

SOCIEDAD CHILENA DE INGENIERÍA HIDRÁULICA
XXVII CONGRESO CHILENO DE INGENIERÍA HIDRÁULICA

¿SOMOS CONCIENTES DE LOS ALCANCES DE LOS MÉTODOS DE CORRECCIÓN DE SESGO DE VARIABLES CLIMÁTICAS DIARIAS? CASO DE LA CUENCA DEL RÍO MAIPO CON VARIACIONES DEL MÉTODO QUANTILE DELTA MAPPING

SEBASTIÁN AEDO-QUILILONGO¹
PABLO CHONG²

RESUMEN

La corrección de sesgo de variables climáticas es el proceso en la cual se corrige la salida de un Modelo de Circulación General (GCM) para hacerla consistente con las condiciones locales. A pesar de lo crucial que es la corrección de sesgo, no es habitual que se verifique o reporte de forma extensiva el éxito de esta y los alcances de la información generada. Este trabajo presenta una metodología para la corrección de sesgo, denominada QM-kNN, además de una propuesta de variables a analizar para cuantificar la precisión, robustez y alcances de la información generada por una corrección de sesgo. Estas variables incluyen valores anuales, extremos, variabilidad, ocurrencia de eventos, estacionalidad, correlaciones, persistencia de eventos y transiciones de estado, además de la capacidad de preservar las tendencias de los GCM. La metodología QM-kNN es flexible, de enfoque multi-variable y no estacionario, y se estructura en dos etapas principales: 1) corrección de sesgo estadístico a escala mensual y 2) desagregación estocástica a escala diaria mediante análogos. La metodología es flexible porque los pasos que la definen se pueden modificar según las condiciones y necesidades locales, con el fin de preservar tanto las características del clima local como las proyecciones de los GCM, al mismo tiempo de incorporar la variabilidad espacio-temporal que los resultados de los GCM no presentan debido a la escala espacial en la que están construidos. La metodología QM-kNN se comparó con otras metodologías ampliamente usadas en Chile (QDM, SDM, MBCn), aplicadas a la cuenca del río Maipo en condiciones homólogas a las del balance hídrico nacional de Chile. Los resultados destacan a la metodología QM-kNN como la más robusta, balanceando representatividad local y captura de las proyecciones de cambio climático de los GCM. La metodología MBCn también presentó un buen desempeño en el período de referencia, pero mostró distorsionar las proyecciones de cambio climático en los promedios. Este trabajo es un avance en el análisis y entendimiento del alcance de las metodologías utilizadas para el análisis de impactos del cambio climático, además de presentar una nueva metodología flexible para análisis más robustos.

¹ Investigador, Centro Latinoamericano, Stockholm Environment Institute - email: sebastian.aedo@sei.org

² Jefe de Proyectos e Innovación, HIDRICA Water Resources Consulting - email: pichong@hidricaconsultores.cl

1. INTRODUCCIÓN

La corrección de sesgo de variables climáticas es una etapa de la cadena de modelación de impactos del cambio climático en la cual se corrige la salida de un Modelo de Circulación General (GCM) para hacerla consistente con las condiciones locales. Sin embargo, este proceso introduce una nueva fuente de incertidumbre y sesgos al análisis de impactos del cambio climático (Maraun, 2013; Hakala et al., 2019; Aedo, 2024; Aedo and Chong, 2024). Uno de los potenciales sesgos que se pueden inducir es que los patrones espaciales de la información escalada reflejan los del GCM en lugar de patrones representativos de las condiciones locales (Maraun, 2013).

A pesar de los desafíos e implicancias de la corrección de sesgo a escalas temporales diarias y espaciales finas (por ejemplo, 0.1°), diversos estudios se han enfocado en generar productos grillados a estas escalas, validando su representatividad a escala gruesa, pero no a las resoluciones a las cuales proponen su usabilidad (por ejemplo, Fernández-Palomino et al., 2024). El trabajo de Aedo and Chong (2024) presenta un avance respecto a lo extensivo que debe ser la verificación de la corrección de sesgo, incluyendo variables asociadas a valores anuales, extremos, variabilidad, ocurrencia de eventos, estacionalidad, correlaciones, persistencia de eventos y transiciones de estado, además de la capacidad de preservar las tendencias de los GCM.

El trabajo de Aedo and Chong (2024) propone también la metodología QM-kNN para la corrección de sesgo a escala diaria que captura las tendencias mensuales de los GCM y las características locales diarias, incluyendo la variabilidad espacio-temporal faltante en los GCM mediante una componente estocástica, como sugiere Maraun (2013) debido a las múltiples combinaciones de la resolución fina que pueden ser compatibles con la agregación gruesa. Esta metodología se comparó en Perú y Ecuador con las propuestas por Cannon (2017; MBCn) y Lange (2019; ISIMIP3), las cuales también buscan capturar variabilidad espacio-temporal faltante en los GCM mediante una componente estocástica. Los resultados destacaron la metodología QM-kNN como la más robusta de las tres y mostraron que el producto de Fernández-Palomino et al. (2024) y metodología de Lange (2019) presentan diversas limitaciones. Sin embargo, la comparación no fue equitativa para la metodología MBCn, al considerar estrategias de aplicación considerablemente distintas.

