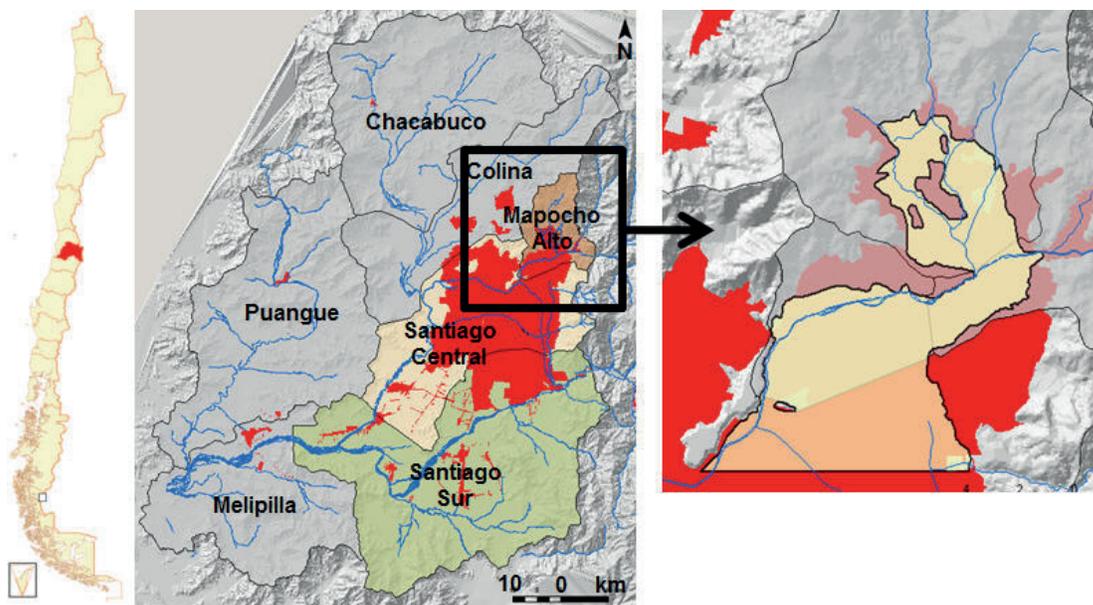


Figura 1 | Ubicación y límites del acuífero Mapocho Alto.

Superficialmente el acuífero está influenciado por la presencia del río Mapocho, su cauce más importante, principal fuente de recarga y responsable del comportamiento estacional observado. Además, el acuífero recibe aportes superficiales y subsuperficiales de cuencas laterales no controladas (DICTUC, 1999).

Diversos estudios han examinado el acuífero Mapocho Alto permitiendo disponer de un modelo conceptual de funcionamiento hidrogeológico de la zona bastante detallado. En general hay consenso en que el movimiento del flujo subterráneo sigue la dirección de los cauces (Figura 2). Respecto del balance hídrico, existen diversos mecanismos de recarga y descarga para el acuífero analizado, sin embargo los estudios coinciden en que la principal fuente de recarga es la infiltración desde el río Mapocho (DGA SIT n°62, 2000; Muñoz *et al.*, 2002; DICTUC, 2003), mientras que la principal descarga ocurre subterráneamente por el límite sur del dominio (Tabla 1).

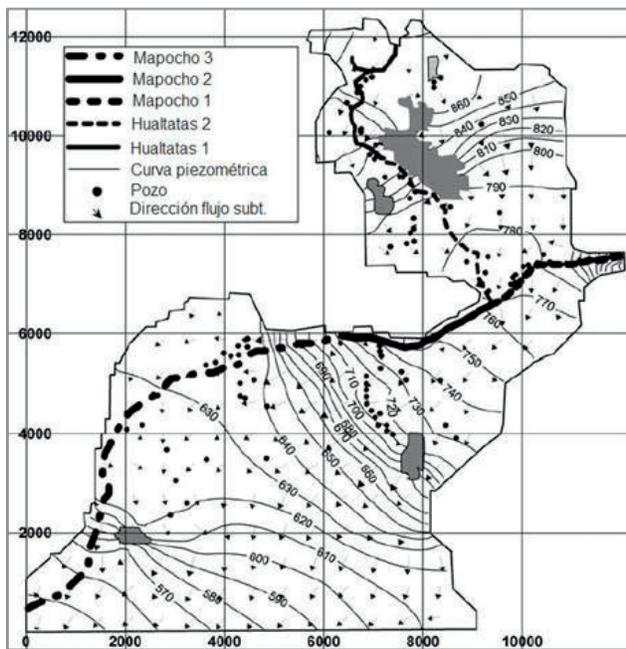


Tabla 1 | Balance hídrico para todo el acuífero (DICTUC, 1999).

Fuente	(L/s)
Río Mapocho	1890
Estero Hualtatas	144
Cuencas laterales	188
Infiltración difusa (Pp, riego, redes AP)	229
Total recargas	2450
Bombeos	745
Flujo subterráneo	1750
Total descargas	2495

Figura 2 | Contorno de la superficie libre (Modificado de Muñoz *et al.*, 2002).

Al revisar los niveles piezométricos (o estáticos NE), no se observa una tendencia general de ascenso o descenso del nivel de la napa, sino más bien diversos ciclos en los últimos años (Figura 3). Destacan las caídas de niveles en los años 1997, 1999 y 2011 en adelante, correlacionables con las condiciones hidrológicas imperantes esos años, como fueron los años secos 1996, 1998 y el actual periodo seco iniciado el año 2010 y que se prolonga hasta la fecha de este trabajo.

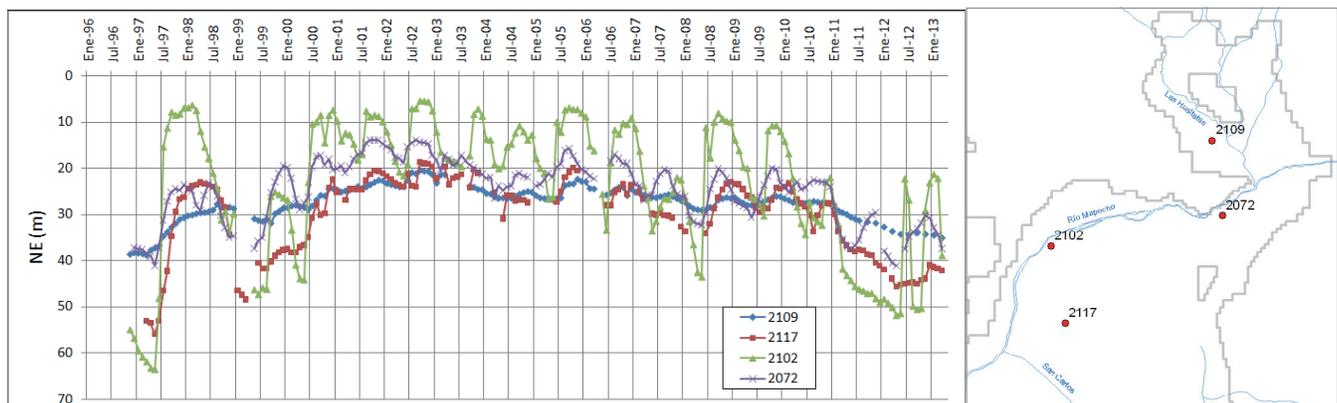


Figura 3 | Series de NE de pozos ubicados según se muestra a la derecha.

con $z^{t-1} \sim N(0, 1)$, $v^t \sim N(0, 1)$ y $a^t \sim N(0, S_a^2)$

donde $*z^t$: valor según modelo AR ó FT utilizado para relleno, z^{t-1} : valor observado del periodo anterior, ϕ_1 : coeficiente del modelo AR igual a ρ_1 de la ACF (desfase 1), $\phi_1 < 1$, v^t : valor observado del mismo periodo de pozo vecino (variable explicativa), ω_0 : coeficiente del modelo FT igual a ρ_0 de la CCF (desfase 0), $\omega_0 < 1$, a^t : ruido aleatorio asociado a la incertidumbre del proceso.

