

Modelos para la predicción de viento

En este capítulo se busca detallar los fundamentos teóricos de los posibles métodos a usar, para obtener un modelo eficaz para la estimación de los valores futuros de la variable a estudio, la velocidad del viento. Se mostrarán los ajustes de diferentes modelos calculados y hasta encontrar el que mejor predicción garantiza para cada caso.

3.1 Tipos de modelos de predicción

La velocidad del viento es la variable que se quiere predecir a partir de una cierta cantidad de datos históricos disponibles y de un modelo de comportamiento del mismo. Para ello se considera que la velocidad del viento sigue un proceso estocástico, es decir, una colección de variables aleatorias $\{v_t$, con $t \in T\}$, ordenadas según el subíndice t que identifica el tiempo, por lo que la velocidad del viento será una serie temporal. Por tanto para cada instante t se tiene una variable aleatoria representada por v_t . Un modelo para un proceso estocástico es cualquier conjunto de hipótesis bien definidas sobre las propiedades estadísticas de dicho proceso.

Para predecir el valor futuro, se genera un modelo matemático que determine las relaciones entre los valores pasados y se aplique para obtener los valores futuros.

Este tipo de modelos consisten en un conjunto de ecuaciones, que pueden ser lineales o no, que al calcular los valores futuros de la variable, minimizan el error de la predicción con respecto a los datos del pasado.

Al tratar de representar la influencia que hechos pasados tienen sobre el presente, y en consecuencia, sobre el futuro del proceso estocástico, se consideran los modelos ARMA, que están formados por un modelo AR del inglés (*AutoRegressive Model*) y otro MA (*Movil Average*) [10].

Un modelo es auto-regresivo (AR), si el valor de una variable en cualquier instante se puede explicar a partir de los valores anteriores más un término de error. La ecuación (3.1) muestra la formulación general de un modelo auto-regresivo de orden p . Se observa cómo los modelos auto-regresivos son lineales.

$$y_t = a_0 + a_1 \cdot y_{t-1} + \dots + a_p \cdot y_{t-p} + e_t \quad (3.1)$$

Los factores a_i representan los coeficientes del modelo y e_t , un error llamado ruido blanco. El ruido blanco tiene como propiedades una media nula, una varianza constante y que el error de un instante de tiempo no guarda relación con los errores de instantes anteriores ni futuros.

El orden p es el número de predecesores del valor actual a estimar que influyen en el mismo. De tal manera que existirán tantos coeficientes a_i como valor de p .

La ecuación (3.1) puede escribirse de forma abreviada mediante lo que se conoce como operador polinomial de retardos, como se muestra en la ecuación (3.2).

$$a_p(B)y_t = a_0 + e_t \quad (3.2)$$

Donde $a_p(B)$ es dicho polinomio y se define según la ecuación (3.3)

$$a_p(B) = 1 - a_1 \cdot B - a_2 \cdot B^2 - \dots - a_p \cdot B^p \quad (3.3)$$

Al operador B se le llama operador de retardo o rezago, y aplicado a una variable determina su valor en el periodo anterior. Si se aplica p veces, se obtiene el valor de la variable tantos periodos atrás tal y como se muestra en la ecuación (3.4).

$$B^p \cdot y_t = y_{t-p} \quad (3.4)$$

Los modelos de media móvil (MA), se definen por que el valor de la variable a estimar depende de un término independiente y de una sucesión ponderada de errores correspondientes a los predecesores. El número de errores de los predecesores a tener en cuenta será el orden, en este caso llamado q . La formulación general para un modelo MA(q) se muestra en la ecuación (3.5).

$$y_t = \mu - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} + e_t \quad (3.5)$$

El valor de μ es una constante numérica, θ_i son los coeficientes del modelo y e_{t-i} son los errores de la variable y en el instante $t-i$. Reformulando la ecuación con el operador de retardo queda:

$$y_t = \theta_q(B) \cdot e_t + \mu \quad (3.6)$$

El modelo ARMA (*Auto-Regressive Movil Average*) se obtiene al unir un modelo auto-regresivo y otro de media móvil. Por tanto un modelo ARMA tendrá dos órdenes diferentes.

