



Escuela
Universitaria
Ingeniería
Técnica
Industrial
ZARAGOZA

UNIVERSIDAD DE ZARAGOZA

Escuela Universitaria de Ingeniería

Técnica Industrial de Zaragoza

Proyecto Fin de Carrera

**Evaluación de la velocidad de viento para
parques offshore con telemetría y métodos de
previsión estadísticos**

UNIVERSIDAD DE ZARAGOZA

Escuela Universitaria de Ingeniería

Técnica Industrial de Zaragoza

Proyecto Fin de Carrera

Evaluación de la velocidad de viento para parques offshore con telemetría y métodos de previsión estadísticos

AUTOR: JUAN LUIS SÁNCHEZ SARASA

DIRECTORES: JOSÉ ANTONIO DOMÍNGUEZ NAVARRO

MARÍA JESÚS VELILLA MARCO

ÍNDICE

ÍNDICE DE FIGURAS	I
ÍNDICE DE TABLAS	VII
<i>RESUMEN DEL PROYECTO</i>	VIII
<u>CAPÍTULO 1</u>	<u>1</u>
1.1 INTRODUCCIÓN	1
1.2 MISIÓN DEL SEAWINDS DENTRO DEL <i>QUIKSCAT</i>	3
1.3 THE PO.DAAC OCEAN ESIP TOOL (POET)	8
1.4 REVISIÓN BIBLIOGRÁFICA	10
<u>CAPÍTULO 2</u>	<u>13</u>
2.1 SOFTWARE	13
2.2 MÉTODO ARIMA	15
2.3 SERIES TEMPORALES	33
2.4 SERIES ESPACIO-TEMPORALES	37
<u>CAPÍTULO 3</u>	<u>40</u>
3.1 OBTENCIÓN DE DATOS Y ZONA DE TRABAJO	40
3.2 ANÁLISIS DE DATOS	46
3.3 APLICACIÓN DE LOS MÉTODOS ARIMA	50
3.4 DESARROLLO DEL CÓDIGO EN <i>R LANGUAGE</i>	163
<u>CAPÍTULO 4</u>	<u>169</u>
4.1 ANÁLISIS Y DISCUSIÓN DE DATOS	169
4.2 ESTUDIO TEMPORAL	173
4.3 ESTUDIO ESPACIO-TEMPORAL	180
<u>CAPÍTULO 5</u>	<u>182</u>
5.1 CONCLUSIONES	182
5.2 REFERENCIAS	184

Índice de figuras

Figura 1 Imagen artificial del satélite QuikSCAT

Figura 2 Señales del satélite QuikSCAT atravesando nubes

Figura 3 Ejemplo de una órbita polar y otra geoestacionaria

Figura 4 Ejemplo de selección de parámetro de la herramienta “POET”

Figura 5 Ejemplo de Selección de la franja horaria deseada de la herramienta “POET”

Figura 6 Ejemplo de selección de la zona geográfica de la herramienta “POET”

Figura 7 Selección de parámetro de la herramienta “POET”

Figura 8 Selección de la franja horaria deseada de la herramienta “POET”

Figura 9 Selección de la zona geográfica de la herramienta mediante dibujo de zona

Figura 10 Selección de la zona geográfica de la herramienta mediante inserción de coordenadas

Figura 11 Selección de formato de salida de datos

Figura 12 Formato de visualización

Figura13 Pantalla de toma de datos

Figura 14 Mapa de los puntos a estudio

Figura 16 y 22 Diferencia DATOS-PREDICCIÓN AR (1).

Figura 17 y 23 Gráfica DATOS-PREDICCIÓN AR (1)

Figura 18 y 24 Gráfica DATOS-PREDICCIÓN \pm ERROR AR (1)

Figura 19 y 25 Diferencia DATOS-PREDICCIÓN AR (1) + PREDICT

Figura 20 y 26 Gráfica DATOS-PREDICCIÓN AR (1).+ PREDICT

***Figura 21 y 27 Gráfica DATOS-PREDICCIÓN \pm ERROR AR (1) +
PREDICT***

Figura 28 y 34 Diferencia DATOS-PREDICCIÓN AR (2).

Figura 29 y 35 Gráfica DATOS-PREDICCIÓN AR (2)

Figura 30 y 36 Gráfica DATOS-PREDICCIÓN \pm ERROR AR (2)

Figura 31 y 37 Diferencia DATOS-PREDICCIÓN AR (1) + PREDICT

Figura 32 y 38 Gráfica DATOS-PREDICCIÓN AR (2).+ PREDICT

***Figura 33 y 39 Gráfica DATOS-PREDICCIÓN \pm ERROR AR (2) +
PREDICT***

Figura 40 y 46 Diferencia DATOS-PREDICCIÓN AR (5).

Figura 41 y 47 Gráfica DATOS-PREDICCIÓN AR (5)

Figura 42 y 48 Gráfica DATOS-PREDICCIÓN \pm ERROR AR (5)

Figura 43 y 49 Diferencia DATOS-PREDICCIÓN AR (5) + PREDICT

Figura 44 y 50 Gráfica DATOS-PREDICCIÓN AR (5).+ PREDICT

***Figura 45 y 51 Gráfica DATOS-PREDICCIÓN \pm ERROR AR (5) +
PREDICT***

Figura 52 y 58 Diferencia DATOS-PREDICCIÓN AR (10).

Figura 53 y 59 Gráfica DATOS-PREDICCIÓN AR (10)

Figura 54 y 60 Gráfica DATOS-PREDICCIÓN \pm ERROR AR (10)

Figura 55 y 61 Diferencia DATOS-PREDICCIÓN AR (10) + PREDICT

Figura 56 y 62 Gráfica DATOS-PREDICCIÓN AR (10).+ PREDICT

Figura 57 y 63 Gráfica DATOS-PREDICCIÓN \pm ERROR AR (10) + PREDICT

Figura 64 y 70 Diferencia DATOS-PREDICCIÓN MA (1).

Figura 65 y 71 Gráfica DATOS-PREDICCIÓN MA (1)

Figura 66 y 72 Gráfica DATOS-PREDICCIÓN \pm ERROR MA (1)

Figura 67 y 73 Diferencia DATOS-PREDICCIÓN MA (1) + PREDICT

Figura 68 y 74 Gráfica DATOS-PREDICCIÓN AR (1).+ PREDICT

Figura 69 y 75 Gráfica DATOS-PREDICCIÓN \pm ERROR MA (1) + PREDICT

Figura 76 y 82 Diferencia DATOS-PREDICCIÓN MA (2).

Figura 77 y 83 Gráfica DATOS-PREDICCIÓN MA (2)

Figura 78 y 84 Gráfica DATOS-PREDICCIÓN \pm ERROR MA (2)

Figura 79 y 85 Diferencia DATOS-PREDICCIÓN MA (2) + PREDICT

Figura 80 y 86 Gráfica DATOS-PREDICCIÓN MA (2).+ PREDICT

Figura 81 y 87 Gráfica DATOS-PREDICCIÓN \pm ERROR MA (2) + PREDICT

Figura 88 y 94 Diferencia DATOS-PREDICCIÓN MA (5).

Figura 89 y 95 Gráfica DATOS-PREDICCIÓN MA (10)

Figura 90 y 96 Gráfica DATOS-PREDICCIÓN \pm ERROR MA (10)

Figura 91 y 97 Diferencia DATOS-PREDICCIÓN MA (10) + PREDICT

Figura 92 y 98 Gráfica DATOS-PREDICCIÓN MA (10).+ PREDICT

Figura 93 y 99 Gráfica DATOS-PREDICCIÓN \pm ERROR MA (10) + PREDICT

Figura 113 y 119 Diferencia DATOS-PREDICCIÓN ARMA (1,1)

Figura 114 y 120 Gráfica DATOS-PREDICCIÓN ARMA (1,1)

Figura 115 y 121 Gráfica DATOS-PREDICCIÓN \pm ERROR ARMA (1,1)

Figura 116 y 122 Diferencia DATOS-PREDICCIÓN ARMA (1,1) +
PREDICT

Figura 117 y 123 Gráfica DATOS-PREDICCIÓN ARMA (1,1).+
PREDICT

Figura 118 y 124 Gráfica DATOS-PREDICCIÓN \pm ERROR ARMA (1,1)
+ PREDICT

Figura 125 y 131 Diferencia DATOS-PREDICCIÓN ARMA (1,2).

Figura 126 y 132 Gráfica DATOS-PREDICCIÓN ARMA (1,2)

Figura 127 y 133 Gráfica DATOS-PREDICCIÓN \pm ERROR ARMA (1,2)

Figura 128 y 134 Diferencia DATOS-PREDICCIÓN ARMA (1,2) +
PREDICT

Figura 129 y 135 Gráfica DATOS-PREDICCIÓN ARMA (1,2).+
PREDICT

Figura 130 y 136 Gráfica DATOS-PREDICCIÓN \pm ERROR ARMA (1,2)
+ PREDICT

Figura 137 y 143 Diferencia DATOS-PREDICCIÓN ARMA (1,5).

Figura 138 y 144 Gráfica DATOS-PREDICCIÓN ARMA (1,5)

Figura 139 y 145 Gráfica DATOS-PREDICCIÓN \pm ERROR ARMA (1,5)

Figura 140 y 146 Diferencia DATOS-PREDICCIÓN ARMA (1,5) +
PREDICT

Figura 141 y 147 Gráfica DATOS-PREDICCIÓN ARMA (1,5).+
PREDICT

Figura 142 y 148 Gráfica DATOS-PREDICCIÓN \pm ERROR ARMA (1,5)
+ PREDICT

Figura 149 y 155 Diferencia DATOS-PREDICCIÓN ARMA (1,10).

Figura 150 y 156 Gráfica DATOS-PREDICCIÓN ARMA (1,10)

Figura 151 y 157 Gráfica DATOS-PREDICCIÓN \pm ERROR ARMA (1,10)

Figura 152 y 158 Diferencia DATOS-PREDICCIÓN ARMA (1,10) +
PREDICT

Figura 153 y 159 Gráfica DATOS-PREDICCIÓN ARMA (1,10).+
PREDICT

Figura 154 y 160 Gráfica DATOS-PREDICCIÓN \pm ERROR ARMA
(1,10)+ PREDICT

Figura 161 y 164 Diferencia DATOS-PREDICCIÓN ARIMA (0,1,0)
+PREDICT

Figura 162 y 165 Gráfica DATOS-PREDICCIÓN ARIMA (0,1,0).+
PREDICT

Figura 163 y 166 Gráfica DATOS-PREDICCIÓN \pm ERROR ARIMA
(0,1,0) + PREDICT

Figura 167 y 170 Diferencia DATOS-PREDICCIÓN ARIMA (1, 1,1)
+PREDICT

Figura 168 y 171 Gráfica DATOS-PREDICCIÓN ARIMA (1, 1,1).+
PREDICT

Figura 169 y 172 Gráfica DATOS-PREDICCIÓN \pm ERROR ARIMA (1,
1,1) + PREDICT

Figura 173 y 176 Diferencia DATOS-PREDICCIÓN ARIMA (1, 2,1)+
PREDICT

Figura 174 y 177 Gráfica DATOS-PREDICCIÓN ARIMA (1, 2,1)+
PREDICT

Figura 175 y 178 Gráfica DATOS-PREDICCIÓN \pm ERROR ARIMA (1, 2,1) + PREDICT

Figura 179 Comparación datos reales, AR(2) y MA(2)

Figura 180 Modelo AR(2) y datos reales del mes de Febrero

Figura 181 Modelo AR(2) y datos reales del mes de Marzo

Figura 182 Modelo AR(2) y datos reales del mes de Abril

Figura 183 Modelo AR(2) y datos reales del mes de Mayo

Figura 184 Modelo AR(2) y datos reales del mes de Junio

Figura 185 Modelo AR(2) y datos reales del mes de Agosto

Figura 186 Modelo AR(2) y datos reales del mes de Septiembre

Figura 187 Modelo AR(2) y datos reales del mes de Octubre

Figura 188 Modelo AR(2) y datos reales del mes de Noviembre

Figura 189 Modelo AR(2) y datos reales del mes de Diciembre

Figura 190 Datos reales en el año 2000

Figura 191 Modelo AR(2) en año 2000

Figura 192 Modelo AR(2) y datos reales en el año 2000

Figura 193 Estudio espacio-temporal

Figura 194 Comparación datos reales, AR(2) y MA(2)

Figura 195 Estudio espacio-temporal

Índice de Tablas

Tabla 1 Disponibilidad de los datos QuikSCAT

Tabla 2 Coordenadas elegidas para la realización del estudio

Tabla 3 Velocidad del viento en los puntos de estudio (m/s)

Tabla 4 Resumen de datos

Tabla 5 Sumatorio errores entre valor real y valor pronosticado

Tabla 6 Comparación errores estándar

Tabla 7 Nuevas predicciones

Resumen del Proyecto

El objetivo de este Proyecto Fin de Carrera es la evaluación de distintos métodos estadísticos de modelos autorregresivos integrados de media móvil (ARIMA) para la realización de ensayos de predicción de velocidades del viento en territorios marinos cercanos a la costa.

Una vez seleccionado del método que más se aproxime a la realidad se realiza un estudio temporal durante un año y otro estudio espacio-temporal del que se han extraído datos, gráficas e imágenes que hacen más fácil la comprensión de lo expuesto en el proyecto.

Los datos de partida del estudio han sido obtenidos del satélite orbital QuickSCAT, el cual ha proporcionado información meteorológica a nivel planetario de la superficie de los océanos y mares a lo largo de la última década. Todas las operaciones del proyecto han sido realizadas utilizando el código *R language*, herramienta muy potente a la hora de trabajar con grandes bases de datos.

Una de las razones de por las que se ha decidido realizar el proyecto acerca de la energía eólica es por el gran potencial de desarrollo que posee este tipo de energía, ya que a corto plazo la eólica *offshore* será una de las energías más representativas del planeta y se necesitarán técnicas predictivas para obtener el máximo rendimiento.

Capítulo 1

1.1 Introducción

En la actualidad, las necesidades energéticas son una de las principales causas de preocupación de los gobiernos a nivel mundial. La energía eólica es una de las energías limpias de recurso inagotable con mayor capacidad de creación de electricidad.

Durante las últimas dos décadas, este tipo de energía se ha ido desarrollando a lo largo de todo el planeta, especialmente en países como Estados Unidos, Alemania, Dinamarca y España. Hace pocos años se empezaron a realizar estudios de granjas eólicas en espacios marinos cercanos a la costa, como el de Thanet en la costa Británica, ya que al no existir relieves y contar con velocidades de viento constantes la electricidad generada es mayor que en los parques *onshore*.

El objeto de este proyecto es intentar evaluar diferentes tipos de modelos estadísticos para pronosticar velocidades de viento que ayuden a mejorar el rendimiento de estos parques *offshore* y además, al trabajar con datos obtenidos por satélites, cabe la posibilidad de reducir costes evitando la colocación de boyas meteorológicas que tengan que estar constantemente en proceso de mantenimiento.

Como decíamos, los datos de observación han sido obtenidos a partir del satélite QuikSCAT, estos datos, son la base de información de un grandísimo abanico de disciplinas relacionadas con el estudio climatológico de los mares y los océanos de La Tierra. La importancia de observar y procesar los vientos marinos es tal, que nos hace dependientes para realizar pronósticos meteorológicos fiables. La información obtenida por cada punto de observación es muy completa: velocidad del viento (exactitud de unos 2 m/s), dirección del viento (exactitud de unos 20°) y precipitación en un punto concreto. Los datos fueron puestos a disposición del público a las pocas horas de haber sido procesados en los servidores del Physical Oceanography

Trabajar con las observaciones obtenidas como la información oceanográfica no es nada sencillo. Son una gran cantidad de datos en cada fichero proporcionado por la NASA y es necesario apoyarse en unas herramientas para el correcto uso que determine las áreas de selección o consulta. Estas herramientas se constituyen en visualizadores, que ayudan al usuario a realizar operaciones de consulta y selección de una forma ágil.

En los siguientes capítulos detallaremos la base teórica y las diferentes operaciones realizadas para obtener las soluciones de este proyecto

1.2 Misión del Seawinds dentro del *QuikSCAT*

El satélite QuikSCAT (contracción de Quick Scatterometer) se ha encargado durante más de una década en recolectar datos meteorológicos marinos. El proyecto se llevó a cabo con el trabajo colaborativo de la NASA y la NOAA (Administración Nacional Oceánica y Atmosférica, National Oceanic & Atmospheric Administration).

Los objetivos de la misión se pueden generalizar en dos clases: **científicos y operativos**. En los objetivos científicos se destaca que los datos obtenidos se usan para combinar los datos de viento con las mediciones de los instrumentos científicos de otras disciplinas que ayuden a entender mejor los mecanismos del cambio climático:

- Estudio de los cambios anuales y semestrales de la lluvia.
- Estudio de los cambios diario/estacional del hielo del mar Ártico y el movimiento de los glaciares.
- Determinar la fuerza atmosférica, la respuesta de los océanos, y los mecanismos de interacción aire-mar en varias escalas espaciales y temporales.

Como objetivos operativos los datos obtenidos del satélite QuikSCAT ayudan a mejorar el pronóstico del tiempo cerca de las costas mediante el uso de los datos numéricos del viento en la intemperie y modelos de predicción de olas. También ayudan a mejorar el pronóstico de tormenta y en la vigilancia de su evolución.



Figura 1. Imagen artificial del satélite QuikSCAT

El corazón de QuikSCAT es un instrumento especialmente diseñado llamado Scatterometer. Es un radar que opera a una frecuencia de microondas que penetra las nubes. Esto, unido a la órbita polar del satélite, hace que los sistemas de vientos sobre los océanos sean visibles para QuikSCAT en el mundo entero. Las mediciones dan una información detallada acerca de los vientos de los océanos, las olas, corrientes, características polares de hielo y otros fenómenos, en beneficio de meteorólogos, climatólogos, oceanógrafos y marinos.

Los haces del radar no son parados por las nubes, sin embargo, la observación queda alterada por todo fenómeno que destruya las ondas: la lluvia, los vientos muy débiles o los vientos fuertes (Figura 2).




Figura 2. Señales del satélite QuikSCAT atravesando nubes, obtenida de

Técnicamente el instrumento usado en el QuikSCAT es un radar de alta frecuencia de microondas (de 13,4 GHz) diseñado específicamente para medir la velocidad y la dirección del viento próximas a la superficie del océano. El radar está montado en un plato giratorio de 1 metro de diámetro que produce dos haces de cobertura, barriendo en forma circular.

Este instrumento explora una andana de 1.800 kilómetros de ancho y realiza aproximadamente 400.000 medidas, cubriendo el 90% de la superficie de la tierra en un día, y proporcionándonos dos tipos de resoluciones: cada 25 km la más gruesa, y cada 12,5 km la fina.

El satélite QuikSCAT fue lanzado el 19 de junio del 1999 desde la base de la fuerza aérea Vandenberg, EE.UU., montado en un cohete Titán II. Dieciocho días después del lanzamiento la instrumentación del satélite empezó a recoger datos. La duración de la misión estaba estimada en 2 o 3 años pero la misión se alargó hasta el 2009 (10 años). El 23 de noviembre del 2009 una de las antenas del satélite cuya función era recoger las señales en tiempo real dejó de girar debido al desgaste de los rodamientos. Las piezas tenían una vida de alrededor de 5 años. Esta avería provocó el final de la misión.



Figura 3 Ejemplo de una órbita polar y otra geoestacionaria

El satélite realizaba 14 orbitas polares (ver figura 3) diarias alrededor del planeta. Cada órbita queda registrada en un fichero. Los datos están organizados por un tipo de ficheros llamados HDF, Hierarchical Data Format (HDF, 2010). La principal ventaja de estos ficheros es que son capaces de almacenar una gran cantidad de datos numéricos referidos a multitud de variables. La versión de los ficheros que utiliza es la HDF4 (HDF4, 2010), la cual puede soportar diferentes modelos de datos incluyendo matrices multidimensionales, imágenes raster y tablas.