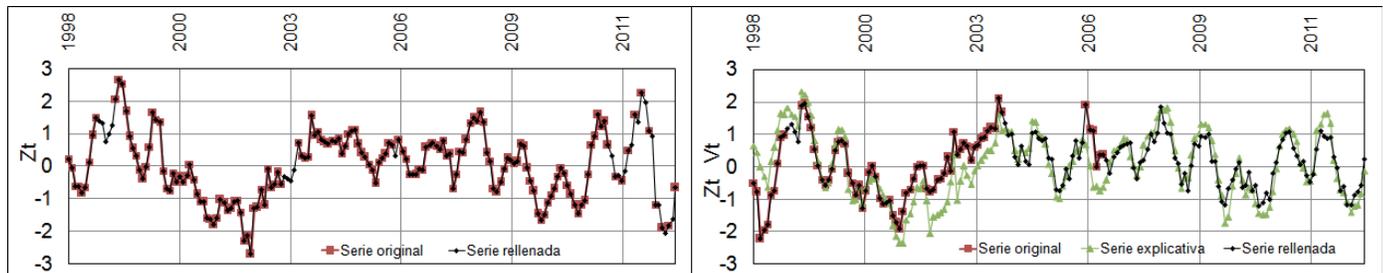


Figura 5 | Ejemplos de series* rellenadas; izquierda AR(1), derecha FT(0,0,0). *Desviaciones del estado de equilibrio de la variable original.

MODELO HIDROGEOLÓGICO DE BASE FÍSICA (MBF)

El MBF escogido en el presente trabajo es uno de los modelos numéricos más completos desarrollados en la región central de Chile, utilizado ampliamente, validado por la Autoridad y demás actores de la cuenca y con un sólido sustento físico dado por el extenso estudio que lo generó (DGA SIT n°62, 2000). En la conceptualización y construcción de este MBF, se consideró toda la información conocida sobre estratigrafía de pozos, pruebas de bombeo, prospecciones geofísicas, relaciones río-acuíferos, etc., por lo que la herramienta desarrollada llegó a contener prácticamente todo el conocimiento hidrogeológico que se tenía en ese entonces del sistema. Su dominio comprende el denominado valle del Gran Santiago, que corresponde al interfluvio de los ríos Mapocho y Maipo incluyendo los esteros Lampa y Colina por el norte y el río Angostura por el sur, cubriendo una superficie aproximada de 2300 km² (Figura 6).

Este modelo fue desarrollado en plataforma Visual MODFLOW, con discretización temporal mensual y representando su dominio mediante 1 capa o estrato en vertical y 265 filas por 236 columnas en horizontal, totalizando 62540 celdas de discretización no regular con dimensiones variables en planta entre 100 m y 620 m.

Desde su creación, el MBF no ha sufrido grandes cambios, siendo utilizado hasta hoy para estimar disponibilidades en sectores acuíferos, situación que le otorga carácter oficial a esta herramienta (DGA SDT n°235, 2006; DGA SIT n°119, 2007).

El dominio temporal original del MBF (1950-1998) fue extendido para poder comparar sus resultados con la estadística observada disponible (1996-2013). Recordando que la idea básica de una corrección complementaria es corregir un MBF sin intervenirlo, la extensión temporal fue realizada solamente para disponer de series observadas y simuladas en un periodo temporal común, por lo que la extensión mantuvo los procedimientos originales cuando fue posible de tal forma de contar con un MBF equivalente al original pero que realice simulaciones hasta 2013. En términos espaciales el MBF no fue modificado, tampoco fueron modificados los parámetros elásticos ni las condiciones de borde.

Las actualizaciones y extensiones anteriores permitieron ejecutar el MBF hasta el año 2013, observando comportamientos de niveles según lo esperado en el periodo extendido (Figura 7). Comprobada la confiabilidad de la extensión anterior, se redujo finalmente el dominio temporal sólo al periodo de interés (1998-2013). Esto además permitió mejorar la representatividad del modelo, por cuanto se pudieron incorporar una condición inicial y series de bombeos observados.

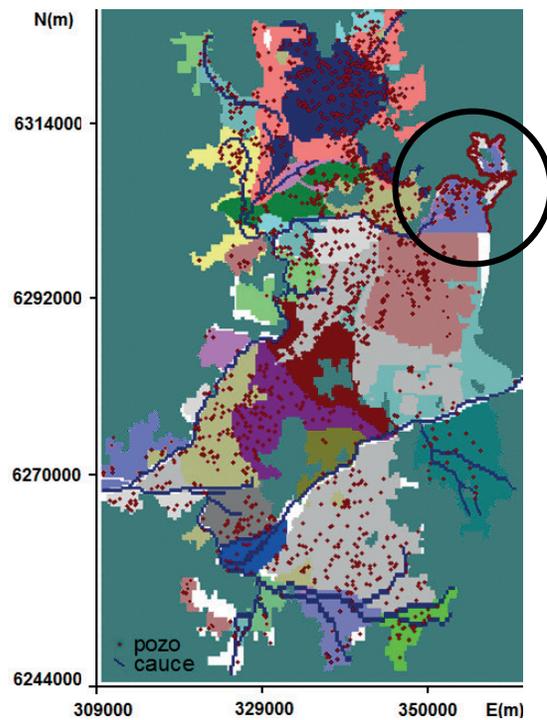


Figura 6 | Modelo de Base Física (MBF), utilizado en el presente trabajo. Se destaca la zona de estudio.

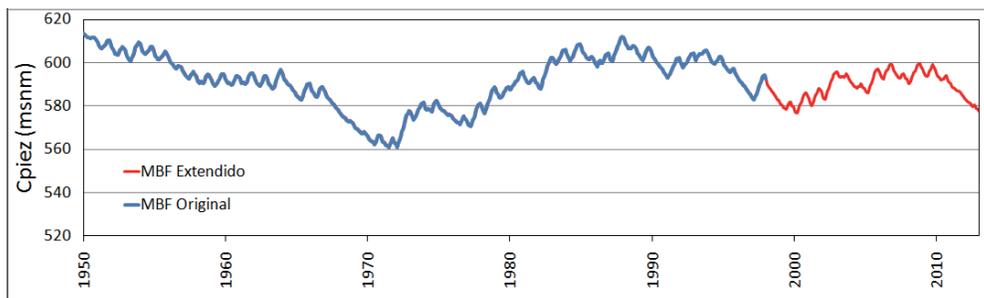


Figura 7 | Ejemplo de serie de cotas piezométricas simuladas por el MBF original (azul) y extendido (rojo).