Este trabajo evalúa el desempeño de las metodologías QM-kNN; la metodología MBCn, la cual es ampliamente utilizada en Chile, incluyendo el balance hídrico nacional (DGA, 2022); y otras dos metodologías relacionadas en cuanto a su construcción. Esta evaluación se basó en las métricas propuestas por Aedo and Chong (2024) en el contexto de la cuenca del río Maipo en Chile

2. MATERIALES Y MÉTODOS

2.1 ÁREA DE ESTUDIO

El área de estudio de este trabajo comprende la cuenca del río Maipo (Figura 1), ubicada en Chile Central (70.6° S, 33.6° O), la cual cubre un área de aproximadamente $15,000 \text{ km}^2$ y se extiende desde la cordillera de los Andes hasta su desembocadura en el mar, albergando cerca de un 40% de la población nacional, incluyendo la capital del país. Esta cuenca presenta diversas condiciones topográficas y climáticas, abarcando elevaciones desde 0 a $6,000 \text{ m.s.n.m.}$, precipitaciones de 360 a $1,900 \text{ mm/año}$ y temperaturas medias anuales que varían entre -7 y 16°C .

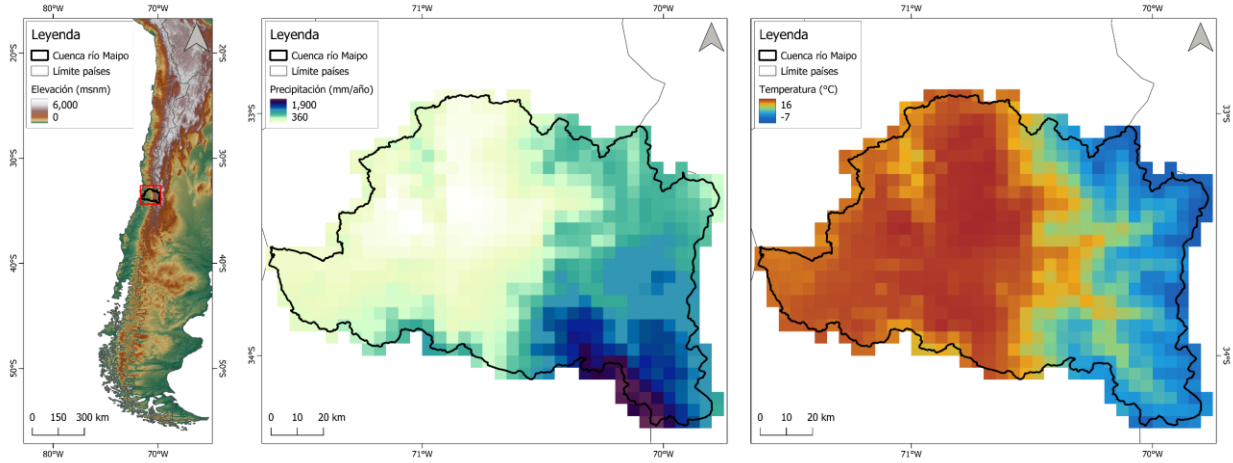


Figura 1. Área de estudio y clima en el período 1979 – 2005, a partir del producto CR2MET v2.5.

2.2 INFORMACIÓN CLIMÁTICA

Para este estudio se consideró como información de precipitación y temperatura media representativa del área de estudio el producto CR2METv2.5 (Boisier, 2023), el cual corresponde a un producto grillado que abarca Chile continental a una resolución espacial de 0.05° (~ 5 km) y el período 1960 – 2021 a una escala temporal diaria. La temperatura media se estimó como el promedio entre la temperatura mínima y máxima del producto CR2MET. Respecto a los GCM, se consideraron las salidas de precipitación y temperatura media diaria de cuatro GCM, en su realización r1i1p1, del Quinto Informe de Evaluación del Panel Intergubernamental de Cambio Climático (AR5-IPCC), bajo el escenario RCP 8.5: CCSM4, CISRO-Mk-3-6-0, IPSL-CM5A-LR y MIROC-ESM. Esta información es la utilizada en el balance hídrico nacional (DGA, 2022).

2.3 MÉTODOS DE CORRECCIÓN DE SESGO

En este trabajo se consideraron cuatro metodologías de corrección de sesgo: Quantile Delta Mapping (QDM; Cannon et al., 2015), Scaled Distribution Mapping (SDM; Switanek et al., 2017), Multivariable Bias Corrección N-pdf (MBCn; Cannon, 2017) y QM-kNN (Aedo and Chong, 2024). Todas las metodologías presentadas son no estacionarias y solo las últimas dos son multi-variables. Previo a la corrección de sesgo, cada GCM se interpoló linealmente a la grilla CR2MET dentro de la cuenca del río Maipo. Se consideró el período 1979 – 2005 como referencia.

Antes de presentar las metodologías, se describe el método Quantile Mapping (QM; Panofsky and Brier, 1968), que es la base de las metodologías analizadas. El método QM es una transformación de equiprobabilidad que ajusta las salidas de los GCM a las condiciones locales en términos de la función de distribución acumulada en el período de referencia, como se presenta a continuación:

$$\tilde{x} = F_o^{-1}(F_m[x]) \quad (1)$$

donde F es la función de probabilidad acumulada y F^{-1} su inversa, los sub-índices o y m indican si la curva corresponde a las observaciones o al GCM, respectivamente. x corresponde a la información del GCM y \tilde{x} corresponde a la información del GCM ajustada en base a las

observaciones (Figura 2a). Finalmente, al igualar las probabilidades en el período de referencia, esta transformación resulta en un ajuste los momentos estadísticos (i.e. promedio y desviación estándar) de la serie del GCM, manteniendo la secuencia de eventos original del GCM.

