



Desarrollo de un sistema de pronóstico operacional de eventos extremos basado en modelos numéricos de predicción de las condiciones meteorológicas, de oleaje y marea de tormenta, incluyendo la evaluación del desempeño de los modelos y la determinación de incertidumbres, con fines de alertamiento

PRIMER INFORME TRIMESTRAL CORRESPONDIENTE A LA ACTIVIDAD 1:

DESCRIPCIÓN DEL SISTEMA DE PRONÓSTICO NUMÉRICO OPERACIONAL PARA EVENTOS EXTREMOS DE LAS CONDICIONES METEOROLÓGICAS, DE OLAJE Y MAREA DE TORMENTA Y DE SU VALIDACIÓN

Incluye los reportes correspondientes a los numerales:

- 1.1. Descripción detallada del sistema de pronóstico.**
- 1.2. Bases teóricas de la validación de los pronósticos que se desarrollarán.**

Responsable:

**Dr. Jorge Zavala Hidalgo
Centro de Ciencias de la Atmósfera
Universidad Nacional Autónoma de México**

**Primera versión: Noviembre de 2016
Versión revisada: Marzo de 2017**

Contenido

CAPÍTULO I. DESCRIPCIÓN DETALLADA DEL SISTEMA DE PRONÓSTICO (numeral 1.1).. 1

I.1. INTRODUCCIÓN	1
I.1.1. <i>Objetivos del proyecto</i>	6
I.1.2. <i>Metas</i>	7
I.2. DESCRIPCIÓN DE LOS MODELOS QUE SE UTILIZARÁN	7
I.2.1. <i>Modelo WRF</i>	8
I.2.2. <i>Modelo WWill</i>	12
I.2.3. <i>Modelo ADCIRC</i>	14
I.3. CONFIGURACIÓN DE LOS MODELOS	16
I.3.1. <i>Configuración del modelo WRF</i>	16
I.3.2. <i>Configuración del modelo WWill</i>	19
I.3.3. <i>Configuración del modelo ADCIRC</i>	21
I.4. VISUALIZACIÓN DE LOS PRONÓSTICOS Y CÁLCULO DE INCERTIDUMBRES	24
I.4.1. <i>Módulos para la visualización</i>	24
I.4.2. <i>Incertidumbres</i>	24
I.5. HARDWARE EN EL CUAL SE INSTALARÁ EL SISTEMA DE PRONÓSTICO	25
I.6. REFERENCIAS BIBLIOGRÁFICAS (CAPÍTULO I)	28

CAPÍTULO II. BASES TEÓRICAS DE LA VALIDACIÓN DE PRONÓSTICOS NUMÉRICOS Y ESTRATEGIAS DE VERIFICACIÓN (numeral 1.2) 30

II.1. INTRODUCCIÓN	30
II.2. TIPOS DE PRONÓSTICOS Y DATOS PARA SU VERIFICACIÓN	31
II.3. CARACTERÍSTICAS DE UN BUEN PRONÓSTICO	33
II.3.1. <i>Puntajes de habilidad</i>	34
II.3.2. <i>Habilidad artificial</i>	35
II.3.3. <i>Significancia estadística</i>	36
II.4. CALIDAD DE LOS DATOS	36
II.5. MÉTODOS DE VERIFICACIÓN ESTÁNDAR	37
II.5.1. <i>Verificación visual</i>	37
II.5.2. <i>Métodos para pronósticos dicotómicos</i>	38
II.5.3. <i>Métodos para pronósticos multi-categoría</i>	40
II.5.4. <i>Métodos para pronósticos de variables continuas</i>	43
II.5.5. <i>Métodos para pronósticos probabilísticos</i>	48
II.6. ESTRATEGIAS PROPUESTAS PARA LA VERIFICACIÓN DE LOS PRONÓSTICOS EN EL SISTEMA MMOM	50
II.7. REFERENCIAS BIBLIOGRÁFICAS (CAPÍTULO II)	53

CAPÍTULO I

DESCRIPCIÓN DETALLADA DEL SISTEMA DE PRONÓSTICO

I.1. INTRODUCCIÓN

Año con año el país se ve afectado por fenómenos hidrometeorológicos tales como ciclones tropicales y huracanes, los cuales provocan pérdida de vidas humanas y daños materiales asociados a inundaciones, desbordamiento de ríos, oleaje e inundación por marea de tormenta.

Para contribuir a la prevención de los efectos arriba mencionados, se desarrollará un Sistema Operacional de Pronóstico Numérico de las condiciones meteorológicas, de oleaje y de marea de tormenta, incluyendo la evaluación del desempeño de los modelos numéricos empleados y la determinación de incertidumbres en los pronósticos.

Los sistemas operacionales de pronóstico numérico se han convertido en una herramienta indispensable para apoyar el análisis de los especialistas en fenómenos hidrometeorológicos, de marea de tormenta y marejada. Estos sistemas se encuentran en constante desarrollo, permitiendo mayor certeza sobre el peligro que representa cada fenómeno. El desarrollo del sistema propuesto se enmarca en este esquema, buscando mejorar los pronósticos numéricos con los que se cuenta en México e incluir, por primera vez, incertidumbres en los pronósticos de las variables más importantes, en particular de la precipitación, la temperatura, las variaciones del nivel del mar y el oleaje.

El sistema proporcionará información sobre regiones que puedan verse afectadas, en el corto plazo, por precipitaciones extremas, vientos intensos, oleaje y sobre-elevación del nivel del mar por marea de tormenta, la cual podrá ser transmitida a los estados y municipios para que se tomen medidas preventivas encaminadas a reducir pérdidas y daños asociados a los impactos de estos fenómenos naturales extremos. El sistema es autocontenido y trabaja de forma automática, sin la necesidad de que un operador lo active cada día. Se generarán varios miles de productos gráficos para apoyar la tarea de las personas encargadas de emitir pronósticos y boletines, así como para ayudar a los tomadores de decisiones a explicar e interpretar las condiciones observadas. El sistema incluye un servidor de visualización que puede ponerse en Intranet o Internet para que diversos usuarios puedan consultarlo.

Para su desarrollo se cuenta con varios años de experiencia, ya que el Grupo Interacción Océano-Atmósfera (IOA) del Centro de Ciencias de la Atmósfera (CCA) de la UNAM ha venido desarrollando sistemas de pronóstico numérico desde 2007. Entre ellos podemos mencionar los sistemas de pronóstico meteorológico, de oleaje, de marea de tormenta y de dispersión de ceniza volcánica desarrollados para dependencias como el CENAPRED, PEMEX, el Servicio Meteorológico Nacional y para el propio CCA. Todos estos sistemas de pronóstico numérico continúan operando al día de hoy. Asimismo, se realizó un estudio numérico para el INECC sobre la reconstrucción del derrame petrolero ocurrido en 2010 en el Golfo de México.

Como se mencionó anteriormente, el territorio mexicano se ve afectado año con año por diversos fenómenos hidrometeorológicos que provocan tanto pérdida de vidas humanas como importantes pérdidas económicas por los daños materiales a bienes e infraestructura. Entre esos fenómenos están las lluvias torrenciales asociadas a ciclones tropicales o a sistemas convectivos locales o de mesoescala, las cuales pueden generar inundaciones, desbordamiento de ríos, deslaves, avalanchas de lodo y desprendimiento de rocas y árboles. En particular, los registros históricos muestran que ha habido un gran número de decesos asociados con el paso de ciclones tropicales desde principios del siglo pasado. Por ejemplo, entre los ciclones que han causado más pérdidas humanas en México se puede mencionar el ocurrido en agosto de 1909, que ocasionó 1,500 muertes en el estado de Nuevo León, o el ocurrido en octubre de 1959 que afectó la región de Manzanillo en Colima y también ocasionó alrededor de 1,500 decesos (CENAPRED, 2014).

Entre los fenómenos más devastadores ocurridos recientemente podemos mencionar al huracán Odile (categoría 4) que se generó en septiembre de 2014 y afectó grandes áreas de la península de Baja California (BC), en especial al estado de Baja California Sur (BCS), siendo el primer huracán de categoría mayor que golpea la península de BC en los últimos 25 años (NHC, 2015). También causó daños menores en diversos estados de la República Mexicana y en algunas zonas del suroeste de los Estados Unidos. Las lluvias torrenciales y la marea de tormenta asociadas con el desarrollo inicial de Odile provocaron algunos decesos en Oaxaca y Jalisco, y un total de 15 muertos a lo largo de sus nueve días de existencia. Las pérdidas estimadas en BC ascendieron a 12 mil millones de pesos y los vientos y la lluvia asociados al ciclón provocaron apagones y dejaron sin electricidad al 92% de la población en BCS (https://en.wikipedia.org/wiki/Hurricane_Odile). Este fenómeno también provocó inundaciones severas y desbordamiento de ríos, con la consecuente evacuación de miles de habitantes y de turistas que se encontraban en la zona (NHC, 2015).

En la Figura 1 se muestra el pronóstico de precipitación acumulada a 120 horas, a partir de las 00:00 horas del 13 de Septiembre de 2014, generado con el modelo numérico de circulación atmosférica conocido como WRF (Weather Research & Forecasting Model) y que ha sido implementado en el CCA-UNAM para el territorio mexicano y zonas adyacentes. En esta figura se observa la gran cantidad de precipitación acumulada en la península de BC, prevista para ese período de 120 horas, y que estuvo asociada con el paso del huracán Odile.




Figura 1. Pronóstico de precipitación acumulada a 120 horas a partir de las 00:00 horas del 13 de Septiembre de 2014. Imagen tomada del Sistema de Pronóstico Operativo del CCA-UNAM (<http://grupo-ioa.atmosfera.unam.mx/pronosticos>)

En la Figura 2 se muestra el campo de viento cerca de la superficie y los contornos de presión reducida a nivel del mar pronosticados con el modelo WRF para las 20:00 hrs del 14 de Septiembre de 2014, en donde se observa la circulación ciclónica y la baja presión asociadas al huracán Odile.




Figura 2. Campo de viento en superficie y contornos de presión reducida al nivel del mar pronosticados para las 20:00 horas del 14 de Septiembre de 2014. Imagen tomada del Sistema de Pronóstico Operativo del CCA-UNAM (<http://grupo-ioa.atmosfera.unam.mx/pronosticos>)

Entre los efectos relacionados con los ciclones tropicales están el oleaje intenso y la marea de tormenta. La marea de tormenta (o *storm surge* en inglés) es una sobre-elevación del nivel del mar por encima de su nivel medio o nivel de marea astronómica, debida principalmente al empuje de los vientos intensos del ciclón sobre la superficie del mar y a la consecuente acumulación de agua hacia las zonas costeras (http://www.nws.noaa.gov/om/hurricane/resources/surge_intro.pdf). Este fenómeno provoca inundaciones que, asociadas con un fuerte oleaje, pueden ser muy destructivas. Eventos recientes, como la marea de tormenta provocada por el huracán Katrina en agosto de 2005, que causó más de 1,200 muertes en el área de Nueva Orleans y a lo largo de la costa de Mississippi (<http://www.nhc.noaa.gov/outreach/history/#katrina>), o la asociada al huracán Sandy en octubre de 2012, que afectó las costas de Nueva Jersey, Nueva York y Connecticut en los Estados Unidos y

varias localidades en el Caribe provocando en total alrededor de 190 fallecimientos y pérdidas materiales que oscilan entre los treinta y cincuenta mil millones de dólares (NHC, 2013), muestran la capacidad destructiva de este fenómeno. En México, el huracán Gilbert ocurrido en 1988, generó una marea de tormenta de aproximadamente tres metros que afectó varias zonas de la península de Yucatán, en particular al Puerto de Progreso (CENAPRED, 2001).

Además de los ciclones tropicales, otros fenómenos que causan serias afectaciones en distintos sectores sociales y económicos son los 'nortes'. Estos eventos, que afectan principalmente a la región nororiental del país y a los estados costeros del Golfo de México, producen lluvias muy fuertes y vientos intensos que pueden generar oleaje superior a los 6 m de altura (Botello et al., 2005). Entre las actividades que se ven más seriamente afectadas por los 'nortes' podemos mencionar las actividades marítimas, agropecuarias y de turismo, así como las operaciones navales, aéreas, de generación de electricidad y de extracción y producción de petróleo (Acevedo y Luna, 2006). Las características atmosféricas de gran escala de estos fenómenos los hacen predecibles con varios días de anticipación, por lo cual los modelos de predicción del tiempo son de gran utilidad para tomar las previsiones correspondientes y mitigar el efecto adverso que pudieran producir.