RESIDUOS

Las series de residuos corresponden a la diferencia entre las series de niveles observadas (depuradas y completadas) y sus correspondientes series de niveles simuladas por el MBF (Ecuación 3), por lo que también pueden ser llamadas series de errores (Figura 8). Estas series fueron analizadas estadísticamente para detectar estructuras temporales y espaciales.

$$e_i^t = O_i^t - S_i^t \quad \forall t \quad (3)$$

con: e_i^t serie de residuos, O_i^t serie observada y S_i^t serie simulada para el pozo i .

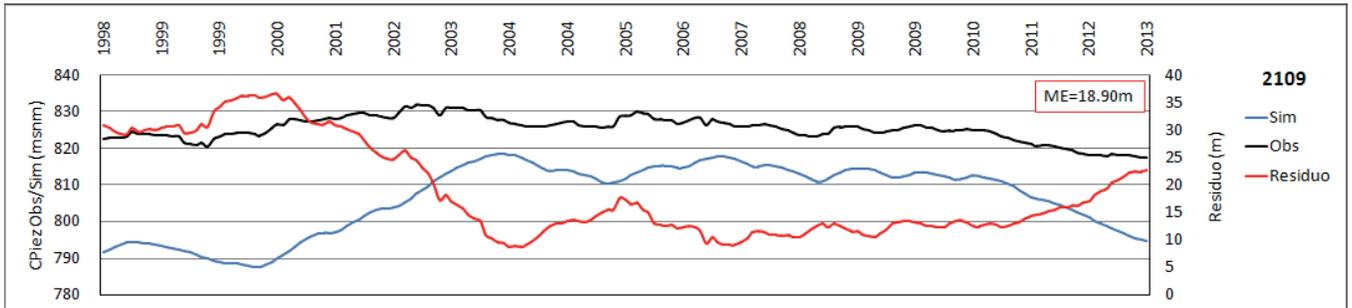


Figura 8 | Series de cotas piezométricas observada (negro), simulada (azul) y de residuos (roja). Se incluye el error medio (ME).

Uno de los primeros resultados es la magnitud del error medio (ME), valores que al ser graficados espacialmente permiten construir curvas de isodiferencias (Figura 9). Este análisis mostró desviaciones locales apreciables, las principales motivadas por condiciones físicas existentes no incluidas dentro del MBF cuando éste fue elaborado.

Como segundo paso se verificó la normalidad de la serie de residuos, pues se espera que los errores de un MBF calibrado estén normalmente distribuidos (SEA, 2012; Xu, 2012; MODFLOW User’s manual, 2007). En 53 de 54 pozos el estadístico Anderson-Darling (AD) resultó mayor al valor crítico y el valor-p menor a 0.05, lo cual implica rechazar la hipótesis nula H_0 , es decir, las series de residuos no siguen una distribución normal.

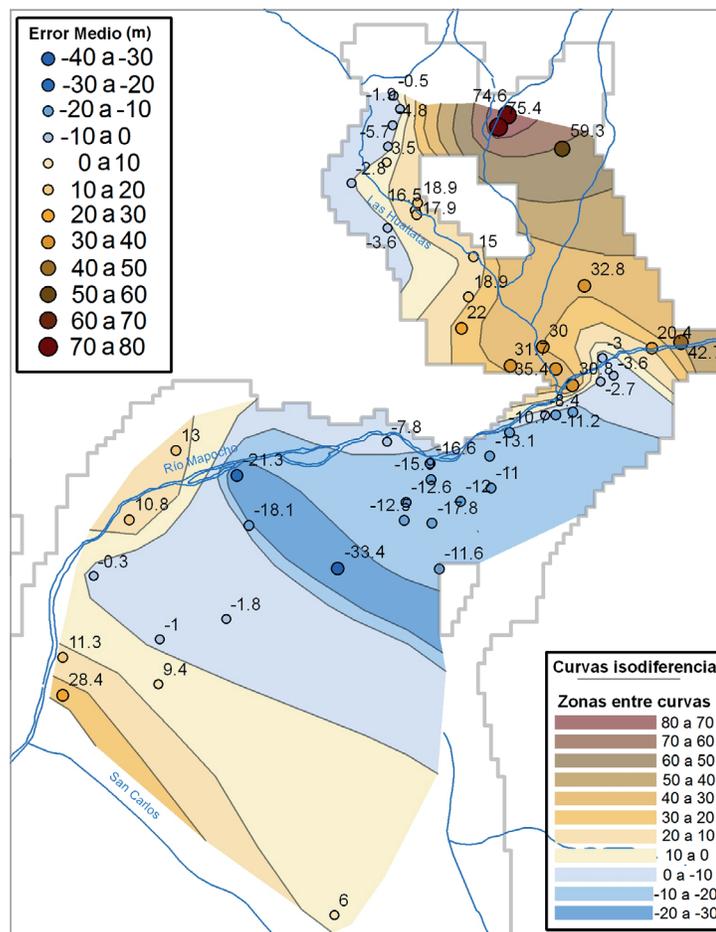


Figura 9 | Curvas de isodiferencia de ME con desviaciones locales apreciables.

Estructuras temporales se verificaron mediante funciones de autocorrelación simples (ACF), las cuales no decayeron rápidamente a cero como se esperaría para series no correlacionadas temporalmente (Figura 10). Además, para todos los pozos, el estadístico Durbin-Watson (DW) a nivel mensual resultó menor al valor límite lo que indica presencia de correlación temporal positiva.

Estructuras espaciales fueron detectadas mediante análisis geoestadístico. Los semivariogramas teóricos (SVT) ajustados a los semivariogramas experimentales (SVE), presentaron rangos mayores a la distancia promedio entre los pozos de observación (817 m), situación que sugiere la presencia de correlaciones espaciales (Figura 11). Los análisis anteriores demuestran que las series de residuos o errores presentan desviaciones apreciables y estructuras tanto especial como temporal, que posibilitan su modelación mediante MCC.

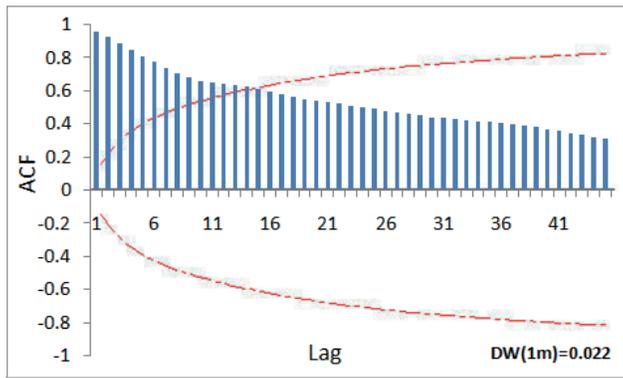


Figura 10 | ACF de residuos con bandas de significancia 5% y estadístico DW menor a 0.5.