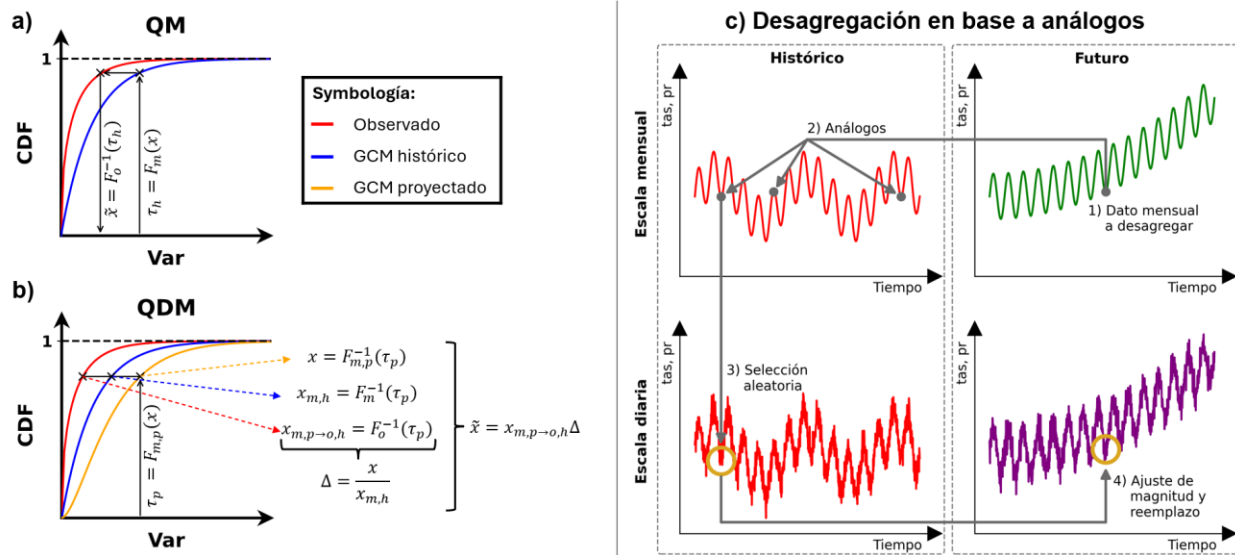


Figura 2. Esquemas de: a) método QM, b) método QDM y c) desagregación en base a análogos.

La primera metodología de corrección de sesgo corresponde a la aplicación del método QDM (Figura 2b), el cual usa la misma transformación del método QM, pero la información del modelo corresponde a la del período futuro para eliminar la tendencia y luego se incorpora el cambio proyectado del GCM de cada uno de los cuantiles. Este método se aplicó mediante la librería climQMBC (Aedo et al., 2021), considerando para cada día-año a corregir, una ventana móvil de 31 días centrada en el día a corregir y una ventana móvil hacia atrás del mismo largo del período de referencia para calcular las estadísticas y cambios proyectados.

La segunda metodología de corrección de sesgo corresponde a la aplicación del método SDM, el cual escala la curva de distribución acumulada de las observaciones con la información futura e histórica del GCM para corregir los períodos de retorno. Luego, a la distribución de probabilidad escalada se le aplica un proceso similar al del método QDM (Figura 2b). Finalmente, los valores corregidos se asignan según la probabilidad de eventos. Para la precipitación, el método SDM ajusta también la frecuencia de días lluviosos. Al igual que para la metodología QDM, este método se aplicó mediante la librería climQMBC (Aedo et al., 2021), considerando para cada día-año a corregir, una ventana móvil de 31 días centrada en el día a corregir y una ventana móvil hacia atrás del mismo largo del período de referencia para calcular las estadísticas y cambios proyectados.

La tercera metodología de corrección de sesgo corresponde a la aplicación del método MBCn, el cual se basa en el método QDM (Figura 2b) junto a un proceso aleatorio iterativo que busca conservar las correlaciones entre variables (precipitación y temperatura). Este método se aplicó mediante la librería MBC (Cannon, 2017) para cada mes (todos los días del mes) de forma independiente, considerando las variables precipitación y temperatura de forma conjunta.

La cuarta y última metodología de corrección de sesgo corresponde a la aplicación del método QM-kNN, específicamente la variante QDM-kNNev, la cual consiste en 1) aplicar el método QDM (Figura 2b) a la información agregada a escala mensual mediante la librería climQMBC (Aedo et al., 2021), considerando una ventana móvil hacia atrás del mismo largo del período de referencia para calcular las estadísticas y cambios proyectados y 2) desagregar desde la escala mensual a la escala diaria mediante el método k-Nearest Neighbour (kNN; Rajagopalan and Lall, 1999; Figura 2c), considerando conjuntamente todas las celdas y las variables. La desagregación con el método kNN se basa en un enfoque estocástico de análogos: para cada mes-año que se desagrega se asignan datos diarios de un mes-año ya conocido (análogos), reconstruyendo así la serie temporal diaria. Los análogos se seleccionan en función de una búsqueda aleatoria entre los meses-años que tengan una menor distancia respecto al mes-año a desagregar y se escalan para preservar la magnitud de la escala mensual, proceso similar al de un generador de clima (Chadwick et al., 2018).

2.4 INDICADORES DE DESEMPEÑO

El desempeño o ajuste de las metodologías se evaluó en función de la capacidad de representar condiciones en el período de referencia (período 1979 – 2005) y de capturar las tendencias crudas de los GCM interpolados. Los parámetros utilizados corresponden a los propuestos por Aedo and Chong (2024), que se basan en el trabajo de Fowler et al (2007), Gutmann et al. (2014), Canon et al. (2015), Canon (2017) y Switanek et al. (2017) y son presentados en la Tabla 1.

Tabla 1. Parámetros para evaluar el desempeño de las metodologías analizadas.