El formato HDF es auto descriptivo, lo que permite que una aplicación pueda interpretar los datos sin ningún tipo de información externa.

Los datos recogidos se guardan en los servidores del PO.DAAC (Physical Oceanography DAAC) agrupados en diferentes resoluciones. Ésta información se encuentra disponible para todo el que esté interesado. La Tabla 1 muestra dónde pueden obtenerse los distintos conjuntos de datos, en todas sus versiones, producidos en la misión QuikSCAT.

Productos	Data	Software	Validated	Latency	UWND	VWND	WND	DIR	Temporal Resolution	Spatial Resolution
L3 Daily Gridded OWV	FTP HEFT	S/W	Y	24 - 96 horas	Y	Y	Y	N	Twice Daily	0.25°
Documentación: Manual del usuario	Comentarios: Cuando se cruzan franjas adyacentes, la medición más reciente sobrescribe la medición anterior.									
L2B OWV 25km Swath	FTP HEFT	S/W	Y	24-96 horas	N	N	Y	Y	Multiple Times Daily	25 km
Documentación: Manual del usuario	Comentarios: Fichero esta organizados de acuerdo a una orbital individual. Normalmente hay 14 orbitas por día.									
L2B OWV 12.5km Swath	FTP HEFT	S/W	Y	24-96 horas	N	N	Y	Y	Multiple Times Daily	12.5 km
Documentación: Manual del usuario	Comentarios: Fichero esta organizados de acuerdo a una orbital individual. Normalmente hay 14 orbitas por día.									

Tabla 1. Disponibilidad de los datos QuikSCAT

1.3 The PO.DAAC Ocean ESIP Tool (POET)

Existe otra herramienta llamada **The PO.DAAC Ocean ESIP Tool (POET)** la cual se ha utilizado para obtener los datos necesarios de este proyecto.

POET también permite la visualización de los datos obtenidos por el satélite QuikSCAT, pudiendo elegir el parámetro de búsqueda (temperatura, viento...) en una zona determinada y en un periodo de tiempo concreto

Esta herramienta es más práctica si no se desean grandes cantidades de datos, ya que no es necesaria ninguna otra aplicación para la comprensión de estos. Las tres siguientes imágenes muestran la interfaz gráfica de la herramienta POET.

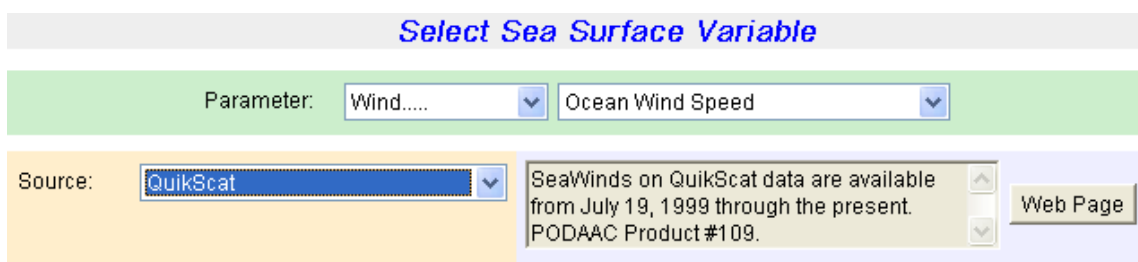


Figura 4. Ejemplo de selección de parámetro de la herramienta “POET”

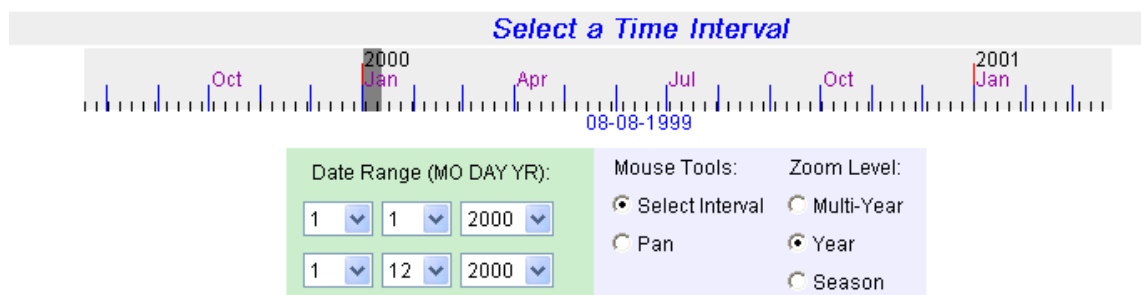


Figura 5. Ejemplo de selección de la franja horaria deseada de la herramienta “POET”




Figura 6. Ejemplo de selección de la zona geográfica de la herramienta “POET”

Una vez seleccionados todos los indicadores, podremos elegir en que formato nos devuelve los datos (ASCII, HDF, Binario...)

The PO.DAAC Ocean ESIP Tool (POET) puede encontrarse en:

<http://poet.jpl.nasa.gov/>

1.4 Revisión bibliográfica

Este proyecto no es el primero que se basa en la predicción de viento, los métodos para realizar pronósticos deben estar en constante desarrollo utilizando técnicas innovadoras para intentar aproximarse lo más posible a la realidad. Como hemos mencionado anteriormente, el QuikSCAT empezó a trabajar en el año 1999. Durante estos primeros años se realizaron varios estudios, donde los datos obtenidos fueron evaluados para certificar su validez, o bien fueron utilizados para apoyarse en otro tipo de métodos de predicción para un mayor rendimiento.

En el periodo comprendido entre los años 2002 y 2004 se realizaron comparaciones entre modelos operativos de predicción meteorológica y los datos obtenidos del satélite QuikSCAT en la costa Gallega. En este estudio se añadieron como complemento las mediciones tomadas de varias boyas meteorológicas situadas en alta mar, este trabajo se centró en un análisis estadístico basado en errores medios y correlación de datos. Los modelos utilizados para la predicción fueron los sistemas ARPS y MM5. Una vez vistos los resultados se dedujo que las estimaciones por satélite de viento mostraban un comportamiento dentro de los límites de confianza, por lo que podrían ser utilizados para fines futuros [E. Penabad , 06]

Continuando con el mismo propósito, fue otro el trabajo realizado durante los años 2000-2006 en el Mar Mediterráneo. A la hora de predicción de vientos, siempre han existido problemas en los límites mar-tierra, pues bien, estos estudios se apoyaron los datos QuikSCAT para optimizar resultados, los cuales mejoraron cuantiosamente. [A. Birol Kara, 07]

Nombrar también una comparativa realizada entre datos QuikSCAT y datos obtenidos por una boya situada en el Mar de Ligure (Golfo de Génova) ya que como hemos nombrado anteriormente se producen varios problemas a la hora de conocer vientos en los límites mar-tierra. En este caso los datos del satélite cumplieron los requisitos para velocidades altas pero su habilidad no fue satisfactoria en el caso de pronosticar direcciones para velocidades inferiores a los 3 m/s [Sara Pensieri, 09]

Estos tres estudios se basaron en la comprobación de los datos vía satélite pero no fue hasta el año 2007 cuando en Brasil se empezó a plantear la utilización de estos en plataformas *offshore*. En el estudio, los datos obtenidos por el satélite sirvieron como complemento de estaciones meteorológicas ya que estas carecían de capacidad para poder abarcar toda la costa brasileña. Las conclusiones fueron que los datos obtenidos vía satélite son un buen complemento de las estaciones meteorológicas para el aprovechamiento de la energía eólica en alta mar. Por consecuencia, se decidió impulsar este tipo de energía para un futuro a medio plazo, debido al gran potencial eólico del que dispone este país. [*Felipe Pimienta, 07*]

Mientras unos se planteaban la posibilidad de utilizar datos de satélites otros daban un paso más e intentaban realizar métodos de predicción que daban como óptimos los resultados obtenidos por telemetría.

Como en este proyecto, los trabajos a continuación expuestos buscaron diversas técnicas para aproximarse al valor real de velocidades del viento como por ejemplo, predecir velocidades de viento y altitud de olas a partir de datos obtenidos por el satélite TOPEX, usando redes neuronales. Se demostró la complejidad de realizar estos estudios debido a la rápida variación de magnitudes. [*Ruchi Kalra, 03*]

Aunque sabiendo la complejidad de la predicción mediante redes neuronales, muchos proyectos siguieron adelante manejando algoritmos BPTT y estructuras LF-DFNN obteniendo resultados bastante aceptables, con el único inconveniente del error estándar obtenido. [*T.G. Barbounis, 05*]

Como hemos indicado al principio del apartado, los métodos están en continuo desarrollo y mejora. Durante el año 2008 se desarrollaron algoritmos evolutivos en Alemania, pronosticando el viento de diez granjas eólicas, las conclusiones a las que se llegó fueron que utilizando este tipo de algoritmos se reducían el error en relación con el método de redes neuronales. [*René Jursa, 08*]

Por último comentar un trabajo realizado, en el cual se dan las claves, problemas, retos y soluciones de la teledetección para el desarrollo de energía eólica marina, destacando como principales problemas, el fuerte oleaje y la interferencia de radares provenientes de los barcos. Como curiosidad nombrar el inconveniente de las rutas migratorias de las aves, problema no solo existente en parques eólicos *onshore* ya que es una dificultad añadida a la hora de construcción de este tipo de parques.

[T.A. Kelly, 08]

A lo largo de este apartado hemos visto algunos ejemplos de cómo los datos del QuikSCAT han sido utilizados, examinados, comparados, pero siempre con la validez como resultado, otros ejemplos nombrados han sido sobre diferentes métodos utilizados para pronosticar vientos.

Durante de este proyecto, asumimos la validez de los datos e intentamos aportar una nueva manera de predecir vientos basándonos en métodos estadísticos ARIMA.

Capítulo 2

A lo largo de este capítulo se mostrarán los programas utilizados y la base teórica necesaria para en el capítulo tres, poder entender todas las operaciones realizadas

2.1 Software

R language

R es un lenguaje y entorno de programación para análisis estadístico y gráfico. Se trata de un proyecto de software libre, resultado de la implementación GNU del premiado lenguaje S. *R* y S-Plus -versión comercial de S- son, probablemente, los dos lenguajes más utilizados en investigación por la comunidad estadística, siendo además muy populares en el campo de la investigación biomédica, la bioinformática y las matemáticas financieras. A esto contribuye la posibilidad de cargar diferentes bibliotecas o paquetes con finalidades específicas de cálculo o gráfico. *R* se distribuye bajo la licencia GNU GPL y está disponible para los sistemas operativos Windows, Macintosh, Unix y GNU/Linux.

R forma parte de un proyecto colaborativo y abierto. Sus usuarios pueden publicar paquetes que extienden su configuración básica. Existe un repositorio oficial de paquetes cuyo número superó en otoño de 2009 la cifra de los 2000. Dado el enorme número de nuevos paquetes, éstos se han organizado en vistas (o temas), que permiten agruparlos según su naturaleza y función. Por ejemplo, hay grupos de paquetes relacionados con estadística bayesiana, econometría, series temporales, etc.

Los paquetes utilizados a lo largo del proyecto han sido:

- gstat
- sp
- zoo
- xts
- spacetime
- foreign
- lattice
- maptools
- maps
- mapdata
- forecast
- quadprog
- tseries

Todos estos paquetes han sido obtenidos a través del programa R versión 2.12.2, el propio programa y los manuales de usuario de cada paquete están disponibles en

<http://cran.r-project.org/>

2.2 Método ARIMA

El objetivo es obtener predicciones óptimas de Y_t en algún momento futuro basadas en un conjunto de información dado que en el caso del análisis de series temporales invariante está formada por el pasado disponible de la serie temporal

$$I_T = \{Y_T, Y_{T-1}, Y_{T-2}, Y_{T-3}, \dots\}$$

Supongamos que se observa una **serie temporal denotada por Y_t** , para $t = 0$ hasta $t = T$, donde T es la última observación de que disponemos. La predicción de series temporales supone decir algo sobre el valor que tomara la serie en momentos futuros $T+l$, donde **l representa el numero de periodos** en el futuro que estamos considerando. A la predicción de Y_{T+l} con información hasta el momento T la vamos a denotar por $Y_T(l)$. Si $l = 1$, entonces se predice el valor de Y_{T+1} y se calcula lo que se denomina predicción un periodo hacia adelante. Si $l = 3$, entonces se predice el valor de Y_{T+3} y se calcula la predicción tres periodos hacia adelante, etc.

Como estamos considerando que la serie temporal es una realización de un proceso estocástico estacionario, el valor que se quiere predecir, Y_{T+l} es también una variable aleatoria. Para predecir una variable aleatoria, se debería predecir su función de distribución y así poder hacer afirmaciones tales como: $\text{PROB}(163 < Y_{T+1} \cdot 190) = 0,42$.

Ahora bien, en general, va a ser muy difícil determinar completamente la forma de la función de densidad sin hacer supuestos muy fuertes y poco realistas sobre la forma de esta función. Un objetivo menos ambicioso sería diseñar unos intervalos de confianza alrededor del valor Y_{T+l} , que nos permitan decir que $\text{prob}(B < Y_{T+l} \cdot A) = 0,95$. Estos valores **A y B permiten poner unos límites al valor que se quiere predecir con un grado de confianza de estar en lo cierto suficientemente alto.**

Es interesante distinguir entre *predicción por intervalo* que conlleva la construcción de estos intervalos de predicción y la *predicción por punto*, que implica simplemente asignar un valor a Y_{T+l} que de alguna manera represente a toda la distribución de valores.

Por predictor óptimo (o predicción óptima) se denomina a aquel que es la mejor en el sentido de que minimiza una determinada función de pérdida. Lo más usual es minimizar el **Error Cuadrático Medio de Predicción**, por lo que diremos que $Y_T(l)$ es un predictor óptimo si minimiza el **ECMP**, es decir, si cumple que:

$$E[Y_{T+l} - Y_T(l)]^2 \leq E[Y_{T+l} - Y_T^*(l)]^2 \quad \forall Y_T^*(l)$$

Se puede demostrar que, bajo condiciones de regularidad muy débiles, el predictor por punto óptimo viene dado por la **esperanza (E)** condicionada al conjunto de información:

$$Y_T(l) = E[Y_{T+l}|I_T] = E[Y_{T+l}|Y_T, Y_{T-1}, Y_{T-2}, Y_{T-3}, \dots] = E_T[Y_{T+l}]$$

Es decir, por el valor esperado de la distribución de $Y_T(l)$ condicionada la información disponible.

Nada garantiza que esta esperanza condicionada sea una función lineal del pasado de la serie. Pero si el proceso sigue una distribución normal, se puede demostrar que la esperanza condicionada se puede expresar como una función lineal del conjunto de información I_T . Por lo tanto, bajo el supuesto de normalidad, el predictor óptimo en el sentido de minimizar el ECMP es lineal. Si no se cumple este supuesto, la proyección lineal de Y_{T+l} en su pasado proporcionaría el predictor óptimo dentro de la clase de predictores lineales. La predicción óptima por intervalo se construirá a partir de la distribución del error de predicción que, bajo el supuesto de que $a_t \approx RBN(0, \sigma^2)$ (**Proceso de ruido blanco normal con varianza σ**) es la siguiente:

$$e_T(\ell) = Y_{T+\ell} - Y_T(\ell) \sim N(0, V(e_T(\ell)))$$

Tipificando se obtiene:

$$\frac{Y_{T+\ell} - Y_T(\ell) - 0}{\sqrt{V(e_T(\ell))}} \sim N(0, 1)$$

De forma que el **intervalo de predicción** de probabilidad $(1 - \alpha)$ es:

$$\left[Y_T(\ell) - N_{\alpha/2} \sqrt{V(e_T(\ell))}, \quad Y_T(\ell) + N_{\alpha/2} \sqrt{V(e_T(\ell))} \right]$$

Predicción con modelos estacionarios

Consideremos el modelo lineal general $Y_t = a_t + \psi_1 a_{t-1} + \psi_2 a_{t-2} + \dots$, siendo $t=1, 2, \dots$, MA (∞) y el conjunto de información dado $I_t = \{Y_t, Y_{t-1}, Y_{t-2}, \dots\}$. La estrategia de predicción se va a basar en escribir el valor que se desea predecir, $Y_{T+\ell}$, tal y como se genera en función del modelo para luego obtener la predicción óptima calculando la esperanza condicionada al conjunto de información. Para la representación medias móviles general, $Y_{T+\ell}$ viene dado por:

$$Y_{T+\ell} = a_{T+\ell} + \psi_1 a_{T+\ell-1} + \psi_2 a_{T+\ell-2} + \dots + \psi_{\ell-1} a_{T+1} + \psi_{\ell} a_T + \psi_{\ell+1} a_{T-1} + \psi_{\ell+2} a_{T-2} + \dots$$

Tomando la esperanza condicionada al conjunto de información, se obtiene:

$$Y_T(\ell) = E_T[Y_{T+\ell}] = \psi_\ell a_T + \psi_{\ell+1} a_{T-1} + \psi_{\ell+2} a_{T-2} + \psi_{\ell+3} a_{T-3} + \dots$$

Dado que:

$$E_T(a_{T+j}) = \begin{cases} a_{T+j} & j \leq 0 \\ E(a_{T+j}) = 0 & j > 0 \end{cases}$$

La perturbación a_t es la innovación en el momento t . Si, dado el conjunto de información I_T , se conoce el verdadero valor de Y_t , como la parte sistemática se puede predecir mediante el modelo, la perturbación $a_t \approx Y_t - \text{PS}_t$ (**PS_t Parte sistemática o comportamiento regular de la variable**) está determinada, es fija. Si, dado I_T , no se conoce el verdadero valor de Y_t , entonces la innovación a_t no está determinada por el conjunto de información, con lo que su media condicionada será la misma que su media no condicionada, es decir, cero.

Los errores de predicción (e_T) son:

$$\begin{aligned} e_T(1) &= Y_{T+1} - Y_T(1) = a_{T+1} + \psi_1 a_T + \psi_2 a_{T-1} + \psi_3 a_{T-2} + \dots - \\ &\quad - (\psi_1 a_T + \psi_2 a_{T-1} + \psi_3 a_{T-2} + \dots) = a_{T+1} \\ e_T(2) &= Y_{T+2} - Y_T(2) = a_{T+2} + \psi_1 a_{T+1} + \psi_2 a_T + \psi_3 a_{T-1} + \dots - \\ &\quad - (\psi_2 a_T + \psi_3 a_{T-1} + \psi_4 a_{T-2} + \dots) = a_{T+2} + \psi_1 a_{T+1} \\ \dots &= \dots \\ e_T(\ell) &= Y_{T+\ell} - Y_T(\ell) = a_{T+\ell} + \psi_1 a_{T+\ell-1} + \psi_2 a_{T+\ell-2} + \dots + \psi_{\ell-1} a_{T+1} + \\ &\quad + \psi_\ell a_T + \psi_{\ell+1} a_{T-1} + \psi_{\ell+2} a_{T-2} + \dots - \\ &\quad - (\psi_\ell a_T + \psi_{\ell+1} a_{T-1} + \psi_{\ell+2} a_{T-2} + \psi_{\ell+3} a_{T-3} + \dots) = \\ &= a_{T+\ell} + \psi_1 a_{T+\ell-1} + \psi_2 a_{T+\ell-2} + \dots + \psi_{\ell-1} a_{T+1} \end{aligned}$$

Los errores de predicción son una combinación lineal de las perturbaciones futuras a_{T+l} , $l=1, 2, \dots$ con valor medio cero:

$$E_T(e_T(\ell)) = E_T[a_{T+\ell} + \psi_1 a_{T+\ell-1} + \psi_2 a_{T+\ell-2} + \dots + \psi_{\ell-1} a_{T+1}] = 0$$

La varianza del error (V_T) de predicción o Error Cuadrático Medio de Predicción viene dado por:

$$V_T(e_T(1)) = E_T[e_T(1)]^2 = E_T[a_{T+1}]^2 = \sigma^2$$

$$V_T(e_T(2)) = E_T[e_T(2)]^2 = E_T[a_{T+2} + \psi_1 a_{T+1}]^2 = (1 + \psi_1^2) \sigma^2$$

$$\dots = \dots$$

$$\begin{aligned} V(e_T(\ell)) &= E_T[e_T(\ell)]^2 = E_T[a_{T+\ell} + \psi_1 a_{T+\ell-1} + \psi_2 a_{T+\ell-2} + \dots + \psi_{\ell-1} a_{T+1}]^2 = \\ &= (1 + \psi_1^2 + \psi_2^2 + \dots + \psi_{\ell-1}^2) \sigma^2 = \sigma^2 \sum_{i=0}^{\ell-1} \psi_i^2 \end{aligned}$$

Como se puede observar la varianza del error de predicción va creciendo conforme nos alejamos en el futuro. Ahora bien, si el proceso es estacionario se cumple que:

$$\sum_{i=1}^{\infty} \psi_i^2 < \infty$$

Por lo que esta varianza no crece indefinidamente, sino que tiene una cota máxima finita. Se puede observar que la perturbación o innovación a_t y su varianza σ^2 tienen una nueva interpretación:

$a_t = Y_t - Y_{t-1}(1)$ Es el error de predicción un periodo hacia adelante.