La formulación de un modelo ARMA(p, q) se muestra en la ecuación (3.7), donde se puede observar que es igual a sumar las ecuaciones (3.1) y (3.5) salvo por el coeficiente μ que se suma al coeficiente a_0 .

$$y_t = a_0 + a_1 \cdot y_{t-1} + \dots + a_p \cdot y_{t-p} + e_t - \theta_1 \cdot e_{t-1} - \dots - \theta_q \cdot e_{t-q} \quad (3.7)$$

En literaturas de otros autores [8], en ocasiones se elimina el coeficiente a_0 por simplificación. Usando el operador de retardo, la ecuación del modelo queda:

$$a_p(B) \cdot y_t = a_0 + \theta_q(B) \cdot e_t \quad (3.8)$$

Una vez explicados los fundamentos teóricos de los modelos, se entra en cómo evaluar la calidad de los mismos. Para ello se define el error $e(t)$, con $y(t)$ como el valor real medido en el instante t e $\hat{y}(t)$ como el valor estimado por el modelo para este mismo instante t , de la siguiente manera:

$$e(t) = y(t) - \hat{y}(t) \quad (3.9)$$

En este estudio los datos se toman cada diez minutos, por lo que un conjunto de seis valores conforma una hora. Este será el horizonte de predicción mínimo que se use, ya que carece de utilidad un horizonte menor para el propósito de este trabajo, donde lo que se busca es vender la energía en el mercado diario.

El error para un horizonte de predicción genérico j será:

$$e(t+j|t) = y(t+j) - \hat{y}(t+j|t) \quad (3.10)$$

Donde el término $e(t+j|t)$ se corresponderá con el valor del error de la predicción del instante $t+j$ realizada en el instante t [9].

La función `armax` del programa MATLAB realiza la comparación entre el valor real y el estimado según la siguiente relación:

$$Ajuste = \left(1 - \frac{\sqrt{\sum(y-\hat{y})^2}}{\sqrt{\sum(y-\bar{y})^2}} \right) \cdot 100 \quad (3.11)$$

Donde \hat{y} es el vector de predicciones, y es el vector de datos reales, \bar{y} es la media de los valores de y , la velocidad media real y donde *Ajuste* vendrá dado en porcentaje y será usado para elegir un modelo u otro en la optimización posterior.

El *Ajuste* servirá para comparar entre los modelos de predicción de una estación a otra, y no variará de valor si se realiza a un modelo con coeficientes estimados mediante unos datos de viento a una altura o a otra. Si se modifican las velocidades de viento según la exponencial de Hellman en función de la altura de un aerogenerador u otro el valor final del ajuste no se modificará, dependiendo sólo del horizonte de predicción y de los órdenes del modelo.

3.2 Elaboración y elección del modelo de predicción

Para la generación de un buen modelo, primero es fundamental recoger datos históricos de los emplazamientos donde se pretende hacer la estimación. Se requiere la utilización de un buen número de datos para estimar los coeficientes del modelo. Teóricamente deben usarse como mínimo tantos datos como orden tenga el modelo [11], pero para un buen resultado estable se requieren algunos más. En este caso se han utilizado tanto para Isla Laitec como para Sibaya un tercio de los datos iniciales. Los datos restantes serán los que verificarán el modelo y los que se aplicarán para los cálculos de apartados posteriores.

El ajuste de los coeficientes del modelo lo hace la función `armax`, ya existente en la librería del programa MATLAB, por medio del ajuste por mínimos cuadrados. Lo que no ajusta el programa es el valor óptimo de los órdenes del modelo p y q .

A modo introductorio y para una mejor comprensión de los modelos se representa en la Fig. 3.1 el ajuste de un modelo ARMA(1,0), es decir, un modelo AR(1). Este modelo trata de predecir la velocidad del viento en Isla Laitec para un horizonte de predicción de seis datos a intervalos de 10 minutos, lo que equivale a una hora.