Concepto	Parámetros precipitación	Parámetros temperatura
Valores anuales	Promedio anual Desviación estándar anual	
Extremos	Mínimos y percentil 5% promedio anual (solo para temperatura) Máximos y percentil 95% promedio anual	
Ocurrencia	Curva de duración de las diaria y mensual Curva de duración de máximos anuales (solo para precipitación)	
Estadísticos	Promedio y desviación estándar diaria y mensual	
Consistencia espacial y entre variables	Correlación espacial diaria y mensual Correlación entre variables diaria y mensual	
Persistencia de eventos	Días lluvia (precipitación > 1 mm) Persistencia de lluvia y no lluvia Probabilidad de transición lluvia-lluvia y no lluvia-no lluvia	Días fríos (temperatura < 0 °C) Persistencia de días fríos Amplitud térmica anual
Autocorrelaciones	Autocorrelación con desfase de hasta 3 y 7 días	
Preservación de tendencias	Cambio proyectado en el promedio, desviación estándar anual entre 2006 y 2100, respecto al período de referencia	

Los parámetros seleccionados para evaluar el desempeño del período de referencia incluyen tanto los tradicionalmente utilizados para caracterizar la climatología de una zona, como otros menos convencionales, como lo son la variabilidad, las correlaciones espaciales, entre variables y temporales, así como la persistencia y transición entre condiciones secas/húmedas. Estos últimos

son relevantes para representar correctamente la ocurrencia y evolución de eventos locales, analizar sistemas con memoria (humedales, embalses, acuíferos) o donde las extracciones están limitadas por disponibilidad, y estudiar procesos que dependen de la coherencia entre distintas variables como la acumulación y derretimiento de nieve, el cálculo de la evapotranspiración de cultivos, la evaporación neta en embalses o la evapotranspiración de referencia. Respecto a las proyecciones, se evaluaron las tendencias en el promedio y desviación estándar anual como promedios móviles de 27 años (duración del período de referencia), comparando la información corregida y la información de los GCM interpolada a la información de referencia.

Para evaluar los parámetros de la Tabla 1, se utilizó una modificación del sesgo porcentual, que considera sumatorias de valores absolutos para evitar compensaciones de errores negativos y positivos. El sesgo absoluto porcentual (APBIAS) de cada parámetro se calculó de forma agregada considerando las 679 celdas con información, mediante la siguiente ecuación:

$$APBIAS = 100 \times \frac{\sum_{celda} |Y_{celda}^{obs} - Y_{celda}^{esc}|}{\sum_{celda} |Y_{celda}^{obs}|} \quad (2)$$

donde Y_{celda} corresponde a los valores de una celda. Los super-índices *obs* y *esc* indican si la información corresponde al producto de referencia o al resultado de la metodología. Un ajuste perfecto corresponde a un APBIAS de 0 y valores mayores indican una degradación del ajuste.

3. RESULTADOS Y DISCUSIÓN

Esta sección presenta la comparación del desempeño de las metodologías analizadas con base en los parámetros presentados en la Tabla 1. A modo de síntesis, la Figura 3 presenta una matriz con los resultados del APBIAS para cada método evaluado, diferenciado por GCM. En general, todas las metodologías exhiben fortalezas y limitaciones, y su desempeño varía según el GCM utilizado.

Para los promedios anuales, todas las metodologías resultaron en APBIAS menores a 20%, específicamente, todas tuvieron valores menores a 10%; excepto la metodología QDM. La desviación estándar anual resultó en un menor ajuste, con APBIAS entre 0 y 60%, siendo la metodología QDM-kNNev la con mejor ajuste.

En cuanto a los valores extremos anuales y las curvas de duración de variables a escala diaria, mensual y de precipitación máxima anual, todas las metodologías resultaron en APBIAS menores a 20%, destacando la metodología MBCn y QDM-kNNev con valores menores a 10% en todas las variables, excepto la QDM-kNNev en la curva de duración de precipitación máxima anual, la cual resultó en valores entre 10 y 20%. Por otro lado, la metodología QDM resultó en varios casos con APBIAS menores a 10% y mayores dificultades en la precipitación máxima y curva de duración de la precipitación mensual, mientras la metodología SDM también resultó en varios casos con APBIAS menores a 10%, pero dificultades en las temperaturas mínima.

En cuanto a la estacionalidad diaria de la precipitación, tanto para los promedios como desviación estándar, los resultados muestran APBIAS entre 40 y 60%, excepto para la metodología QDM-kNNev, con algunos casos entre 20 y 40%. Para la temperatura diaria, todas las metodologías resultaron en APBIAS menores a 10% para el promedio y entre 10 a 20% para la desviación

estándar, excepto por la metodología SDM, la cual resultó en valores entre 20 y 40%. En el caso de la estacionalidad mensual, la metodología QDM-kNNev destaca por *APBIAS* menores a 10% para el promedio y desviación estándar tanto de la precipitación como de la temperatura, seguido de la metodología MBCn, con *APBIAS* menores a 10% en el promedio y entre 10 y 20% para la desviación estándar. La metodología SDM resultó en *APBIAS* menores a 10% en los promedios mensuales, pero valores entre 20 y 60 en la desviación estándar, con mayores dificultades en la desviación estándar de la temperatura. La metodología QDM resultó en *APBIAS* entre 20 y 40% en el promedio mensual de la precipitación y menores a 10% en el caso de la temperatura, mientras que, en la desviación estándar de ambas variables resultó en *APBIAS* entre 20 y 40%.