$V(a_t) = \sigma^2$ Es la varianza del error de predicción un periodo hacia adelante

Si el proceso ruido blanco sigue una distribución normal, se tiene que:

$$e_T(\ell) = Y_{T+\ell} - Y_T(\ell) \sim N[0, V(e_T(\ell))]$$

Por lo que el intervalo de predicción de probabilidad $(1 - \alpha)$ es:

$$\begin{aligned} Y_{T+1} : & \quad \left[Y_T(1) - N_{\alpha/2} \sqrt{\sigma^2} \quad ; \quad Y_T(1) + N_{\alpha/2} \sqrt{\sigma^2} \right] \\ Y_{T+2} : & \quad \left[Y_T(2) - N_{\alpha/2} \sqrt{\sigma^2 (1 + \psi_1^2)} \quad ; \quad Y_T(2) + N_{\alpha/2} \sqrt{\sigma^2 (1 + \psi_1^2)} \right] \\ & \quad \vdots \quad \vdots \\ Y_{T+\ell} : & \quad \left[Y_T(\ell) - N_{\alpha/2} \sqrt{\sigma^2 \sum_{i=0}^{\ell-1} \psi_i^2} \quad ; \quad Y_T(\ell) + N_{\alpha/2} \sqrt{\sigma^2 \sum_{i=0}^{\ell-1} \psi_i^2} \right] \end{aligned}$$

Predicción con modelos MA (q)

Comencemos por un modelo de medias móviles sencillo, por ejemplo, el MA (2) de media cero:

$$Y_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} \quad a_t \sim RBN(0, \sigma^2) \quad t = 1, 2, \dots$$

La función de predicción es:

$$Y_{T+1} = a_{T+1} - \theta_1 a_T - \theta_2 a_{T-1}$$

$$Y_T(1) = E_T[Y_{T+1}] = E_T[a_{T+1} - \theta_1 a_T - \theta_2 a_{T-1}] = -\theta_1 a_T - \theta_2 a_{T-1}$$

$$Y_{T+2} = a_{T+2} - \theta_1 a_{T+1} - \theta_2 a_T$$

$$Y_T(2) = E_T[Y_{T+2}] = E_T[a_{T+2} - \theta_1 a_{T+1} - \theta_2 a_T] = -\theta_2 a_{T-1}$$

$$Y_{T+3} = a_{T+3} - \theta_1 a_{T+2} - \theta_2 a_{T+1}$$

$$Y_T(3) = E_T[Y_{T+3}] = E_T[a_{T+3} - \theta_1 a_{T+2} - \theta_2 a_{T+1}] = 0$$

$$Y_T(\ell) = E_T[Y_{T+\ell}] = 0 \quad (= E(Y_t)) \quad \forall \ell > 2$$

Por lo tanto, la función de predicción de un MA (2), depende del conjunto de información, I_T , para $l = 1, 2$. A partir de $l > 2$, la predicción óptima viene dada por la media del proceso.

Estos resultados se pueden generalizar fácilmente para el modelo MA(q):

$$Y_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad a_t \sim RBN(0, \sigma^2) \quad t = 1, 2, \dots$$

La función de predicción es:

$$Y_T(\ell) = \begin{cases} Y_T(1) = -\theta_1 a_T - \theta_2 a_{T-1} - \dots - \theta_q a_{T+1-q} \\ Y_T(2) = -\theta_2 a_T - \theta_3 a_{T-2} - \dots - \theta_q a_{T+2-q} \\ \dots \quad \dots \\ Y_T(q) = -\theta_q a_T \\ Y_T(\ell) = 0 \quad \forall \ell = q+1, q+2, \dots \end{cases}$$

Como el modelo $MA(2)$ está escrito directamente en forma medias móviles, se obtiene la varianza del error de predicción aplicando la expresión $I_t = \{Y_t, Y_{t-1}, Y_{t-2}, \dots\}$ con $\psi_i = \theta_i, i = 1, 2, \dots, q$ y $\psi_i = 0, \forall i > q$:

$$V(e_T(\ell)) = \begin{cases} V(e_T(1)) = \sigma^2 \\ V(e_T(2)) = (1 + \theta_1^2) \sigma^2 \\ \dots \quad \dots \\ V(e_T(q)) = (1 + \theta_1^2 + \theta_2^2 + \dots + \theta_{q-1}^2) \sigma^2 \\ V(e_T(\ell)) = (1 + \theta_1^2 + \theta_2^2 + \dots + \theta_q^2) \sigma^2 (= V(Y_t)) \quad \ell = q+1, q+2, \dots \end{cases}$$

Aunque la varianza del error de predicción es una función creciente de l , el horizonte de predicción, tiene una cota máxima que viene dada por la varianza no condicionada del proceso y que se alcanza para $l = q$.

Se puede concluir que para un modelo $MA(q)$ las predicciones para los q primeros horizontes de predicción, $l = 1, 2, \dots, q$, dependen del conjunto de información a través de los errores de predicción un periodo hacia adelante $a_T, a_{T-1}, \dots, a_{T+1-q}$, con lo que se mejora la predicción respecto de la media no condicionada del proceso porque se predice con una varianza del error de predicción menor que la varianza no condicionada

del proceso. A partir de $l = q$, el conjunto de información no aporta nada a la predicción porque las predicciones optimas son la media no condicionada del proceso y la varianza del error de predicción es la varianza no condicionada del proceso. Esto significa que, condicionando al conjunto de información, se obtienen los mismos resultados que sin condicionar, luego a partir de $l = q$, I_T ya no es informativo.

La predicción por intervalo viene dada por:

$$\begin{aligned}
 \ell = 1 & \quad \left[-\theta_1 a_T - \theta_2 a_{T-1} - \dots - \theta_q a_{T+1-q} \pm N_{\alpha/2} \sqrt{\sigma^2} \right] \\
 \ell = 2 & \quad \left[-\theta_2 a_T - \theta_3 a_{T-2} - \dots - \theta_q a_{T+2-q} \pm N_{\alpha/2} \sqrt{\sigma^2 (1 + \theta_1^2)} \right] \\
 & \quad \dots \quad \dots \\
 \ell = q & \quad \left[-\theta_q a_T \pm N_{\alpha/2} \sqrt{\sigma^2 (1 + \theta_1^2 + \dots + \theta_{q-1}^2)} \right] \\
 \ell > q & \quad \left[0 \pm N_{\alpha/2} \sqrt{\sigma^2 (1 + \theta_1^2 + \dots + \theta_{q-1}^2 + \theta_q^2)} \right]
 \end{aligned}$$

La amplitud de los intervalos de predicción va creciendo con l , con el límite impuesto por:

$$\pm N_{\alpha/2} \sqrt{\sigma^2 (1 + \theta_1^2 + \dots + \theta_{q-1}^2 + \theta_q^2)} = \pm N_{\alpha/2} \sqrt{V(Y_t)}$$

Predicción con modelos AR (p)

Consideremos el modelo autorregresivo más sencillo, el $AR(1)$.

$$Y_t = \phi Y_{t-1} + a_t \quad a_t \sim RBN(0, \sigma^2) \quad t = 1, 2, \dots$$

La función de predicción es:

$$Y_{T+1} = \phi Y_T + a_{T+1}$$

$$Y_T(1) = E_T[Y_{T+1}] = E_T[\phi Y_T + a_{T+1}] = \phi Y_T$$

$$Y_{T+2} = \phi Y_{T+1} + a_{T+2}$$

$$Y_T(2) = E_T[Y_{T+2}] = E_T[\phi Y_{T+1} + a_{T+2}] = \phi E_T[Y_{T+1}] = \phi Y_T(1)$$

$$Y_{T+3} = \phi Y_{T+2} + a_{T+3}$$

$$Y_T(3) = E_T[Y_{T+3}] = E_T[\phi Y_{T+2} + a_{T+3}] = \phi E_T[Y_{T+2}] = \phi Y_T(2)$$

De forma que la **función de predicción** es:

$$Y_T(\ell) = \phi Y_T(\ell), \quad \ell = 1, 2, 3, \dots$$

Dado que:

$$E_T(Y_{T+j}) = \begin{cases} Y_{T+j} & j \leq 0 \\ E(Y_T(j)) & j > 0 \end{cases}$$

La función de predicción $I_T(l) = \phi I_T(l)$ recoge una regla de cadena para obtener las predicciones de un proceso autorregresivo unas en función de las otras hasta un futuro indefinido. La trayectoria de la función de predicción depende de la estructura de la parte autorregresivo

$$Y_T(1) = \phi Y_T$$

$$Y_T(2) = \phi Y_T(1) = \phi \phi Y_T = \phi^2 Y_T$$

$$Y_T(3) = \phi Y_T(2) = \phi \phi^2 Y_T = \phi^3 Y_T$$

$$Y_T(4) = \phi Y_T(3) = \phi \phi^3 Y_T = \phi^4 Y_T$$

$$Y_T(\ell) = \phi^\ell Y_T \quad \ell = 1, 2, 3, \dots$$

Como el proceso autorregresivo es estacionario, $|\phi| < 1$, y por lo tanto cuando nos alejamos en el futuro la función de predicción tiende hacia la media no condicionada del proceso.

$$\lim_{\ell \rightarrow \infty} Y_T(\ell) = 0 (= E(Y_t))$$

Para construir los intervalos de predicción, se ha de obtener la varianza del error de predicción. Para ello es preciso partir del modelo escrito en forma medias móviles. En el caso del $AR(1)$:

$$(1 - \phi L) Y_t = a_t \rightarrow Y_t = \frac{1}{1 - \phi L} a_t$$

$$\rightarrow Y_t = (1 + \phi L + \phi^2 L^2 + \phi^3 L^3 + \dots) a_t$$

$$\rightarrow Y_t = a_t + \phi a_{t-1} + \phi^2 a_{t-2} + \phi^3 a_{t-3} + \dots$$

Por lo que la varianza del error de predicción se obtiene aplicando la fórmula general:

$$\sigma^2 \sum_{i=0}^{\ell-1} \psi_i^2$$

Con $\psi_i = \phi^i, \forall i$:

$$V(e_T(\ell)) = \begin{cases} V(e_T(1)) = & \sigma^2 \\ V(e_T(2)) = & (1 + \phi^2) \sigma^2 \\ V(e_T(3)) = & (1 + \phi^2 + (\phi^2)^2) \sigma^2 \\ V(e_T(4)) = & (1 + \phi^2 + (\phi^2)^2 + (\phi^3)^2) \sigma^2 \\ V(e_T(\ell)) = & (1 + \phi^2 + (\phi^2)^2 + \dots + (\phi^{\ell-1})^2) \sigma^2 \end{cases}$$

La varianza del error de predicción es monótonamente creciente conforme nos alejamos en el futuro. Como el proceso es estacionario, esta varianza no crece indefinidamente sino que tiene una cota superior dada por la varianza no condicionada del proceso:

$$\lim_{\ell \rightarrow \infty} V(e_T(\ell)) = \lim_{\ell \rightarrow \infty} \sigma^2 \left[1 + \phi^2 + (\phi^2)^2 + \dots + (\phi^{\ell-1})^2 \right] = \frac{\sigma^2}{1 - \phi^2} = V(Y_t)$$

La predicción por intervalo es:

$$\begin{aligned}
 \ell = 1 & \quad \left[\phi Y_T \pm N_{\alpha/2} \sqrt{\sigma^2} \right] \\
 \ell = 2 & \quad \left[\phi Y_T(1) \pm N_{\alpha/2} \sqrt{\sigma^2 (1 + \phi^2)} \right] \\
 \ell = 3 & \quad \left[\phi Y_T(2) \pm N_{\alpha/2} \sqrt{\sigma^2 (1 + \phi^2 + (\phi^2)^2)} \right] \\
 & \quad \dots \quad \dots \\
 \ell & \quad \left[\phi Y_T(\ell - 1) \pm N_{\alpha/2} \sqrt{\sigma^2 (1 + \phi^2 + (\phi^2)^2 + \dots + (\phi^{\ell-1})^2)} \right]
 \end{aligned}$$

La amplitud de los intervalos de predicción va creciendo con ℓ , con el límite impuesto por:

$$\pm N_{\alpha/2} \sqrt{\frac{\sigma^2}{1 - \phi^2}} = \pm N_{\alpha/2} \sqrt{V(Y_t)}$$

Los resultados obtenidos para el modelo $AR(1)$ se pueden extender para el modelo $AR(p)$. En general, las funciones de predicción de procesos autorregresivo puros, se obtendrán a partir de reglas de cadena:

$$Y_T(\ell) = \phi_1 Y_T(\ell - 1) + \phi_2 Y_T(\ell - 2) + \phi_3 Y_T(\ell - 3) + \dots + \phi_p Y_T(\ell - p), \quad \ell = 1, 2, 3, \dots$$

La función de predicción de un proceso $AR(1)$ utiliza la última observación Y_T para obtener la predicción un periodo hacia adelante y luego, a partir de esta, se obtienen el resto de las predicciones. En el caso de un autorregresivo de orden p autorregresivo de orden p , se utilizaran las p últimas observaciones para obtener las predicciones para $\ell = 1, 2, \dots, p$, y el resto se obtienen a partir de las p primeras.

Predicción con modelos ARMA (p,q).

Consideremos un modelo ARMA (p, q) sencillo, el ARMA (1, 2)

$$Y_t = \delta + \phi Y_{t-1} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} \quad a_t \sim RBN(0, \sigma^2) \quad t = 1, 2, \dots$$

La media de este proceso no es cero si $\delta \neq 0$

$$E(Y_t) = \frac{\delta}{1 - \phi}$$

Las predicciones por punto son:

$$Y_{T+1} = \delta + \phi Y_T + a_{T+1} - \theta_1 a_T - \theta_2 a_{T-1}$$

$$\begin{aligned} Y_T(1) &= E_T[Y_{T+1}] = E_T[\delta + \phi Y_T + a_{T+1} - \theta_1 a_T - \theta_2 a_{T-1}] = \\ &= \delta + \phi Y_T - \theta_1 a_T - \theta_2 a_{T-1} \end{aligned}$$

$$Y_{T+2} = \delta + \phi Y_{T+1} + a_{T+2} - \theta_1 a_{T+1} - \theta_2 a_T$$

$$\begin{aligned} Y_T(2) &= E_T[Y_{T+2}] = E_T[\delta + \phi Y_{T+1} + a_{T+2} - \theta_1 a_{T+1} - \theta_2 a_T] = \\ &= \delta + \phi Y_T(1) - \theta_2 a_T \end{aligned}$$

$$Y_{T+3} = \delta + \phi Y_{T+2} + a_{T+3} - \theta_1 a_{T+2} - \theta_2 a_{T+1}$$

$$\begin{aligned} Y_T(3) &= E_T[Y_{T+3}] = E_T[\delta + \phi Y_{T+2} + a_{T+3} - \theta_1 a_{T+2} - \theta_2 a_{T+1}] = \\ &= \delta + \phi Y_T(2) \end{aligned}$$

$$\rightarrow Y_T(\ell) = E_T[Y_{T+\ell}] = \delta + \phi Y_T(\ell - 1) \quad \forall \ell > 2$$

La estructura de la función de predicción es la siguiente. Las dos primeras predicciones dependen de la última observación Y_T (parte autorregresivo) y de los últimos errores de predicción un periodo hacia adelante a_T y a_{T-1} (parte medias móviles). Para $l > 2$, la parte medias móviles no aparece de forma explícita en la función de predicción, y cada predicción se va obteniendo de las anteriores siguiendo una *regla en cadena* marcada por la parte autorregresivo. Esta función se va acercando a la media del proceso conforme nos alejamos en el futuro:

$$Y_T(3) = \delta + \phi Y_T(2)$$

$$Y_T(4) = \delta + \phi Y_T(3) = \delta + \phi(\delta + \phi Y_T(2)) = \delta(1 + \phi) + \phi^2 Y_T(2)$$

$$Y_T(5) = \delta + \phi Y_T(4) = \delta + \phi(\delta(1 + \phi) + \phi^2 Y_T(2)) = \delta(1 + \phi + \phi^2) + \phi^3 Y_T(2)$$

$$\dots \quad \dots$$

$$Y_T(\ell) = \delta + \phi Y_T(\ell - 1) = \delta(1 + \phi + \phi^2 + \dots + \phi^{\ell-3}) + \phi^{\ell-2} Y_T(2)$$

De forma que como el modelo ARMA (2, 1) es estacionario, $|\phi| < 1$ y:

$$\lim_{\ell \rightarrow \infty} Y_T(\ell) = \delta \sum_{i=0}^{\ell-3} \phi^i = \frac{\delta}{1 - \phi} (= E(Y_t))$$

Para obtener la varianza del error de predicción y, por lo tanto, las predicciones por intervalo, se deriva la representación medias móviles infinitas:

$$(1 - \phi L) Y_t = (1 - \theta_1 L - \theta_2 L^2) a_t$$

$$\rightarrow Y_t = \frac{1 - \theta_1 L - \theta_2 L^2}{1 - \phi L} a_t = (1 + \psi_1 L + \psi_2 L^2 + \psi_3 L^3 + \dots) a_t$$

De donde:

$$\frac{1 - \theta_1 L - \theta_2 L^2}{1 - \phi L} = 1 + \psi_1 L + \psi_2 L^2 + \psi_3 L^3 + \dots$$

$$\rightarrow 1 - \theta_1 L - \theta_2 L^2 = (1 - \phi L)(1 + \psi_1 L + \psi_2 L^2 + \psi_3 L^3 + \dots)$$

E igualando coeficientes:

$$\begin{aligned} L \quad -\theta_1 L &= (\psi_1 - \phi) L \Rightarrow -\theta_1 = \psi_1 - \phi \Rightarrow \psi_1 = \phi - \theta_1 \\ L^2 \quad -\theta_2 L^2 &= (\psi_2 - \phi\psi_1) L^2 \Rightarrow -\theta_2 = \psi_2 - \phi\psi_1 \Rightarrow \psi_2 = \phi\psi_1 - \theta_2 = \phi(\phi - \theta_1) - \theta_2 \\ L^3 \quad 0 L^3 &= (\psi_3 - \psi_2 \phi) L^3 \Rightarrow 0 = \psi_3 - \psi_2 \phi \Rightarrow \psi_3 = \phi \psi_2 \\ \dots \quad \dots & \end{aligned}$$

Los pesos de la forma medias móviles infinita son:

$$\psi_i = \begin{cases} k=0 & \psi_0 = 1 \\ k=1 & \psi_1 = \phi - \theta_1 \\ k=2 & \psi_2 = \phi\psi_1 - \theta_2 = \phi(\phi - \theta_1) - \theta_2 \\ k>2 & \psi_k = \phi \psi_{k-1} \end{cases}$$

Con estos pesos se pueden construir los intervalos de predicción. Como el proceso ARMA (1, 2) es estacionario, la amplitud de los intervalos iría creciendo conforme nos alejamos en el futuro pero con una cota máxima dada por $\left[\pm N_{\alpha/2} \times \sqrt{V(Y_t)} \right]$

Predicciones con modelos estacionarios estimados

Habitualmente no se conoce el proceso que ha generado la serie temporal Y_t por lo que hay que estimarlo con los datos disponibles, obteniendo:

$$\hat{\phi}_p(L) Y_t = \hat{\theta}_q(L) \hat{a}_t \quad t = 1, 2, \dots, T$$

Donde a_t son los residuos del modelo, pero también una estimación del error de predicción un periodo hacia adelante.