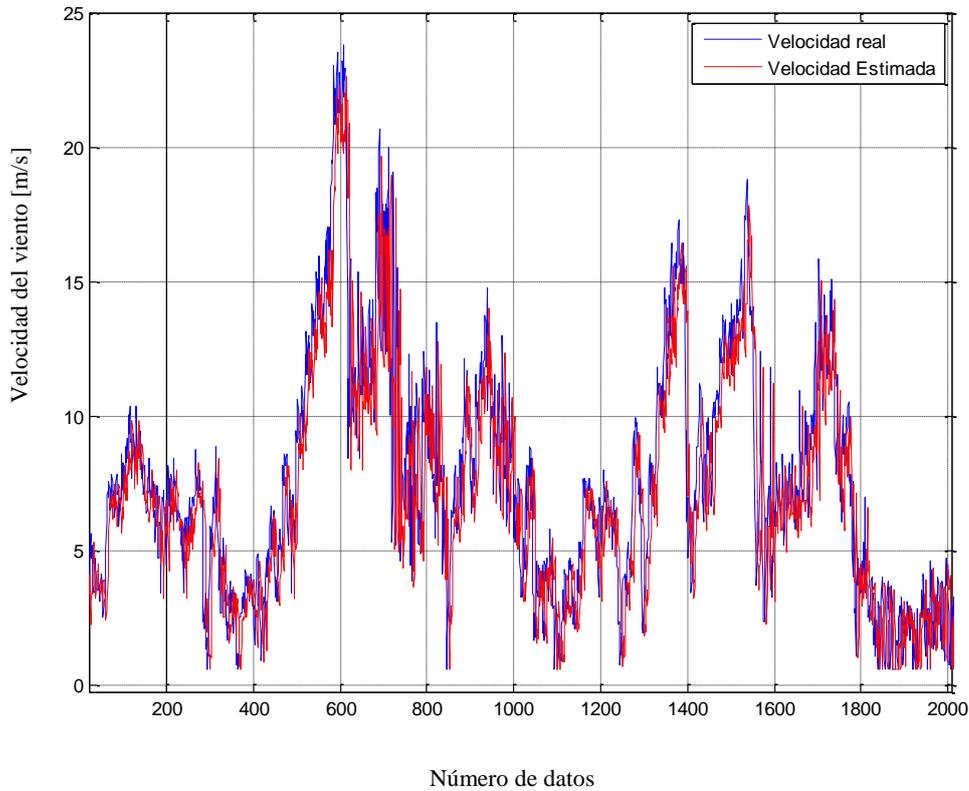


Figura 3.1: Ajuste de la velocidad del viento en Isla Laitec con un modelo AR(1) y un horizonte de predicción de una hora.

Se han representado los primeros 2000 datos estimados en la Fig. 3.1, lo que serían 13.89 días, para una mejor visualización del ajuste del modelo. También puede observarse el comportamiento no cíclico de las velocidades en Isla Laitec.

Los coeficientes del modelo ajustados por el programa son los mostrados en (3.12) donde B es el operador de retardo.

$$(1 - 0.9914 \cdot B) \cdot y_t = e_t \quad (3.12)$$

Al ser un modelo AR(1), se usa un único valor del pasado para estimar el siguiente valor futuro, por lo que sólo hay un coeficiente que multiplica el operador de retardo B . Este coeficiente indica el peso que tiene sobre el siguiente valor estimado, el dato que estamos utilizando para estimarlo. Como sólo hay un valor, éste es muy próximo a 1, a lo que también influye que es el dato inmediatamente anterior.

Este modelo, a pesar de ser el más sencillo posible con esta metodología que se está empleando, consigue un ajuste del 50.37%. Si se hace lo mismo para un horizonte de predicción de dos horas se obtiene un ajuste del 37.96% con los mismos valores de los coeficientes. Para comprobar si el valor de ajuste de los coeficientes se ve afectado por el horizonte temporal se prueba con un horizonte de veinticuatro horas (Fig. 3.2), sin que aparezca variación alguna. Se obtiene un ajuste negativo debido a la diferencia entre los valores estimados y los reales, pero se mantienen los mismos coeficientes. Por lo tanto el ajuste de los coeficientes del modelo no se verá afectado por el valor tomado del horizonte de predicción.