Por otra parte, el complejo relieve del territorio mexicano favorece el desarrollo de grandes tormentas convectivas con alto potencial de precipitación (no necesariamente vinculadas con ciclones tropicales), las cuales provocan desastres tanto en las regiones montañosas como en las planicies hacia donde escurre gran cantidad de agua. Además de lluvias muy intensas, estas tormentas pueden generar la caída de grandes cantidades de granizo. Por su escala espacial y temporal relativamente menor, estos eventos son más difíciles de pronosticar, pero la información proporcionada por el sistema de pronóstico, como por ejemplo sondeos virtuales, humedad en toda la columna de aire e índices de estabilidad, ayudan al meteorólogo a identificar zonas con alta probabilidad de ocurrencia de estos fenómenos.

En la actualidad, los modelos numéricos de predicción tanto de la atmósfera como del océano se han vuelto una herramienta fundamental para los tomadores de decisiones y encargados de la protección civil. Dichos modelos utilizan la información de las condiciones actuales proporcionada por instrumentos de medición ubicados sobre la superficie terrestre (en tierra y mar), así como de radiosondas y satélites meteorológicos, entre otros. En particular, las mejoras hechas a los modelos regionales han permitido avances significativos en la predicción de la trayectoria e intensidad de ciclones tropicales. Sin embargo, junto con las incertidumbres asociadas a la resolución de las ecuaciones que usan los modelos, la poca densidad y mala calidad de las observaciones que los

alimentan afectan la precisión de las estimaciones. Cabe mencionar también que los errores en las predicciones numéricas crecen con el tiempo de pronóstico. Por ello, es fundamental llevar a cabo una evaluación de los pronósticos con el objeto de asociarles un nivel de confiabilidad.

En este informe se presenta el diseño y desarrollo del Sistema de Pronóstico Numérico Meteorológico, de Mareas de Tormenta, Oleaje y Marejadas (**MMOM**) para los mares mexicanos y zona costera, tanto del Atlántico como del Pacífico, realizado para el CENAPRED. El sistema consta, principalmente, de los pronósticos numéricos; de programas para preprocesar y postprocesar la información requerida y la generada por los modelos; de un conjunto de *scripts* que automatizan la ejecución de los modelos y programas; de un sitio web para el despliegue gráfico de la información para su consulta, y de una base de datos para almacenamiento y despliegue de los pronósticos históricos.

1.1.1. Objetivos del proyecto

a) El objetivo general del Proyecto de Investigación es el siguiente: Desarrollar un sistema operativo de pronóstico numérico de las condiciones meteorológicas, de oleaje, marejada y marea de tormenta, cuyas estimaciones sean evaluadas de manera satisfactoria y que incluya un sistema de visualización de las simulaciones numéricas que sea amigable para el usuario.

b) Los objetivos específicos del proyecto son los siguientes:

1. Configurar e implementar cada uno de los modelos que conformarán el sistema de pronóstico propuesto.
2. Determinar las características del hardware donde se correrán los modelos y adquirir el equipo necesario.
3. Seleccionar las variables y generar los productos gráficos más adecuados que sirvan de complemento y apoyo a los pronosticadores y tomadores de decisiones, para lo cual se creará un sitio web que permita el despliegue de la información con diferentes navegadores y sistemas operativos.
4. Evaluar el desempeño de cada uno de los modelos del sistema de pronóstico.
5. Estimar las incertidumbres asociadas a los distintos pronósticos e implementar un identificador de eventos extremos para variables como precipitación, temperatura, viento, oleaje y nivel del mar.
6. Automatizar el Sistema de Pronóstico operativo.

I.1.2. Metas

- Apoyar la toma de decisiones de las instancias encargadas de la protección civil de los tres niveles de gobierno.
- Implementar mejores modelos numéricos de predicción meteorológica, de oleaje y de marea de tormenta para el territorio mexicano.

I.2. DESCRIPCIÓN DE LOS MODELOS QUE SE UTILIZARÁN

El sistema de pronóstico MMOM se basa en tres modelos numéricos: el modelo atmosférico de mesoescala *Weather Research and Forecasting* (WRF) (Skamarock et al., 2008), el modelo de marea de tormenta *Advanced Circulation* (ADCIRC) (Luettich and Westerink, 2004), y el modelo de oleaje y marejada *WAVEWATCH III* (Tolman, 2009). También se correrán programas especialmente desarrollados para preprocesar la información que se requiere para correr los diferentes modelos, postprocesar sus salidas, generar gráficas y transferirlas al servidor web. Además, se incluirá un sistema de visualización de los pronósticos mediante el software OWGIS (Zavala-Romero et al., 2014), que es un sistema dinámico de código abierto desarrollado por uno de los participantes en el proyecto. El sistema también contará con un sitio web para el despliegue de los pronósticos en forma gráfica, y con una base de datos para almacenar pronósticos históricos, los cuales también pueden ser consultados a través del portal web.

Del modelo WRF se extraerán las variables de presión en superficie y vientos a 10 m, las cuales se utilizarán para forzar los modelos ADCIRC y WWIII; estos datos tienen que cambiarse de formato para adaptarse a las mallas y formatos requeridos por los modelos. Los datos de entrada para el WRF se obtienen del modelo de pronóstico *Global Forecast System* (GFS), disponible en el sitio de Internet <ftp://ftp.prdd.ncep.noaa.gov/pub/data/nccf/com/gfs/prod/>. Una vez obtenidas las condiciones iniciales y de frontera se correrá el modelo de pronóstico meteorológico WRF y posteriormente se correrá el modelo WWIII en tres dominios: uno para todo el Pacífico, utilizando como forzamiento los vientos del GFS, y dos para los mares mexicanos y zonas adyacentes, usando los vientos generados por el WRF. Para el dominio del Pacífico mexicano se utilizarán, como condiciones de frontera, los campos generados por el pronóstico del dominio que incluye a todo el Pacífico. Posteriormente se correrá el modelo de marea de tormenta ADCIRC, utilizando como forzamiento los vientos generados por el WRF y como condiciones de frontera las principales componentes de la marea astronómica. Las componentes de la marea se obtienen del TPXO Global Tidal Solutions (<http://volkov.oce.orst.edu/tides/global.html>). Una vez obtenidas las salidas de los tres modelos, se

generarán los gráficos correspondientes y se enviarán al servidor web y a la base de datos del MMOM. En la Figura 3 se muestra un diagrama de flujo del sistema MMOM.




Figura 3. Diagrama de flujo del Sistema de Pronóstico Meteorológico, de Marea de tormenta, Oleaje y Marejada (MMOM).

1.2.1. El modelo WRF

Entre los modelos numéricos más avanzados en la actualidad para la predicción del tiempo a escala regional o mesoescala está el WRF. Por sus capacidades probadas, se escogió como el modelo para generar los vientos de alta resolución que requieren los otros modelos del MMOM. El WRF es un modelo de predicción numérica del tiempo diseñado para realizar investigación y para aplicaciones operativas. Diversas instituciones han contribuido y siguen contribuyendo a su desarrollo, con el firme objetivo de construir el modelo de pronóstico numérico de mesoescala de la *siguiente generación*.

(modelos como el MM5 pertenecen a la generación anterior), para lograr un avance en el entendimiento de los procesos atmosféricos y en la predicción del tiempo (Skamarock, 2008). El WRF ha sido desarrollado principalmente por los siguientes organismos: el *National Center for Atmospheric Research* (NCAR), la *National Oceanic and Atmospheric Administration* (NOAA), el *National Center for Environmental Prediction* (NCEP), el *Earth System Research Laboratory* (ESRL), la *Air Force Weather Agency* (AFWA), el *Naval Research Laboratory* (NRL), el *Center for Analysis and Prediction Storms* (CAPS) y la *Federal Aviation Administration* (FAA). El código del modelo está abierto a la comunidad y ha sido optimizado de manera que puede ser adaptado tanto a supercomputadoras que trabajan en paralelo como a computadoras personales. El modelo es muy versátil y se puede usar en una gran diversidad de aplicaciones, tales como simulaciones idealizadas, simulaciones reales (predicción numérica en tiempo real), modelación de la calidad del aire y estudios de interacción océano-atmósfera mediante el acoplamiento con modelos oceánicos.

Los principales componentes del modelo WRF se muestran en la Figura 4. El *WRF Software Framework* (WSF) contiene los códigos que incorporan la física al modelo (*dynamic solvers*), los módulos físicos que constituyen la interfaz con los códigos y los programas para la inicialización. También se localizan aquí los códigos necesarios para realizar asimilación de datos y para emplear algunas opciones relacionadas con la química atmosférica. Fuera del WSF se encuentra la parte de preprocesamiento y postprocesamiento de las simulaciones numéricas. El sistema de preprocesamiento del WRF (*WRF Preprocessing System* o WPS) es un conjunto de tres programas cuya tarea colectiva es preparar la entrada para el programa que realiza las simulaciones de datos reales (*real.exe*). Cada uno de los programas realiza una etapa de la preparación: *geogrid* define los dominios del modelo e interpola los datos geográficos estáticos (tales como terreno, uso de suelo, tipos de suelo, etc.) a las mallas especificadas para las simulaciones; *ungrib* extrae los campos meteorológicos de archivos con formato GRIB; y *metgrid* interpola horizontalmente los campos meteorológicos extraídos por *ungrib* a las mallas del modelo definidas mediante *geogrid* (WRF, 2017).




Figura 4. Diagrama de los componentes del núcleo WRF-ARW.

El modelo cuenta con dos núcleos dinámicos que resuelven las ecuaciones de los procesos físicos, el Advanced Research WRF (ARW) y el Nonhydrostatic Mesoscale Model (NMM). En la configuración desarrollada para el MMOM se utilizará el núcleo ARW, cuyas características se describen brevemente a continuación.

Núcleo WRF-ARW

El núcleo ARW es el componente donde se inicializa el modelo para cualquiera de los casos de simulación, ideales o reales. En este núcleo también se lleva a cabo la integración numérica del dominio principal y de los anidamientos. Las características del núcleo ARW son las siguientes:

- **Ecuaciones:** Totalmente compresibles, no-hidrostáticas, basadas en flujo *euleriano*, con una opción hidrostática. Conservativas para variables escalares.

- **Variables de pronóstico:** Componentes de la velocidad, u y v , en coordenadas Cartesianas, velocidad vertical w , perturbación de temperatura potencial, perturbación geopotencial, y perturbación de presión superficial del aire seco. Opcionalmente, energía cinética turbulenta y cantidades escalares tales como las razones de mezcla del vapor de agua, lluvia/nieve y agua de nube/hielo.
- **Coordenada vertical:** Coordenada que sigue el terreno y que permite un estiramiento en los niveles verticales. El límite superior del modelo es una superficie de presión constante.
- **Malla horizontal:** Malla escalonada tipo Arakawa C.
- **Integración en tiempo:** Esquema Runge-Kutta de 2do y 3er orden con paso de tiempo menor para ondas acústicas y de gravedad.
- **Discretización espacial:** Opciones de advección de 2do a 6to orden en la horizontal y vertical.
- **Mezcla turbulenta y filtros:** Formulación de turbulencia en escala de sub-malla, tanto en el espacio físico como de coordenadas. Opción de filtro explícito.
- **Condiciones iniciales:** En tres dimensiones para datos reales, y en una, dos y tres dimensiones para datos idealizados.
- **Condiciones de frontera laterales:** Periódicas, abiertas y simétricas. Para casos reales, especificadas con zona de relajación.
- **Condiciones de frontera en el límite superior:** Absorción de ondas de gravedad (difusión, amortiguamiento de Rayleigh). Nivel de presión constante en la frontera superior a lo largo de una superficie material. Opción de tapa rígida.
- **Condiciones de frontera en superficie:** Física o de deslizamiento libre (*free-slip*).
- **Rotación de la Tierra:** Se incluyen los términos completos de Coriolis.
- **Maapeo:** Incluye cuatro proyecciones para simulaciones reales: polar estereográfica, conforme de Lambert, Mercator, y latitud-longitud. Incluye términos de curvatura.
- **Anidamientos (*Nesting*):** Unidireccionales interactivos, bi-direccionales interactivos y movibles, estos últimos pueden usarse con un conjunto de movimientos prescritos o con un algoritmo que permite al dominio seguir el movimiento de un vórtice.
- **Nudging:** Capacidad para *nudging* de malla y de observaciones.
- **Malla global:** Cuenta con capacidad para realizar simulaciones globales (usando un filtro polar de Fourier y condiciones periódicas este-oeste).

El ARW incluye parametrizaciones para representar diversos procesos físicos, como por ejemplo:

- **Microfísica:** Esquemas simplificados para simulaciones idealizadas y esquemas complejos que incorporan explícitamente procesos de precipitación, vapor de agua y nubes.