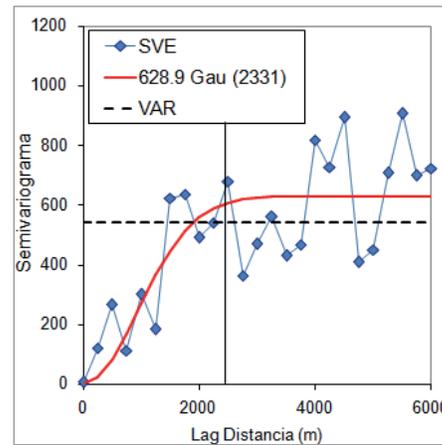


Figura 11 | SVE (puntos azules) y SVT Gaussiano ajustado (línea roja) de la forma "Varianza x Gau(Rango)" para ME. Se observa un Rango (2331 m) mayor a la distancia promedio entre pozos (817 m).

MODELOS DE CORRECCIÓN COMPLEMENTARIA (MCC)

Los MCC buscan mejorar los resultados de la modelación subterránea corrigiendo las diferencias (residuos) entre los valores simulados y observados (Xu, 2013). Se busca reproducir matemáticamente los residuos mediante modelación externa para agregar esta nueva serie generada a la cota piezométrica simulada por el MBF, consiguiendo obtener un valor final más cercano a la cota piezométrica observada (Figura 12).

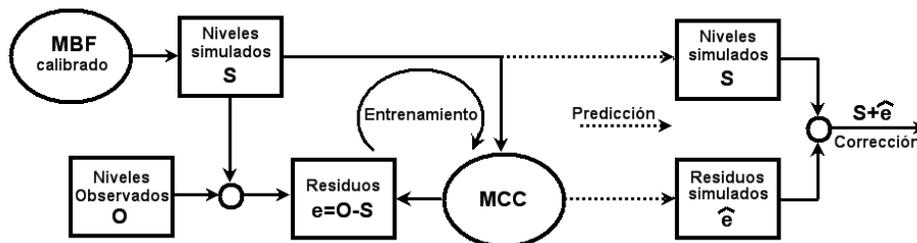


Figura 12 | Representación esquemática del proceso de modelación complementaria.

Considerando a la serie de residuos en un pozo como la suma de un error medio (ME) asociado a la ubicación y una serie de tiempo de media cero, su modelación se abordó separadamente mediante un MCC espacial y un MCC temporal, partes que se integran finalmente para formar el MCC final.

El MCC espacial busca la construcción de un modelo posicional, es decir, un modelo que entregue información detallada en todo el espacio del dominio para un tiempo o periodo dado. Fue construido utilizando elementos de Geoestadística, la cual considera a los datos disponibles como una realización de una función aleatoria (Emery, 2007) y fue destinado a reproducir el ME de cada pozo.

Con las coordenadas de los pozos seleccionados se construyó la respectiva matriz de distancias y utilizando los ME de los pozos, se obtuvo el SVE. Una vez ajustado un SVT Gaussiano (Ecuación 4) al SVE (Figura 13) y aplicando el método de Kriging, se busca estimar el valor de la variable aleatoria residuo $ME(X)$ en cualquier punto del dominio. Dicha metodología supera a otras técnicas de estimación espacial de valores desconocidos por cuanto, además de asignar pesos de acuerdo a la distancia entre los datos, considera la estructura espacial subyacente (Barra 2010).

$$\text{SVT Gaussiano ajustado: } \gamma(h) = 611.5 \cdot \left(1 - e^{-\frac{3h^2}{1545^2}}\right) \quad (4)$$

con h separación entre pozos (lag)

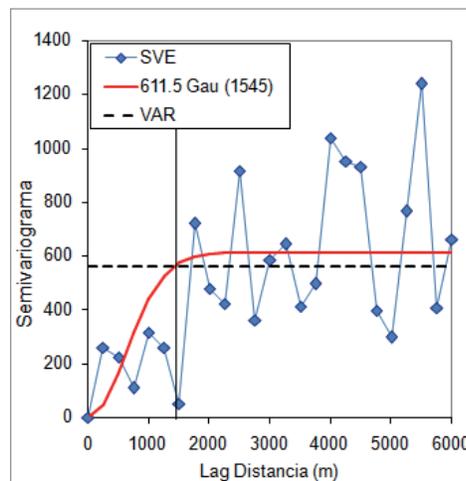


Figura 13 | SVE (puntos azules, $\Delta h = 250\text{m}$) y SVT Gaussiano ajustado (línea roja) para el ME de los residuos.

De esta forma, al ingresar la ubicación del punto deseado (x,y,z) , el modelo entregará el valor que debe sumarse a la serie simulada para reducir su ME. Como ejemplo, las figuras siguientes muestran a un pozo, donde su ME (serie residuo = serie observada – serie simulada) mejoró de un valor inicial de 21.1 m a un valor de 0.7 m (Figura 14).

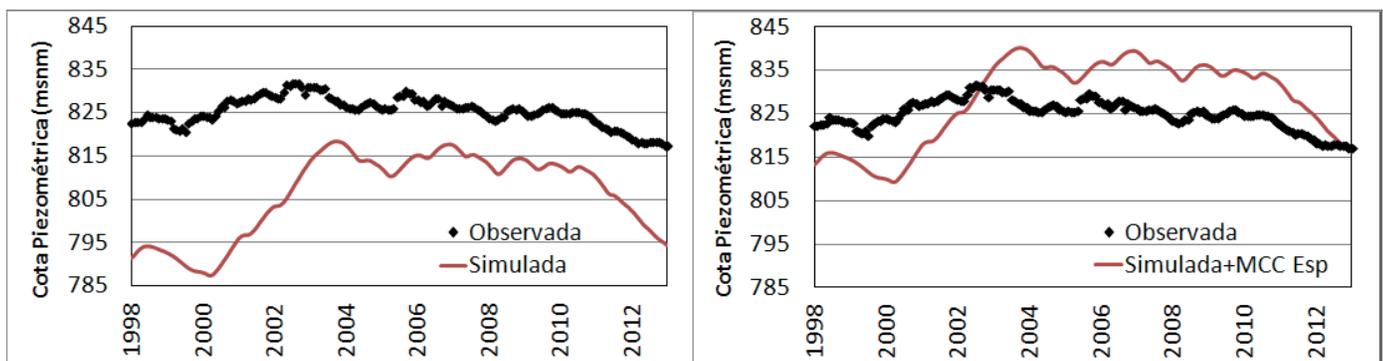


Figura 14 | Cotas piezométricas observadas (puntos negros) y simuladas (línea café). A la izquierda se observa la situación original (ME = 21.1 m), mientras que a la derecha se observa la aplicación del MCC espacial (ME = 0.7 m).

El MCC temporal utilizó herramientas de redes neuronales artificiales (RNA) y busca reproducir una serie de tiempo de residuo con media 0. Se escogió esta técnica, dada su capacidad para adaptarse a cambios recurrentes y detectar patrones en complejos sistemas naturales. Se optó por un típico esquema tipo FeedForward (Figura 15), con una capa oculta y entrenamiento tipo Backpropagation, reconocido por presentar un buen desempeño y precisión de pronósticos (Daliakopoulos *et al.*, 2004; Coppola, 2005). Las funciones de transferencia utilizadas fueron Tangente-Sigmoidal (tansig) para la capa oculta y Lineal (purelin) para la capa de salida, los entrenamientos utilizaron algoritmo tipo Levenberg-Marquardt (trainlm) con descenso de gradiente con momentum (learnqdm) como función de aprendizaje y como función de desempeño se utilizó MSE (mse). La mayor parte de estas funciones y algoritmos se incluyen por defecto en Matlab (User's Guide Matlab, 2015) al crear una red neuronal tipo FeedForward (newff).