Por ejemplo, en el caso del modelo

$$Y_t = \delta + \phi Y_{t-1} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2}$$

La función de predicción estimada sería:

$$Y_T(\ell) = \begin{cases} \ell = 1 & Y_T(1) = \hat{\delta} + \hat{\phi} Y_T - \hat{\theta}_1 \hat{a}_T - \hat{\theta}_2 \hat{a}_{T-1} \\ \ell = 2 & Y_T(2) = \hat{\delta} + \hat{\phi} Y_T(1) - \hat{\theta}_2 \hat{a}_T \\ \ell > 2 & Y_T(\ell) = \hat{\delta} + \hat{\phi} Y_T(\ell - 1) \end{cases}$$

Predicción con modelos no estacionarios.

La predicción con modelos no estacionarios *ARIMA* (p, d, q) se lleva a cabo de la misma manera que con los modelos estacionarios *ARMA* (p, q). El predictor por punto óptimo de Y_{T+l} viene dado por la esperanza condicionada al conjunto de información Y_T ($l = E_T[Y_{T+l}]$). Para obtener esta **esperanza condicionada** basta con escribir el modelo en forma de ecuación en diferencias y obtener las esperanzas condicionadas, sabiendo que:

$$E_T[Y_{T+j}] = \begin{cases} Y_{T+j} & j \leq 0 \\ Y_T(j) & j > 0 \end{cases} \quad E_T[a_{T+j}] = \begin{cases} a_{T+j} & j \leq 0 \\ 0 & j > 0 \end{cases}$$

Para construir los **intervalos de predicción**,

$$\left[Y_T(\ell) \pm N_{\alpha/2} \sqrt{V(e_T(\ell))} \right] \quad \text{donde} \quad V(e_T(\ell)) = \sigma^2 \sum_{j=0}^{\ell-1} \psi_j^2$$

El modelo ha de estar escrito en forma MA (∞) ya que ψ_j son los pesos del modelo *ARIMA* escrito en forma medias móviles.

.

2.3 Series Temporales

Una serie temporal se define como una colección de observaciones de una variable recogidas secuencialmente en el tiempo. Estas observaciones se suelen recoger en instantes de tiempo equiespaciados. Si los datos se recogen en instantes temporales de forma continua, se debe o bien digitalizar la serie, es decir, recoger sólo los valores en instantes de tiempo equiespaciados, o bien acumular los valores sobre intervalos de tiempo.

Clasificaciones de las series temporales

Una serie temporal puede ser **discreta o continua** dependiendo de cómo sean las observaciones. Si se pueden predecir exactamente los valores, se dice que las series son determinánticas. Si el futuro sólo se puede determinar de modo parcial por las observaciones pasadas y no se pueden determinar exactamente, se considera que los futuros valores tienen una distribución de probabilidad que está condicionada a los valores pasados. Las series son así estocásticas. **Dado el tema a tratar en este proyecto la serie pertenece a este último caso.**

Objetivos del análisis de series temporales

Se pueden considerar varios posibles objetivos:

1. Descripción

Cuando se estudia una serie temporal, lo primero que se tiene que hacer es dibujarla y considerar las medidas descriptivas básicas. Así, se tiene que considerar:

- a) Si los datos presentan forma creciente (tendencia), en nuestro caso no, ya que el viento puede aumentar o disminuir

- b) Si existe influencia de ciertos periodos de cualquier unidad de tiempo (estacionalidad).
- c) Si aparecen outliers (observaciones extrañas o discordantes), esto también nos afecta, ya que a la hora de recopilar datos con el satélite aparecen datos “*muertos*”

2. Predicción

Cuando se observan los valores de una serie, se pretende normalmente no sólo explicar el pasado, sino también predecir el futuro.

Componentes de una serie temporal

El estudio descriptivo de series temporales se basa en la idea de descomponer la variación de una serie en varias componentes básicas. Este enfoque no siempre resulta ser el más adecuado, pero es interesante cuando en la serie se observa cierta tendencia o cierta periodicidad. Hay que resaltar que esta descomposición no es en general única.

Este enfoque descriptivo consiste en encontrar componentes que correspondan a una tendencia a largo plazo, un comportamiento estacional y una parte aleatoria.

Las componentes o fuentes de variación que se consideran habitualmente son las siguientes:

- 1. Tendencia:** Se puede definir como un cambio a largo plazo que se produce en relación al nivel medio, o el cambio a largo plazo de la media. La tendencia se identifica con un movimiento suave de la serie a largo plazo.

2. Efecto Estacional: Muchas series temporales presentan cierta periodicidad o dicho de otro modo, variación de cierto periodo (anual, mensual...). Por ejemplo, el paro laboral aumenta en general en invierno y disminuye en verano. Estos tipos de efectos son fáciles de entender y se pueden medir explícitamente o incluso se pueden eliminar del conjunto de los datos, desestacionalizando la serie original.

3. Componente Aleatoria: Una vez identificados los componentes anteriores y después de haberlos eliminado, persisten unos valores que son aleatorios. Se pretende estudiar qué tipo de comportamiento aleatorio presentan estos residuos, utilizando algún tipo de modelo probabilístico que los describa.

De las tres componentes reseñadas, las dos primeras son componentes determinísticas, mientras que la última es aleatoria. Así, se puede denotar que:

$$X_t = T_t + E_t + I_t$$

Donde **T_t** es la **tendencia** y **E_t** es la **componente estacional**, que constituyen la señal o parte determinística, e **I_t** es el ruido o parte aleatoria. Es necesario aislar de alguna manera la componente aleatoria, en nuestro caso el mismo programa las aísla y estudiar qué modelo probabilístico es el más adecuado. Conocido éste, podremos conocer el comportamiento de la serie a largo plazo. Esto será motivo de estudio en Inferencia Estadística.

Este aislamiento de la componente aleatoria se suele abordar de dos maneras:

- 1. Enfoque descriptivo:** Se estima T_t y E_t y se obtiene I_t como
- 2. Enfoque de Box-Jenkins:** Se elimina de X_t la tendencia y la parte estacional (mediante transformaciones o filtros) y queda sólo la parte probabilística. A esta última parte se le ajustan modelos paramétricos.

2.4 Series Espacio-Temporales

En la actualidad, existe un gran interés en la modelización geoestadística de dependencias espacio-temporales que considere las interacciones de ambos argumentos, espacio y tiempo, con la finalidad de incrementar la capacidad predictiva de los procedimientos de *krigeado* y *cokrigeado*. El procedimiento *krigeado* es el que se utilizará a la hora de realizar predicciones espaciotemporales en la última parte del proyecto, este procedimiento nos permite utilizar el programa *R language*

Dichas dependencias, incorporadas en las funciones de covarianza o variogramas no separables, exigen de la disposición de un elenco suficientemente amplio de modelos teóricos covariográficos o variográficos válidos

La estadística espacial reconoce y aprovecha la ubicación espacial de los datos a la hora de diseñar, recopilar, gestionar, analizar y mostrar las observaciones. Éstas son generalmente dependientes, si bien existen modelos espaciales a disposición del investigador que permiten tratar con dicha dependencia espacial a la hora de llevar a cabo labores de predicción. La estadística espacio-temporal incorpora, además, el tiempo y su interacción con el espacio como argumento de ayuda en tales labores predictivas.

En los últimos 10 años ha habido una creciente toma de conciencia de esta necesidad, habiéndose realizado un gran esfuerzo por buscar herramientas adecuadas y útiles a tales efectos. Y todo ello porque utilizar modelos espaciales o espacio-temporales para caracterizar y explotar la dependencia espacial de un conjunto de observaciones el cual tiene importantes ventajas:

- Modelos más generales, ya que, en la mayoría de los casos, los modelos clásicos que no tienen en consideración la dimensión espacial o la interacción de las dimensiones espacial y temporal son un caso particular de un modelo espacial o espacio-temporal
- Estimaciones más eficientes: de la tendencia, de los efectos de las variables explicativas, de promedios regionales,...
- Mejora de las predicciones: más eficientes, con propiedades de extrapolación más estables,...
- La variación espacial no explicada en la estructura de la media debe ser absorbida por la estructura del error, por lo que un modelo que incorpore la dependencia espacial puede decirse que está protegido frente a una mala especificación de este tipo. Esto, en muchos casos, tiene como resultado una simplificación en la especificación de la tendencia; en general, los modelos con dependencia espacial suelen tener una descripción más parsimoniosa (en ocasiones con muchos menos parámetros) que los clásicos modelos de superficie de tendencia.

Conceptos básicos de funciones covariográficas espacio-temporales

Esta sección es meramente expositiva y lo que contiene es el instrumental básico relacionado con la definición de covarianza espacio-temporal, puesto que la principal dificultad del análisis de las funciones aleatorias espacio-temporales será seleccionar aquel modelo de función de covarianza que mejor se ajuste a las observaciones, entre aquellas que son válidas.

Sea un conjunto de duplas espacio-temporales denotadas por $Z(s,t)_i$, $i = 1, 2, \dots, n$. Sea $Z(s,t)$, una función aleatoria espacio-temporal Gaussiana con media $m(s,t)$ y con varianza constante y finita. Entonces, la function

$$(s_1, s_2, t_1, t_2) \rightarrow C_{st}(s_1, s_2, t_1, t_2)$$

Se denomina *función de covarianza espacio-temporal* de la función aleatoria en cuestión y, si no se consideran nuevas hipótesis, depende únicamente de las coordenadas espacio-temporales (s_1, s_2, t_1, t_2)

Capítulo 3

En este apartado vamos a ir describiendo cada uno de los pasos realizados durante el proyecto: toma de datos, operaciones y código de programación

Mas adelante, en el capítulo cuatro analizaremos la viabilidad de los datos

3.1 Obtención de datos y zona de trabajo

CAPTURA DE DATOS

Como ya indicamos en el apartado 1.3 los datos han sido obtenidos a partir de la herramienta POET (The PO.DAAC Ocean ESIP Tool). Las acciones necesarias para poder disponer de estos datos son las siguientes:

La primera opción de la herramienta es elegir el parámetro con el que queremos trabajar, en nuestro caso será el viento, a continuación, otra de las posibilidades que presenta la herramienta, es el satélite con el que queremos trabajar, se ha elegido el satélite QuikSCAT dada su importancia en la previsión de fenómenos meteorológicos marinos en la última década.

Por último en esta primera selección, POET nos permite elegir la resolución espacio-temporal, aunque en nuestro caso, al trabajar con QuikSCAT, los parámetros están ya fijados por la propia herramienta, impidiendo modificarlos.

Todo lo anterior descrito queda reflejado en la siguiente imagen.

Select Sea Surface Variable

Parameter: Wind.... Ocean Wind Speed

Source: QuikScat

SeaWinds on QuikScat data are available from July 19, 1999 through the present. PODAAC Product #109.

Web Page

Figura 7. Selección de parámetro de la herramienta “POET”

Una vez seleccionadas todas las variables de búsqueda, el siguiente paso es el de seleccionar el intervalo de tiempo con el cual vamos a trabajar, en nuestro caso, no hay ninguna preferencia, podríamos haber elegido cualquier intervalo, nos hemos decantado por los primeros veintiocho días del año 2000.

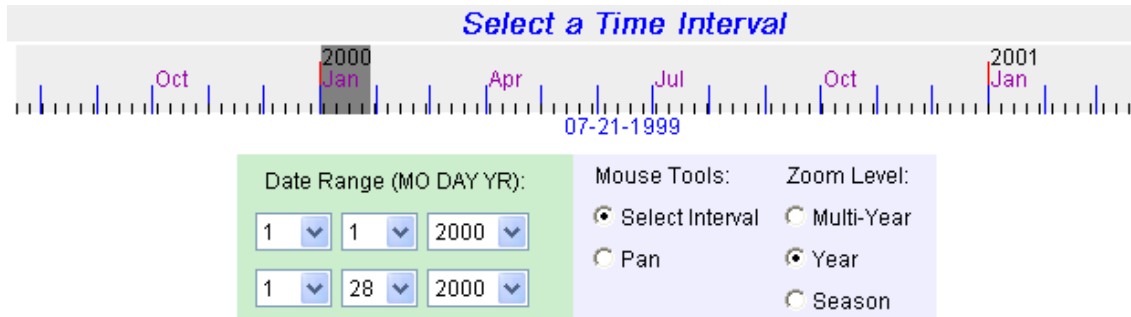


Figura 8. Selección de la franja horaria deseada de la herramienta “POET”

El tercer paso, es seleccionar la zona geográfica con la que vamos a trabajar, al igual que en el intervalo de tiempo, esta elección también es irrelevante, nos hemos decantado por una zona de nuestro país, siendo esta una zona del mar Cantábrico situada entre Asturias y Cantabria.




Figura 9. Selección de la zona geográfica de la herramienta “POET” mediante dibujo de zona




Figura 9. Selección de la zona geográfica de la herramienta “POET” mediante inserción de coordenadas

El último paso es el de elegir el formato de salida, podemos elegir diferentes formatos: desde imágenes hasta archivos en formato HDF. Nuestra selección es la de dato tipo ASCII debido a su facilidad de lectura.

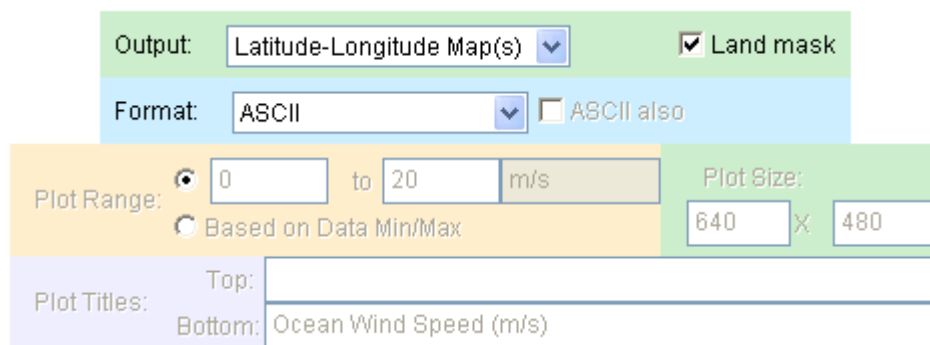


Figura 11 Selección de formato de salida de datos

Una posibilidad de la aplicación es la de ver la búsqueda on-line o descargar los datos.


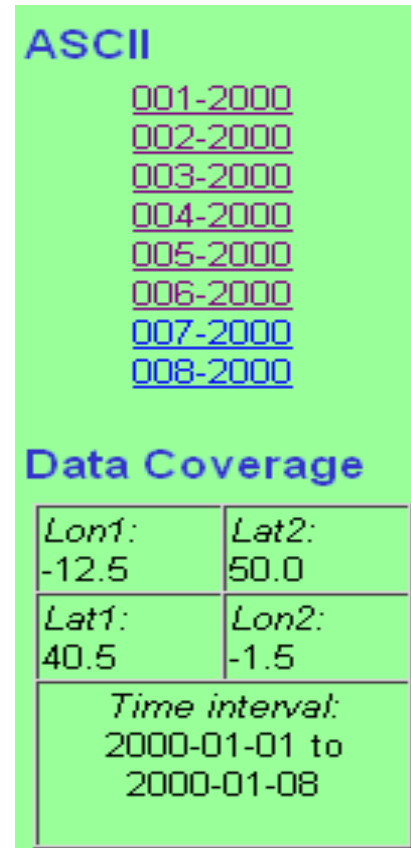


Figura 12 Formato de visualización

Una vez cumplimentado todos los requisitos, y tras un breve periodo de espera, la herramienta POET nos proporciona los datos solicitados.

La forma en que POET nos proporciona los datos es la siguiente:

Una columna en la que podemos elegir el día del cual queremos saber la velocidad del viento y un cuadro donde nos indica la zona geográfica en la que estamos trabajando



The screenshot shows a green background with two main sections. The top section, titled 'ASCII' in blue, contains eight blue underlined links: '001-2000', '002-2000', '003-2000', '004-2000', '005-2000', '006-2000', '007-2000', and '008-2000'. The bottom section, titled 'Data Coverage' in blue, contains a table with geographic coordinates and a time interval.

Lon1: -12.5	Lat2: 50.0
Lat1: 40.5	Lon2: -1.5
Time interval: 2000-01-01 to 2000-01-08	

Figura13 Pantalla de toma de datos

Hay que indicar que rango del número de día es de [000-365], por lo que el día 2 de Febrero será el día 32 y el día 30 de Diciembre será el día 364

La manera de lectura de datos es la siguiente:

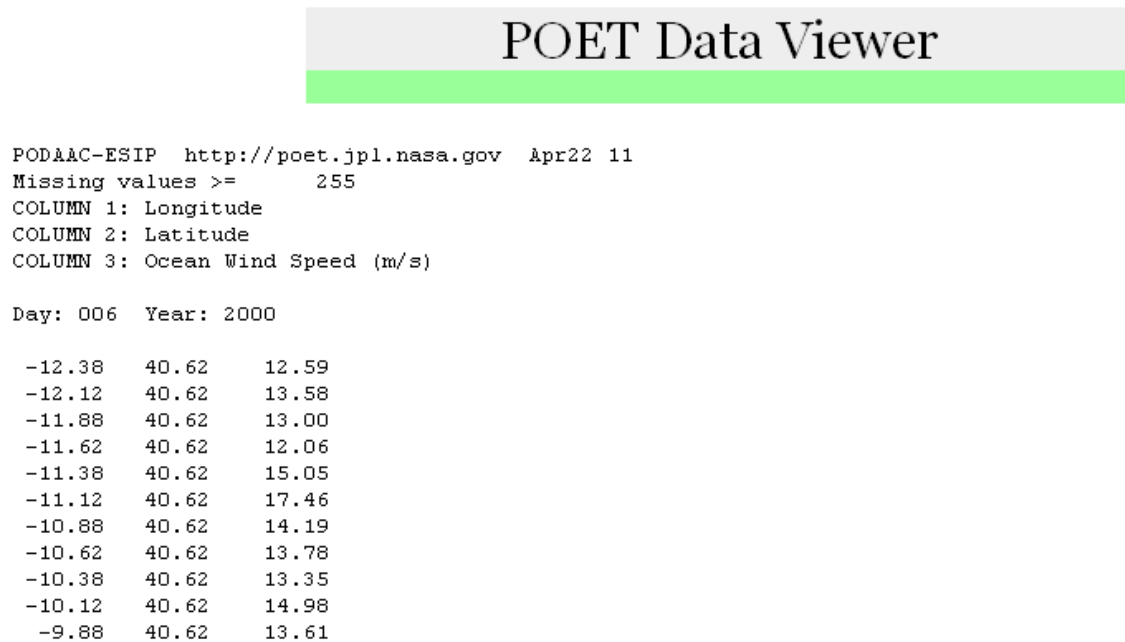


Figura13 Pantalla de toma de datos

Donde tenemos las coordenadas de un punto en el espacio y la velocidad del viento en el punto, en este caso de día 6 de Enero.

Hay que indicar también, que en algunos puntos el valor es de 255 m/s, esto significa que ha existido una pérdida de datos del satélite normalmente, a causa de intervalos nubosos o lluvia.