- **Parametrizaciones de cúmulus:** Esquemas de ajuste y flujo de masa para la modelación de mesoescala.
- **Física de superficie:** Modelos de superficie multi-capas que van desde un modelo térmico simple hasta modelos completos de vegetación y humedad del suelo, incluyendo cubierta de nieve y hielo marino.
- **Capa límite planetaria:** Esquema de energía cinética turbulenta o esquemas no locales.
- **Física de radiación atmosférica:** Esquemas de onda corta y onda larga con múltiples bandas espectrales y un esquema simple de onda corta adecuado para aplicaciones de clima y tiempo. Incluye efectos de nubes y flujos superficiales.

Postprocesamiento y visualización

Esta componente del modelo depende totalmente del usuario, pues existe una gran cantidad de herramientas gráficas que pueden ser utilizadas para visualizar las simulaciones numéricas. Algunas de estas opciones son: NCAR Command Language (NCL), Read/Interpolate/Plot (RIP4), Grid Analysis and Display System (GrADS), Vis5D, Visualization and Analysis Platform for Ocean, Atmosphere, and Solar Researchers (VAPOR), General Equilibrium Modelling Software (GEMPAK) y MATrix LABoratory (MATLAB).

1.2.2. El modelo WAVEWATCH III

El modelo WAVEWATCH III (Tolman, 1991, 1996, 2009) es un modelo de predicción de oleaje de tercera generación desarrollado en la NOAA/NCEP como un sucesor del modelo WAM (WAMDIG, 1998; Komen et al., 1994). Este modelo es utilizado para predecir la evolución del oleaje generado por viento haciendo uso de métodos numéricos. Las simulaciones de predicción de oleaje consideran, entre otras cosas, el forzamiento del viento, las interacciones no lineales, el cambio en la amplitud por someramiento y la disipación por fricción. Entre las variables de salida de este modelo se encuentran la altura significativa de ola, la dirección de propagación y el periodo. El pronóstico se puede realizar tanto para mares regionales como para océanos globales. El WAVEWATCH III (WWIII) es actualmente el modelo utilizado por la NOAA en forma operativa para las costas de los Estados Unidos.

Se eligió este modelo para el sistema de pronósticos MMOM debido a que tiene ventajas en la implementación de los anidamientos dinámicos. El modelo WWIII también tiene implementados algunos cambios en los parámetros de forzamiento cuando los vientos superan los 28 m/s, lo que

redunda en mejores simulaciones en esas condiciones, particularmente con la presencia de huracanes.

Características físicas del modelo WWIII

Las ecuaciones gobernantes del modelo WWIII incluyen refracción y tensión del campo de onda debido a variaciones temporales y espaciales de la profundidad promedio del agua y de la corriente promedio. Las parametrizaciones de los procesos físicos (términos fuente) incluyen: crecimiento y decaimiento de la onda debido a la acción del viento, interacciones de resonancia no lineales, disipación (*whitecapping*), fricción de fondo, rompimiento y dispersión debida a interacciones con el fondo. La propagación de la ola se considera lineal, y los efectos no lineales más relevantes son incluidos dentro de los términos fuente.

Parametrizaciones del modelo WWIII

En aguas profundas, el término fuente neto (S) se considera generalmente conformado por tres términos: un término de interacción ola-viento (S_{in}); un término de interacciones no lineales (S_{nl}), y un término de disipación “whitecapping” (S_{ds}). El término de entrada, S_{in} , está dominado por el término de crecimiento exponencial, y generalmente describe únicamente este proceso dominante. Para la inicialización del modelo, y para proveer un crecimiento inicial de ola más realista, se puede considerar un término de entrada lineal S_{ln} .

En aguas someras deben de considerarse varios procesos adicionales, principalmente las interacciones con el fondo (S_{bot}). En aguas extremadamente someras, los términos de frenado inducido por la profundidad (S_{db}) y de interacción onda-onda (S_{tr}) se vuelven importantes. Dentro del modelo WWIII también se encuentran disponibles términos fuente para la dispersión de olas por características del fondo (S_{sc}), y un espacio adicional para términos fuente definidos por el usuario (S_{xx}). Esto define los términos fuente generales usados en WWIII como:

$$S = S_{ln} + S_{in} + S_{nl} + S_{ds} + S_{bot} + S_{db} + S_{tr} + S_{sc} + S_{xx}$$

Componentes del modelo WWIII

El modelo WWIII posee una estructura modular, es decir, consta de un conjunto de subprogramas de preprocesamiento, procesamiento y postprocesamiento. Los programas de preprocesamiento se

encargan de aspectos tales como la malla, la física, las condiciones iniciales, los campos de entrada y las condiciones de frontera externas. Los programas de postprocesamiento se encargan de dar distintos formatos a los datos de salida del modelo: ASCII, binario, GRIB, GRIB2, NetCDF y GrADS. En la Figura 5 se muestran los elementos básicos del modelo WWIII (*grid preprocessor*, *input preprocessor*, *initial conditions*, *wave model* y *output postprocessing*), junto con el flujo de datos.




Figura 5. Esquema de los elementos básicos del modelo WWIII y del flujo de datos.

1.2.3. El modelo ADCIRC

El pronóstico de marea de tormenta se llevará a cabo utilizando el modelo ADvanced CIRCulation Model (ADCIRC), el cual es un modelo de última generación que también está en período de implementación por parte de la NOAA y es, en muchos sentidos, superior al modelo SLOSH que se había venido utilizando en forma operacional en los últimos años. El ADCIRC consiste en un conjunto

de códigos computacionales que resuelven problemas de transporte y circulación de la superficie libre del mar dependientes del tiempo. Este modelo resuelve las ecuaciones de movimiento para un fluido en movimiento en una Tierra en rotación, utilizando las aproximaciones hidrostática y de Boussinesq, discretizadas en espacio utilizando el método de elemento finito y en tiempo el de diferencias finitas. Una de las ventajas de este modelo es que corre sobre mallas no estructuradas, por lo que es posible tener muy alta resolución en la zona costera. El ADCIRC se puede correr tanto en coordenadas esféricas como cartesianas.

Las condiciones de frontera en el ADCIRC incluyen:

- Elevación especificada (constituyentes armónicos de marea o series de tiempo de valores del nivel del mar en la frontera abierta).
- Flujo normal especificado (constituyentes armónicos de marea o series de tiempo de valores del nivel del mar en la frontera abierta).
- Flujo normal nulo.
- Condiciones de deslizamiento y no-deslizamiento para la velocidad.
- Desbordamiento de agua sobre la barrera externa fuera del dominio.
- Desbordamiento de agua sobre una barrera interna entre secciones dentro del dominio.
- Esfuerzo en la superficie (esfuerzo de radiación por olas/viento).
- Presión atmosférica.
- Radiación de olas hacia el exterior (condición de Sommerfield).

El modelo ADCIRC puede ser forzado por:

- Condiciones de frontera de elevación.
- Condiciones de flujo normal.
- Condiciones de esfuerzo superficial.
- Potencial de marea.

I.3. CONFIGURACIÓN DE LOS MODELOS

A continuación se presenta una descripción detallada de las configuraciones que se implementarán para realizar las simulaciones numéricas con cada uno de los modelos del sistema de pronóstico, incluyendo las características de los dominios, las condiciones iniciales y de frontera, y algunos ejemplos del tipo de productos gráficos que se generarán.

I.3.1. Configuración del modelo WRF

En el desarrollo del MMOM se utilizará la versión más actual del modelo WRF, la 3.8.1 (WRF, 2017). La configuración del modelo WRF que se usará en el sistema ha sido diseñada para realizar un pronóstico de tipo operativo para los mares mexicanos y zonas adyacentes, incluyendo parte del Mar Caribe con el objeto de dar seguimiento a los ciclones tropicales que puedan afectar las costas nacionales. Esta configuración incluirá los desarrollos previos con que cuenta el sistema de pronóstico del CCA-UNAM, incluyendo la actualización de la capa con información de uso y cobertura de suelo.

Dominios

Para satisfacer las necesidades del MMOM, el dominio abarcará los mares mexicanos y las zonas de influencia de marea de tormenta (aunque éste puede cambiar al realizarse las evaluaciones preliminares del sistema). En principio, su extensión cubrirá la región de 10°N a 35°N y de 120°W a 75°W, con una resolución de 21 km en la horizontal y al menos 27 niveles en la vertical. Asimismo, se implementará un anidamiento para la parte central de México, cubriendo un dominio que va de 15°N a 22°N y de 106°W a 94°W con una resolución horizontal de 7 km.

Parametrizaciones físicas

A continuación se especifican los esquemas que serán utilizados en la configuración del modelo para representar los distintos procesos físicos:

- Esquema *Dudhia* para la radiación de onda corta. Representa el flujo de energía solar que llega a la atmósfera considerando la absorción del vapor de agua y la absorción y albedo de las nubes.
- Esquema *Rapid Radiative Transfer Model* (RRTM) para radiación de onda larga. Este esquema utiliza valores predeterminados en tablas que representan los procesos de radiación de onda

larga debidos al vapor de agua, ozono, CO₂ y gases traza (si existen), considerando también las propiedades ópticas de la nube en función de su profundidad.

- Esquema *Kain-Fritsch* para la parametrización de cúmulus. Es utilizado para representar los procesos convectivos por medio de un modelo que considera las corrientes verticales de aire húmedo en ambos sentidos.
- Esquema *Yonsei University* para la capa límite planetaria. Este esquema se encarga de representar los flujos verticales pequeños que son resultado del transporte turbulento en toda la columna atmosférica.

Condiciones iniciales y de frontera

Los datos que se utilizarán para especificar las condiciones iniciales y de frontera para el modelo WRF se tomarán de las salidas del modelo GFS para las 00:00 horas GMT.

Productos gráficos


La ejecución del modelo produce un conjunto de datos de salida que son los valores pronosticados de las variables meteorológicas para el dominio especificado. De los campos resultantes se elegirán y combinarán, para su visualización, los siguientes:

- a) Intensidad y dirección del viento a 10 m sobre la superficie y presión reducida al nivel del mar (PRNM), de 0 a 120 horas en incrementos de 1 hora para todo el dominio.
- b) Temperatura del aire cerca de la superficie (2 m).
- c) Precipitación acumulada cada hora, 3-horas y 24-horas.
- d) Cizalla vertical del viento horizontal.
- e) Viento en altura y divergencia.
- f) Viento en superficie y divergencia.
- g) Velocidad vertical en altura y en superficie.
- h) Nubosidad.
- i) Líneas de corriente en altura y precipitación acumulada.
- j) Líneas de corriente en superficie y precipitación acumulada.
- k) Agua precipitable por espesores.
- l) Temperatura potencial equivalente en altura y en superficie.
- m) Temperatura y PRNM.
- n) Viento en altura y altura geopotencial.
- o) Viento en altura y humedad relativa.
- p) Viento en altura y vorticidad relativa.


- q) Viento en superficie y humedad relativa.
- r) Viento en superficie y vorticidad relativa.
- s) Termodiagramas.
- t) Meteogramas (combinados con series de nivel del mar y oleaje en donde corresponda).

Para el graficado de las simulaciones numéricas se usará el software *NCAR Command Language* (NCL). A continuación se muestran algunos gráficos de ejemplo de las salidas del WRF (Figura 6).


a) Temperatura en superficie y PRNM



b) Viento en superficie y humedad relativa (Dom 2)



c) Precipitación acumulada



d) Temperatura potencial equivalente en superficie




Figura 6. Ejemplos de productos gráficos de las salidas del modelo WRF para distintas variables y combinaciones de ellas.

1.3.2. Configuración del modelo WWIII

Para el pronóstico de oleaje se utilizará la versión 5.16 del modelo WWIII, la cual fue liberada públicamente el 31 de octubre de 2016. Como se mencionó antes, el WWIII fue elegido para el MMOM debido a las ventajas que tiene en cuanto a la implementación de anidamientos dinámicos.

Dominios

El WWIII se correrá en tres dominios: uno que abarca la mayor parte del océano Pacífico (que denominaremos Océano Pacífico) con una resolución de un grado (~111 km); otro que abarca las costas mexicanas adyacentes al Pacífico (que denominaremos Pacífico Mexicano) con una resolución de 21 km; y el tercero que incluye al Golfo de México y parte del Mar Caribe (que denominaremos Golfo de México), también con una resolución de 21 km. En la Figura 7 se muestran las regiones que abarcarán los tres dominios usados en el WWIII.