Esto tiene sentido, porque el modelo se crea a partir de unos órdenes que marcan el número de datos pasados que influyen en los datos futuros, y que a partir de ahí se estimen uno, dos, o mil puntos, no es una cuestión que modifique a los coeficientes. El buen ajuste de unos valores futuros para un horizonte de predicción determinado, dependerá de lo bien elegidos que estén los órdenes del modelo y de la calidad y cantidad de los datos pasados que se usen en la estimación de los coeficientes.

Inicialmente se hace una búsqueda de los órdenes que mejor ajustan el modelo a la realidad para cada estación, pero queda limitada por el equipo informático que se usa para el cálculo, de forma que no se pueden alcanzar valores superiores a un ARMA(20,20). De este modo se obtienen, dentro del rango, los modelos ARMA(4,11) y ARMA(9,11) para Isla Laitec, y el modelo ARMA(4,8) para Sibaya. En la Tabla 3.1 se presentan los valores del Ajuste para cada horizonte temporal.

Tabla 3.1: Valores de Ajuste para los diferentes horizontes de predicción de los mejores modelos calculados inicialmente para las estaciones de Sibaya e Isla Laitec.

| Estación | Modelo | Valor del Ajuste (%) | |
|-------------|------------|----------------------|----------------|
| | | Horizonte 1 h | Horizonte 24 h |
| Sibaya | ARMA(4,8) | 36.98 | 13.30 |
| Isla Laitec | ARMA(4,11) | 52.87 | -3.61 |
| | ARMA(9,11) | 52.88 | -3.38 |

En Isla Laitec aparecen dos modelos que se ajustan mejor que los demás a la realidad cuando el horizonte de predicción es uno u otro. El comportamiento de los modelos es muy diferente para las dos estaciones, consiguiendo buenos valores en horizontes de 1 h y muy malos en horizontes de 24 h para Isla Laitec y un ajuste más bajo a corto plazo en Sibaya, que en horizontes de 24 h baja a sólo poco más de la mitad.

Al analizar los datos históricos de la estación de Sibaya se observa un comportamiento cíclico que se repite cada 24 horas aproximadamente. Esto hace que los modelos de órdenes pequeños que daban un resultado relativamente bueno

en Isla Laitec para el horizonte de predicción de una hora, no den tan buen resultado en Sibaya. Y sin duda, si se trata de predecir el viento con un horizonte de predicción de 24 horas, los resultados obtenidos se podrán mejorar si se tiene en cuenta la característica cíclica.

Para arreglar esto se prueba con un modelo ARMA(144,0), es decir, un modelo auto-regresivo de orden 144. De esta forma el modelo tendrá en cuenta los valores tiempo atrás hasta el día anterior, 144 datos equivalen a 24 h, por lo que se ajustará bastante mejor que el obtenido anteriormente. El problema de un modelo de esta magnitud es el tiempo necesario para procesar la información, ya que primero deberá estimar 144 coeficientes y después predecir los valores futuros teniendo en cuenta esta gran cantidad de datos. En la Fig.3.2 se muestra el resultado obtenido