Se han elegido las siguientes coordenadas como puntos de estudio

PUNTO	COORDENADA	
	LATITUD	LONGITUD
A	-4,88	43.88
B	-4,62	43.88
C	-4,38	43.88
D	-4,12	43.88
E	-4,88	44.12
F	-4,62	44.12
G	-4,38	44.12
H	-4,12	44.12

Tabla 2 Coordenadas elegidas para la realización del estudio

Como hemos hecho en apartados anteriores adjuntamos una imagen para una mejor visualización de los puntos seleccionados



Figura 12 Puntos de estudio

La extensión de la zona a trabajar es de unos 100 Km² siendo la distancia de unos 20 Km entre los puntos A-D y de unos 5 Km entre A-E

3.2 Análisis de datos

Antes de empezar a realizar cualquier operación con métodos matemáticos realizaremos un estudio básico de los datos obtenidos por la herramienta POET. En la tabla siguiente podemos ver la velocidad del viento en cada uno de los ocho puntos de estudio (A,B,C....H) a lo largo de los primeros veinticuatro días del mes de Enero del año 2000.

	A	B	C	D	E	F	G	H
1	4.07	3.72	3.25	3.76	2.72	3.43		3.70
2								
3	3.62	3.12		2.44	3.19	2.70	3.49	2.84
4	4.67	4.75	5.10	5.57	5.71			6.61
5	3.95	4.11	3.83	3.90	4.25		4.39	4.01
6		4.29	3.96	3.24	3.42	4.22	3.90	5.69
7		1.98	2.07	0.00	1.17	1.24	0.6	1.56
8	4.20	3.96	4.44	3.61	4.62	4.20	3.99	4.49
9	10.79	11.19	11.89	13.59		13.84	13.26	13.49
10	6.25	6.67	6.47	7.54	6.61	6.86	7.22	
11	6.70	6.68	5.90	6.66	5.64	5.69	5.57	5.39
12	4.54	3.90	4.48			4.26	4.43	4.06
13	5.92		6.45	3.13		4.32	5.93	5.89
14	13.72	8.56	9.57	5.78	7.88			4.52
15		13.74	11.83	12.03	9.78	11.28	9.84	
16	9.45		9.42	8.96		7.60	9.07	7.62
17	7.08	6.54	7.24	6.16		6.12	6.51	
18	7.88	6.15	7.88	6.65	7.16			6.49
19	9.51	9.42	8.84		8.68	8.53		7.64
20	8.96	8.85		8.19	9.09	8.28	8.82	
21			5.39	9.09	5.65	9.83	5.62	10.53
22	4.14	4.82	4.57			4.01	5.04	4.93
23	6.86	6.13	7.54			6.79	5.97	6.46
24	6.04	6.08		5.77	4.79	5.38	5.51	


Tabla 3 Velocidad del viento en los puntos de estudio (m/s)

Estudio de datos

ESTADÍSTICOS ESTANDAR


Punto A:

	A
Mín.	3.620
1º Qu	4.370
Medina	6.250
Media	6.755
3º Qu	8.420
Máx.	13.720
Vacios	5.000




PUNTO B

	B
Mín.	1.980
1º Qu	4.072
Medana	6.105
Media	6.233
3º Qu	7.150
Máx	13.740
Vacios	4




PUNTO C

	C
Mín.	2.070
1º Qu	4.470
Medana	6.175
Media	6.506
3º Qu	8.120
Máx	11.890
Vacios	4




PUNTO D


	D
Mín.	0
1º Qu	3.685
Medana	5.780
Media	6.109
3º Qu	7.865
Máx	13.590
Vacios	5

**PUNTO E**

	E
Mín.	1.170
1º Qu	4.043
Medana	5.645
Media	5.647
3º Qu	7.340
Máx	9.780
Vacios	8


**PUNTO F**

	F
Mín.	1.240
1º Qu	4.221
Medana	6.333
Media	6.371
3º Qu	7.840
Máx	13.840
Vacios	5




PUNTO G

	G
Mín.	0.600
1º Qu	4.400
Medana	5.595
Media	6.064
3º Qu	7.043
Máx	13.260
Vacios	6



PUNTO H

	H
Mín.	1.560
1º Qu	4.168
Medana	5.540
Media	5.884
3º Qu	6.580
Máx	13.490
Vacios	6



3.3 Aplicación de los métodos ARIMA

Con cada uno de los métodos mostrados en la siguiente lista, vamos a realizar un estudio en los ocho puntos mostrados, tomando como valores de viento los obtenidos con la herramienta POET.

La elección de estos métodos no es casual, como se indica en el apartado 2.2, los resultados pueden ser de lo más diversos modificando el orden (p,d,q) por lo que tomaremos valores pequeños de p y q como por ejemplo 1 y 2 para después dar a estos parámetros valores más elevados como 5 ó 10 y ver como varían los resultados.

Métodos utilizados

- RA (1)
- RA (2)
- RA (5)
- RA (10)
- MA (1)
- MA (2)
- ARIMA(0,1,0)
- ARIMA(1,1,1)
- ARIMA(1,2,1)
- MA (5)
- MA (10)
- ARMA (1,1)
- ARMA (1,2)
- ARMA (1,5)
- ARMA (1,10)

Mencionar que se han realizado estudios preliminares de otros métodos, pero al realizar las primeras predicciones se han desechado por carecer sus resultados de significado alguno.

Descripción de las operaciones realizadas

Disponiendo de los datos de viento desde el día D-24 hasta el día D-1 se han realizado predicciones para los días D y D+1, siendo estos dos últimos los días 25 y 26 de Enero del año 2000.

Para cada día se han realizado predicciones con el método ARIMA, variando el orden del método, proporcionándonos una predicción (**pre**) y un error estándar (**se**), además de este método se realizó una predicción con una función proporcionada por R language llamada PREDICT, la cual genera predicciones a partir de un modelo lineal ARIMA. Las predicciones de PREDICT (**pred**) son muy próximas a las obtenidas por ARIMA, incluso las mejora, el inconveniente es que su error estándar (**sed**) suele ser mayor.

El esquema con el cual se ha realizado el estudio de todos los métodos es el siguiente:

1º Apoyándonos en los datos anteriores (D-24 hasta D-1) se realiza una predicción para el día D. Una vez hecha se adjuntan gráficas donde se muestra la diferencia con los datos reales.

2º Se realiza la misma acción que en 1º pero esta vez añadiendo la función PREDICT volviendo a mostrar las gráficas correspondientes.

Una vez realizada la predicción para el día D, añadimos los datos REALES de viento a la base de datos para predecir la velocidad del viento del día D+1, por lo que a la hora de realizar la segunda predicción contaremos con las velocidades de viento desde el día D-24 hasta el día D. Los siguientes dos pasos son semejantes a los realizados en 1º y 2º

3º Predicción D +1

4º Predicción D+1 utilizando la función PREDICT.

ESTUDIO MODELO AR (1)

Los datos reales son los siguientes:

PUNTO	A	B	C	D	E	F	G	H
REAL D		6,68	8,83	7,99	8,38	7,74	7,79	

Como podemos ver en los puntos A y H aparecen datos *muertos*, lo cuales surgen como ya se ha comentado a causa de lluvias y existencia de nubes en el momento que se realizó la lectura. Aunque no dispongamos de estos datos, trabajaremos con los datos disponibles y averiguaremos que modelo se aproxima más a la realidad.

Realizando predicciones con el Modelo AR (1) los datos obtenidos con su error estándar han sido:

DIA D	PRE	6,67	6,20	6,33	6,03	5,50	8,97	6,05	5,75
	SE	0,76	0,88	0,89	0,92	1,00	1,77	0,80	0,79

La diferencia de los datos reales con los datos obtenidos se puede ver en la siguiente gráfica.




Figura 16 Diferencia DATOS-PREDICCIÓN AR (1).

Para ver el gráfico de valores reales y datos obtenidos, tenemos las siguientes imágenes, en la primera simplemente representamos en dato real y el dato obtenido por AR (1) y en la segunda añadimos el error estándar de los datos generados, creándose un MAX1 y un MIN1.




Figura 17 Gráfica DATOS-PREDICCIÓN AR (1)




Figura 18 Gráfica DATOS-PREDICCIÓN \pm ERROR AR (1)

Estudiado AR(1), haremos una ampliación AR(1) + PREDICT, los resultados han sido:

DIA D	PRED	6,52	6,15	6,57	5,95	5,03	10,29	5,90	5,78
	SED	2,62	0,81	2,60	3,00	1,73	5,97	2,64	2,71

La diferencia de los datos reales con los datos obtenidos es:




Figura 16 Diferencia DATOS-PREDICCIÓN AR (1).

El gráfico de valores reales y datos obtenidos, tenemos las siguientes gráficas, en la primera, al igual que en las anteriores se representa el dato real y el dato obtenido por AR (1) + la función PREDICT y en la segunda se representan de nuevo el dato real, pero esta vez se añaden los posibles errores siendo estos MAX2 y MIN2, lo indicamos con esta nomenclatura para situarnos en el acto en el tipo de gráfica que se está observando.




Figura 19 Diferencia DATOS-PREDICCIÓN AR (1) + PREDICT




Figura 20 y26 Gráfica DATOS-PREDICCIÓN AR (1).+ PREDICT

Una vez realizado los cambios mencionados al inicio del apartado, los datos para el día D+1 son los siguientes:

PUNTO	A	B	C	D	E	F	G	H
REAL D+1	10.07	9,92		9.09	10.91	9.83	10.81	10.53

Los datos obtenidos:

DÍA D +1	PRE	6,67	10,24	10,23	9,36	7,17	9,54	8,59	5,75
	SE	0,76	1,59	1,32	1,22	1,44	1,88	1,61	0,59

La representación de los datos es la siguiente:




Figura 22 Diferencia DATOS-PREDICCIÓN AR (1).




Figura 23 Gráfica DATOS-PREDICCIÓN AR (1)




Figura 24 Gráfica DATOS-PREDICCIÓN \pm ERROR AR (1)

Añadiendo la función PREDICT al día D+1 los resultados son los siguientes




Figura 25 Diferencia DATOS-PREDICCIÓN AR (1) + PREDICT




Figura 26 Gráfica DATOS-PREDICCIÓN AR (1).+ PREDICT




Figura 27 Gráfica DATOS-PREDICCIÓN \pm ERROR AR (1) + PREDICT

ESTUDIO MODELO AR (2)

Los datos reales para el día D los siguientes:

PUNTO	A	B	C	D	E	F	G	H
REAL D		6,68	8,83	7,99	8,38	7,74	7,79	

Realizando predicciones con el Modelo AR (2) los datos obtenidos han sido:

DIA D	PRE	6,64	6,20	6,44	5,99	5,45	8,95	6,05	5,70
	SE	0,79	0,78	0,75	0,77	1,14	1,43	0,62	0,62

La diferencia entre datos reales y datos predichos son:




Figura 28 Diferencia DATOS-PREDICCIÓN AR (2).

Los gráficos de valores reales y datos obtenidos junto a los errores estándar son:




Figura 29 Gráfica DATOS-PREDICCIÓN AR (2)




Figura30 Gráfica DATOS-PREDICCIÓN \pm ERROR AR (2)

Una vez estudiado AR(2), haremos una ampliación AR(2) + PREDICT, los resultados han sido:

DÍA D	PRED	5,74	6,15	6,73	5,98	5,08	8,94	5,89	5,70
	SED	2,52	2,56	2,53	3,02	1,78	5,80	2,49	2,63

La diferencia de los datos reales con los datos obtenidos son los siguientes:




Figura 31 Diferencia DATOS-PREDICCIÓN AR (1) + PREDICT

Los gráficos de valores reales y datos obtenidos, los mostramos en las siguientes gráficas:




Figura 32 Gráfica DATOS-PREDICCIÓN AR (2).+ PREDICT




Figura 33 Gráfica DATOS-PREDICCIÓN \pm ERROR AR (2)+PREDICT

Al igual que para el día D, los datos para el día D+1 son:

PUNTO	A	B	C	D	E	F	G	H
REAL D+1	10,07	9,92		9,09	10,91	9,83	10,81	10,53

Los datos obtenidos:

DIA D+1	PRE	6,64	10,28	10,17	9,29	7,20	9,53	8,59	5,70
	SE	0,79	1,29	1,45	0,83	0,79	1,57	1,61	0,62

Al igual que hemos realizado anteriormente, la representación de los datos es:




Figura 34 Diferencia DATOS-PREDICCIÓN AR (2).




Figura 35 Gráfica DATOS-PREDICCIÓN AR (2)




Figura 36 Gráfica DATOS-PREDICCIÓN \pm ERROR AR (2)

Añadiendo la función PREDICT al día D+1 los resultados son:




Figura 37 Diferencia DATOS-PREDICCIÓN AR (1) + PREDICT




Figura 38 Gráfica DATOS-PREDICCIÓN AR (2).+ PREDICT




Figura 39 Gráfica DATOS-PREDICCIÓN \pm ERROR AR (2) + PREDICT

ESTUDIO MODELO AR (5)

Los datos reales son los siguientes:

PUNTO	A	B	C	D	E	F	G	H
REAL D		6,68	8,83	7,99	8,38	7,74	7,79	

Realizando predicciones con el Modelo AR (5) los datos obtenidos con su error estándar han sido:

DIA D	PRE	6,27	5,95	6,15	5,66	5,19	8,96	5,97	5,56
	SE	1,29	1,26	1,23	1,34	1,02	1,78	1,00	0,80

La diferencia de los datos reales con los datos obtenidos son los expuestos en siguiente gráfica.




Figura 40 Diferencia DATOS-PREDICCIÓN AR (5).

Gráficos de valores reales y datos obtenidos:




Figura 41 Gráfica DATOS-PREDICCIÓN AR (5)




Figura42 Gráfica DATOS-PREDICCIÓN \pm ERROR AR (5)

Una vez estudiado AR(5), haremos una ampliación AR(5) + PREDICT, los resultados son:

DIA D	PRE	7,9	7,46	7,18	5,92	4,71	8,32	7,30	5,11
	SE	2,19	2,33	2,51	2,82	1,47	5,54	2,28	2,75

La diferencia de los datos reales con los datos obtenidos se puede ver en la siguiente gráfica.




Figura 43 Diferencia DATOS-PREDICCIÓN AR (5) + PREDICT

En las siguientes gráficas se representa el dato real y el dato obtenido por AR (5) + la función PREDICT y por otro lado el dato real, pero esta vez se añaden los posibles errores al valor predicho




Figura 44 Gráfica DATOS-PREDICCIÓN AR (5).+ PREDICT




Figura45 Gráfica DATOS-PREDICCIÓN \pm ERROR AR (5) + PREDICT

Los datos para el día D+1 son los siguientes:

PUNTO	A	B	C	D	E	F	G	H
REAL D+1	10,07	9,92		9,09	10,91	9,83	10,81	10,53

Los datos obtenidos:

DIA D	PRE	6,27	10,06	10,21	9,27	7,13	9,67	8,08	5,56
	SE	1,29	1,71	1,58	0,67	0,91	2,55	3,18	0,80

La representación de los datos para el día D+1 es la siguiente:




Figura 46 Diferencia DATOS-PREDICCIÓN AR (5).




Figura 47 Gráfica DATOS-PREDICCIÓN AR (5)




Figura 48 Gráfica DATOS-PREDICCIÓN \pm ERROR AR (5)

Añadiendo la función PREDICT al día D+1 los resultados son:




Figura 49 Diferencia DATOS-PREDICCIÓN AR (5) + PREDICT




Figura 50 Gráfica DATOS-PREDICCIÓN AR (5).+ PREDICT




Figura 51 Gráfica DATOS-PREDICCIÓN \pm ERROR AR (5) + PREDICT

ESTUDIO MODELO AR (10)

Los datos reales son los siguientes:

PUNTO	A	B	C	D	E	F	G	H
REAL D		6,68	8,83	7,99	8,38	7,74	7,79	

Realizando predicciones con el Modelo AR (10) los datos obtenidos con su error estándar han sido:

DIA D	PRE	6,54	6,15	6,49	7,31			6,74	5,44
	SE	0,12	0,31	0,67	1,31			0,24	0,08

En este modelo, a la hora de realizar alguna operación surgen problemas al utilizar el método AR(10), lo que nos impide pronosticar la velocidad del viento en esos dos puntos.

La diferencia de los datos reales con los datos obtenidos se puede ver a continuación




Figura 52 Diferencia DATOS-PREDICCIÓN AR (10).

Las gráficas de valores reales y datos obtenidos, son las siguientes:




Figura 53 Gráfica DATOS-PREDICCIÓN AR (10)




Figura 54 Gráfica DATOS-PREDICCIÓN \pm ERROR AR (10)

Una vez estudiado AR(10), haremos una ampliación AR(10) + PREDICT, los resultados han sido:

DIA D	PRE	1,12	3,32	5,47	13,24			5,37	4,11
	SE	0,5	0,99	2,11	1,67			0,69	1,09

La diferencia de los datos reales con los datos obtenidos se puede ver en la siguiente gráfica.




Figura 55 y 61 Diferencia DATOS-PREDICCIÓN AR (10) + PREDICT

El gráfico de valores reales y datos obtenidos más sus respectivos errores son los siguientes:




Figura 56 Gráfica DATOS-PREDICCIÓN AR (10).+ PREDICT




Figura 57 Gráfica DATOS-PREDICCIÓN \pm ERROR AR (10) + PREDICT

Al igual que para el día D, los datos para el día D+1 son:

PUNTO	A	B	C	D	E	F	G	H
REAL D+1	10,07	9,92		9,09	10,91	9,83	10,81	10,53

Los datos obtenidos:

PRED D+1	PRE	6,54							5,44
	SE	0,12							0,08

La representación de los datos es la siguiente:




Figura 58 Diferencia DATOS-PREDICCIÓN AR (10)




Figura 59 Gráfica DATOS-PREDICCIÓN AR (10)




Figura 60 Gráfica DATOS-PREDICCIÓN \pm ERROR AR (10)

Añadiendo la función PREDICT al día d+1 los resultados son los siguientes




Figura 61 Diferencia DATOS-PREDICCIÓN AR (10) + PREDICT




Figura 62 Gráfica DATOS-PREDICCIÓN AR (10).+ PREDICT




Figura 63 Gráfica DATOS-PREDICCIÓN \pm ERROR AR (10) +PREDICT

ESTUDIO MODELO MA (1)

Los datos reales son los siguientes:

PUNTO	A	B	C	D	E	F	G	H
REAL 25		6,68	8,83	7,99	8,38	7,74	7,79	

Realizando predicciones con el Modelo MA(1) los datos obtenidos con su error estándar han sido:

DIA D	PRE	6,72	6,17	6,45	6,00	5,54	8,92	6,05	5,68
	SE	0,65	0,76	0,64	0,91	0,66	2,10	0,80	2,06

La diferencia de los datos reales con los datos obtenidos es:




Figura 64 Diferencia DATOS-PREDICCIÓN MA (1).

Para ver el gráfico de valores reales y datos obtenidos, tenemos las siguientes gráficas:




Figura 65 Gráfica DATOS-PREDICCIÓN MA (1)




Figura 66 Gráfica DATOS-PREDICCIÓN \pm ERROR MA (1)

Una vez estudiado MA(1), haremos una ampliación MA(1) + PREDICT, los resultados han sido:

DIA D	PRE	6,66	6,07	6,45	5,91	5,23	4,99	5,80	5,68
	SE	2,65	2,61	2,60	2,99	2,02	5,36	2,54	2,75

La diferencia de los datos reales con los datos obtenidos se puede ver en la siguiente gráfica.