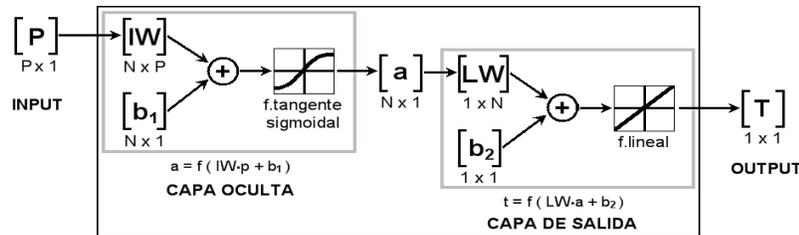


Figura 15 | Estructura de RNA de la forma P-N-1, es decir, P elementos en el input, N elementos en la capa oculta y 1 elemento de salida.

Como inputs para alimentar la estructura neuronal anterior se escogieron la misma serie simulada por el MBF (con distintos desfases) y una serie sinusoidal sintética (para reproducir la variación estacional). La serie objetivo fue la serie de residuos de media cero. Se realizaron diversas iteraciones para determinar el número final óptimo de inputs considerados y la cantidad óptima de neuronas ocultas (Figuras 16). De esta forma el esquema final adoptado para el MCC temporal es 6-10-1, es decir, 6 inputs y 10 neuronas ocultas (Tabla 2), el cual se calibró y permitió obtener series de residuo simuladas (Figura 17).

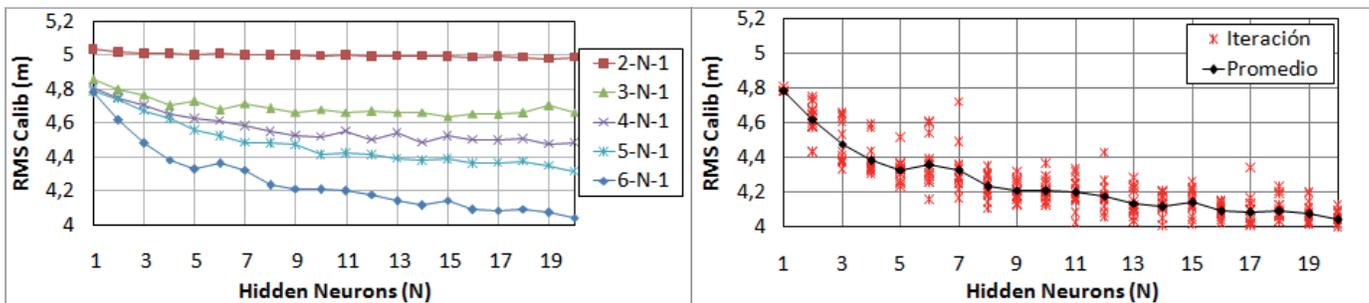


Figura 16 | (izquierda) RMS promedio en función de la cantidad N de neuronas ocultas y del número de inputs; (derecha) RMS promedio y 15 iteraciones para un esquema 6-N-1 en función de la cantidad N de neuronas ocultas.

Tabla 2 | Matrices de pesos IW{1,1} Input Weight Matrix y LW{2,1} Layer Weight Matrix y vectores bias para cada capa b{1} y b{2}, obtenidos con la función net. de Matlab.

IW						b1	
3.13558473	0.38865137	-0.91394393	-4.38404003	-0.46317863	-0.88942801	-4.28151193	
-0.21680336	-4.74741594	5.80385061	0.36744262	-1.09294328	1.55778197	3.11559611	
3.492159	1.02581782	-0.70835182	-0.52437035	-2.95862282	-0.2046452	0.0618822	
-6.84809255	7.99587914	1.66054728	-2.56016847	-0.57008052	0.48292531	-0.61210814	
6.43338858	2.32190978	-3.0178344	-1.81396989	-0.04349851	-1.6302235	-2.52493352	
2.25827436	-1.86427242	-0.65168906	1.31102058	-0.5803019	1.94662073	-0.13873155	
-3.564368	-0.88419094	0.7949968	0.38560745	2.74458599	0.24133983	-0.16300692	
-3.72168279	0.08954037	0.85354125	5.46315894	-2.94138174	2.88172722	-5.43758047	
-6.2076288	4.54024538	-1.10830564	0.40655241	-3.6975062	1.20725728	-2.55817794	
-5.76388273	2.56117332	-3.21843192	-2.76748499	-0.67093438	-0.30442442	-5.26618978	
LW						b2	
1.60854859	2.12155041	-2.4154366	0.13144408	0.18417356	0.05308623	-2.47794486	0.54323971
						1.05359352	
						-0.05746808	
						-0.06762587	

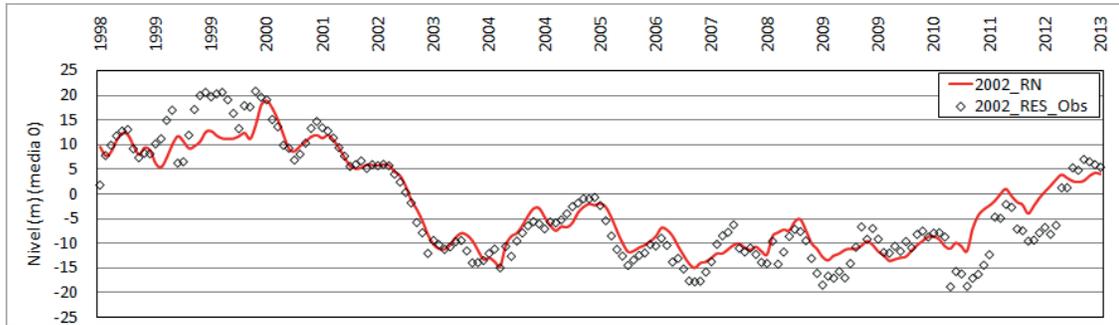


Figura 17 | Ejemplo de series de residuo de media cero observado y modelado por RNA (esquema 6-10-1).

Con el objeto de evaluar la herramienta en el contexto de un pronóstico, se decidió utilizar en la calibración de ambos MCC sólo parte de la información disponible, tanto espacial como temporal, reservando una cierta cantidad de pozos y un lapso de tiempo para una evaluación de los modelos ante datos desconocidos a los mismos. Lo anterior genera 4 grupos de estudio:

1. Pozos de calibración en periodo de calibración (grupo de calibración C)
2. Pozos de calibración en periodo de evaluación (grupo de predicción temporal PT)
3. Pozos de evaluación en periodo de calibración (grupo de predicción espacial PE)
4. Pozos de evaluación en periodo de evaluación (grupo de predicción espacio-temporal PET)

Normalmente la aplicación de un MCC a un MBF implicará un gran grupo de calibración (grupo C), con toda la información disponible. El grupo de predicción espacial (grupo PT), corresponderá a la simulación futura de los pozos de calibración. Los grupos de predicción espacial (grupo PE) y predicción espacio-temporal (grupo PET) corresponderán a un pequeño grupo de puntos exploratorios de los cuales se quiera saber su evolución actual y/o futura.