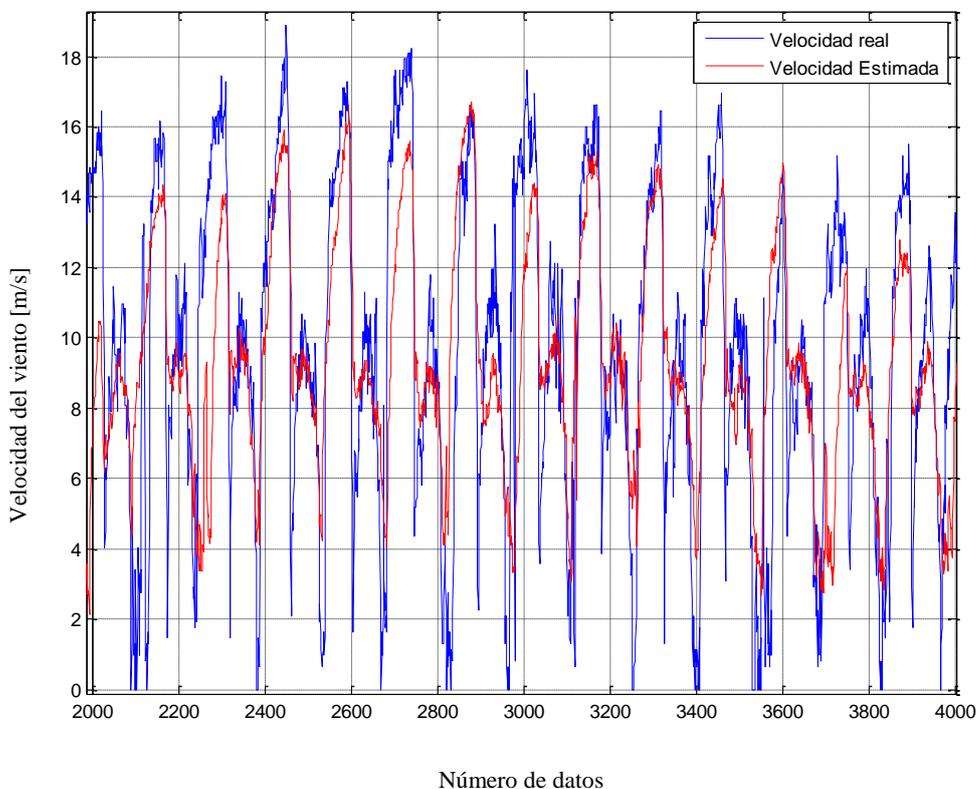


Figura 3.2: Estimación de la velocidad del viento en la estación de Sibaya con un horizonte de predicción de 24 h y un modelo AR(144).

Se han representado dos mil valores para su mejor visualización, es decir, 13.89 días. El ajuste logrado con este modelo es de 19.36%.

En la fig. 3.3 queda patente el problema que se puede presentar cuando un día deja de soplar el viento de forma repentina, pero es algo que ningún modelo puede predecir. Se observa como entre los datos 4100 y 4200 el viento se hace

prácticamente nulo durante un semiciclo cuando debería estar dando velocidades relativamente altas, entre los 8 m/s y los 15 m/s, similares a las que marca la curva azul de los valores estimados.

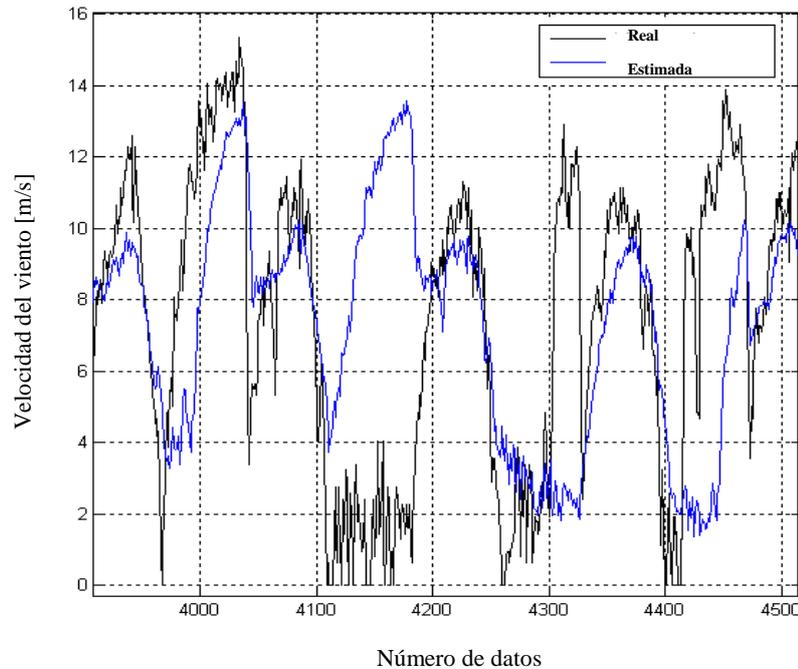


Figura 3.3: Representación del ciclo de la velocidad del viento en Sibaya y de un caso anómalo que condiciona la predicción de días sucesivos.