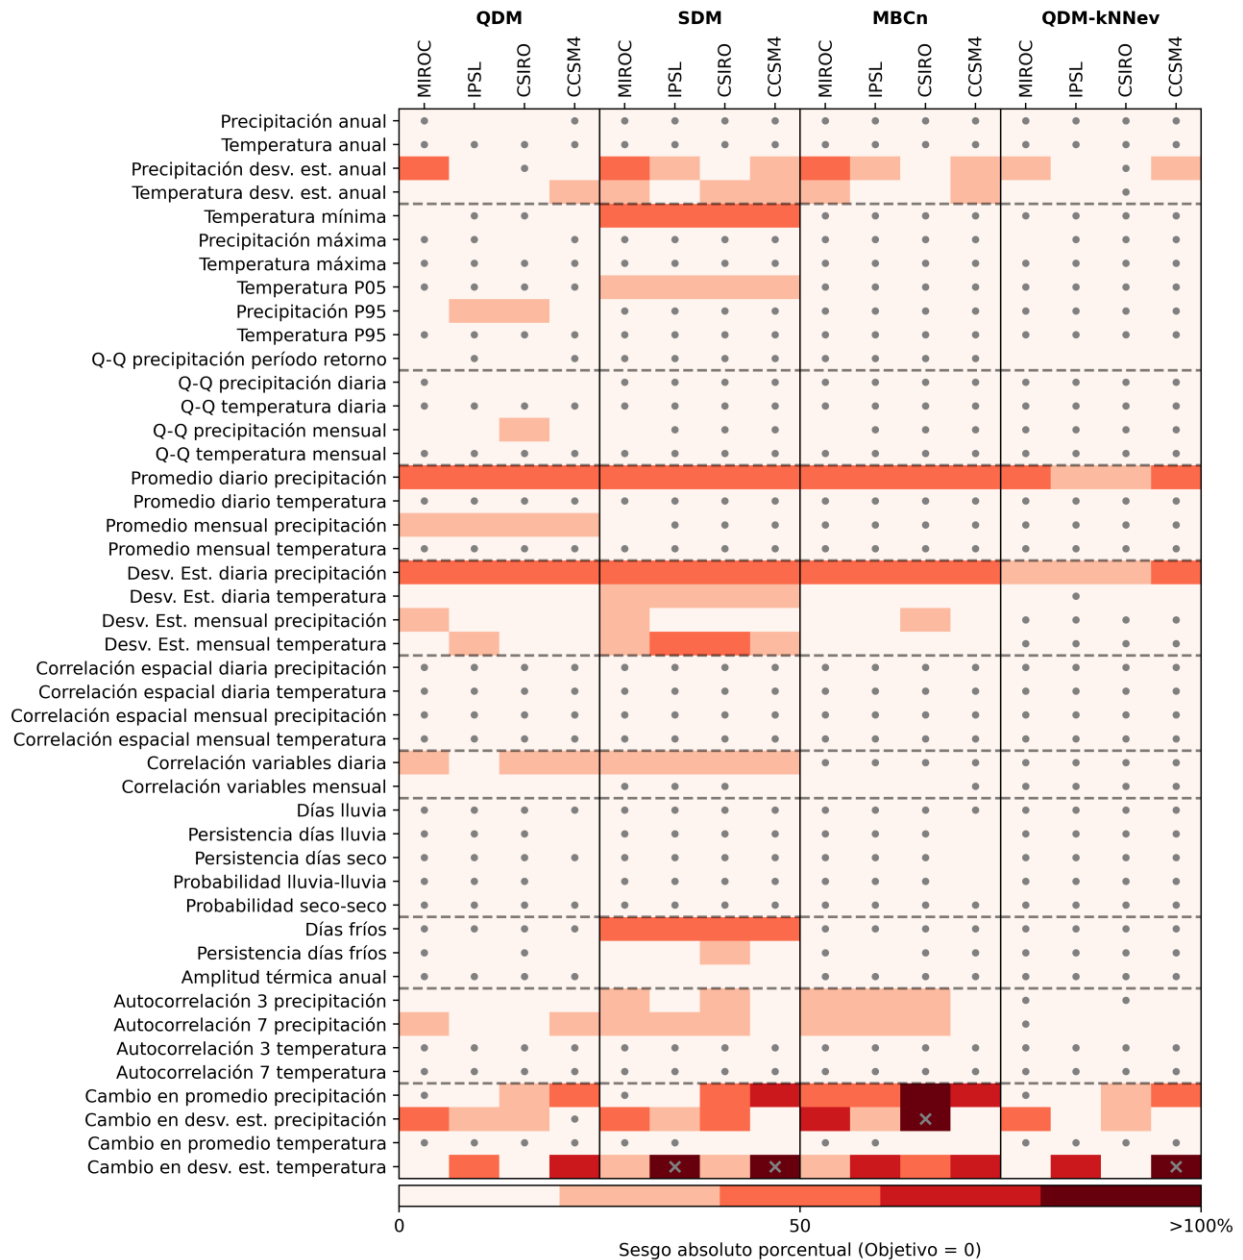


Figura 3. Sesgo absoluto porcentual (*APBIAS*) de las metodologías evaluadas. Los colores van cada 20%, los puntos indican valores menores a 10% y las cruces valores mayores a 90%.

El caso de la estacionalidad de la precipitación diaria se presenta en la Figura 4, aplicado al GCM IPSL-CM5A-LR. Estos gráficos presentan de forma superpuesta la estacionalidad de todas las celdas de la grilla. Las distintas metodologías resultan en distintos grados de dispersión tanto para el promedio como para la desviación estándar, con casos de sobre y subestimación. Si las estacionalidades se suavizan mediante media móvil, tiende a mejorar la representatividad en todos los casos, lo cual tiene sentido con el nivel de variabilidad que tiene la estacionalidad diaria.




Figura 4. Promedio y desviación estándar estacional diaria de la precipitación en base al GCM IPSL-CM5A-LR en el período 1979 – 2005. Colores oscuros indican mayor densidad de puntos.