Figura 67 Diferencia DATOS-PREDICCIÓN MA (1) + PREDICT

Las gráficas de MA (1) + la función PREDICT son:




Figura 68 Gráfica DATOS-PREDICCIÓN AR (1).+ PREDICT




Figura 69 Gráfica DATOS-PREDICCIÓN \pm ERROR MA (1) + PREDICT

Al igual que para el día D, los datos para el día D+1 son los siguientes:

PUNTO	A	B	C	D	E	F	G	H
REAL D+1	10,07	9,92		9,09	10,91	9,83	10,81	10,53

Los datos obtenidos:

DIA D+1	PRE	6,72	10,26	10,23	9,29	7,20	9,66	8,61	5,68
	SE	0,65	1,71	1,33	0,93	1,57	1,84	1,52	2,06

Al igual que hemos realizado en el día anterior, la representación de los datos es la siguiente




Figura 70 Diferencia DATOS-PREDICCIÓN MA (1).




Figura 71 Gráfica DATOS-PREDICCIÓN MA (1)




Figura 72 Gráfica DATOS-PREDICCIÓN \pm ERROR MA (1)

Añadiendo la función PREDICT al día D+1 los resultados son los siguientes:




Figura 73 Diferencia DATOS-PREDICCIÓN MA (1) + PREDICT




Figura 74 Gráfica DATOS-PREDICCIÓN AR (1).+ PREDICT




Figura 75 Gráfica DATOS-PREDICCIÓN \pm ERROR MA (1) + PREDICT

ESTUDIO MODELO MA (2)

Los datos reales son los siguientes:

PUNTO	A	B	C	D	E	F	G	H
REAL D		6,68	8,83	7,99	8,38	7,74	7,79	

Realizando predicciones con el Modelo MA (2) los datos obtenidos con su error estándar han sido:

DIA D	PRE	6,65	6,24	6,40	6,05	5,45	8,90	6,00	6,06
	SE	0,86	0,92	0,81	0,79	0,79	1,40	0,72	0,72

La diferencia de los datos reales con los datos obtenidos se puede ver en la siguiente gráfica.




Figura 76 Diferencia DATOS-PREDICCIÓN MA (2).

Las siguientes gráficas muestran los resultados proporcionados por el modelo MA(1) y sus errores:




Figura 77 Gráfica DATOS-PREDICCIÓN MA (2)




Figura 78 Gráfica DATOS-PREDICCIÓN \pm ERROR MA (2)

Una vez estudiado MA(2), haremos una ampliación MA(2), + PREDICT, los resultados han sido:

DIA D	PRE	7,05	6,32	6,64	5,96	5,00	5,44	5,86	5,86
	SE	2,52	2,52	2,65	3,10	1,68	5,17	2,52	2,53

La diferencia de los datos reales con los datos obtenidos se puede ver en la siguiente gráfica.




Figura 79 Diferencia DATOS-PREDICCIÓN MA (2) + PREDICT

Gráficas MA(2) + función PREDICT




Figura 80 Gráfica DATOS-PREDICCIÓN MA (2).+ PREDICT




Figura 81 Gráfica DATOS-PREDICCIÓN \pm ERROR MA (2) + PREDICT

Para el día D+1, los datos son los siguientes:

PUNTO	A	B	C	D	E	F	G	H
REAL D+1	10,07	9,92		9,09	10,91	9,83	10,81	10,53

Los datos obtenidos:

DIA D+1	PRE	6,65	10,29	10,18	9,41	7,14	9,72	8,60	5,69
	SE	0,86	1,31	1,41	0,22	0,99	1,63	1,58	0,61

Al igual que hemos realizado en el día anterior, la representación de la diferencia de datos es :




Figura 82 Diferencia DATOS-PREDICCIÓN MA (2).




Figura 83 Gráfica DATOS-PREDICCIÓN MA (2)




Figura 84 Gráfica DATOS-PREDICCIÓN \pm ERROR MA (2)

Añadiendo la función PREDICT al día D+1 los resultados son los siguientes




Figura 85 Diferencia DATOS-PREDICCIÓN MA (2) + PREDICT




Figura 86 Gráfica DATOS-PREDICCIÓN MA (2).+ PREDICT




Figura 87 Gráfica DATOS-PREDICCIÓN \pm ERROR MA (2) + PREDICT

ESTUDIO MODELO MA(5)

Los datos reales son los siguientes:

PUNTO	A	B	C	D	E	F	G	H
REAL D		6,68	8,83	7,99	8,38	7,74	7,79	

Realizando predicciones con el Modelo MA(5) los datos obtenidos con su error estándar han sido:

DIA D	PRE	6,37	6,23	6,29	5,98	5,32	9,40	6,00	6,02
	SE	0,91	0,88	0,91	0,99	0,83	3,00	0,78	0,38

La diferencia de los datos reales con los datos obtenidos se puede ver en la siguiente gráfica.




Figura 88 Diferencia DATOS-PREDICCIÓN MA (5).

Las gráficas correspondientes a MA(5) son:




Figura 89 Gráfica DATOS-PREDICCIÓN MA (5)




Figura 90 Gráfica DATOS-PREDICCIÓN \pm ERROR MA (5)

Estudiado MA(5), haremos una ampliación MA(5) + PREDICT, los resultados han sido:

DIA D	PRE	7,12	6,31	6,00	6,51	4,79	8,68	5,89	7,03
	SE	2	2,59	2,52	3,23	1,54	4,77	2,08	6,54

La diferencia de los datos reales con los datos obtenidos se puede ver en la siguiente gráfica.




Figura 91 Diferencia DATOS-PREDICCIÓN MA (5) + PREDICT

Las gráficas MA(5) + la función PREDICT con sus errores son:




Figura 92 Gráfica DATOS-PREDICCIÓN MA (5).+ PREDICT




Figura 93 Gráfica DATOS-PREDICCIÓN \pm ERROR MA (5) + PREDICT

Al igual que para el día D, los datos para el día D+1 son los siguientes:

PUNTO	A	B	C	D	E	F	G	H
REAL D+1	10,07	9,92		9,09	10,91	9,83	10,81	10,53

Los datos obtenidos:

DIA D+1	PRE	6,37	10,11	10,33	9,37	6,86	10,20	8,68	6,02
	SE	0,91	1,50	1,45	0,29	1,27	2,70	2,00	0,38

Al igual que hemos realizado en el día anterior, la representación de los datos es la siguiente




Figura 94 Diferencia DATOS-PREDICCIÓN MA (5).




Figura 95 Gráfica DATOS-PREDICCIÓN MA (5)




Figura 96 Gráfica DATOS-PREDICCIÓN \pm ERROR MA (5)

Añadiendo la función PREDICT al día D+1 los resultados son los siguientes




Figura 97 Diferencia DATOS-PREDICCIÓN MA (5) + PREDICT




Figura 98 Gráfica DATOS-PREDICCIÓN MA (5).+ PREDICT




Figura 99 Gráfica DATOS-PREDICCIÓN \pm ERROR MA (5) + PREDICT

ESTUDIO MODELO MA(10)

Los datos reales son los siguientes:

PUNTO	A	B	C	D	E	F	G	H
REAL D		6,68	8,83	7,99	8,38	7,74	7,79	

Realizando predicciones con el Modelo MA (10) los datos obtenidos con su error estándar han sido:

DIA D	PRE	6,1	6,09	6,70	5,79	5,35	6,70	6,35	5,37
	SE	1,13	1,08	0,38	0,43	0,78	0,38	0,32	0,39

La diferencia de los datos reales con los datos obtenidos se puede ver en la siguiente gráfica.




Figura 100 Diferencia DATOS-PREDICCIÓN MA (10).

Para ver el gráfico de valores reales y datos obtenidos, tenemos las siguientes gráficas, en la primera representamos en dato real y el dato obtenido por MA (10) y en la segunda añadimos el error estándar de los datos generados




Figura 101 Gráfica DATOS-PREDICCIÓN MA (10)




Figura 102 Gráfica DATOS-PREDICCIÓN \pm ERROR MA (10)

Una vez estudiado MA (10), haremos una ampliación MA (10) + PREDICT, los resultados han sido:

DIA D	PRE	1,87	7,53	6,64	5,15	6,48	6,64	6,55	3,61
	SE	1,83	2,02	1,90	2,53	1,30	1,90	1,99	3,31

La diferencia de los datos reales con los datos obtenidos se puede ver en la siguiente gráfica.




Figura 103 Diferencia DATOS-PREDICCIÓN MA (10) + PREDICT

Las gráficas que representan los valores reales, la predicción y los errores estándar son:




Figura 104 Gráfica DATOS-PREDICCIÓN MA (10).+ PREDICT




Figura 105 Gráfica DATOS-PREDICCIÓN \pm ERROR MA (10)+PREDICT

Al igual que para el día D, los datos para el día D+1 son los siguientes:

PUNTO	A	B	C	D	E	F	G	H
REAL D+1	10,07	9,92		9,09	10,91	9,83	10,81	10,53

Los datos obtenidos:

DIA D+1	PRE	6,1	10,04	10,51	9,42	7,08	10,06	8,73	5,37
	SE	1,13	1,97	0,73	0,43	0,47	2,26	2,52	0,39

Al igual que hemos realizado en el día anterior, la representación de los datos es:




Figura 106 Diferencia DATOS-PREDICCIÓN MA (5).




Figura 107 Gráfica DATOS-PREDICCIÓN MA (10)




Figura 108 Gráfica DATOS-PREDICCIÓN \pm ERROR MA (10)

Añadiendo la función PREDICT al día D+1 los resultados son los siguientes




Figura 110 Diferencia DATOS-PREDICCIÓN MA (10) + PREDICT




Figura 111 Gráfica DATOS-PREDICCIÓN MA (10).+ PREDICT




Figura 112 Gráfica DATOS-PREDICCIÓN \pm ERROR
MA(10)+PREDICT

ESTUDIO MODELO ARMA (1,1)

Los datos reales son los siguientes:

PUNTO	A	B	C	D	E	F	G	H
REAL D		6,68	8,83	7,99	8,38	7,74	7,79	

Realizando predicciones con el Modelo ARMA (1,1) los datos obtenidos con su error estándar han sido:

DIA 25	PRE	6,51	6,19	6,41	6,05	5,42	6,15	5,05	5,69
	SE	0,94	0,85	0,81	0,82	1,18	0,78	0,76	0,62

La diferencia de los datos reales con los datos obtenidos se puede ver en la siguiente gráfica.




Figura 113 Diferencia DATOS-PREDICCIÓN ARMA (1,1).

Los gráficos de valores reales y datos obtenidos del modelo ARMA (1,1) son:




Figura 114 Gráfica DATOS-PREDICCIÓN ARMA (1,1)




Figura 115 Gráfica DATOS-PREDICCIÓN \pm ERROR ARMA (1,1)

Una vez estudiado ARMA (1,1), haremos una ampliación ARMA (1,1) + PREDICT, los resultados han sido:

DIA D+1	PRE	6,45	6	6,57	5,89	5,12	5,87	5,83	5,67
	SE	2,58	2,58	2,64	3,03	1,78	2,96	2,53	2,74

La diferencia de los datos reales con los datos obtenidos se puede ver en la siguiente gráfica.




Figura 116 Diferencia DATOS-PREDICCIÓN ARMA (1,1)

Gráficas de los datos y errores del modelo ARMA (1,1) + función PREDICT




Figura 117 Gráfica DATOS-PREDICCIÓN ARMA (1,1)




Figura 118 Gráfica DATOS-PREDICCIÓN \pm ERROR ARMA (1,1)+ PREDICT

Los datos para el día D+1 son los siguientes:

PUNTO	A	B	C	D	E	F	G	H
REAL D+1	10,07	9,92		9,09	10,91	9,83	10,81	10,53

Los datos obtenidos:

DIA D+1	PRE	6,51	6,22	6,58	6,15	5,77	6,2	6,18	5,69
	SE	0,96	0,82	0,78	0,79	1,21	0,74	0,73	0,62

Al igual que hemos realizado en el día anterior, la representación de los datos es la siguiente




Figura 119 Diferencia DATOS-PREDICCIÓN ARMA (1,1).




Figura 120 Gráfica DATOS-PREDICCIÓN ARMA (1,1)




Figura 121 Gráfica DATOS-PREDICCIÓN \pm ERROR ARMA (1,1)

Añadiendo la función PREDICT al día D+1 los resultados son los siguientes




Figura 122 Diferencia DATOS-PREDICCIÓN ARMA (1,1) + PREDICT




Figura 123 Gráfica DATOS-PREDICCIÓN ARMA (1,1).+ PREDICT




Figura 124 Gráfica DATOS-PREDICCIÓN \pm ERROR ARMA (1,1) + PREDICT

ESTUDIO MODELO ARMA (1, 2)

Los datos reales son los siguientes:

PUNTO	A	B	C	D	E	F	G	H
REAL D		6,68	8,83	7,99	8,38	7,74	7,79	

Realizando predicciones con el Modelo ARMA (1,2) los datos obtenidos con su error estándar han sido:

DIA D	PRE	6,70	6,42	6,42	6,05	5,47	6,36	6,08	5,70
	SE	0,82	0,83	0,80	0,85	0,74	0,73	0,66	0,61

La diferencia de los datos reales con los datos obtenidos se puede ver en la siguiente gráfica.




Figura 125 Diferencia DATOS-PREDICCIÓN ARMA (1,2).

Disponemos de las siguientes gráficas, en la primera simplemente representamos en dato real y el dato obtenido por ARMA (1,2) y en la segunda añadimos el error estándar de los datos generados




Figura 126 Gráfica DATOS-PREDICCIÓN ARMA (1,2)




Figura 127 Gráfica DATOS-PREDICCIÓN \pm ERROR ARMA (1,2)

Una vez estudiado ARMA (1,2), haremos una ampliación ARMA (1,2) + PREDICT, los resultados han sido:

DIA D	PRE	7,46	6,52	6,64	5,89	4,92	6,07	5,88	5,63
	SE	2,47	2,52	2,64	3,03	1,79	0,94	2,52	2,74

La diferencia de los datos reales con los datos obtenidos se puede ver en la siguiente gráfica.




Figura 128 Diferencia DATOS-PREDICCIÓN ARMA (1,2) + PREDICT

Los gráficos de ARMA (1,2) + la función PREDICT son:




Figura 129 Gráfica DATOS-PREDICCIÓN ARMA (1,2).+ PREDICT




Figura 130 Gráfica DATOS-PREDICCIÓN \pm ERROR ARMA (1,2) + PREDICT

Los datos reales para el día D+1 son los siguientes:

PUNTO	A	B	C	D	E	F	G	H
REAL D+1	10,07	9,92		9,09	10,91	9,83	10,81	10,53

Los datos obtenidos:

DIA D+1	PRE	6,70	10,27	10,06	9,41	7,20		8,41	5,70
	SE	0,72	1,83	1,68	0,25	0,90		2,31	0,60

Al igual que hemos realizado en el día anterior, la representación de los datos es la siguiente




Figura 131 Diferencia DATOS-PREDICCIÓN ARMA (1,2).




Figura 132 Gráfica DATOS-PREDICCIÓN ARMA (1,2)




Figura 133 Gráfica DATOS-PREDICCIÓN \pm ERROR ARMA (1,2)

Añadiendo la función PREDICT al día D+1 los resultados son:




Figura 134 Diferencia DATOS-PREDICCIÓN ARMA (1,2) + PREDICT




Figura 135 Gráfica DATOS-PREDICCIÓN ARMA (1,2).+ PREDICT




Figura 136 Gráfica DATOS-PREDICCIÓN \pm ERROR ARMA(1,2)
+ PREDICT

ESTUDIO MODELO ARMA (1,5)

Los datos reales son los siguientes:

PUNTO	A	B	C	D	E	F	G	H
REAL D		6,68	8,83	7,99	8,38	7,74	7,79	

Realizando predicciones con el Modelo ARMA (1,5) los datos obtenidos con su error estándar han sido:

DIA D	PRE	6,06	6,13	5,79	5,47	5,04	9,23	5,99	5,73
	SE	1,15	1,15	1,13	1,39	1,02	2,40	0,87	0,72

La diferencia de los datos reales con los datos obtenidos se puede ver en la siguiente gráfica.




Figura 137 Diferencia DATOS-PREDICCIÓN ARMA (1,5).

Las gráficas del modelo ARMA (1,5) y sus errores son:




Figura 138 Gráfica DATOS-PREDICCIÓN ARMA (1,5)




Figura139 Gráfica DATOS-PREDICCIÓN \pm ERROR ARMA (1,5)

Realizando ARMA (1,5) + PREDICT, los resultados han sido:

DIA D	PRE	6,3	5,89	5,88	6,14	4,40	10,43	5,86	5,09
	SE	1,96	2,50	2,39	2,37	1,36	4,78	2,06	2,64

La diferencia de los datos reales con los datos obtenidos se puede ver en la siguiente gráfica.




Figura 140 Diferencia DATOS-PREDICCIÓN ARMA (1,5) + PREDICT

Gráficas ARIMA (1,5) + la función PREDICT:




Figura 141 Gráfica DATOS-PREDICCIÓN ARMA (1,5).+ PREDICT




Figura142 Gráfica DATOS-PREDICCIÓN \pm ERROR ARMA (1,5)
+PREDICT

Los datos reales para el día D+1 son los siguientes:

PUNTO	A	B	C	D	E	F	G	H
REAL D+1	10,07	9,92		9,09	10,91	9,83	10,81	10,53

Los datos obtenidos:

DIA D+1	PRE	6,06	9,84	10,60	9,37	6,86	9,95	8,75	5,73
	SE	1,15	2,43	0,86	0,30	1,29	2,46	1,92	0,40

La representación de los datos del día D+1 es:




Figura 143 Diferencia DATOS-PREDICCIÓN ARMA (1,5).




Figura 144 Gráfica DATOS-PREDICCIÓN ARMA (1,5)




Figura 145 Gráfica DATOS-PREDICCIÓN \pm ERROR ARMA (1,5)

Añadiendo la función PREDICT al día D+1 los resultados son los siguientes




Figura 146 Diferencia DATOS-PREDICCIÓN ARMA (1,5) + PREDICT




Figura 147 Gráfica DATOS-PREDICCIÓN ARMA (1,5).+ PREDICT




Figura 148 Gráfica DATOS-PREDICCIÓN \pm ERROR ARMA
(1,5)PREDICT

ESTUDIO MODELO ARMA (1,10)

Los datos reales son los siguientes:

PUNTO	A	B	C	D	E	F	G	H
REAL D		6,68	8,83	7,99	8,38	7,74	7,79	

Realizando predicciones con el Modelo ARMA (1,10) los datos obtenidos con su error estándar han sido:

DIA D	PRE	5,95	6,02	6,58	5,71	4,44	9,05	6,31	5,25
	SE	1,41	1,25	0,51	0,60	1,47	0,85	0,39	0,39

La diferencia de los datos reales con los datos obtenidos se puede ver en la siguiente gráfica.




Figura 149 Diferencia DATOS-PREDICCIÓN ARMA (1,10).

Disponemos de las siguientes gráficas, en la primera representamos el dato real y el dato obtenido por ARMA (1,10) y en la segunda añadimos el error estándar




Figura 150 Gráfica DATOS-PREDICCIÓN ARMA (1,10)



Figura 151 Gráfica DATOS-PREDICCIÓN \pm ERROR ARMA (1,10)

Una vez estudiado ARMA (1,10), haremos una ampliación ARMA (1,10) + PREDICT, los resultados han sido:

DIA D	PRE	6,38	7,52	6,64	5,86	4,55	4,60	6,43	3,83
	SE	1,77	1,88	1,88	2,43	1,11	3,90	2,00	2,32

La diferencia de los datos reales con los datos obtenidos se puede ver en la siguiente gráfica.




Figura 152 Diferencia DATOS-PREDICCIÓN ARMA (1,10) +

Tenemos las siguientes gráficas, en la primera simplemente se representa el dato real y el dato obtenido por ARMA (1,10)+ la función PREDICT y en la segunda se representan el dato real junto con los errores




Figura 153 Gráfica DATOS-PREDICCIÓN ARMA (1,10).+ PREDICT




Figura154 Gráfica DATOS-PREDICCIÓN \pm ERROR ARMA (1,10)
+ PREDICT

Al igual que para el día D, los datos para el día D+1 son los siguientes:

PUNTO	A	B	C	D	E	F	G	H
REAL D+1	10,07	9,92		9,09	10,91	9,83	10,81	10,53

Los datos obtenidos:

DIA D+1	PRE	5,95	10,11	10,44	9,43	7,08	9,97	8,73	5,25
	SE	1,41	1,82	0,87	0,24	0,47	2,86	2,54	0,39

Al igual que hemos realizado en el día anterior, la representación de los datos es la siguiente




Figura 155 Diferencia DATOS-PREDICCIÓN ARMA (1,10).