Se ve claro como el modelo ajusta con gran verosimilitud la velocidad del viento del día anterior, y cómo el comportamiento anómalo de los puntos [4100,4200] influye después en el día siguiente.

Al probar este modelo con un horizonte de 1 h se obtiene un ajuste de 41.74%, superior al realizado por el modelo ARMA(4,8) que no superaba el 36.98%. En la Fig. 3.4 se muestra el mismo día con comportamiento anómalo viéndose como el modelo en este caso corrige sus predicciones minimizando relativamente el error en ese semiciclo y haciéndolo desaparecer para el semiciclo siguiente donde la velocidad del viento vuelve a ser la esperada.

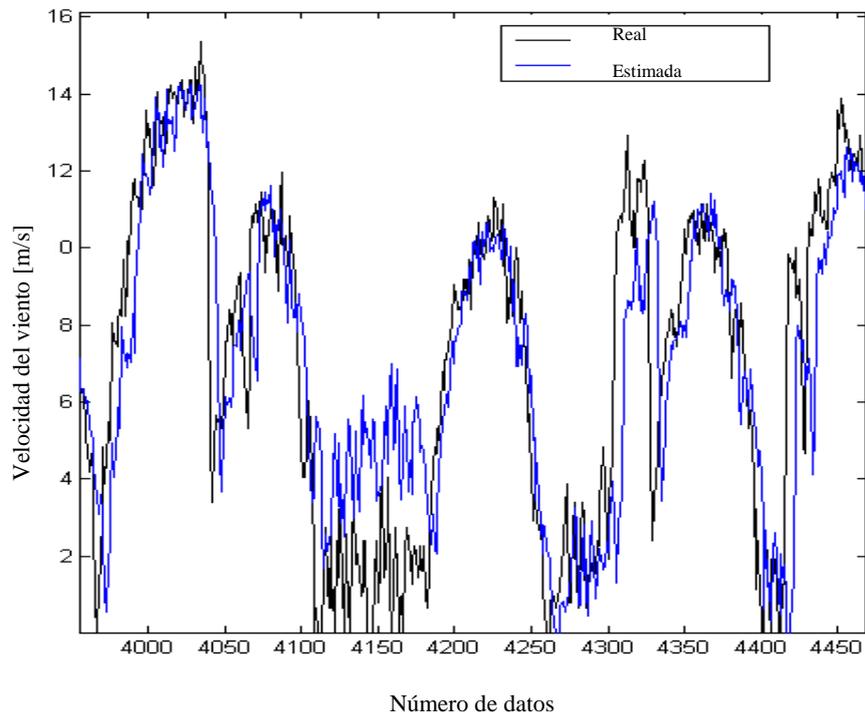


Figura 3.4: Corrección del comportamiento anómalo del viento en Sibaya por el modelo AR(144) con horizonte 1h.

A continuación se prueba a mejorar este modelo convirtiéndolo en un ARMA(144,4). Se consigue un ajuste del 21.16% para un horizonte de 24 h (Fig. 3.5) y de 43.44% para un horizonte de 1 h.