Figura 7: Dominios que serán utilizados en el modelo WWIII: Golfo de México-Mar Caribe (arriba izq.); Pacífico Mexicana (arriba der.), y Océano Pacífico (abajo).

El dominio del Océano Pacífico se utilizará para generar las condiciones de frontera para el dominio del Pacífico Mexicano. Esto es importante debido a que se ha observado la ocurrencia de fenómenos de marejada o mar de fondo (*swell*) en las costas mexicanas que se originan en el hemisferio sur, a varios miles de kilómetros de distancia de las costas mexicanas.

Condiciones iniciales

Los datos de entrada necesarios para correr el WWIII sobre el dominio del Océano Pacífico se tomarán del modelo de escala global GFS, y para los dominios del Pacífico Mexicano y Golfo de México-Mar Caribe se tomarán de la salida del modelo meteorológico WRF. La ventaja de los datos del WRF es que tienen mayor resolución espacial y temporal, lo cual permite simular más adecuadamente las variaciones de los vientos observados cerca de las costas mexicanas. La variable atmosférica utilizada como entrada es el viento a 10 m sobre la superficie, la cual se interpolará a las distintas mallas del modelo.

Productos gráficos

Los productos gráficos que se generarán incluyen mapas de altura significativa de ola (en metros), período y dirección promedio de propagación. Los pronósticos se realizarán para un intervalo de 120 horas a partir de la incorporación de las condiciones iniciales de viento, con salidas cada hora para los dominios descritos en la sección previa. La altura significativa se graficará en una escala cromática, cubriendo un rango de 11 metros. La dirección de propagación se representará, de manera natural, mediante vectores. La Figura 8 muestra ejemplos de productos gráficos de las salidas del modelo WWIII para la altura significativa de ola y dirección promedio de propagación en los tres dominios.




Figura 8. Ejemplos de productos gráficos de las salidas del modelo WWIII de la altura significativa de ola (m) (contornos en color) y dirección promedio de propagación (vectores) para los tres dominios.

El periodo de la ola se graficará en una escala cromática, cubriendo un rango de 20 segundos. La Figura 9 muestra ejemplos de productos gráficos de las salidas del modelo WWIII para el periodo y la dirección de propagación de la ola en los tres dominios.




Figura 9. Ejemplos de productos gráficos de las salidas del modelo WWIII para el periodo (s) (contornos en color) y la dirección de propagación de la ola (vectores) para los tres dominios.

1.3.3. Configuración del modelo ADCIRC

En el sistema de pronóstico propuesto se correrá el modelo ADCIRC en dos dimensiones integrado en la vertical.

Dominios

El ADCIRC se implementará en dos dominios: uno que cubre el Golfo de México y la región noroccidental del Mar Caribe, con coordenadas 99°W a 81°W y de 16°N a 30.50°N, y otro que abarca el Pacífico Mexicano y zonas adyacentes, con coordenadas 123.55°W a 75°W y de 4.40°N a 38.81°N. La resolución a lo largo de las costas mexicanas será de aproximadamente 500 m. En las Figuras 10 y 11 se presentan ejemplos de mallas no estructuradas similares a las que se usarán para las simulaciones en ambos dominios.




Figura 10. Visualización de los nodos de una malla no estructurada para el Golfo de México y región noroccidental del Mar Caribe, con mayor resolución en la zona costera, similar a la que se usará en el modelo ADCIRC. La imagen de la derecha muestra un acercamiento a la isla de Cozumel.




Figura 11. Visualización de los nodos de una malla no estructurada para el Pacífico Mexicano, con mayor resolución en la zona costera y zonas insulares, similar a la que se usará en el modelo ADCIRC. La imagen de la derecha muestra un acercamiento a la zona sur de la península de Baja California.

Condiciones iniciales y de frontera

Para los forzamientos se utilizarán los vientos y presión atmosférica obtenidos del pronóstico meteorológico realizado con el modelo WRF. Para las condiciones de frontera abierta se incluirán los ocho armónicos de marea más importantes para cada cuenca tomados de la base TPXO. Los componentes de la marea astronómica que serán usados son: M2, S2, K2, N2, K1, O1, P1 y Q1.

Productos gráficos

Se generarán mapas de anomalía del nivel del mar para el Pacífico Mexicano y para el Golfo de México y parte del Mar Caribe. También se producirán series de tiempo de nivel del mar para al menos 20 sitios frente a ciudades o puertos importantes de México. En la Figura 12 se muestran ejemplos de las salidas del modelo ADCIRC en donde se representa el nivel del mar en falso color.




Figura 12. Pronóstico de nivel del mar para el Pacífico (izquierda) y el Golfo de México-Mar Caribe (derecha) simulados con el modelo ADCIRC. En el gráfico de la derecha se muestra el pronóstico de la elevación del nivel del mar asociada con el paso del huracán Wilma en 2005.

I.4. VISUALIZACIÓN DE LOS PRONÓSTICOS Y CÁLCULO DE INCERTIDUMBRES

I.4.1. Módulos para la visualización

Para la visualización de los pronósticos se construirán dos módulos complementarios. Uno con gráficos e información preprocesada que sintetizará las alertas y permitirá visualizar una gran variedad de productos gráficos, y el otro, de última generación, que servirá para presentar en forma interactiva mapas en la web con las variables más importantes.

Para visualizar la información en el primer módulo se desarrollará software para construir un sitio web con las especificaciones más rigurosas para sitios de Internet, que permita el despliegue con diferentes navegadores y sistemas operativos sin la necesidad de algún controlador adicional, como por ejemplo Flash. El portal se desarrollará en una plataforma LAMP (Linux-Apache-MySQL-PHP) el cual se implementará en un servidor de visualización, que es parte del sistema de pronóstico.

El segundo módulo estará basado en la aplicación web de código abierto OWGIS (Zavala-Romero et al., 2014), que está desarrollada principalmente en Java y Javascript. Este software se utiliza para generar, de forma dinámica, sitios web de Sistemas de Información Geográfica (o GIS por sus siglas en inglés). OWGIS se ha utilizado para generar páginas web que despliegan distintos datos georeferenciados, entre ellos datos oceanográficos y atmosféricos. Las páginas web creadas con OWGIS permiten visualizar y analizar datos georeferenciados a partir de animaciones temporales, series de tiempo, perfiles verticales, transectos, animaciones de líneas de corriente y viento, proyecciones en 3D, etc. De igual forma, OWGIS facilita el uso de distintas paletas de colores, la generación de páginas web en distintos idiomas, la descarga de datos, así como el despliegue de los datos en dispositivos móviles.

I.4.2. Incertidumbres

Para la parte del cálculo y la visualización de las incertidumbres de los modelos, se integrará al sistema un estimador de la incertidumbre de los pronósticos para determinadas variables y un identificador de eventos extremos. Para ello, se implementarán las siguientes acciones:

- Se entrenará al sistema realizando pronósticos durante un período de al menos un año.
- Se calcularán los errores en cada pronóstico y se generarán las distribuciones de probabilidad correspondientes.

- Los errores serán calculados para las variables de precipitación acumulada, temperatura y magnitud del viento.
- Con base en la estimación de los errores de pronósticos históricos, se calcularán intervalos de confianza para los valores medios y extremos de las distintas variables pronosticadas.
- Se eliminarán los errores sistemáticos y se incluirá el rango de incertidumbre para sitios específicos.
- Las alertas para eventos extremos se construirán con base en la climatología de cada región.

I.5. HARDWARE EN EL CUAL SE INSTALARÁ EL SISTEMA DE PRONÓSTICO

El sistema de pronóstico numérico MMOM incluirá un servidor para correr los modelos y los programas de graficado, preprocesado y postprocesado de la información; una computadora/servidor de visualización para el almacenamiento de los pronósticos históricos y el despliegue gráfico de los pronósticos; un ruteador para distribuir la información y tener conexión directa de equipos, y un switch para la conexión de los equipos a Internet. Además se incluirán otros componentes, como unidades UPS y cableado de diversos tipos. En la Figura 13 se muestra un esquema del hardware del cual estará compuesto el equipo.

Se propone implementar el sistema de pronóstico en un equipo de memoria distribuida con la siguiente configuración (ésta puede cambiar de acuerdo con el avance de las tecnologías, pero en cualquier caso tendrá una capacidad similar o superior).

Sistema de memoria distribuida para simulación numérica intensiva

i. Componentes de hardware

- **NODO MAESTRO**
 - 2 Procesadores Intel Xeon E5-2683 v4
 - 256 GigaBytes de RAM usando módulos de 16 GB en bus de 2400 MHz DDR4
 - 2 puertos ethernet de 1 Gbps
 - Un puerto de comunicaciones Infiniband FDR de 56 Gbps
 - Dos discos duros de estado sólido de 1 TB en RAID 1 para el sistema principal
 - Almacenamiento interno en RAID 6 de capacidad mínima de 20TB
- **NODOS DE PROCESAMIENTO**
 - 2 Procesadores Intel Xeon E5-2680 v4

- 128 GigaBytes de RAM usando módulos de 16 GB en bus de 2400 MHz DDR4
- 2 puertos ethernet de 1 Gbps
- Un puerto de comunicaciones Infiniband FDR de 56 Gbps
- Almacenamiento interno en una unidad SSD de 200GB

ii. Componentes de software

- Sistema operativo Linux CentOS
- Sistema de instalación, configuración y administración de clusters
- Sistema de procesamiento por lotes de trabajos seriales y paralelos de usuario
- Sistema de monitoreo web de recursos de cómputo
- Sistema de administración física-remota
- Herramientas de desarrollo *open source* (libres)
- Herramientas de desarrollo comerciales

iii. Componentes de interconexión

- 1 red de datos InfiniBand FDR
- 1 red de datos Ethernet Gigabit




Figura 13. Esquema de componentes de hardware similar al que se implementará para el sistema de pronósticos MMOM.

I.6. REFERENCIAS BIBLIOGRÁFICAS (CAPÍTULO I)

Acevedo Rosas, F. y Luna Díaz-Peón, A. (2006): Principales fenómenos meteorológicos que afectaron al Estado de Veracruz en el año 2005. En: *Inundaciones 2005 en el Estado de Veracruz*. Tejeda-Martínez, A. y C. Welsh-Rodríguez (Eds). Universidad Veracruzana, México.

Botello, A. V., J. Rendón von Osten, G. Gold-Bouchot y C. Agraz-Hernández (2005): Golfo de México, contaminación e impacto ambiental: Diagnóstico y tendencias. 2da. Ed. Universidad Autónoma de Campeche, UNAM, Instituto Nacional de Ecología, 696 p., México.

CENAPRED (2001): Diagnóstico de Peligros e Identificación de Riesgos de Desastres en México. Centro Nacional de Prevención de Desastres, SEGOB, Sistema Nacional de Protección Civil. ISBN: 970-628-593-8, 232 p., México.

CENAPRED (2014): Folleto "Ciclones Tropicales". Versión electrónica. Centro Nacional de Prevención de Desastres. ISBN: 978-970-821-008-9, 35 p., México.

Komen, G. J., L. Cavaleri, M. Donelan, K. Hasselmann, S. Hasselmann and P. A. E. M. Janssen (1994): *Dynamics and Modelling of Ocean Waves*. Cambridge University Press, 532 pp.

Luetlich, R. A. and J. J. Westerink (2004): *Formulation and Numerical Implementation of the 2D/3D ADCIRC Finite Element Model Version 44.XX*, 74 pp. URL http://www.adcirc.org/adcirc_theory_2004_12_08.pdf

NHC (2013): Hurricane Sandy (AL182012). 22-29 October 2012. National Hurricane Center Tropical Cyclone Report. 157 pp.

NHC (2015): Hurricane Odile (EP152014). 10-18 September 2014. National Hurricane Center Tropical Cyclone Report. 26 pp.

Skamarock, W. C., Klemp, J. B., Dudhia, J., Gill, D. O., Barker, D. M., Duda, M. G., Huang, X., Wang, W., Powers, J. G. (2008): A description of the Advanced Research WRF Version 3, NCAR Tech. Note. NCAR/TN-475+STR, 113 pp.

Tolman, H. L. (1991): A third-generation model for wind waves on slowly varying, unsteady and inhomogeneous depths and currents. *J. Phys. Oceanogr.*, 21, 782–797.

Tolman, H. L. and D. V. Chalikov (1996): Source terms in a third-generation wind-wave model. *J. Phys. Oceanogr.*, 26, 2497–2518.

Tolman, H. L. (2009): User Manual and System Documentation of WAVEWATCH III version 3.14, U. S. Department of Commerce; NOAA; NWS; NCEP.