En cuanto a las correlaciones espaciales, todas las metodologías resultaron en *APBIAS* menor a 10%. Sin embargo, este buen ajuste puede estar asociado a las características la zona de estudio, ya que en el trabajo de Aedo and Chong (2024) se observaron condiciones contrastantes entre metodologías. En el caso de las correlaciones entre variables, la metodología QDM-kNNev resultó en *APBIAS* menores a 10% tanto en la escala diaria como en la mensual, mientras que la metodología MBCn resultó en *APBIAS* menores a 10% en la escala diaria y entre 10 y 20% en la escala mensual. En el caso de las metodologías QDM y SDM, resultaron en *APBIAS* entre 20 y 40% a escala diaria, mientras que a escala mensual la metodología QDM resultó en *APBIAS* entre 10 y 20% y la SDM en valores menores a 10%.

El caso de la correlación entre la precipitación y temperatura diaria se presenta en la Figura 5, aplicado al GCM MIROC-ESM. Esta figura muestra patrones similares para las metodologías QDM y SDM, al mismo tiempo de mostrar la ganancia de la metodología QDM-kNNev respecto a la QDM, además de destacar al MBCn con errores cercanos a 0 en todo el espacio.




Figura 5. Correlación entre precipitación y temperatura diaria para el GCM MIROC-ESM en el período 1979 – 2005.

En cuanto a las condiciones de lluvia y no lluvia, todas las metodologías resultaron en *APBIAS* menores a 10%. Lo mismo ocurre para los días fríos y la amplitud térmica anual, excepto para la metodología SDM, la cual en general resultó en un menor ajuste para las temperaturas mínimas. En cuanto a las autocorrelaciones de la precipitación, la metodología QDM y QDM-kNNev son las que resultaron en un mejor ajuste, con *APBIAS* entre 0 y 20%, comparado a las metodologías SDM y MBCn, con *APBIAS* entre 10 y 40%, mientras que para la temperatura todas las metodologías resultaron en *APBIAS* menores a 10%.

Respecto a las proyecciones para la precipitación anual, las metodologías QDM y QDM-kNNev resultaron en *APBIAS* entre 0 y 40%, mientras que la metodología SDM valores entre 0 y 60% y la metodología MBCn valores entre 40 y 100% tanto para el promedio como para la desviación estándar. En cuanto a los cambios en el promedio de la temperatura, todas las metodologías resultaron *APBIAS* menores a 10%, mientras que, para la desviación estándar, los valores van de 20 a 100%, siendo la metodología QDM la con mejor ajuste.

El caso de las proyecciones climáticas se presenta en la Figura 6, aplicado al GCM CCSM4, la cual muestra el cambio proyectado en la precipitación anual y temperatura para finales de siglo, además de la evolución temporal para la latitud -33.325 y longitud -69.825 (zona con mayor discrepancia) en base a una ventana móvil de igual largo que el período de referencia (27 años). En ambos casos los cambios se presentan respecto al período de referencia 1979-2005.

Los cambios en precipitación muestran que ninguna de las metodologías captura la distribución espacial del GCM, el cual muestra una disminución de hasta 30% en el oeste (zona baja) de la cuenca y un cambio cercano a 0% en el este (zona alta). Las metodologías QDM, SDM y QDM-kNNev aproximan el patrón, pero con disminuciones entre 30 (oeste) y 15% (este), mientras que la metodología MBCn, muestra cambios menores en el oeste y en el este de la cuenca, comparado con la zona central, patrón inconsistente con la información del GCM. Parte de este error está asociado a que todas las metodologías, por construcción, buscan capturar los cambios de los GCM de cada uno de los meses, lo cual resulta en discrepancias al momento de analizar la información anual, consistente con el trabajo de Aedo (2024). Para validar esto, la Figura 6b incluye la serie de tiempo que se construye al aplicar un escalamiento lineal a cada mes de las observaciones y luego agregarlo a escala anual, resultando en una serie distinta a la original del GCM. Esto resulta en una modificación de la tendencia que las metodologías buscan replicar.

En cuanto a las temperaturas, las metodologías QDM y QDM-kNNev muestran patrones espaciales similares a los del GCM. La metodología MBCn muestra una distorsión de la señal, pero con una consistencia en que los mayores aumentos de temperatura se encuentran al este, a diferencia de la metodología SDM, que muestra un patrón espacial distinto.

Consistentes con el trabajo de Aedo and Chong (2024), todas las metodologías lograron capturar 1) los promedios anuales, 2) extremos anuales, excepto las temperaturas mínimas en el caso del SDM, 3) curvas de duración, 4) temperatura promedios diaria y mensual, 5) correlaciones espaciales, 6) días lluvia y no lluvia, además de la persistencia, 7) días fríos y amplitud térmica anual, a excepción de la metodología SDM, y 8) autocorrelación de la temperatura. Por otro lado, los desafíos transversales a las metodologías incluyen: 1) la desviación estándar anual de la precipitación y temperatura, 2) promedio y desviación estándar de la precipitación diaria, 3) los

cambios proyectados en la desviación estándar de la temperatura anual, y 4) los cambios proyectados en el promedio y desviación estándar de la precipitación anual; sin embargo, este último está relacionado a la construcción de las metodologías para el caso de la QDM, SDM y QDM-kNNev, a diferencia de la MBCn, la cual distorsiona arbitrariamente las tendencias.