Figura 156 Gráfica DATOS-PREDICCIÓN ARMA (1,10)




Figura 157 Gráfica DATOS-PREDICCIÓN \pm ERROR ARMA (1,10)

Añadiendo la función PREDICT al día D+1 los resultados son los siguientes




Figura 158 Diferencia DATOS-PREDICCIÓN ARMA (1,10) + PREDICT




Figura 159 Gráfica DATOS-PREDICCIÓN ARMA (1,10).+ PREDICT




Figura 160 Gráfica DATOS-PREDICCIÓN \pm ERROR ARMA (1,10)+
PREDICT

ESTUDIO MODELO ARIMA (0,1,0)

Los datos reales son los siguientes:

PUNTO	A	B	C	D	E	F	G	H
REAL D		6,68	8,83	7,99	8,38	7,74	7,79	

Indicar que a diferencia de los otros modelos, a la hora de realizar las operaciones de ARIMA (p,d,q) con *R language* el programa no nos proporciona resultado alguno y tenemos que apoyarnos en la función PREDICT para obtenerlos

Realizando predicciones con el Modelo ARIMA (0,1,0) los datos obtenidos con su error estándar han sido:

DIA D	PRED	6,04	6,08	7,54	5,77	4,79	13,00	5,51	4,46
	SED	3,08	3,05	3,09	3,92	1,84	7,42	3,25	5,03

La diferencia de los datos reales con los datos obtenidos es la siguiente:




Figura 161 Diferencia DATOS-PREDICCIÓN ARIMA (0,1,0) +PREDICT

Tenemos las siguientes gráficas, en la primera representamos en dato real y el dato obtenido por ARIMA (0,1,0) y en la segunda añadimos el error estándar a los datos generados




Figura 162 Gráfica DATOS-PREDICCIÓN ARIMA (0,1,0).+ PREDICT




Figura163 Gráfica DATOS-PREDICCIÓN ± ERROR ARIMA (0,1,0)+ PREDICT

Los datos para el día D+1 son los siguientes:

PUNTO	A	B	C	D	E	F	G	H
REAL D+1	10,07	9,92		9,09	10,91	9,83	10,81	10,53

Los datos obtenidos:

DIA D+1	PRE	6,04	13,00	19,00	18,00	15,00	18,00	16,00	6,46
	SE	4,36	9,02	9,89	9,84	7,09	7,79	7,87	6,16

La representación de los datos para el día D+1




Figura 164Diferencia DATOS-PREDICCIÓN ARIMA (0,1,0) +PREDICT




Figura 165 Gráfica DATOS-PREDICCIÓN ARIMA (0, 1,0).+ PREDICT




Figura 166 Gráfica DATOS-PREDICCIÓN \pm ERROR ARIMA (0, 1,0)+ PREDICT

ESTUDIO MODELO ARIMA (1,2,1)

Los datos reales son los siguientes:

PUNTO	A	B	C	D	E	F	G	H
REAL D		6,68	8,83	7,99	8,38	7,74	7,79	

Realizando predicciones con el Modelo ARIMA (1,2,1) los datos obtenidos con su error estándar han sido:

DIA D	PRED	6,56	6,21	7,62	6,08	5,04	13,81	5,68	6,30
	SED	3,05	3,18	3,93	3,93	3,05	7,60	3,41	4,23

La diferencia de los datos reales con los datos obtenidos se puede ver en la siguiente gráfica.




Figura 167 Diferencia DATOS-PREDICCIÓN ARIMA (1, 2, 1) + PREDICT

Gráficas obtenidas mediante ARIMA (1,2,1)




Figura 168 Gráfica DATOS-PREDICCIÓN ARIMA (1, 2,1).+ PREDICT




Figura 169 Gráfica DATOS-PREDICCIÓN \pm ERROR ARIMA (1, 2,1)+ PREDICT

Al igual que para el día D, los datos para el día D+1 son los siguientes:

PUNTO	A	B	C	D	E	F	G	H
REAL D+1	10,07	9,92		9,09	10,91	9,83	10,81	10,53

Los datos obtenidos:

DIA D+1	PRE	6,46	13,62	9,35	17,00	15,70	17,70	14,60	6,30
	SE	3,52	8,90	8,50	9,40	7,30	7,70	7,50	5,10

Al igual que hemos realizado en el día anterior, la representación de los datos es la siguiente




Figura 170 Diferencia DATOS-PREDICCIÓN ARIMA (1, 2, 1) + PREDICT




Figura 171 Gráfica DATOS-PREDICCIÓN ARIMA (1, 2,1).+ PREDICT




Figura 172 Gráfica DATOS-PREDICCIÓN \pm ERROR ARIMA (1, 2,1)+ PREDICT

ESTUDIO MODELO ARIMA (1,1,1)

Los datos reales son los siguientes:

PUNTO	A	B	C	D	E	F	G	H
REAL D		6,68	8,83	7,99	8,38	7,74	7,79	

Realizando predicciones con el Modelo ARIMA (1,1,1) los datos obtenidos con su error estándar han sido:

DIA D	PRED	6,73	6,55	7,09	6,56	5,34	12,10	5,86	6,42
	SED	2,51	2,74	2,86	3,24	1,87	6,03	2,76	2,85

La diferencia de los datos reales con los datos obtenidos se puede ver en la siguiente gráfica.




Figura 113 Diferencia DATOS-PREDICCIÓN ARIMA (1, 1,1) + PREDICT

Al igual que en pasos anteriores, tenemos las siguientes gráficas, en la primera simplemente representamos en dato real y el dato obtenido por ARIMA (1,1,1) y en la segunda añadimos el error estándar de los datos generados




Figura 174 Gráfica DATOS-PREDICCIÓN ARIMA (1, 1, 1).+ PREDICT




Figura 175 Gráfica DATOS-PREDICCIÓN \pm ERROR ARIMA (1, 1, 1)+ PREDICT

Al igual que para el día D, los datos para el día D+1 son los siguientes:

PUNTO	A	B	C	D	E	F	G	H
REAL D+1	10,07	9,92		9,09	10,91	9,83	10,81	10,53

Los datos obtenidos:

DIA D+1	PRE	6,68	12,42	10,10	8,94	15,56	14,59	12,25	6,42
	SE	2,79	7,05	7,14	6,90	6,69	6,41	6,30	2,88

Al igual que hemos realizado en el día anterior, la representación de los datos es la siguiente




Figura 176 Gráfica DATOS-PREDICCIÓN ARIMA (1, 1, 1).+ PREDICT




Figura 177 Gráfica DATOS-PREDICCIÓN \pm ERROR ARIMA (1, 1,1)+
PREDICT




Figura 178 Diferencia DATOS-PREDICCIÓN ARIMA (1, 1,1) +PREDICT

Una vez realizadas todas las operaciones, mostramos los resultados obtenidos en la siguiente tabla resumen:

MODELO		A	B	C	D	E	F	G	H
AR(1)	PREDICCIÓN DIA D	6,67	6,2	6,33	6,03	5,5	8,97	6,05	5,75
	ERROR DIA D	0,76	0,88	0,89	0,92	1	1,77	0,8	0,79
	PREDICCIÓN DIA D+1	6,67	10,24	10,23	9,36	7,17	9,54	8,59	5,75
	ERROR DÍA D+1	0,76	1,59	1,32	1,22	1,44	1,88	1,61	0,59
AR(1)+PREDICT	PREDICCIÓN DIA D	6,52	6,15	6,57	5,95	5,03	10,29	5,9	5,78
	ERROR DIA D	2,62	0,81	2,6	3	1,73	5,97	2,64	2,71
	PREDICCIÓN DIA D+1	6,63	10,68	9,9	8,59	9,17	12,51	10,4	5,74
	ERROR DÍA D+1	2,7	6,67	6,85	6,62	1,63	6,52	6,22	2,52
AR(2)	PREDICCIÓN DIA D	6,64	6,2	6,44	5,99	5,45	8,95	6,05	5,7
	ERROR DIA D	0,79	0,78	0,75	0,77	1,14	1,43	0,62	0,62
	PREDICCIÓN DIA D+1	6,64	10,28	10,17	9,29	7,2	9,53	8,59	5,7
	ERROR DÍA D+1	0,79	1,29	1,45	0,83	0,79	1,57	1,61	0,62
AR(2)+PREDICT	PREDICCIÓN DIA D	5,74	6,15	6,73	5,98	5,08	8,94	5,89	5,7
	ERROR DIA D	2,52	2,56	2,53	3,02	1,78	5,8	2,49	2,63
	PREDICCIÓN DIA D+1	6,52	9,99	8,91	6,36	9,79	12,38	10,35	5,71
	ERROR DÍA D+1	2,6	6,59	6,82	6,15	4,57	6,1	6,22	2,63
AR(5)	PREDICCIÓN DIA D	6,27	5,95	6,15	5,66	5,19	8,96	5,97	5,56
	ERROR DIA D	1,29	1,26	1,23	1,34	1,02	1,78	1	0,8
	PREDICCIÓN DIA D+1	6,27	10,06	10,21	9,27	7,13	9,67	8,08	5,56
	ERROR DÍA D+1	1,29	1,71	1,58	0,67	0,91	2,55	3,18	0,8
AR(5)+PREDICT	PREDICCIÓN DIA D	7,9	7,46	7,18	5,92	4,71	8,32	7,3	5,11
	ERROR DIA D	2,19	2,33	2,51	2,82	1,47	5,54	2,28	2,75
	PREDICCIÓN DIA D+1	7,39	7,52	11,23	4,01	9,35	14,28	11,83	6,45
	ERROR DÍA D+1	2,42	6,14	6,64	4,86	4,48	5,76	5,32	2,73
AR(10)	PREDICCIÓN DIA D	6,54	6,15	6,49	7,31			6,74	5,44
	ERROR DIA D	0,12	0,31	0,67	1,31			0,24	0,08
	PREDICCIÓN DIA D+1	6,54							5,44
	ERROR DÍA D+1	0,12							0,08
AR(10)+PREDICT	PREDICCIÓN DIA D	1,12	3,32	5,47	13,24			5,37	4,11
	ERROR DIA D	0,5	0,99	2,11	1,67			0,69	1,09
	PREDICCIÓN DIA D+1	4,29							6,24
	ERROR DÍA D+1	0,68							1,33

MODELO		A	B	C	D	E	F	G	H
MA(1)	PREDICCIÓN DIA D	6,72	6,17	6,45	6	5,54	8,92	6,05	5,68
	ERROR DIA D	0,65	0,76	0,64	0,91	0,66	2,1	0,8	2,06
	PREDICCIÓN DIA D+1	6,72	10,26	10,23	9,29	7,2	9,66	8,61	5,68
	ERROR DÍA D+1	0,65	1,71	1,33	0,93	1,57	1,84	1,52	2,06
MA(1)+PREDICT	PREDICCIÓN DIA D	6,66	6,07	6,45	5,91	5,23	4,99	5,8	5,68
	ERROR DIA D	2,65	2,61	2,6	2,99	2,02	5,36	2,54	2,75
	PREDICCIÓN DIA D+1	6,72	10,82	9,96	6,5	10,57	14,6	10,31	5,68
	ERROR DÍA D+1	2,66	6,68	10,85	6,54	5,2	6	6,2	2,75
MA(2)	PREDICCIÓN DIA D	6,65	6,24	6,4	6,05	5,45	8,9	6	6,06
	ERROR DIA D	0,86	0,92	0,81	0,79	0,79	1,4	0,72	0,72
	PREDICCIÓN DIA D+1	6,65	10,29	10,18	9,41	7,14	9,72	8,6	5,69
	ERROR DÍA D+1	0,86	1,31	1,41	0,22	0,99	1,63	1,58	0,61
MA(2)+PREDICT	PREDICCIÓN DIA D	7,05	6,32	6,64	5,96	5	5,44	5,86	5,86
	ERROR DIA D	2,52	2,52	2,65	3,1	1,68	5,17	2,52	2,53
	PREDICCIÓN DIA D+1	6,64	9,28	9,12	6,55	8,44	18,18	10,27	5,69
	ERROR DÍA D+1	0,83	6,42	6,82	5,8	5,16	5,69	6,23	2,74
MA(5)	PREDICCIÓN DIA D	6,37	6,23	6,29	5,98	5,32	9,4	6	6,02
	ERROR DIA D	0,91	0,88	0,91	0,99	0,83	3	0,78	0,38
	PREDICCIÓN DIA D+1	6,37	10,11	10,33	9,37	6,86	10,2	8,68	6,02
	ERROR DÍA D+1	0,91	1,5	1,45	0,29	1,27	2,7	2	0,38
MA(5)+PREDICT	PREDICCIÓN DIA D	7,12	6,31	6	6,51	4,79	8,68	5,89	7,03
	ERROR DIA D	2	2,59	2,52	3,23	1,54	4,77	2,08	6,54
	PREDICCIÓN DIA D+1	5,85	7,78	12,5	3,82	7,66	16,69	9,82	4,77
	ERROR DÍA D+1	2,36	6,32	6,08	5,21	3,95	5,22	5,22	2,49
MA(10)	PREDICCIÓN DIA D	6,1	6,09	6,7	5,79	5,35	6,7	6,35	5,37
	ERROR DIA D	1,13	1,08	0,38	0,43	0,78	0,38	0,32	0,39
	PREDICCIÓN DIA D+1	6,1	10,04	10,51	9,42	7,08	10,06	8,73	5,37
	ERROR DÍA D+1	1,13	1,97	0,73	0,43	0,47	2,26	2,52	0,39
MA(10)+PREDICT	PREDICCIÓN DIA D	1,87	7,53	6,64	5,15	6,48	6,64	6,55	3,61
	ERROR DIA D	1,83	2,02	1,9	2,53	1,3	1,9	1,99	3,31
	PREDICCIÓN DIA D+1	5,74	13,1	1,72	6,89	6,52	19,89	12,13	6,21
	ERROR DÍA D+1	2,39	5,53	5	4,82	3,74	4,59	4,77	2,37

MODELO		A	B	C	D	E	F	G	H
ARMA(1,1)	PREDICCIÓN DIA D	6,51	6,19	6,41	6,05	5,42	6,15	5,05	5,69
	ERROR DIA D	0,94	0,85	0,81	0,82	1,18	0,78	0,76	0,62
	PREDICCIÓN DIA D+1	6,51	6,22	6,58	6,15	5,77	6,2	6,18	5,69
	ERROR DÍA D+1	0,96	0,82	0,78	0,79	1,21	0,74	0,73	0,62
ARMA(1,1)+PREDICT	PREDICCIÓN DIA D	6,45	6	6,57	5,89	5,12	5,87	5,83	5,67
	ERROR DIA D	2,58	2,58	2,64	3,03	1,78	2,96	2,53	2,74
	PREDICCIÓN DIA D+1	6,46	6,45	7,58	7,00	6,75	6,62	6,64	5,69
	ERROR DÍA D+1	2,62	2,52	2,34	2,90	1,89	2,92	2,50	2,74
ARMA(1,2)	PREDICCIÓN DIA D	6,7	6,42	6,42	6,05	5,47	6,36	6,08	5,7
	ERROR DIA D	0,82	0,83	0,8	0,85	0,74	0,73	0,66	0,61
	PREDICCIÓN DIA D+1	6,7	10,27	10,06	9,41	7,2		8,41	5,7
	ERROR DÍA D+1	0,72	1,83	1,68	0,25	0,9		2,31	0,6
ARMA(1,2)+PREDICT	PREDICCIÓN DIA D	7,46	6,52	6,64	5,89	4,92	6,07	5,88	5,63
	ERROR DIA D	2,47	2,52	2,64	3,03	1,79	0,94	2,52	2,74
	PREDICCIÓN DIA D+1	6,53	9,13	9,13	7,40	9,11		10,92	5,76
	ERROR DÍA D+1	2,57	6,40	6,79	5,70	5,06		6,15	2,74
ARMA(1,5)	PREDICCIÓN DIA D	6,06	6,13	5,79	5,47	5,04	9,23	5,99	5,73
	ERROR DIA D	1,15	1,15	1,13	1,39	1,02	2,4	0,87	0,72
	PREDICCIÓN DIA D+1	6,06	9,84	10,6	9,37	6,86	9,95	8,75	5,73
	ERROR DÍA D+1	1,15	2,43	0,86	0,3	1,29	2,46	1,92	0,4
ARMA(1,5)+PREDICT	PREDICCIÓN DIA D	6,3	5,89	5,88	6,14	4,40	10,43	5,86	5,09
	ERROR DIA D	1,96	2,50	2,39	2,37	1,36	4,78	2,06	2,64
	PREDICCIÓN DIA D+1	5,55	11,80	12,14	3,83	7,73	15,75	10,62	6,59
	ERROR DÍA D+1	2,36	5,77	6,07	5,41	3,94	4,96	1,00	2,64
ARMA(1,10)	PREDICCIÓN DIA D	5,95	6,02	6,58	5,71	4,44	9,05	6,31	5,25
	ERROR DIA D	1,41	1,25	0,51	0,6	1,47	0,85	0,39	0,39
	PREDICCIÓN DIA D+1	5,95	10,11	10,44	9,43	7,08	9,97	8,73	5,25
	ERROR DÍA D+1	1,41	1,82	0,87	0,24	0,47	2,86	2,54	0,39
ARMA(1,10)+PREDICT	PREDICCIÓN DIA D	6,38	7,52	6,64	5,86	4,55	4,60	6,43	3,83
	ERROR DIA D	1,77	1,88	1,88	2,43	1,11	3,90	2,00	2,32
	PREDICCIÓN DIA D+1	5,63	11,41	1,78	6,84	6,52	20,48	12,03	6,73
	ERROR DÍA D+1	2,38	5,66	1,05	4,71	3,74	4,35	4,77	2,22

MODELO		A	B	C	D	E	F	G	H
ARIMA(0,1,0)	PREDICCIÓN DIA D	6,04	6,08	7,54	5,77	4,79	13	5,51	4,46
	ERROR DIA D	3,08	3,05	3,09	3,92	1,84	7,42	3,25	5,03
	PREDICCIÓN DIA D+1	6,04	13	19	18	15	18	16	6,46
	ERROR DÍA D+1	4,36	9,02	9,89	9,84	7,09	7,79	7,87	6,16
ARIMA(1,1,1)	PREDICCIÓN DIA D	6,73	6,55	7,09	6,56	5,34	12,10	5,86	6,42
	ERROR DIA D	2,51	2,74	2,86	3,24	1,87	6,03	2,76	2,85
	PREDICCIÓN DIA D+1	6,68	12,42	10,10	8,94	15,56	14,59	12,25	6,42
	ERROR DÍA D+1	2,79	7,05	7,14	6,90	6,69	6,41	6,30	2,88
ARIMA(1,2,1)	PREDICCIÓN DIA D	6,56	6,21	7,62	6,08	5,04	13,81	5,68	6,3
	ERROR DIA D	3,05	3,18	3,93	3,93	3,05	7,6	3,41	4,23
	PREDICCIÓN DIA D+1	6,46	13,62	9,35	17	15,7	17,7	14,6	6,3
	ERROR DÍA D+1	3,52	8,9	8,5	9,4	7,3	7,7	7,5	5,1

Tabla 4 Resumen de datos

3.4 Desarrollo del código en *R language*

Código

Una vez utilizado los modelos ARIMA para predecir cual será la velocidad del viento para los 2 próximos días (días 25 y 26 de Enero), vamos a implementar un código para que realice una previsión espacio temporal que cubra la zona a estudio, no solo los ocho puntos indicados, sino también los puntos cercanos a ellos.