WAMDI (1988): The WAM Model - A Third Generation Ocean Wave Prediction Model. *J. Phys. Oceanogr.*, 18, 1775–1810, doi: 10.1175/1520-0485(1988)018<1775:TWMTGO>2.0.CO;2.

Wang, H. V., and Y. Teng. Modeling Forerunner of the Storm Surge in the Gulf of Mexico -- Implication on Anomalous Water Levels Induced by Typhoons in Taiwan Strait. International Workshop on Coastal Observation and Sediment Transport in Coastal Zones, Taiwan, 06-27-2011.

WRF (2017): WRF-ARW Version 3 Modeling System User's Guide. NCAR.

Zavala-Romero, O., A. Ahmed, E. P. Chassignet, J. Zavala-Hidalgo, A. Fernández-Eguiarte, A. Meyer-Baese (2014): An open source Java web application to build self-contained web GIS sites. *Environmental Modelling & Software*, 62, 210-220. DOI: 10.1016/j.envsoft.2014.08.029.

CAPÍTULO II

BASES TEÓRICAS DE LA VALIDACIÓN DE PRONÓSTICOS NUMÉRICOS Y ESTRATEGIAS DE VERIFICACIÓN

II.1. INTRODUCCIÓN

La verificación de un pronóstico es el proceso de evaluar su calidad y es una parte indispensable en la investigación meteorológica y en las actividades del pronóstico operacional. Dicho proceso consiste en comparar el pronóstico contra una observación de lo que ocurrió en la realidad o contra alguna buena estimación del resultado verdadero (CAWCR; Wilks, 2006). Existe una amplia variedad de métodos para la verificación de pronósticos, pero todos ellos involucran medidas de la relación entre el valor pronosticado y la observación correspondiente (Wilks, 2006). Si se diseña adecuadamente la metodología, los resultados de la verificación pueden satisfacer efectivamente las necesidades de grupos muy diversos, incluyendo modeladores, pronosticadores y usuarios de la información de los pronósticos (Casati et al., 2008). La verificación puede ser cualitativa o cuantitativa; en ambos casos debe proporcionar información respecto a la naturaleza de los errores del pronóstico.

La verificación de pronósticos no fue una rama de investigación muy activa en la primera mitad del siglo XX; sin embargo, a partir de 1950, con el advenimiento de pronósticos meteorológicos numéricos, se dió una considerable expansión de productos de pronóstico del tiempo que estuvo acompañada por un esfuerzo de investigación sobre cómo evaluar los pronósticos realizados (Jolliffe, 2012). En 1987, Murphy and Winkler establecieron un marco de referencia general para la verificación de pronósticos basado en la distribución de probabilidad conjunta del evento pronosticado y el evento observado. Durante los 90's se publicaron discusiones sobre la complejidad y dimensionalidad de la verificación de pronósticos y acerca de lo que constituye un “*buen*” pronóstico (Murphy, 1991 y 1993). En particular, Murphy (1993) escribió un ensayo sobre las tres características que hacen bueno a un pronóstico: la consistencia, la calidad y el valor. Asimismo, la Organización Meteorológica Mundial (OMM) publicó un reporte técnico que proporciona una revisión completa de los métodos de verificación de pronósticos usados a finales de los 80's (Stanski et al., 1989). Actualmente la OMM proporciona un Sistema de Verificación Estándar para Pronósticos de Largo Plazo (Standard Verification System for Long-Range Forecasts), que incluye áreas y datos de verificación, estrategias de verificación recomendadas y puntajes de evaluación.

En general, las razones para realizar la verificación de un pronóstico se pueden clasificar en administrativas, científicas y económicas. El punto de vista científico está relacionado con el entendimiento y, en consecuencia, con el mejoramiento del sistema de pronóstico. Una evaluación detallada de las fortalezas y debilidades de un conjunto de pronósticos generalmente requiere de varios puntajes. Una mayor inversión en esquemas de verificación complejos resultará en una mejor apreciación sobre las deficiencias del pronóstico y, con ello, en la posibilidad de mejorar el entendimiento de los procesos físicos que están siendo pronosticados (Jolliffe, 2012). Algunas de las razones más importantes para verificar los pronósticos son: (a) monitorear la calidad de los pronósticos en el tiempo, (b) comparar la calidad de diferentes sistemas de pronóstico, y (c) mejorar la calidad de los pronósticos a través de una mejor comprensión de sus errores (WMO, 2008). En última instancia, la justificación para la realización de un pronóstico es para apoyar una mejor toma de decisiones; esto dependerá de las características de sus errores, las cuales se harán evidentes a través de los métodos de verificación (Wilks, 2006).

II.2. TIPOS DE PRONÓSTICOS Y DATOS PARA SU VERIFICACIÓN

Los ensambles de pronósticos que incluyen predicciones de diversas variables meteorológicas en diferentes tiempos, sitios y niveles verticales, son extremadamente difíciles de verificar de manera exhaustiva, pero aún la verificación de pronósticos binarios (ocurre o no ocurre, 0-1) puede estar lejos de ser un problema trivial. En la mayoría de las circunstancias es altamente deseable que un sistema de verificación sea objetivo; para que esto suceda, debe tenerse claro lo que se está pronosticando y el proceso de verificación debe, idealmente, reflejar el pronóstico con precisión (Jolliffe, 2012).

Hay muchos tipos de pronósticos, cada uno de los cuales requiere de métodos de verificación ligeramente distintos, aunque generalmente es posible convertir de un tipo de pronóstico a otro simplemente reacomodando, categorizando o estableciendo umbrales para los datos. En la Tabla siguiente se resumen los distintos tipos de pronósticos y los métodos de verificación que se usan comúnmente en cada caso, mencionando algunos ejemplos particulares (CAWCR).

	Ejemplos	Métodos de verificación
Naturaleza del pronóstico:		
Determinístico (no probabilístico)	Pronóstico cuantitativo de precipitación	Visual, dicotómico, multi-categoría, continuo, espacial

Probabilístico	Probabilidad de precipitación, pronóstico de ensamble	Visual, probabilístico, ensamble
Cualitativo (con palabras, redactado)	Pronóstico a 5 días	Visual, dicotómico, multi-categoría
Dominio espacio-tiempo:		
Series de tiempo	Pronósticos de temperatura máxima diaria para una ciudad	Visual, dicotómico, multi-categoría, continuo, probabilístico
Distribución espacial	Mapa de altura geopotencial, carta de lluvia	Visual, dicotómico, multi-categoría, continuo, probabilístico, espacial, ensamble
Conjunto espacio y tiempo	Anomalía promedio mensual global de temperatura	dicotómico, multi-categoría, continuo, probabilístico, ensamble
Especificidad del pronóstico:		
Dicotómico (sí/no)	Ocurrencia de neblina	Visual, dicotómico, probabilístico, espacial, ensamble
Multi-categoría	Condiciones frías, normales o cálidas	Visual, multi-categoría, probabilístico, espacial, ensamble
Continuo	Temperatura máxima	Visual, continuo, probabilístico, espacial, ensamble
Orientado a un objeto o evento	Desplazamiento e intensidad de un ciclón tropical	Visual, dicotómico, multi-categoría, continuo, probabilístico, espacial

Junto con un incremento en los tipos de pronóstico disponibles, también han habido cambios en la cantidad y naturaleza de los datos disponibles para verificar los pronósticos. Los cambios en los datos incluyen cambios en las estaciones de observación, cambios de ubicación y tipo de instrumentos de medición, y en la cantidad creciente de datos obtenidos remotamente por satélites, radares o dispositivos de registro automáticos. Por ejemplo, supongamos que un pronóstico de lluvia para una región va a ser verificado y que existe un cambio inevitable en el conjunto de estaciones usadas para la verificación. Si el promedio o la variabilidad de la lluvia es diferente para el nuevo conjunto de estaciones comparado con el anterior, tales diferencias pueden afectar muchos de los puntajes usados para la verificación (Jolliffe, 2012; AMS, 2015).

Otro ejemplo ocurre en el pronóstico estacional del número de ciclones tropicales. Existe evidencia de que el acceso a un registro más amplio de imágenes satelitales ha conducido a redefiniciones de los ciclones a través de los años. En consecuencia, las tendencias aparentes en la frecuencia de

ciclones pueden deberse a cambios de definición en lugar de una tendencia climática genuina. Esto, a su vez, hace difícil saber si los cambios en los métodos de pronóstico han dado como resultado una mejoría en la calidad de los pronósticos (Jolliffe, 2012).

II.3. CARACTERÍSTICAS DE UN BUEN PRONÓSTICO

Para un tipo de datos dado, es sencillo construir un puntaje numérico que mida la calidad relativa de diferentes pronósticos. Ciertamente, existe todo un rango de puntajes posibles. Cualquier conjunto de pronósticos puede entonces jerarquizarse como el mejor, el segundo mejor, ..., el peor, de acuerdo a un puntaje elegido, aunque la jerarquización no necesita ser la misma para diferentes elecciones del puntaje. Surgen entonces dos preguntas: ¿Cómo elegir los puntajes a usar? y ¿Cómo evaluar la calidad absoluta, en lugar de la relativa, de un pronóstico?. Para abordar la primera de estas preguntas se han hecho intentos para definir las propiedades deseables de los puntajes potenciales (Jolliffe, 2012). La mayoría de los puntajes tienen algunas fortalezas, pero todos tienen debilidades, y en la mayoría de las circunstancias se requiere más de un puntaje para obtener un panorama informado de los méritos relativos de los pronósticos. Por ello, un sistema de verificación a menudo incluirá el cálculo de varias medidas, elegidas para describir los atributos que son más pertinentes para cumplir con el objetivo de la verificación (Jolliffe, 2012).

Los atributos que contribuyen a la calidad de un pronóstico son (según Murphy, 1993 y Wilks, 2006):

Sesgo – Es la correspondencia entre la predicción media y el valor medio observado.

Asociación – Es una medida de la intensidad de la relación lineal entre los pronósticos y las observaciones (p. ej., el coeficiente de correlación mide esta relación lineal).

Exactitud – Mide el nivel de correspondencia entre los pronósticos individuales y los eventos que predicen. La diferencia entre el pronóstico y la observación es el error; a errores menores, mayor la exactitud. Las medidas escalares de la exactitud pretenden resumir, en un sólo número, la calidad general de un conjunto de pronósticos.

Habilidad – Mide la precisión relativa del pronóstico con respecto a algún pronóstico de referencia. El pronóstico de referencia es generalmente un pronóstico 'no calificado' tal como una posibilidad aleatoria, la persistencia o la climatología.

Confiabilidad – Mide la concordancia promedio entre los valores pronosticados y los observados. Si se consideran todos los pronósticos a la vez, entonces la *confiabilidad total* es lo mismo que el

sesgo. Si los pronósticos se clasifican en diferentes rangos o categorías, entonces la confiabilidad es lo mismo que el *sesgo condicional*, es decir, tiene un valor diferente para cada categoría.

Resolución – Es la capacidad del pronóstico de clasificar al conjunto de eventos en subconjuntos con diferentes distribuciones de frecuencias. Aún si los pronósticos son erróneos, el sistema de pronóstico tiene resolución si puede separar exitosamente un tipo de resultado de otro.

Discriminación – Es la capacidad del pronóstico para discriminar entre observaciones, esto es, tener una frecuencia de predicción más alta para un suceso siempre que ese suceso ocurra.

Agudeza (*sharpness*) – Es la tendencia del pronóstico para predecir valores extremos. Por ejemplo, un pronóstico de la “climatología” no tiene agudeza. Esta es una propiedad del pronóstico solamente, y al igual que la resolución, un pronóstico puede tener este atributo aún si es incorrecto (en este caso tendría una confiabilidad pobre).

Incertidumbre – La variabilidad de las observaciones. Cuanto mayor sea la incertidumbre, más difícil será tener un buen pronóstico.

Tradicionalmente, la verificación de pronósticos ha puesto énfasis en la exactitud y la habilidad. A continuación se explica en qué consiste medir la habilidad de un pronóstico y algunos aspectos relevantes que deben tomarse en cuenta al evaluarla.

Nota: Los textos de las siguientes subsecciones fueron tomados de Jolliffe (2012).

II.3.1. Puntajes de habilidad

Es usual medir el desempeño de los pronósticos con relación a algún pronóstico de referencia. Tales medidas relativas son conocidas como *puntajes de habilidad* (*skill scores*) y existen varios pronósticos de referencia que pueden ser elegidos. Uno es el puntaje promedio, o esperado, obtenido mediante la emisión de pronósticos de acuerdo a un mecanismo aleatorio. Lo que esto significa es que se asigna una distribución de probabilidad a los valores posibles de la(s) variable(s) a pronosticar, y se produce una secuencia de pronósticos tomando una serie de valores independientes de esa distribución.