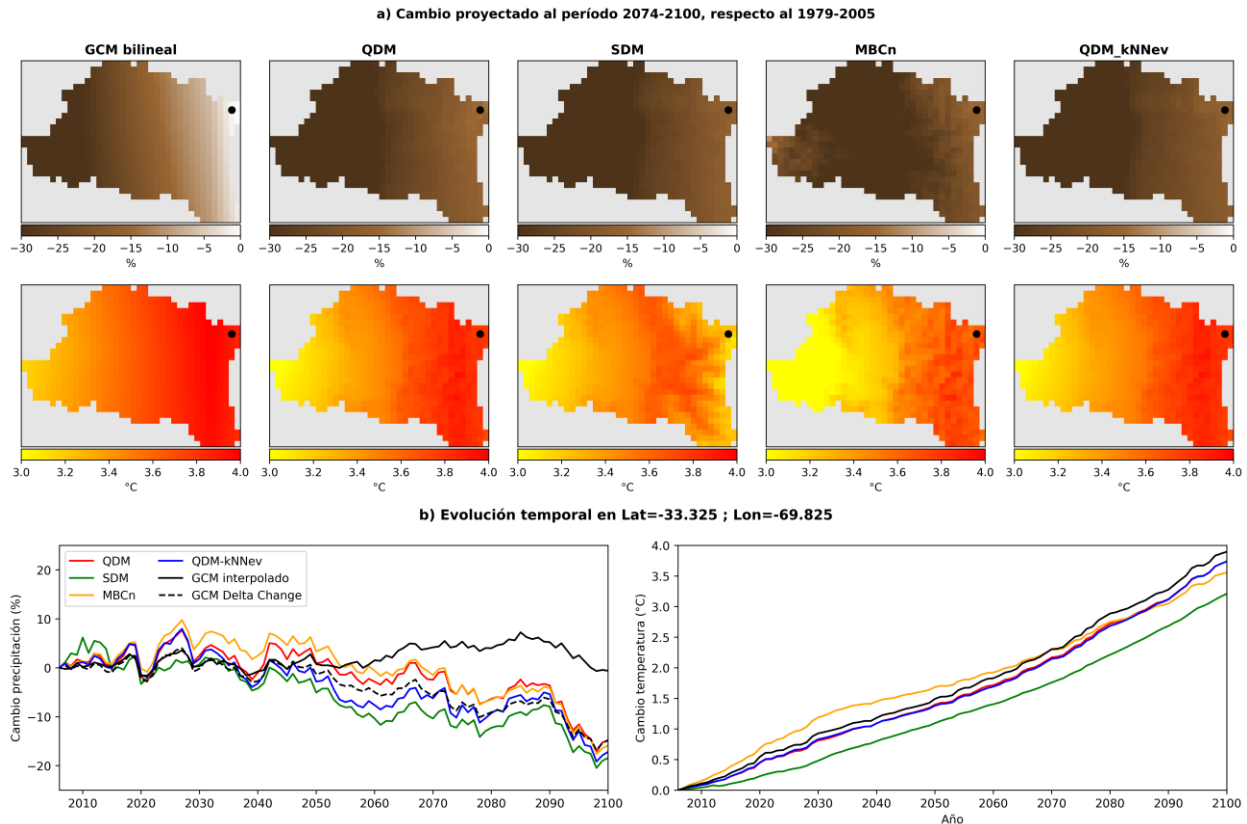


Figura 6. (a) Cambio porcentual en precipitación entre 2074 – 2100 y 1979 – 2005 y (b) evolución temporal del cambio porcentual en la ubicación latitud -33.325° y longitud -69.825 (punto negro en (a)) para el GCM CCSM4. La línea discontinua en (b) corresponde a aplicar un escalamiento lineal a cada mes de la observación y luego agregarlo a escala anual.

La metodología QDM-kNNev es la que presenta una mejor representación de todas las variables analizadas, incluyendo los desafíos transversales, excepto por la curva de duración de las precipitaciones máximas anuales y las correlaciones entre variables diarias, variables que son mejor representadas por la metodología MBCn. Estos resultados destacan a la metodología QDM-kNNv como la más robusta tanto en el período de referencia como en las proyecciones, seguido por la MBCn en el período de referencia y la QDM en las proyecciones. Por otro lado, la metodología SDM es la que presenta un peor desempeño en el período de referencia y la MBCn el peor desempeño en las proyecciones. Es importante mencionar que, respecto al trabajo de Aedo and Chong (2024), aplicar la metodología MBCn a cada mes de forma independiente mejora sustancialmente su representatividad.

4. CONCLUSIONES

Este trabajo presenta una metodología de corrección de sesgo de resultados diarios de los GCM, llamada QM-kNN, la cual se comparó con tres metodologías (QDM, SDM y MBCn). Esta comparación se basó en un set de parámetros extensivos, que habitualmente no son verificados, especialmente en el período de referencia. La metodología QM-kNN se resume en dos etapas: 1) corrección de sesgo del GCM a escala mensual considerando una metodología que preserve tendencias, y 2) desagregación estocástica mediante análogos desde la escala mensual a la diaria.

La comparación entre metodologías se basó en parámetros como totales anuales, valores extremos, estacionalidad diaria y mensual, además de la variabilidad, correlaciones espaciales y entre variables, persistencia de condiciones secas/húmedas y cambios proyectados. El énfasis en la representatividad de las características históricas se basa en que, si no se logran representar las condiciones del período de referencia, no hay certeza de que las proyecciones sean representativas. Una mala representatividad le quita el peso a la metodología y pone en duda la coherencia de la información corregida con respecto a la información de base de los GCM y de las observaciones.

Analizar de forma extensiva la información generada mediante corrección de sesgo está asociado a que cada área temática de análisis (análisis hidráulico, hidrología superficial, hidrología subterránea, abastecimiento de agua, rendimiento de cultivos, incendios, olas de calor, entre otros) requiere de una correcta representatividad de una diversidad de condiciones. Al igual que cuando se validan los resultados de un modelo, por ejemplo, hidrológico, se debe validar y analizar los alcances de la información generada con base en parámetros relevantes previamente identificados. En este estudio, el uso del *APBIAS* permitió realizar una comparación entre metodologías, pero no cierra la discusión en torno a los umbrales óptimos ni a cuál es la metodología perfecta.