Antes de exponer el código utilizado, hay que indicar que la base de datos debe estar dentro de una carpeta específica del paquete a utilizar.

Llamaremos al archivo donde están los datos de posición “win.loc”, este será un archivo “.txt” separado por tabulaciones. El otro archivo donde está el contenido de las velocidades del viento se llamará “win”, este documento tendrá una extensión “.csv”. Ambos archivos deberán estar situados en la carpeta:

R/ R.2.12.2 /library/ gstat / data

Al arrancar el programa R LANGUAGE aparece la pantalla de control siguiente:

```
R version 2.12.2 (2011-02-25)
Copyright (C) 2011 The R Foundation for Statistical Computing
ISBN 3-900051-07-0
Platform: i386-pc-mingw32/i386 (32-bit)

R es un software libre y viene sin GARANTIA ALGUNA.
Usted puede redistribuirlo bajo ciertas circunstancias.
Escriba 'license()' o 'licence()' para detalles de distribucion.

R es un proyecto colaborativo con muchos contribuyentes.
Escriba 'contributors()' para obtener más información y
'citation()' para saber cómo citar R o paquetes de R en publicaciones.

Escriba 'demo()' para demostraciones, 'help()' para el sistema on-line de ayuda,
o 'help.start()' para abrir el sistema de ayuda HTML con su navegador.
Escriba 'q()' para salir de R.

[Previously saved workspace restored]

> |
```

Siempre que abramos la consola nos aparecerá dicho texto. Un dato importante también es que siempre que abramos la consola habrá que cargar todos los paquetes a utilizar.

A partir de este punto vamos a ir introduciendo todo el código necesario para realizar nuestro propósito.

- Carga de paquetes necesarios

```
> library(sp)
> library(zoo)
> library(xts)
> library(spacetime)
> library(gstat)
>
> |
```

- Lectura de las bases de datos

```
> data(win)
> data(win.loc)
> datos<- read.table("d.csv", sep=";")
```

. Para comprobar que la máquina ha leído lo que nosotros queremos, simplemente basta con escribir por pantalla *win* ó *win.loc*

```
> win
  ano mes dia    A    B    C    D    E    F    G    H
1 2000   1  19 9.51  9.42  8.84  8.40  8.68  8.53  8.40  7.64
2 2000   1  20 8.96  8.85  8.30  8.19  9.09  8.28  8.82  8.40
3 2000   1  21 5.40  9.53  5.39  9.09  5.65  9.83  5.62 10.53
4 2000   1  22 4.14  4.82  4.57  4.77  4.82  4.01  5.04  4.93
5 2000   1  23 6.86  6.13  7.54  6.70  6.34  6.42  5.97  6.46
6 2000   1  24 6.65  6.24  6.40  6.05  5.45  8.90  6.00  6.06
7 2000   1  25 6.64  6.20  6.44  5.99  5.45  8.95  6.05  5.70
8 2000   1  26 6.64 10.28 10.17  9.29  7.20  9.53  8.59  5.70

> win.loc
 Station Code Latitude Longitude
1          A      A    43.88     -4.88
2          B      B    43.88     -4.62
3          C      C    43.88     -4.38
4          D      D    43.88     -4.12
5          E      E    44.12     -4.88
6          F      F    44.12     -4.62
7          G      G    44.12     -4.38
8          H      H    44.12     -4.12
> |
```

R es un programa muy potente a la hora de trabajar con datos, eso sí, la manera en que nosotros le introducimos los datos para que la herramienta los manipule debe ser muy precisa y con un código complejo.

- Lectura de situación geográfica

```
> win.loc$y = as.numeric(win.loc$Latitude)
> win.loc$x = as.numeric(win.loc$Longitude)
> coordinates(win.loc) = ~x + y
> proj4string(win.loc) = "+proj=longlat +datum=WGS84"
>
>
```

El siguiente código es utilizado para leer la localización de los puntos indicados, de nuevo, para comprobar los datos bastaría con introducir el código `> win.loc$y` para ver qué datos ha tomado como valores de latitud.

```
> win.loc$y
[1] 43.88 43.88 43.88 43.88 44.12 44.12 44.12 44.12
> |
```

- Lectura temporal

Al igual que la lectura de datos geográficos para la compilación de datos temporales, es necesario un código específico, en este caso ha sido:

```
> win$time = ISOdate(win$ano, win$mes, win$día)
> win$jday = as.numeric(format(win$time, "%j"))
> stations = 4:11
> winsqrt = sqrt(0.5148 * as.numeric(win.loc$Station))
> Jday = 1:11
```

- Lectura y modificación de datos

Las siguientes líneas de código tal vez sean las más difíciles de comprender, esté código lo utilizamos para realizar una lectura de los datos y transformarlos de tal manera que las futuras funciones no tengan problemas de captura. Ya hemos repetido varias veces que R lenguaje, es muy selectivo a la hora de leer de datos.

```
> daymeans = (sapply(split(winsqrt - mean(winsqrt), win$jday), mean))
> meanwin = lowess(daymeans ~ Jday, f = 0.1)$y[win$jday]
> velocities = sapply(winsqrt, function(x) (x - meanwin))
> win.loc = win.loc[match(names(win[4:11]), win.loc$Code),]
> pts = coordinates(win.loc[match(names(win[4:11]), win.loc$Code),])
> rownames(pts) = win.loc$Station
> pts = SpatialPoints(pts)
> proj4string(pts) = "+proj=longlat +datum=WGS84"
```

- Código para realización de gráficas

El siguiente código utilizado no hace más que volver a transformar los datos obtenidos y prepararlos para un futuro uso, añadiendo subgrupos de datos en conjuntos más grandes

```
> win.loc = win.loc[match(names(win[4:11]), win.loc$Code),]
> pts = coordinates(win.loc[match(names(win[4:11]), win.loc$Code),])
> rownames(pts) = win.loc$Station
> pts = SpatialPoints(pts)
> proj4string(pts) = "+proj=longlat +datum=WGS84"
>
> |
```

- Carga de nuevos paquetes

```
> library(rgdal)
> library(lattice)
> library(maps)
> library(maptools)
> library(mapdata)
> library(foreign)
>
```

- Utilización de funciones

A lo largo de toda la implementación anterior hemos estado realizando lectura, operaciones de pequeña envergadura y sobre todo transformaciones para una futura utilización, el siguiente código recopila todo lo realizado anteriormente y se realizan el grueso de operaciones

```
> utm29 = CRS("+proj=utm +zone=29 +datum=WGS84")
> t = xts(1:nrow(win), win$time)
> pts = spTransform(pts, utm29)
> w = STFDF(pts, t, data.frame(values = as.vector(t(velocities))))
>
> |
```

Por último, estas líneas de código las utilizamos para generar una imagen en la cual se podrá ver perfectamente las velocidades de viento a lo largo del tiempo

```
> m = map2SpatialLines(
+ map("worldHires", xlim = c(-9,6), ylim = c(40, 46), plot=F))
> proj4string(m) = "+proj=longlat +datum=WGS84"
> m = spTransform(m, utm29)
> grd = SpatialPixels(SpatialPoints(makegrid(m, n = 10000)),
+ proj4string = proj4string(m))
> w = w[, "2000-01"]
> n = 8
> tgrd = xts(1:n, seq(min(index(w)), max(index(w)), length=n))
> v = list(space = vgm(0.6, "Exp", 300000), time = vgm(1, "Exp", 1 * 3600 * 24))
> pred = krigeST((values)~1, w, STF(grd, tgrd), v)
```

En el capítulo cuarto, veremos las imágenes que nos proporciona este código utilizando los datos del mejor modelo predictivo.

Capítulo 4

4.1 Análisis y Discusión de datos

El método utilizado para seleccionar el modelo óptimo será el siguiente:

1. Se realizará el sumatorio de la operación “valor real – valor pronosticado” de los ocho puntos de los que disponemos datos
2. Una vez dispongamos de los modelos óptimos seleccionaremos aquellos cuyos errores estándar sean menores.
3. Por último y en caso de haber más de un método viable, volveremos a realizar las operaciones del capítulo anterior durante un periodo de tiempo mayor para tener nuevos datos donde apoyarnos a la hora de elegir el mejor modelo.

1º Cálculo de los errores entre valor real y valor pronosticado

MÉTODO	DIAD	DIA D+1	TOTAL
AR1	1,33	1,43	2,76
AR1 + PREDICT	1,56	1,4	2,96
AR2	1,32	1,43	2,75
AR2 + PREDICT	1,36	1,52	2,88
AR5	1,48	1,5	2,98
AR5 + PREDICT	1,14	2	3,14
AR10	2,56	5,83	8,39
AR10 + PREDICT	3,85	5,98	9,83
MA1	1,31	1,41	2,72
MA1 + PREDICT	1,25	1,73	2,98
MA2	1,31	1,43	2,74
MA2 + PREDICT	1,5	2,27	3,77
MA5	1,42	1,45	2,87
MA 5 + PREDICT	1,35	2,85	4,2
MA10	1,29	1,5	2,79
MA10 + PREDICT	1,26	2,95	4,21
ARMA11	1,5	2,78	4,28
ARMA 11 + PREDICT	1,49	2,49	3,98
ARMA12	1,3	2,43	3,73
ARMA 12 + PREDICT	1,41	2,25	3,66
ARMA 15	1,56	1,47	3,03
ARMA 15+PREDICT	1,75	2,5	4,25
ARMA 110	1,47	1,52	2,99
ARMA 110 + PREDICT	1,68	2,8	4,48
ARIMA 010	1,91	3,76	5,67
ARIMA 111	1,57	2,04	3,61
ARIMA 121	1,9	3,59	5,49

Tabla 5 Sumatorio errores entre valor real y valor pronosticado

Podemos observar que los métodos que más se aproximan son el AR(1), AR(2) , MA(1) Y MA(2).

2° Comparación de errores estándar

MÉTODO	ERROR ESTANDAR (SE)		
	DÍA D	DÍA D+1	TOTAL
AR (1)	7,41	10,41	17,82
AR(2)	6,9	8,95	15,85
MA(1)	8,58	11,61	20,19
MA(2)	7,01	8,61	15,62

Tabla 6 Comparación errores estándar

3° Cálculo de nuevos pronósticos

Realizaremos veinte pronósticos nuevos, para poder seleccionar con más precisión el método que se más se aproxime.

Los resultados son los siguientes:

	REAL	MA(2)	AR(2)	ERROR MA(2)	ERROR AR(2)
1	6,04	6,04	6,04		
2		6,65	6,72		
3	10,07	6,65	7,2	3,42	2,87
4	1,81	7,12	7,29	5,31	5,48
5	0,48	7,03	2,1	6,55	1,62
6	12,06	6,99	7,07	5,07	4,99
7	7,59	7,23	7,4	0,36	0,19
8	5,25	7,1	7,3	1,85	2,05
9	4,32	7,13	4,53	2,81	0,21
10	9,49	6,97	8,7	2,52	0,79
11		7,21	6,07		
12	6,85	7,03	6,83	0,18	0,02
13	2,87	7,09	6,58	4,22	3,71
14	2,24	6,95	6,47	4,71	4,23
15	6,92	6,8	6,85	0,12	0,07
16		6,83	6,43		
17	3,05	6,03	5,08	2,98	2,03
18	4,17	6,02	5,63	1,85	1,46
19	8,68	5,94	5,42	2,74	3,26
20	2,42	5,97	5,78	3,55	3,36
			TOTAL	47,88	36,15

Tabla 7 Nuevas predicciones

La gráfica correspondiente es la siguiente:




Figura 179 Comparación datos reales, AR(2) y MA(2)

En un principio se creía que entre los MA(2) Y AR(2) no existían muchas diferencias, una vez realizadas más predicciones, se observa que el mejor modelo estadístico para la zona geográfica seleccionada es el **AR(2)**.

4.2 Estudio temporal

Queda demostrado que el modelo que más se aproxima a los valores reales es el AR(2)

A continuación vamos a mostrar una serie de gráficas en las que se realiza un pronóstico de la velocidad de viento durante el año 2000 en el punto “E” (latitud -4,88 longitud 44.12). Mostraremos las gráficas mes a mes empezando en Febrero ya que los datos de Enero se han utilizado como base.

La última gráfica será una recopilación de todos los meses y dará una visión general de la validez del modelo.




Figura 180 Modelo AR(2) y datos reales en el mes de Febrero




Figura 181 Modelo AR(2) y datos reales en el mes de Marzo




Figura 183 Modelo AR(2) y datos reales en el mes de Abril




Figura 184 Modelo AR(2) y datos reales en el mes de Mayo




Figura 185 Modelo AR(2) y datos reales en el mes de Junio




Figura 186 Modelo AR(2) y datos reales en el mes de Julio




Figura 187 Modelo AR(2) y datos reales en el mes de Agosto




Figura 188 Modelo AR(2) y datos reales en el mes de Septiembre




Figura 189 Modelo AR(2) y datos reales en el mes de Octubre




Figura 190 Modelo AR(2) y datos reales en el mes de Noviembre




Figura 191 Modelo AR(2) y datos reales en el mes de Diciembre




Figura 192 Datos reales en el año 2000




Figura 193 Modelo $AR(2)$ en año 2000




Figura 194 Modelo AR(2) y datos reales en el año 2000

4.3 Estudio espacio-temporal

La herramienta *R language* nos brinda la oportunidad de realizar estudios espacio-temporales. En este apartado vamos a realizar un ejemplo de este tipo de pronóstico para dar fin a todo lo estudiado durante el proyecto

En este caso, lo realizaremos con el procedimiento *krigreado*, este se basa en efectuar una ponderación, de manera que hace mínima la varianza, considerando las características cada problema.

La manera de trabajar del procedimiento *krigreado* en *R language* es el siguiente:

Disponemos de los datos reales de velocidades de todos los puntos de todo el mes de Enero y de los datos obtenidos por el modelo AR(2) de los días 25 y 26 de. Así pues, representaremos una situación espacio-temporal desde el día 19 de Enero hasta el día 26.

El programa además de los ocho puntos (A,B,C...H) que nosotros le introducimos genera por sí solo, 10.696 puntos en los cuales realiza 93.331 pronósticos, generando una imagen nítida y clara de la zona de trabajo permitiendo saber la velocidad del viento en un día cualquiera, en un punto aleatorios dentro de los parámetros establecidos.

En la imagen se ve el perfil norte de la costa española y una serie de formas de diferentes colores que indican la velocidad del viento en unidades del sistema internacional. El valor de las velocidades viene dado según la escala cromática indicada.




Figura 195 Estudio espacio-temporal

CAPÍTULO 5

5.1 Conclusiones

Este proyecto de investigación nace del deseo conocer más ampliamente los métodos de predicción de vientos para parques eólicos situados en alta mar.

Se ha introducido el concepto del satélite QuikSCAT y las herramientas necesarias para poder realizar búsquedas a pequeña escala. En el momento que estas búsquedas fueran mayores necesitaríamos herramientas más específicas como programas que tuvieran la capacidad de leer y trabajar con el formato HDF. Se ha elegido el lenguaje *R language* por ser una de las herramientas más potentes en el trabajo con gran cantidad de datos. Además, a nivel personal, los conocimientos adquiridos en este lenguaje podrán ser utilizado en futuros estudios.

La fase más extensa y complicada de todo el proyecto ha sido la base teórica de ARIMA, sin embargo es un pilar importante para la comprensión de la base matemática utilizada por el programa *R*

Una vez realizados todos los pronósticos de viento, hemos comprobado que variando en orden de ARIMA nos acercamos o alejamos de la realidad, hemos desechado unos modelos y hemos profundizado en otros para poder decidir el adecuado, en este caso y para la zona del Mar Cantábrico seleccionada el modelo AR(2).

Se ha realizado un estudio temporal en el que se ha utilizado pronósticos de un punto a lo largo de un año entero y disponiendo además de datos de coordenadas, velocidad se ha podido realizar una recreación espacio-temporal de la zona integrando mapas de viento para una mayor comprensión.

Después de todo lo anterior que el análisis de las predicciones es un campo complicado en el que se necesitan varios conceptos y herramientas para poder realizar pronósticos viables, tal vez la mejor opción se basa en la combinación de todas ellas.

5.2 Referencias

[**QuikSCAT**] “Quick Scatterometer”. “Missions – SeaWinds on QuikSCAT”
<http://winds.jpl.nasa.gov/missions/quikscat/index.cfm>

[**QuikSCAT**]
es.allmetsat.com/satelite-quikscat.php

[**QuikSCAT**]
es.wikipedia.org/wiki/QuikSCAT

[**HDF**] “Hierarchical Data Format”.
<http://www.hdfgroup.org>

[**HDF4**] “Hierarchical Data Format”.
<http://www.hdfgroup.org/products/hdf4/>,

[**PO.DAAC**] “Physical Oceanography DAAC (PO.DAAC). SeaWinds on QuikSCAT”,
http://podaac.jpl.nasa.gov/DATA_CATALOG/quikscatinfo.html

[**POET**] “Winds Measuring Ocean Wind from Space (Winds) SeaWinds on QuikSCAT”
<http://winds.jpl.nasa.gov/index.cfm>.

[**R language**] “Taller de introducción a R para análisis estadísticos”
www.cricyt.edu.ar/interactio/cursos/r_intro/.../r_taller_1_intro.pdf

[**R language**]
cran.r-project.org/doc/contrib/rdebuts_es.pdf

[**ARIMA**] “Predicción con modelos ARIMA”
www.est.uc3m.es/esp/nueva_docencia/getafe/.../stcap8.ppt

[**ARIMA**] “Análisis de series temporales: Modelos ARIMA”
www.sarriko-online.com/cas/fichas/2009/04-09.pdf

[**ARIMA**]
www.uam.es/ana.delsur/pdf/Box-Jenkins.PDF

[**REVISIÓN BIBLIOGRÁFICA**]
<http://www.sciencedirect.com/roble.unizar.es:9090/>

[E. Penabad , 06] *E. Penabad , I. Álvarez , C.F. Balseiro , M. de Castro , B. Gómez, V. Pérez-Muñuzuri, M. Gómez-Gesteira* “Comparative analysis between operational weather predictions models and QuikSCAT wind data near the Galician coast”

Journal of Marine Systems 72 (2008) 256–270

[A. Birol Kara, 07] *Birol Kara, Alan J. Wallcraft, Paul J. Martin , Randal L. Pauley* “Optimizing surface winds using QuikSCAT measurements in the Mediterranean Sea during 2000–2006”

Journal of Marine Systems 78 (2009) S119–S131

[Sara Pensieri, 09] *Sara Pensieri, Roberto Bozzano, Maria Elisabetta Schiano* “Comparison between QuikSCAT and buoy wind data in the Ligurian Sea”

Journal of Marine Systems 81 (2010) 286–296

[Felipe Pimienta, 07] *Felipe Pimienta, Willett Kempton, Richard Garvine* “Combining meteorological stations and satellite data to evaluate the offshore wind power resource of Southeastern Brazil”

Renewable Energy 33 (2008) 2375–2387

[T.G. Barbounis, 05] *T.G. Barbounis, J.B. Theocharis* “A locally recurrent fuzzy neural network with application to the wind speed prediction using spatial correlation”

Neurocomputing 70 (2007) 1525–1542

[Ruchi Kalra,06] *Ruchi Kalra, M.C. Deo* “Derivation of coastal wind and wave parameters from offshore measurements of TOPEX satellite using ANN”

Coastal Engineering 54 (2007) 187–196

[T.A. Kelly, 08] *T.A. Kelly, T.E. West, J.K. Davenport* “Challenges and solutions of remote sensing at offshore wind energy developments”

Marine Pollution Bulletin 58 (2009) 1599–1604

[René Jursa, 08] *René Jursa , Kurt Rohrig* “Short-term wind power forecasting using evolutionary algorithms for the automated specification of artificial intelligence models”

International Journal of Forecasting 24 (2008) 694–709