La climatología es un segundo punto de partida. Esto se refiere a siempre pronosticar el 'promedio' de la cantidad de interés. El 'promedio' en este contexto generalmente se refiere al valor medio sobre algún periodo de referencia reciente, típicamente de 30 años.

Un tercer punto de partida es la 'persistencia'. Este es un pronóstico en el cual lo que se observa en el momento presente se pronostica que persistirá en el período de pronóstico. Para pronósticos de corto plazo esta estrategia es con frecuencia exitosa, y para demostrar la habilidad real del pronóstico, un sistema de pronóstico menos simplista lo debe hacer mejor.

II.3.2. Habilidad artificial

Cuando se utiliza un conjunto particular de datos para desarrollar un sistema de pronóstico, con frecuencia la calidad de ese sistema se evalúa sobre el mismo conjunto de datos. Esto conduce invariablemente a un sesgo optimista en los puntajes de habilidad, lo que se conoce como “habilidad artificial”. Una solución ideal es evaluar el sistema usando solamente pronósticos de eventos que aún no han ocurrido, lo cual puede ser factible para pronósticos de corto plazo.

Otra solución para reducir la habilidad artificial es dividir los datos en dos subconjuntos exhaustivos que no se traslapen, el conjunto de *entrenamiento* y el de *prueba*. El primero es usado para formular el procedimiento de pronóstico, mientras que éste es verificado usando el conjunto de prueba. Una desventaja es que solamente se usa parte del conjunto de datos para construir el sistema de pronóstico; la parte restante se desperdicia ya que, en general, incrementar la cantidad de datos o información usada para construir un pronóstico proporcionará un mejor pronóstico. Para superar parcialmente este problema puede utilizarse la idea de *validación cruzada (cross-validation)*, la cual consiste en lo siguiente: Supóngase que el conjunto de datos completo consiste de n pronósticos y las correspondientes observaciones. Los datos son divididos en m subconjuntos y para cada subconjunto se construye una regla de pronóstico con base en los datos de los otros $(m-1)$ subconjuntos. La regla es entonces verificada sobre el subconjunto omitido del procedimiento de construcción, y esto se repite para cada uno de los m subconjuntos. Los puntajes de verificación para cada subconjunto se combinan para dar una medida global de la calidad.

El esquema de validación cruzada basa sus “pronósticos” en $(n-1)$ observaciones, algunas de las cuales están “en el futuro” con relación a la observación que se está pronosticando. La palabra “*hindcast*” se refiere a predicciones como ésta, en la que se usan observaciones 'futuras' así como pasadas para construir procedimientos de pronóstico, es decir, son 'predicciones' para períodos históricos para los cuales hay datos para verificación disponibles al momento del pronóstico.

II.3.3. Significancia estadística

Habiendo decidido un punto de partida adecuado para medir la habilidad de un pronóstico, habiendo revisado que el puntaje de habilidad elegido no tenga propiedades indeseables ostensibles, y eliminado la posibilidad de habilidad artificial, ¿es posible juzgar si una mejora observada con respecto al punto de partida es estadísticamente significativa? ¿o la mejora pudo haber surgido por azar? Para abordar estas cuestiones se requieren métodos de inferencia estadística, como pruebas de hipótesis e intervalos de confianza. Sin embargo, surge una dificultad debido a que muchos de los procedimientos estándar de inferencia estadística asumen independencia en las observaciones. La correlación temporal y espacial que con frecuencia está presente en los datos ambientales requiere de hacer adaptaciones a los procedimientos usuales.

II.4. CALIDAD DE LOS DATOS

No siempre se cuenta con datos de buena calidad para llevar a cabo la evaluación de los pronósticos. Generalmente, los servicios meteorológicos nacionales tienen procedimientos para el control de calidad que detectan muchos errores, pero los grandes volúmenes de datos que se manejan hacen más factible que algunos datos erróneos lleguen a la red. Una mayor dependencia en los datos que se derivan indirectamente mediante algún paso de calibración, por ejemplo la intensidad de la lluvia estimada a partir de los datos de radar, también incrementa la posibilidad de sesgos en los datos inferidos (Jolliffe, 2012).

Cuando los datos para la evaluación son incorrectos, el pronóstico es verificado contra algo distinto a la realidad, con consecuencias imprevisibles en los puntajes de verificación. En grandes conjuntos de datos, los datos faltantes siempre han sido comunes, por diversas razones. Los datos faltantes pueden ser ignorados o pueden estimarse a partir de datos relacionados y usarse para la verificación. Esto último es lo más recomendable si se tienen buenas estimaciones, ya que evita desperdiciar información, pero si las estimaciones son pobres, los puntajes de verificación resultantes pueden ser engañosos (Jolliffe, 2012).

Pueden faltar datos de manera aleatoria, o de alguna forma no aleatoria en la cual ciertos valores particulares de la variable pronosticada son más propensos a faltar que otros. Para datos faltantes aleatoriamente, es probable que el puntaje promedio de verificación no se vea muy afectado, aunque generalmente su variabilidad se incrementará. Para datos que faltan de una manera más sistemática, los puntajes de verificación pueden estar sesgados, así como tener mayor variabilidad (Jolliffe, 2012).

Un tipo especial, pero común, de datos faltantes ocurre cuando las mediciones de las variables de interés no han sido obtenidas para un período suficientemente largo para poder establecer una climatología confiable. Este es un problema particular cuando se pronostican eventos extremos, los cuales, por su naturaleza, ocurren raramente y se necesitan registros largos para deducir su naturaleza y frecuencia. El interés en los pronósticos de eventos extremos ha aumentado, en parte debido a los enormes impactos sociales y económicos que producen, pero también en relación a la gran cantidad de esfuerzos de investigación dedicados al cambio climático. Es deseable que un conjunto de datos incluya algunos valores extremos de modo que se logre cubrir todo el rango de observaciones posibles, pero por otra parte, un número pequeño de datos extremos puede tener una influencia excesiva sobre los valores de algunas medidas de habilidad y enmascarar la calidad de los pronósticos para valores no extremos. Para evitar esto, tales medidas deben ser robustas o resistentes a la presencia de valores extremos en las observaciones o pronósticos (Jolliffe, 2012).

II.5 MÉTODOS DE VERIFICACIÓN ESTÁNDAR

Esta sección (con las subsecciones correspondientes) está basada, en su gran mayoría, en los textos del sitio del Center for Australian Weather and Climate Reserch (CAWCR), de WMO (2000), Jolliffe (2012) y Wilks (2006). Las citas a referencias distintas a las anteriores se indican en donde corresponde.

II.5.1. Verificación visual

Uno de los mejores y más antiguos métodos de verificación es el método visual. Hay formas comunes de presentar los datos, como las series de tiempo y los mapas. Este método es muy bueno si se tienen pocos pronósticos, o el interés no se centra en el cálculo de estadísticos cuantitativos. Aún en este último caso es muy recomendable visualizar los datos. Sin embargo, el método visual no es cuantitativo y es muy propenso a sesgos de interpretación subjetivos, por lo que debe usarse con precaución en cualquier procedimiento formal de verificación.

En la Figura 14 se presentan ejemplos de comparación entre series de tiempo de datos observados y pronosticados y de comparación mediante mapas.




Figura 14. (Arriba) Ejemplo de comparación de series de tiempo de datos observados y pronosticados de temperatura media diaria en un sitio dado (elaboración propia). (Abajo) Ejemplo de comparación entre mapas de precipitación acumulada total durante el paso del huracán Fran (Sep. 1996), según mediciones de estaciones pluviométricas (izq.) y usando el pronóstico del modelo GFDL (der.) (tomados de Tuleya et al., 2007).

II.5.2. Métodos para pronósticos dicotómicos

Un pronóstico dicotómico establece, “sí, un evento ocurrirá” o “no, el evento no ocurrirá”. Las predicciones de lluvia y neblina son ejemplos comunes de pronósticos dicotómicos. Para algunas

aplicaciones se puede especificar una cota o umbral para separar el “sí” y el “no”, por ejemplo, vientos superiores a 30 m/s.

Para verificar este tipo de pronósticos se comienza con una tabla de contingencia de 2 x 2 que muestra la frecuencia de pronósticos y ocurrencias de “sí’s” y “no’s”. Las cuatro combinaciones de pronósticos (sí o no) y observaciones (sí o no), llamadas la distribución conjunta, son:

Acierto – pronóstico de ocurrencia del evento y el evento sí ocurrió

Fallo – pronóstico de no ocurrencia del evento pero el evento sí ocurrió

Falsa alarma – pronóstico de ocurrencia del evento pero el evento no ocurrió

Negativo correcto - pronóstico de no ocurrencia del evento y el evento no ocurrió

Los números totales de ocurrencias y no-ocurrencias observadas y pronosticadas se conocen como la distribución marginal.

Tabla de contingencia de 2 x 2

		Observación		
		SI	NO	TOTAL
Pronóstico	SI	Aciertos	Falsas alarmas	Sí's pronosticados
	NO	Fallos	Negativos correctos	No's pronosticados
TOTAL		Sí's observados	No's observados	Total

La tabla de contingencia es una manera útil de ver el tipo de errores que se están cometiendo. Un sistema de pronóstico perfecto produciría solamente *aciertos* y *negativos correctos*, sin *fallos* ni *falsas alarmas*. Una gran variedad de estadísticos categóricos se calculan a partir de los elementos de la tabla de contingencia para describir aspectos particulares del desempeño del pronóstico. Algunos ejemplos son los siguientes:

$$\text{Exactitud} = \frac{\text{Aciertos} + \text{Negativos correctos}}{\text{Total}}$$

Representa la fracción de los pronósticos que estuvieron correctos. Rango de valores: 0 a 1. Puntuación perfecta: 1.

$$\text{Sesgo} = \frac{\text{Aciertos} + \text{Falsas alarmas}}{\text{Aciertos} + \text{Fallos}}$$

Comparación entre la frecuencia de “sí” pronosticados y la frecuencia de “sí” observados. Indica si el sistema de pronóstico tiene una tendencia a subestimar (sesgo < 1) o a sobrestimar (sesgo > 1), únicamente en términos de frecuencias relativas. Rango de valores: 0 a ∞. Puntuación perfecta: 1.

$$\text{Probabilidad de detección (POD)} = \frac{\text{Aciertos}}{\text{Aciertos} + \text{Fallos}}$$

Representa la fracción de los “sí” observados que fueron correctamente pronosticados. Ignora las falsas alarmas. Buena medida para eventos raros. Debe usarse en conjunto con la razón de falsas alarmas. Rango de valores: 0 a 1. Puntuación perfecta: 1.

$$\text{Razón de falsas alarmas (FAR)} = \frac{\text{Falsas alarmas}}{\text{Aciertos} + \text{Falsas alarmas}}$$

Representa la fracción de los “sí” pronosticados que en realidad no ocurrieron. Ignora los fallos. Debe usarse en conjunto con la probabilidad de detección. Rango de valores: 0 a 1. Puntuación perfecta: 0.

$$\text{Probabilidad de detección falsa} = \frac{\text{Falsas alarmas}}{\text{Negativos correctos} + \text{Falsas alarmas}}$$

Representa la fracción de los “no” observados que fueron incorrectamente pronosticados. Ignora los fallos. Este puntaje es utilizado ampliamente para pronósticos probabilísticos. Rango de valores: 0 a 1. Puntuación perfecta: 0.

$$\text{Índice de éxito crítico (Threat score)} = \frac{\text{Aciertos}}{\text{Aciertos} + \text{Fallos} + \text{Falsas alarmas}}$$

Mide la fracción de eventos observados y/o pronosticados que fueron correctamente predichos. No distingue la fuente de error en el pronóstico. Rango de valores: 0 a 1. Puntuación perfecta: 1.

$$\text{Discriminante de Hanssen y Kuipers (HK)} = \frac{\text{Aciertos}}{\text{Aciertos} + \text{Fallos}} - \frac{\text{Falsas alarmas}}{\text{Falsas alarmas} + \text{Negativos correctos}}$$

Utiliza todos los elementos de la tabla. Responde a la pregunta: ¿qué tan bien separó el pronóstico los eventos “sí” de los “no”? Rango de valores: -1 a 1, 0 indica sin habilidad. Puntuación perfecta: 1.

II.5.3. Métodos para pronósticos multi-categoría

Estos métodos también incluyen una tabla de contingencia mostrando la frecuencia de los pronósticos y las observaciones en las distintas categorías. Dicha tabla es análoga a un diagrama de dispersión para categorías.