En este caso la evaluación se refiere a una etapa posterior donde se evalúa el desempeño de la herramienta calibrada ante datos nuevos y cuyos resultados no son utilizados para recalibrar, a diferencia del proceso usual de validación, el cual se considera en este caso incluido en el proceso de calibración.

RESULTADOS

El procedimiento final es la suma de ambos MCC. Al sumar a la serie simulada por el MBF para un determinado pozo, el ME modelado por el MCC espacial y la serie de residuo de media cero modelado por el MCC temporal, se observa cualitativamente un mejor ajuste del modelo corregido (MBF+MCC) respecto del modelo original (MBF) (Figura 18).

Utilizando el parámetro RMS, se observan mejoras en todos los grupos de estudio (Tabla 3).

Las nuevas series simuladas corregidas, al ser comparadas con las series observadas, generan nuevas series de residuos (mismo procedimiento descrito anteriormente), las cuales presentan características que las acercan a una serie sin estructura.

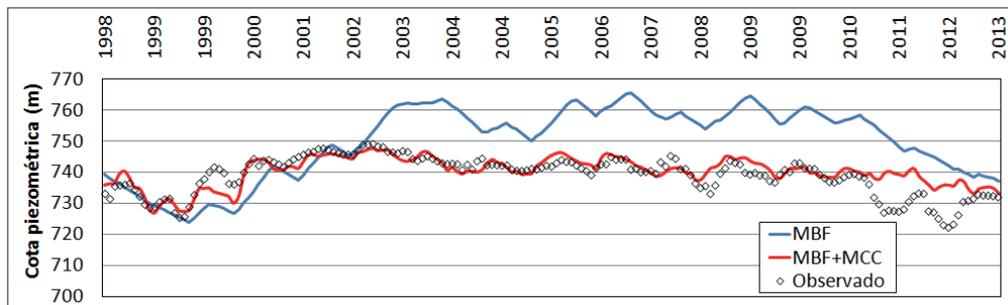
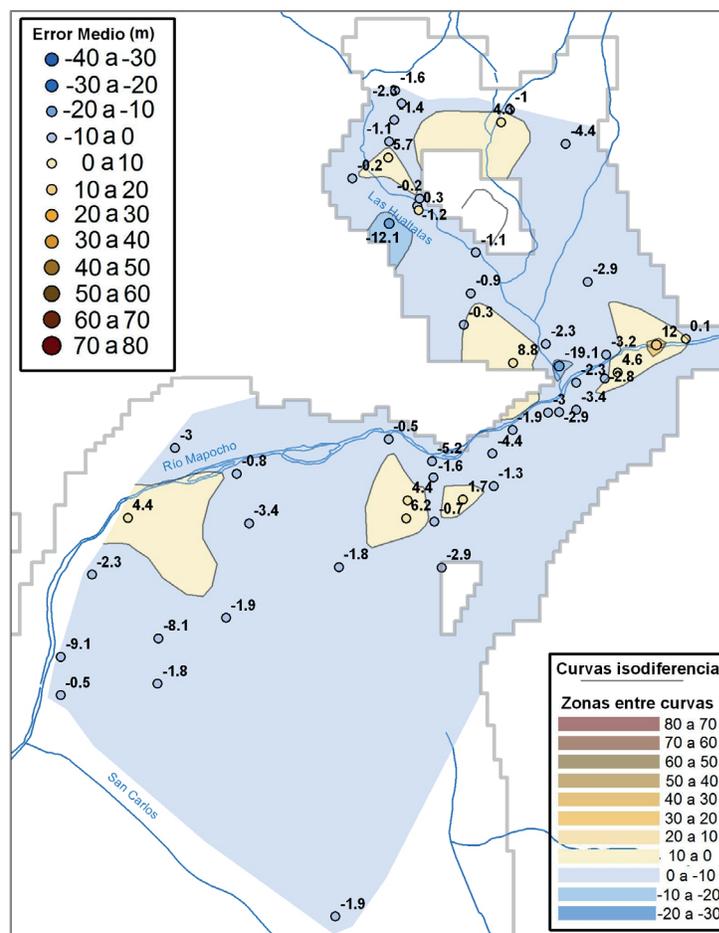


Figura 18 | Comparación de resultados de MBF original (azul) y corregido (rojo), respecto de los valores observados (negro).

Tabla 3 | Mejora del MBF corregido respecto del MBF original como reducción del RMS por grupo y RMSN global.

Modelo	RMS (m)				RMSN
	Grupo C	Grupo PT	Grupo PE	Grupo PET	Global
MBF	22.0	20.6	20.0	18.8	7.0
MBF+MCC	3.8	7.5	7.9	8.4	1.9
Mejora	83%	64%	61%	55%	

Los ME de los nuevos residuos disminuyeron y no se observan grandes desviaciones ni una estructura espacial definida como muestran las nuevas curvas de isodiferencia (Figura 19). La función de distribución acumulada (CDF) para el error medio absoluto (AME), muestra la curva asociada al modelo corregido desplazada claramente hacia la izquierda respecto de la curva original (Figura 20).

**Figura 19** | Error medio (ME) en pozos de observación y curvas de isodiferencia de residuo (m) luego de la aplicación de MCC. Se conservaron las simbologías y escalas de la Figura 9, para evidenciar la reducción.

Los test de normalidad siguen sin permitir aceptar la hipótesis nula, sin embargo, el estadístico Anderson-Darling (AD), redujo su valor promedio (Figura 21), aunque aún lejos del valor límite para considerar que los datos siguen una distribución normal (0.751 con un 95% significancia). No obstante, al comparar los histogramas de frecuencias (Figura 22), se observan residuos mejor distribuidos en el MBF corregido.

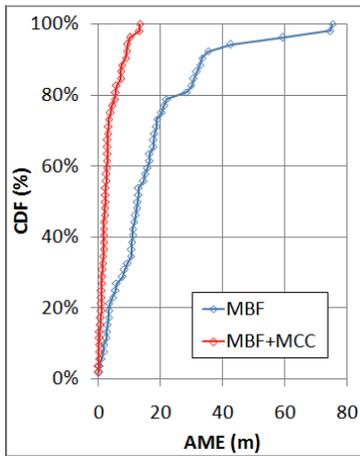


Figura 20 | Funciones de distribución acumulada (CDF) para el error medio absoluto (AME) de los residuos del modelo original (MBF) y modelo corregido (MBF+MCC), para los 52 pozos individuales de observación.

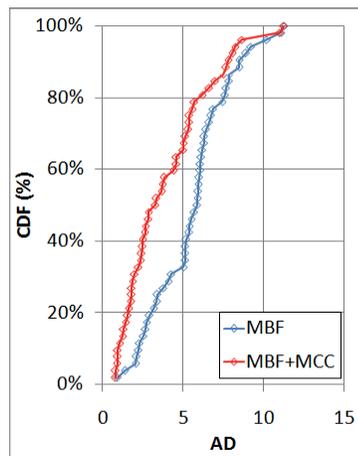


Figura 21 | CDF para el estadístico AD de los residuos del modelo original (MBF) y modelo corregido (MBF+MCC).