La metodología QM-kNN se posiciona como robusta para la corrección de sesgo de variables climáticas a escala diaria, además de ser flexible en el sentido de que la elección del método QM y la forma de implementar el kNN puede ser modificado según las condiciones locales relevantes. Adicionalmente, la desagregación puede ser complementada por modelos estocásticos que se construyan a partir de relaciones locales o cambios que ya se han manifestado para generar una base de datos robustas. Se recomienda priorizar la evaluación y uso de la metodología QM-kNN para productos que deben ser robustos y representativos, como bases de datos nacionales o que se espera sean utilizadas en diversas áreas temáticas.

REFERENCIAS

Aedo, S. (2024). ¿Por qué mis proyecciones de cambio climático difieren de las de los Modelos de Circulación General? XXXI Congreso Latinoamericano de Hidráulica, IAHR, Medellín, Colombia.

Aedo, S. and Chong, P. (2024). Propuesta Metodológica Para El Escalamiento Local A Nivel Diario De Modelos De Circulación General. XXXI Congreso Latinoamericano de Hidráulica, IAHR, Medellín, Colombia.

Aedo, S., Chadwick, C., González-Leiva, F., and Gironás, J. (2021). climQMBC a new package to Bias Correct Climatic Variables While Preserving raw GCM Changes in the Mean and Standard Deviation For R, Python and Matlab. American Geophysical Union fall meeting, 2021. <https://github.com/saedoquililongo/climQMBC>

Boisier, J.P. (2023). CR2MET: A high-resolution precipitation and temperature dataset for the period 1960-2021 in continental Chile. (v2.5) [Data set]. Zenodo. DOI: 10.5281/zenodo.7529682

Cannon, A. J. (2017). Multivariate quantile mapping bias correction: an N-dimensional probability density function transform for climate model simulations of multiple variables, *Climate Dynamics*, 50, 31-49. <https://doi.org/10.1007/s00382-017-3580-6>

Cannon, A., Sobie, S., and Murdock, T. (2015). Bias Correction of GCM Precipitation by Quantile Mapping: How Well Do Methods Preserve Changes in Quantiles and Extremes? *Journal of Climate*, 28(17), 6938-6959. <https://doi.org/10.1175/JCLI-D-14-00754.1>.

Chadwick, C., Gironás, J., González-Leiva, F., and Aedo, S. (2023). Bias adjustment to preserve changes in variability: the unbiased mapping of GCM changes. *Hydrological Sciences Journal*, 68(8), 1184-1201. <https://doi.org/10.1080/02626667.2023.2201450>

Chadwick, C., Gironás, J., Vicuña, S., Meza, F., and McPhee, J. (2018). Using a statistical pre-analysis approach as an ensemble technique for the unbiased mapping of GCM changes to local stations. *Journal of Hydrometeorology*, 19(9), 1447-1465. doi:10.1175/JHM-D-17-0198.1

Dirección General de Aguas. (2022). Homologación del cálculo hidrológico para la estimación de la oferta natural de agua histórica y futura en Chile. SIT N°524. Ministerio de Obras Públicas, Dirección General de Aguas, División de Estudios y Planificación, Santiago, Chile.

Fernandez-Palomino, C., Hattermann, F., Krysanova, V., Vega-Jácome, F., Menz, C., Gleixner, S., Bronstert, A. (2024). High-resolution climate projection dataset based on CMIP6 for Peru and Ecuador: BASD-CMIP6-PE. *Scientific Data* 11, 34. <https://doi.org/10.1038/s41597-023-02863-z>

Fowler, H., Blenkinsop, S., and Tebaldi, C. (2007). Linking climate change modelling to impacts studies: Recent advances in down-scaling techniques for hydrological modelling. *International Journal of Climatology*, 27(12), 1547-1578. <https://doi.org/10.1002/joc.1556>

Gutmann, E., Pruitt, T., Clark, M., Brekke, L., Arnold, J., Raff, D., and Rasmussen R. M. (2014). An intercomparison of statistical downscaling methods used for water resource assessments in the United States, *Water Resources Research*, 50(9), 7167-7186, doi:10.1002/2014WR015559

Hakala, K., Addor, N., Teutschbein, C., Vis, M., Dakhlaoui, H., and Seibert, J. (2019). Hydrological Modeling of Climate Change Impacts. In *Encyclopedia of Water*, P. Maurice (Ed.). <https://doi.org/10.1002/9781119300762.wsts0062>

Lange, S. (2019). Trend-preserving bias adjustment and statistical downscaling with ISIMIP3BASD (v1.0). *Geoscientific Model Development*, 12(7), 3055-3070. <https://doi.org/10.5194/gmd-12-3055-2019>

Maraun, D. (2013). Bias Correction, Quantile Mapping, and Downscaling: Revisiting the Inflation Issue. *Journal of Climate*, 26(6), 2137-2143. <https://doi.org/10.1175/JCLI-D-12-00821.1>

Panofsky, H. and Brier, G. (1968). Some applications of statistics to meteorology. *Earth and Mineral Sciences Continuing Education*, College of Earth and Mineral Sciences. University Park, PA, USA: The Pennsylvania State University.

Rajagopalan, B., and Lall, U. (1999). A k-nearest neighbor simulation for daily precipitation and other weather variables. *Water Resources Research*, 35(10), 3089-3101. <https://doi.org/10.1029/1999WR900028>

Switanek, M., Troch, P., Castro, C., Leuprecht, A., Chang, H.-I., Mukherjee, R., and Demaria, E. (2017). Scaled distribution mapping: a bias correction method that preserves raw climate model projected changes. *Hydrology and Earth System Sciences*, 21(6), 2649-2666. <https://doi.org/10.5194/hess-21-2649-2017>