		Categoría Observada				Total
	i,j	1	2	...	K	
Categoría Pronosticada	1	$n(F_1, O_1)$	$n(F_1, O_2)$	...	$n(F_1, O_K)$	$N(F_1)$
	2	$n(F_2, O_1)$	$n(F_2, O_2)$	...	$n(F_2, O_K)$	$N(F_2)$
	...	...	...	...	...	...
	K	$n(F_K, O_1)$	$n(F_K, O_2)$	...	$n(F_K, O_K)$	$N(F_K)$
Total		$N(O_1)$	$N(O_2)$	...	$N(O_K)$	N

En esta tabla, $n(F_i, O_j)$ denota el número de pronósticos en la categoría i que tuvieron observaciones en la categoría j ; $N(F_i)$ es el número total de pronósticos en la categoría i ; $N(O_j)$ es el número total de observaciones en la categoría j , y N es el número total de pronósticos.

Puesto que la creación de una tabla de contingencia representa una agrupación de los datos en categorías, esto genera problemas con el tamaño de muestra. La selección de categorías suele ser un compromiso entre la importancia para los usuarios de la información de verificación y el objetivo estadístico de tener muestras representativas (suficientemente grandes) en cada categoría de la tabla. Un sistema de pronóstico perfecto tendría valores distintos de cero solamente a lo largo de la diagonal y valores iguales a cero en todas las demás entradas. Los elementos fuera de la diagonal proporcionan información respecto a la naturaleza específica de los errores del pronóstico. Las distribuciones marginales muestran si el pronóstico produce la distribución correcta de valores categóricos cuando se compara con las observaciones. Este sistema tiene la desventaja de que es más difícil condensar los resultados en un sólo número.

Algunos estadísticos y gráficos que resumen el desempeño de pronósticos multi-categorías se presentan a continuación.

Histograma – Es una gráfica de las frecuencias relativas de las categorías pronosticadas y las observadas (Figura 15). Muestra semejanzas entre ubicación, dispersión y asimetría de las distribuciones. No proporciona información sobre la correspondencia entre los pronósticos y las observaciones.




Figura 15. Ejemplo de un histograma en donde se comparan las distribuciones de frecuencias de datos observados y valores pronosticados (tomada de CAWCR).

Precisión – Indica qué fracción de los pronósticos estuvo en la categoría correcta. Es un puntaje simple e intuitivo, aunque se ve ampliamente influenciado por la categoría más común. Rango de valores: 0 a 1. Puntuación perfecta: 1.

$$\text{Precisión} = \frac{1}{N} \sum_{i=1}^K n(F_i, O_i)$$

Puntaje de habilidad de Heidke (HSS) – Mide la fracción (o porcentaje) de pronósticos correctos después de eliminar aquellos pronósticos que habrían sido correctos debido puramente al azar. Requiere de un tamaño de muestra grande para asegurar que todos los elementos de la tabla de contingencia estén adecuadamente muestreados. Rango de valores: $-\infty$ a 1, donde 0 indica sin habilidad. Puntuación perfecta: 1.

$$\text{HSS} = \frac{\frac{1}{N} \sum_{i=1}^K n(F_i, O_i) - \frac{1}{N^2} \sum_{i=1}^K N(F_i) N(O_i)}{1 - \frac{1}{N^2} \sum_{i=1}^K N(F_i) N(O_i)}$$

Discriminante de Hanssen y Kuipers (HK) – Similar al puntaje de habilidad de Heidke, excepto que en el denominador la fracción de pronósticos correctos debido a aleatoriedad es para un pronóstico insesgado. Rango de valores: -1 a 1, donde 0 indica sin habilidad. Puntuación perfecta: 1.

$$\text{HK} = \frac{\frac{1}{N} \sum_{i=1}^K n(F_i, O_i) - \frac{1}{N^2} \sum_{i=1}^K N(F_i) N(O_i)}{1 - \frac{1}{N^2} \sum_{i=1}^K (N(O_i))^2}$$

II.5.4. Métodos para pronósticos de variables continuas

Los métodos de verificación de pronósticos de variables continuas miden qué tanto difieren los valores de los pronósticos de los valores de las observaciones. Incluyen gráficos exploratorios tales como diagramas de dispersión, histogramas y diagramas de caja (box plots), así como también varios puntajes.

Diagramas de dispersión – Es quizás la herramienta de verificación más simple. Representa los valores pronosticados contra los observados mediante un gráfico de puntos en el cual las escalas en los ejes son iguales. Indica la medida de correspondencia entre los valores observados y los pronosticados. Un pronóstico perfecto estará representado por cualquier punto sobre la recta de 45 grados en el diagrama. Si se grafica en el diagrama de dispersión la línea de regresión ajustada a los datos, la correspondencia entre ésta y la recta de 45 grados representa una medida de la confiabilidad de los pronósticos. Una comparación de la orientación de estas dos líneas proporciona una representación visual de la calidad relativa de los pronósticos. Conforme disminuye la calidad, la línea de regresión tiende más hacia la horizontal. Una línea horizontal significa que las observaciones son independientes del pronóstico o, dicho de otra manera, que la media de las observaciones (climatología) es un predictor tan bueno como el método de pronóstico. Otra medida de verificación que puede estimarse a partir de un diagrama de dispersión es el error promedio o sesgo (bias).




Figura 16. Ejemplos de diagramas de dispersión entre observaciones y pronósticos de la temperatura en dos sitios dados. La línea segmentada representa la recta 1:1 y la línea continua es la recta de mejor ajuste (tomada de Libonati et al., 2008).

Box plots (gráficos de caja o de caja-bigotes) – Muestran el rango de datos que cae entre los percentiles 25 y 75, representados por los extremos de la caja. La línea horizontal dentro de la caja muestra el valor de la mediana y los bigotes muestran el rango completo de los datos. También son útiles para identificar valores fuera de rango o *outliers*, los cuales se identifican mediante un símbolo especial (p.e., asteriscos o círculos). Los *box plots* proporcionan información similar a la de los histogramas. La Figura 17 muestra un gráfico con múltiples box plots.




Figura 17. Ejemplo del uso de múltiples *box plots* para representar las distribuciones de los errores en los pronósticos de trayectoria de ciclones tropicales para diferentes tiempos de pronóstico. Están representados los errores obtenidos por dos versiones diferentes de un modelo (box plots negros y rojos). Los círculos representan valores fuera de rango o outliers. En la parte superior se presentan los tamaños de muestra correspondientes. (Figura tomada de WWRP, 2013)

Además del cálculo de los valores promedio y desviaciones estándar de las observaciones y pronósticos, algunos de los puntajes (estadísticos o métricas) más comúnmente utilizados en la verificación de pronósticos de variables continuas se describen a continuación.

Error promedio o sesgo (algebraico) (Mean error, ME) – Es una medida de la confiabilidad total. Es un puntaje simple que se usa comúnmente y se calcula como sigue:

$$ME = \frac{1}{N} \sum_{i=1}^N (F_i - O_i)$$

donde F_i representa los valores pronosticados y O_i las observaciones correspondientes. Rango de valores: $-\infty$ a ∞ . Puntuación perfecta: 0.

El ME indica la dirección promedio de la desviación con respecto a los valores observados. Un sesgo positivo (negativo) indica que el valor pronosticado sobrestima (subestima) el valor observado en promedio. Sin embargo, puede no reflejar la magnitud de los errores ni la correspondencia entre pronósticos y observaciones, es decir, es posible obtener un puntaje perfecto para un pronóstico malo si hay errores que se compensan. Por ello, el ME nunca debe presentarse como único puntaje; como mínimo, debe ir acompañado por el sesgo con respecto a la climatología tanto para el pronóstico como para las observaciones. Sin sesgos comparativos, no hay manera de determinar si la desviación del pronóstico está dentro de límites aceptables y refleja las desviaciones que ocurren dentro de la muestra de verificación.

Sesgo (multiplicativo) – Es una comparación entre la magnitud promedio de los pronósticos y las observaciones. Es un puntaje simple y de uso común. Es más adecuado para cantidades que tienen al 0 como cota inferior o superior. No mide la magnitud de los errores. Tampoco mide la correspondencia entre pronósticos y observaciones, e.d., es posible obtener una puntuación perfecta para un pronóstico malo si hay errores que se compensan. Rango de valores: $-\infty$ a ∞ . Puntuación perfecta: 1.

$$\text{Sesgo}_{mult} = \frac{\frac{1}{N} \sum_{i=1}^N F_i}{\frac{1}{N} \sum_{i=1}^N O_i}$$

Error absoluto medio (Mean absolute error, MAE) – Proporciona la magnitud promedio de los errores del pronóstico, pero no indica la dirección de las desviaciones. Rango de valores: 0 a ∞ . Puntuación perfecta: 0.

$$MAE = \frac{1}{N} \sum_{i=1}^N |F_i - O_i|$$

Error cuadrático medio (Mean squared error, MSE) – Mide la diferencia cuadrática media entre los pronósticos y las observaciones. No indica la dirección de las desviaciones. Sus unidades son el cuadrado de las unidades básicas. Rango de valores: 0 a ∞ . Puntuación perfecta: 0.

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (F_i - O_i)^2$$

Raíz del error cuadrático medio (Root mean square error, RMSE) – Es una medida de la precisión total. Proporciona la magnitud promedio de los errores del pronóstico, ponderada de acuerdo al cuadrado del error. Es un puntaje simple y de uso común que se calcula como la raíz cuadrada del MSE.

$$\text{RMSE} = \left[\frac{1}{N} \sum_{i=1}^N (F_i - O_i)^2 \right]^{1/2}$$

Al igual que el MSE, el RMSE no indica la dirección de las desviaciones. Es un puntaje que se ve más influenciado por los errores grandes que por los pequeños, lo cual puede ser bueno si los errores grandes son especialmente indeseables. Su sensibilidad a errores grandes también significa que no puede proporcionar estimaciones estables del error si se utilizan muestras pequeñas. Esta medida, al igual que otras reglas de puntuación cuadrática, puede favorecer un pronóstico conservador (pronóstico cercano a la media climatológica). Cuando se compara con el MAE, el RMSE proporciona una indicación de la varianza del error, es decir, si $\text{RMSE} \gg \text{MAE}$ esto indicaría una varianza grande, mientras que $\text{RMSE} = \text{MAE}$ ocurriría sólo si todos los errores tienen la misma magnitud. El RMSE nunca puede ser menor que el MAE. Rango de valores: 0 a ∞ . Puntuación perfecta: 0.

Coeficiente de correlación (r) – Medida de la correspondencia entre valores pronosticados y observados. Es una buena medida de asociación lineal o error de fase. Visualmente, la correlación mide qué tan cerca están los puntos de un diagrama de dispersión a una línea recta. No toma en cuenta el sesgo del pronóstico, es decir, sería posible para un pronóstico con errores grandes tener un buen coeficiente de correlación con las observaciones. Este puntaje es sensible a valores aislados o *outliers*. Rango de valores: -1 a 1. Puntuación perfecta: 1.

$$r = \frac{\sum (F - \bar{F})(O - \bar{O})}{\sqrt{[(F - \bar{F})^2]} \sqrt{[(O - \bar{O})^2]}}$$

donde $\bar{F}$ y $\bar{O}$ representan los promedios de los pronósticos y de las observaciones, respectivamente.

Correlación de anomalías (Anomaly correlation, AC) – Mide la correspondencia o diferencia de fase entre pronósticos y observaciones restando la media climatológica (C) a cada punto, en lugar de los valores promedio muestrales. Esta correlación se usa con frecuencia para verificar la salida de los modelos numéricos de predicción del tiempo (NWP, por sus siglas en inglés). Este puntaje no es sensible al sesgo del pronóstico, de modo que un buen AC no es garantía de pronósticos precisos. Rango de valores: -1 a 1. Puntuación perfecta: 1.

$$AC_{(no\ centrado)} = \frac{\sum (F - C)(O - C)}{\sqrt{[(F - C)^2]} \sqrt{[(O - C)^2]}}$$

$$AC_{(centrado)} = \frac{\sum [(F - C) - \overline{(F - C)}][(O - C) - \overline{(O - C)}]}{\sqrt{[(F - C)^2]} \sqrt{[(O - C)^2]}}$$

Puntaje S1 – Se aplica generalmente a campos de altura geopotencial o de presión a nivel del mar. Como S1 depende solamente de los gradientes, pueden obtenerse buenos puntajes aún cuando los pronósticos estén sesgados. También depende de la resolución espacial del pronóstico. Rango de valores: 0 a ∞. Puntuación perfecta: 0.

$$S1 = \frac{\sum_{\text{parejas adyacentes}} |\Delta F - \Delta O|}{\sum_{\text{parejas adyacentes}} \max(|\Delta F|, |\Delta O|)} \times 100$$

donde ΔF (ΔO) es el gradiente horizontal en los pronósticos (observaciones).