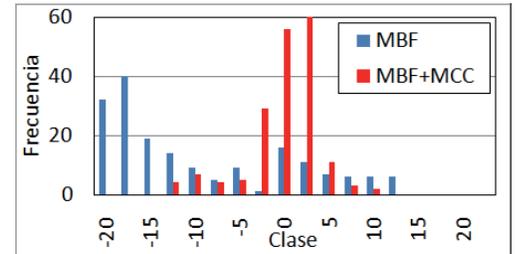


Figura 22 | Histograma de residuos para modelo original (MBF) y corregido (MBF+MCC).

Las funciones de autocorrelación simple (ACF) decaen más rápidamente a cero (Figura 23) que las mismas ACF del modelo original (Figura 10) lo que se interpreta como una reducción en la correlación temporal. Los residuos del modelo corregido presentan estadísticos Durbin-Watson (DW) (lag 1 mes) con valores mayores a los mismos del modelo original (Figura 24), lo cual confirma una reducción en la correlación temporal, sin embargo, la mayoría de los valores sigue siendo menor a 0.5, lo cual es indicativo de que persiste una cierta correlación temporal positiva.

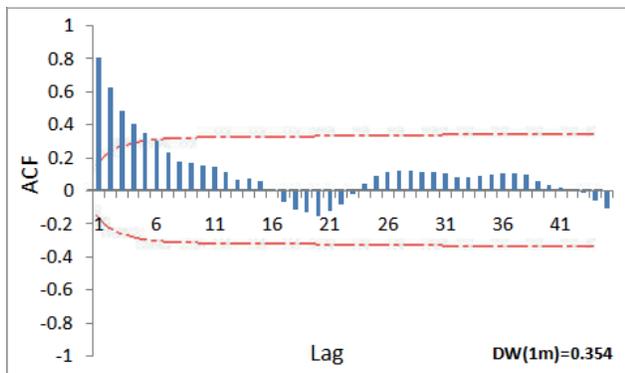


Figura 23 | ACF de residuos con bandas de significancia 5% modelo corregido (MBF+MCC).

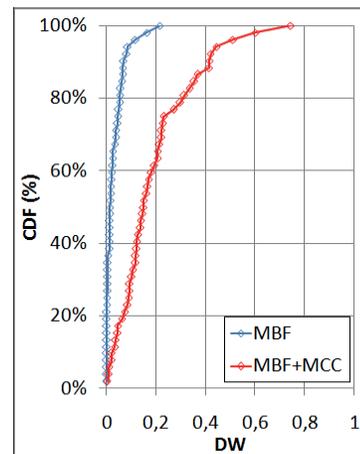


Figura 24 | CDF para el estadístico DW de los residuos del modelo original (MBF) y modelo corregido (MBF+MCC).

La reducción en las correlaciones espaciales fue verificada mediante los nuevos SVT Gaussianos ajustados a los nuevos SVE. Destaca la reducción en el valor de las mesetas de los SVT, en respuesta a la reducción de la varianza del proceso y más importante aún, la disminución en el rango (Figura 25) a un valor menor a la distancia promedio entre los pozos de observación (817 m). Lo anterior se verificó en prácticamente todo el dominio temporal (Figura 26).

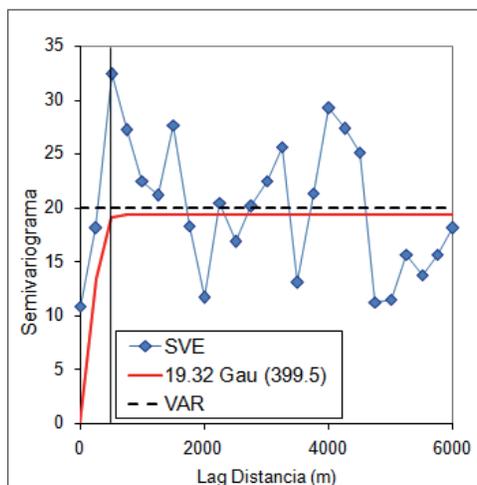


Figura 25 | (izquierda) SVE (puntos azules) y SVT Gaussiano ajustado (línea roja) de la forma "Varianza x Gau(Rango)" para ME modelo corregido (MBF+MCC).

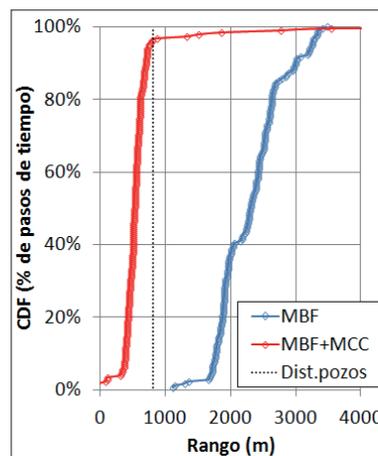


Figura 26 | (derecha) CDF para los rangos de los SVT Gaussianos ajustados a todo el dominio temporal del modelo original (MBF) y modelo corregido (MBF+MCC).

DISCUSIÓN

No obstante los buenos resultados, se reconocen algunos problemas que deben analizarse para evitarlos o reducirlos en trabajos posteriores. Se describen brevemente tres de ellos.

Se observó que el MCC temporal tuvo dificultades para reproducir los residuos desde el 2010 en adelante (ver Figura 18), inicio de la denominada megasequía 2010-2015 ((CR)², 2015). Este último periodo no formó parte de la calibración y refleja una situación hidrológica excepcional no esperada previamente, lo que pone de manifiesto la necesidad de contar con periodos de calibración lo más extensos posibles y que idealmente incluyan periodos extremos, tanto húmedos como secos.

Para la calibración del MCC espacial se escogieron pozos distribuidos en forma relativamente homogénea. Esta selección debiese realizarse más bien en base a un análisis de las curvas de isodiferencia (Figura 9), pues la cercanía de dos pozos no siempre es sinónimo de redundancia de información, por ejemplo cuando existe un gradiente piezométrico importante entre ellos.

Un inconveniente que posee el esquema de corrección complementaria presentado es que no permite conservar la masa. Al corregir los niveles piezométricos, se producirán modificaciones en el balance de las cuales la metodología no se hace cargo. Si bien, existen aproximaciones similares que tratan con flujos (Xu, 2015), se reconoce que es una tarea pendiente para esquemas de este tipo, aunque también es posible argumentar que, si un MBF tiene desviaciones en sus cotas piezométricas, no tiene sentido intentar conservar un balance que estará también erróneo.

CONCLUSIONES

La modelación numérica subterránea de base física tiene límites de precisión que se deben reconocer y es necesario aceptar para intentar mejorarlos. Los fenómenos físicos sobre los cuales se sustenta este tipo de modelación le otorgan una validez que no se cuestiona, sin embargo, es innegable que la simplificación que comúnmente utilizan les resta precisión a sus resultados. Para mejorar esto no es recomendable complejizar el Modelo de Base Física (MBF), pues aunque se capturen todos los procesos involucrados, se manifiesta en última instancia la heterogeneidad propia de los medios subterráneos, condición que imposibilita su representación física.