Puntaje de habilidad (Skill score) – Es una medida de la mejora relativa del pronóstico sobre algún pronóstico de referencia. Implica información respecto al valor de un pronóstico con relación a un pronóstico alternativo (o de referencia). En meteorología el pronóstico de referencia es usualmente la persistencia o la climatología. El *skill score* puede ser inestable para tamaños de muestra pequeños. Cuando el MSE es el puntaje usado en la fórmula, entonces el estadístico resultante es llamado la *reducción de varianza*. Rango de valores: La cota inferior depende del puntaje que se esté usando para calcular la habilidad y del pronóstico de referencia que se use, pero la cota superior siempre es 1; 0 indica que no hay mejora sobre el pronóstico de referencia. Puntuación perfecta: 1.

$$\text{Puntaje de habilidad (skill score)} = \frac{Puntaje_{\text{pronóstico}} - Puntaje_{\text{referencia}}}{Puntaje_{\text{pronóstico perfecto}} - Puntaje_{\text{referencia}}}$$

II.5.5. Métodos para pronósticos probabilísticos

La verificación de pronósticos probabilísticos es más sutil que la verificación de pronósticos no-probabilísticos, ya que estos últimos no contienen expresiones de incertidumbre sino que es claro si el pronóstico individual es correcto o no. Un pronóstico probabilístico proporciona la probabilidad de ocurrencia de un evento, asignando un valor entre 0 y 1 (o 0 y 100%). En general es difícil verificar un solo pronóstico probabilístico por lo que, en su lugar, la evaluación se hace usando una colección de parejas de pronósticos probabilísticos, p_i , y observaciones de la ocurrencia ($o_i = 1$) o no ocurrieron ($o_i = 0$) del evento de interés. La información relevante para la verificación de estos pronósticos está contenida en la distribución conjunta de pronósticos y observaciones. Entre los métodos y puntajes más utilizados en este caso, podemos mencionar los siguientes:

Diagrama de confiabilidad – Gráfica de la frecuencia relativa observada contra la probabilidad pronosticada, donde el rango de probabilidades está dividido en K rangos (por ejemplo, 0-5%, 5-15%, 15-25%, etc.) (Figura 18). El tamaño de muestra en cada rango es incluido generalmente como un histograma al lado de los datos. La confiabilidad está indicada por la proximidad de la curva trazada a la diagonal y la desviación de la diagonal proporciona el sesgo condicional. Si la curva cae debajo de la recta nos indica sobre-estimación (probabilidades muy altas); puntos por encima de la recta indican sub-estimación (probabilidades muy bajas). Mientras más acostada esté la curva en el diagrama de confiabilidad, menor será la resolución que tiene el pronóstico. Un pronóstico de la climatología no discrimina entre ocurrencia y no-ocurrencia, y por lo tanto no tiene resolución. La frecuencia de los pronósticos en cada rango de probabilidad (mostrada en el histograma) muestra la agudeza del pronóstico.




Figura 18. Ejemplo de un diagrama de confiabilidad (tomada de CAWCR).

Puntaje de Brier (Brier score, BS) – Representa el error cuadrático medio de los pronósticos de probabilidad. Puede dividirse en tres términos: (1) confiabilidad, (2) resolución, y (3) incertidumbre. Es sensible a la frecuencia climatológica del evento: mientras más raro sea el evento es más factible obtener un BS bueno sin tener ninguna habilidad real. Rango: 0 a 1. Puntuación perfecta: 0.

$$\text{Puntaje de Brier (BS)} = \frac{1}{N} \sum_{i=1}^N (p_i - o_i)^2 = \frac{1}{N} \sum_{k=1}^K n_k (p_k - \bar{o}_k)^2 - \frac{1}{N} \sum_{k=1}^K n_k (\bar{o}_k - \bar{o})^2 + \bar{o}(1 - \bar{o})$$

Puntaje de habilidad de Brier (Brier skill score, BSS) - Mide la mejora del pronóstico probabilístico en relación a un pronóstico de referencia (usualmente la climatología muestral o de largo plazo), tomando en cuenta la frecuencia climatológica. Es inestable cuando se aplica a conjuntos de datos pequeños; mientras más raro el evento, se necesita un número más grande de muestras. Rango: $-\infty$ a 1, 0 indica sin habilidad. Puntuación perfecta: 1.

$$\text{Puntaje de habilidad de Brier (BSS)} = 1 - \frac{BS}{BS_{\text{referencia}}}$$

Curvas características de operación (Relative Operating Characteristic, ROC) – Comparación de la tasa de aciertos (*hit rate*) contra la tasa de falsas alarmas (*false alarm rate*), usando un conjunto de cotas de probabilidad crecientes (p.ej., 0.05, 0.15, 0.25, etc.) para tomar la decisión si/no. El área bajo la curva ROC se usa frecuentemente como un puntaje. La ROC mide la capacidad del pronóstico para discriminar entre dos resultados alternativos, en consecuencia mide la resolución. No es sensible al sesgo en el pronóstico, de modo que no proporciona información respecto a la confiabilidad. Un pronóstico sesgado puede aún tener buena resolución y producir una buena curva ROC, lo cual significa que puede ser posible mejorar el pronóstico mediante calibración. La ROC puede considerarse como una medida de la utilidad potencial. La curva está condicionada a las observaciones (e.d., dado que Y ocurrió, ¿cuál fue el pronóstico correspondiente?), por lo tanto se puede acompañar con el diagrama de confiabilidad, el cual está condicionado a los pronósticos.

En la Figura 19 se muestra un ejemplo de este tipo de gráfico.




Figura 19. Ejemplo de Curva Característica de Operación o ROC
(tomada de <http://www.metoffice.gov.uk/.../user-guide/interpret-roc>).

II. 6 ESTRATEGIAS PROPUESTAS PARA LA VERIFICACIÓN DE LOS PRONÓSTICOS EN EL SISTEMA MMOM

La elección de los métodos de verificación depende del propósito de la verificación y de la naturaleza del pronóstico que está siendo verificado. En este sentido, para llevar a cabo la verificación de los pronósticos que generará el MMOM se elegirán, de entre los métodos gráficos y puntajes descritos en las secciones previas, aquéllos que sean más adecuados en cada caso, es decir, dependiendo de la variable a analizar.

En principio, se pretenden implementar las siguientes estrategias de verificación de pronósticos en el MMOM:

- Se realizará, hasta donde sea posible, un control de calidad simple de los datos observados en estaciones de monitoreo del Servicio Meteorológico Nacional que sean usados para la verificación de los pronósticos de variables meteorológicas como la temperatura y la precipitación.
- Realizar comparaciones con observaciones puntuales, ya sea interpolando los datos del modelo a los sitios donde se tienen las mediciones o considerando el punto o nodo de malla más cercano al sitio de observación.
- Para la verificación del pronóstico de precipitación se promediarán las observaciones en los cuadros de malla.
- Para sitios donde no se cuente con información de estaciones de monitoreo se harán comparaciones de las salidas del modelo contra datos de reanálisis, aunque debe tenerse en cuenta que los productos de reanálisis pueden tener errores asociados con el suavizado o alteraciones debidas al postprocesamiento de la información.
- Se pretende realizar comparaciones contra datos de radar para la verificación de los pronósticos de precipitación, dependiendo de la disponibilidad de datos que haya y de la calidad de éstos.
- Se pretende realizar comparaciones con datos satelitales referentes al lugar y momento de ocurrencia de eventos de precipitación, en particular para regiones remotas y sobre los océanos.
- Se utilizarán los métodos de verificación para variables categóricas para analizar eventos de precipitación y de viento que rebasen ciertos umbrales específicos. En particular, se pretende calcular los siguientes puntajes: sesgo, exactitud, probabilidad de detección, razón de falsas alarmas y el discriminante de Hanssen y Kuipers.
- Se utilizarán los métodos de verificación descritos para variables continuas, aplicándolos a variables como la temperatura, la cantidad de precipitación y la magnitud del viento. Además de los métodos gráficos de comparación de series de tiempo, mapas, diagramas de dispersión, histogramas y box plots, se calcularán los siguientes puntajes: promedio, desviación estándar, rango intercuartil, error medio (ME), error absoluto medio (MAE), raíz del error cuadrático medio (RMSE), coeficiente de correlación (r), y el puntaje de habilidad considerando algún pronóstico de referencia (persistencia y/o climatología).
- Estratificar por tiempos: 24h, 48h, ..etc.
- Estratificar por estación del año: invierno (DEF), primavera (MAM), verano (JJA), otoño (SON).
- Estratificar por región geográfica: sitios costeros, montañas, ciudades importantes, etc.
- Para el caso de pronósticos probabilísticos, se estratificará por umbrales de intensidad para distintas variables. En estos casos se usarán los siguientes puntajes y gráficos para la verificación

de los pronósticos: puntaje de Brier (BS), puntaje de habilidad de Brier (BSS), diagramas de confiabilidad y curvas características de operación (ROC).

- Se dará una estimación estadística del error en los pronósticos de trayectoria e intensidad de huracanes.
- Para realizar la verificación de los pronósticos de nivel del mar se usarán mediciones de los mareógrafos del Servicio Mareográfico de la UNAM.
- Para realizar la verificación de los pronósticos de oleaje se usarán datos de las boyas metoceánicas ubicadas en el Golfo de México.

II.7. REFERENCIAS BIBLIOGRÁFICAS (CAPÍTULO II)

- American Meteorological Society (2015): Weather Analysis and Forecasting. An Information Statement of the AMS (<https://www.ametsoc.org/ams/index.cfm/about-ams/ams-statements/statements-of-the-ams-in-force/weather-analysis-and-forecasting/>)
- CAWCR. Center for Australian Weather and Climate Reserch. Forecast Verification: Issues, Methods and FAQ (<http://www.cawcr.gov.au/projects/verification/>).
- Casati, B., L. J. Wilson, D. B. Stephenson, P. Nurmi, A. Ghelli, M. Pocerich, U. Damrath, E. E. Ebert, B. G. Brown, and S. Mason (2008): Forecast verification: current status and future directions. *Meteorol. Appl.*, 15: 3-18.
- Jolliffe, I. T., and D. B. Stephenson (2012): *Forecast Verification. A Practitioner's Guide in Atmospheric Science*. 2nd Edition. Wiley and Sons Ltd, 292 pp.
- Libonati, R., I. Trigo, C. C. DaCamara (2008): Correction of 2 m-temperature forecast using Kalman Filtering technique. *Atmospheric Research*, 87, 183-197.
- Murphy, A. H. (1991): Forecast verification: its complexity and dimensionality. *Mon. Weather Rev.*, 119, 1590–1601.
- Murphy, A. H. (1993): What is a good forecast? An essay on the nature of goodness in weather forecasting. *Weather Forecasting*, 8, 281–293.
- Murphy, A. H. and R. L. Winkler (1987): A general framework for forecast verification. *Mon. Weather Rev.*, 115, 1330-1338.
- Stanski, H. R., L. J. Wilson, W. R. Burrows (1989): *Survey of common verification methods in Meteorology*. Atmospheric Environment Service, Canada. WMO World Weather Watch Technical Report No. 8, WMO/TD No. 358.
- Tuleya, R. E., M. DeMaria, R. J. Kuligowski (2007): Evaluation of GFDL and simple statistical model rainfall forecasts for U.S. landfalling tropical storms. *Weather Forecasting*, 22, 56-70.
- Wilks, D. S. (2006): *Statistical Methods in the Atmospheric Sciences*. 2nd Ed. International Geophysics Series. Academic Press. Elsevier. 627 pp.
- WMO (World Meteorological Organization) (2000): Standardised Verification System for Long-Range Forecasts (<http://www.wmo.int/pages/prog/www/DPSdev/SVS-for-LRF.html>).
- WMO (2008): Recommendations for the Verification and Intercomparison of QPFs and PQPFs from Operational NWP Models. WMO/TD – No. 1485. WWRP 2009-1.
- WWRP (World Weather Research Programme - WMO) (2013): Verification methods for Tropical Cyclone Forecasts. WWRP 2013-7.
- Zavala-Romero, O., A. Ahmed, E. P. Chassignet, J. Zavala-Hidalgo, A. Fernández-Eguiarte, A. Meyer-Baese (2014): An open source Java web application to build self-contained web GIS sites. *Environmental Modelling & Software*, 62, 210-220. DOI: 10.1016/j.envsoft.2014.08.029.