La corrección complementaria constituye una respuesta sencilla al problema anterior, por cuanto abandona la interpretación física y se enfrenta al problema intentando corregir los errores sin importar su origen, limitándose a mejorar las simulaciones de acuerdo a lo observado y con el respaldo físico detrás incluido en el MBF a corregir. El Modelo de Corrección Complementaria (MCC) presentado en este trabajo, interpreta a la variable de estado de nivel de la napa como aleatoria y a su serie observada como la realización de un proceso estocástico, lo que le permite tratar con la heterogeneidad del medio al incluir la aleatoriedad como parte del análisis.

La cada vez mayor disponibilidad de datos permite el uso de herramientas que antes no eran posibles de utilizar por la alta demanda de información que requieren. El uso de la estadística observada sólo para calibrar modelos tradicionales, dista mucho de un aprovechamiento cabal de los datos y obliga a los modeladores a aplicar técnicas más elaboradas y capaces de extraer más información desde los registros medidos. El desarrollo del presente trabajo permitió comprobar que la modelación subterránea determinística puede ser complementada con herramientas estocásticas para mejorar los resultados de sus simulaciones. Este esquema constituye una opción simple para aprovechar el mejoramiento en la adquisición de mediciones de terreno, tanto en cantidad como en calidad, que se ha experimentado en los últimos años.

Para el caso en estudio se observaron notables mejoras en los indicadores del MBF corregido. Por ejemplo el RMSN Global se redujo de 7.0% a 1.9%, valor difícil de alcanzar en el contexto de una modelación tradicional.

Si bien, la aplicación del MCC a otros sectores, con sus respectivos MBFs, permitirá comprobar su verdadero potencial, existe confianza en que la modelación complementaria constituye un aporte a la modelación de base física tradicional, no pretendiendo reemplazarla de modo alguno, sino complementarla para alcanzar mayor precisión en los resultados.

REFERENCIAS

- Ayala, Cabrera y Asociados Ltda. 2000. *Modelo de Simulación Hidrológico Operacional, cuencas de los ríos Maipo y Mapocho*, Dpto. de Estudios y Planificación DGA, S.I.T. n°62.
- Barra, L. 2010. *Apuntes del curso Gestión Operacional de Aguas Subterráneas, CI66K*. Departamento de Ingeniería Civil, Universidad de Chile.
- Center for Climate and Resilience Research (CR)² 2015. *La megasequía 2010-2015: Una lección para el futuro*. Nov 2015.
- Coppola, E. A., Rana, A. J., Poulton, M. M., Szidarovszky, F., Uhl, V. W. 2005 A neural network model for predicting aquifer water elevation. *Groundwater*, 43(2), 231-241. <https://doi.org/10.1111/j.1745-6584.2005.0003.x>
- Dagan, G. 2002. An Overview of Stochastic Modeling of Groundwater Flow and Transport: From Theory to Applications. *EOS Transactions American Geophysical Union*, 83(53), 621-625. <https://doi.org/10.1029/2002EO000421>
- Daliakopoulos, I. N., Coulibaly, P., Tsanis, I. K. 2004. Groundwater level forecasting using artificial neural networks. *Journal of Hydrology*, 309(1-4), 229-240. <http://doi.org/10.1016/j.jhydrol.2004.12.001>
- Demissie, Y., Valocchi, A., Minsker, B., Bailey, B. 2008. Integrating a calibrated groundwater flow model with error-correcting data-driven models to improve predictions. *Journal of Hydrology*, 364(3-4), 257-271. <http://doi.org/10.1016/j.jhydrol.2008.11.007>
- Departamento de Administración de Recursos Hídricos, DGA. 2002. *Informe de Zonificación Hidrogeológica para las Regiones Metropolitana y V*, DGA, S.D.T. n°133.
- Departamento de Administración de Recursos Hídricos, DGA. 2007. *Evaluación de la explotación máxima sustentable del acuífero Santiago Sur "Modelación Hidrogeológica de las cuencas Maipo Mapocho"*, DGA S.I.T. n°119.
- Departamento de Estudios y Planificación, DGA. 2006. *Modelación superficial para la cuenca de los ríos Maipo Mapocho -Estimación de la recarga para escenario Actual 2005-*, DGA S.D.T. n°235.

Departamento de Ingeniería Hidráulica y Ambiental, PUC. 1994. *Modelación del Sistema de Agua Subterránea de los acuíferos de La Dehesa, Lo Barnechea y Las Condes*.

DICTUC. 1999. *Estudio Hidrológico de Fuentes Superficiales y Subterráneas de Aguas Cordillera S.A.*

DICTUC. 2003. *Análisis de efectos de pozos Libardón sobre pozos del Grupo Aguas*, Minutas técnicas n°4, n°5 y n°7.

Emery, X. 2007. *Apuntes del curso Geoestadística, MI68A*. Departamento de Ingeniería de Minas, Universidad de Chile.

Muñoz, J., Fernández, B., Escauriaza, C. 2002. Evaluation of Groundwater availability and sustainable extraction rate for the Upper Santiago Valley, Chile. *Hydrogeology Journal*, 11(6), 687-700. <https://doi.org/10.1007/s10040-003-0292-2>

Nourani, V., Mogaddam, A., Nadiri, A. 2008. An ANN-based model for spatiotemporal groundwater level forecasting. *Hydrological Processes*, 22(26), 5054–5066. <https://doi.org/10.1002/hyp.7129>

Renard, P. 2007. Stochastic Hydrogeology: what professionals really need?. *Ground Water*, 45(5), 531-541. <https://doi.org/10.1111/j.1745-6584.2007.00340.x>

Reyes, J. 2016. *Mejora en las simulaciones de un modelo hidrogeológico de base física mediante corrección complementaria de sus errores*. Tesis para optar al grado de Magíster en Ciencias de la Ingeniería, mención Recursos y Medio Ambiente Hídrico. Departamento de Ingeniería Civil, Universidad de Chile.

Servicio de Evaluación Ambiental, Gobierno de Chile. 2012. *Guía para el uso de Modelos de aguas subterráneas en el SEA*.

Vargas, X., McPhee, J. 2012. *Apuntes del curso Análisis Hidrológico y Evaluación de Recursos Hídricos Avanzados, CI71C*. Departamento de Ingeniería Civil, Universidad de Chile.

Xu, T. 2012. *Use of data-driven models to improve prediction of physically based groundwater models*. Thesis submitted in partial fulfillment of the requirements for the degree of Master of Science in Civil Engineering. Graduate College, University of Illinois at Urbana-Champaign.

Xu, T., Valocchi, A., Choi, J., Amir, E. 2013. Use of machine learning methods to reduce predictive error of groundwater models. *National Groundwater Association*, 52(3), 448-460. <https://doi.org/10.1111/gwat.12061>

Xu, T., Valocchi, A. 2015. Data-driven methods to improve baseflow prediction of a regional groundwater model. *Computers & Geosciences*, 85, 124-136. <https://doi.org/10.1016/j.cageo.2015.05.016>