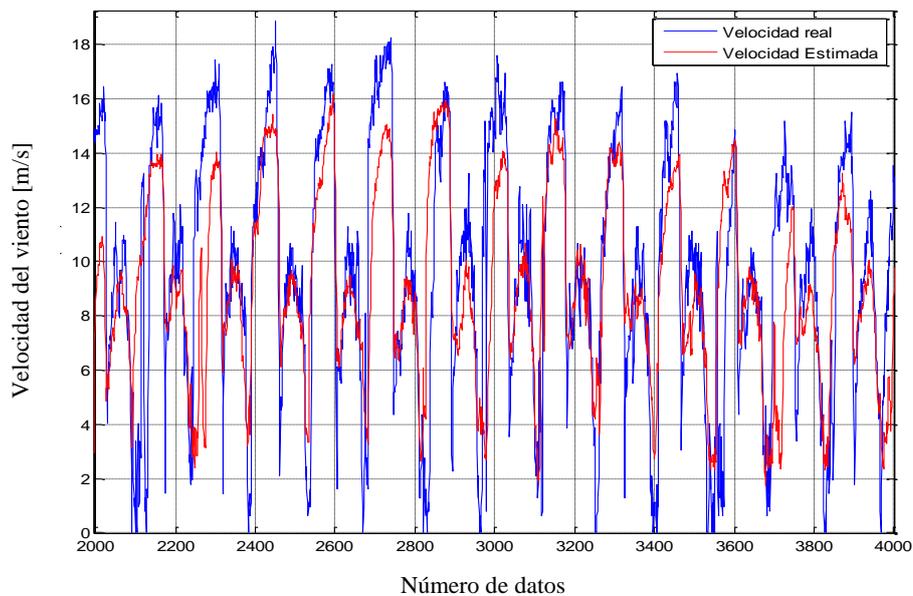


Figura 3.5: Estimación de la velocidad del viento en la estación de Sibaya con un horizonte de predicción de 24 h y un modelo ARMA(144,4).

Tras varias pruebas más se llega al modelo ARMA(144,8) que tiene el mismo orden q que el mejor modelo de la aproximación inicial que se estimó. Este modelo, para un horizonte de 24 h (Fig. 3.6), proporciona un ajuste del 21.23% superando en casi un 7% al modelo inicial ARMA(4,8).

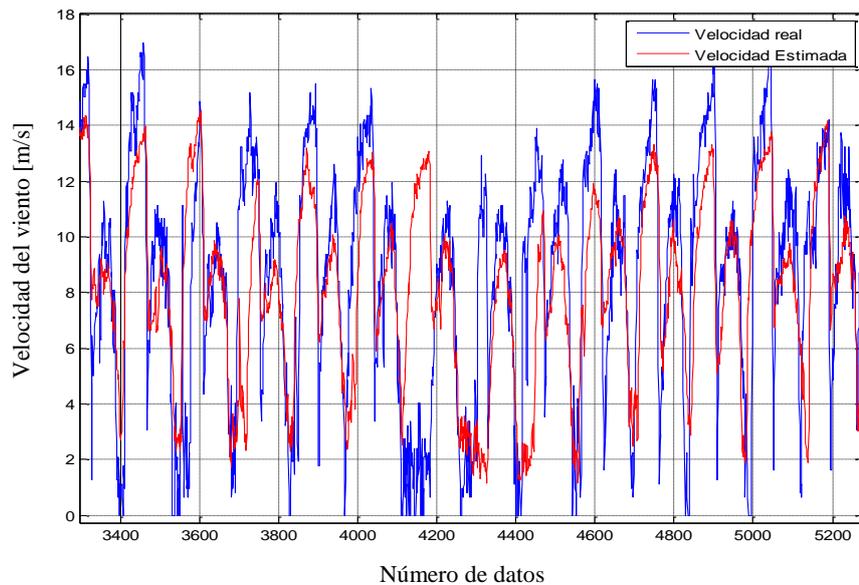


Figura 3.6: Modelo ARMA(144,8) en un horizonte de 24 h para los datos de viento de Sibaya.

No obstante, el resultado mejora si los modelos tienen un orden que abarque varios días. Un ARMA(288,8) consigue una mejora de más de un 2% en horizontes de una hora y de más de un 3% en los de 24 h, con respecto al ARMA(144,8). En la Fig. 3.7 se comparan las predicciones del modelo ARMA(288,8) para los horizontes de tiempo de 1 h y 24 h durante un pequeño periodo de tiempo.

Cuando estos modelos con tantos coeficientes predicen horizontes de una hora, en ocasiones estiman valores negativos de velocidad de viento. Esto perjudica al ajuste aunque no interfiere en la estimación de potencia posterior.

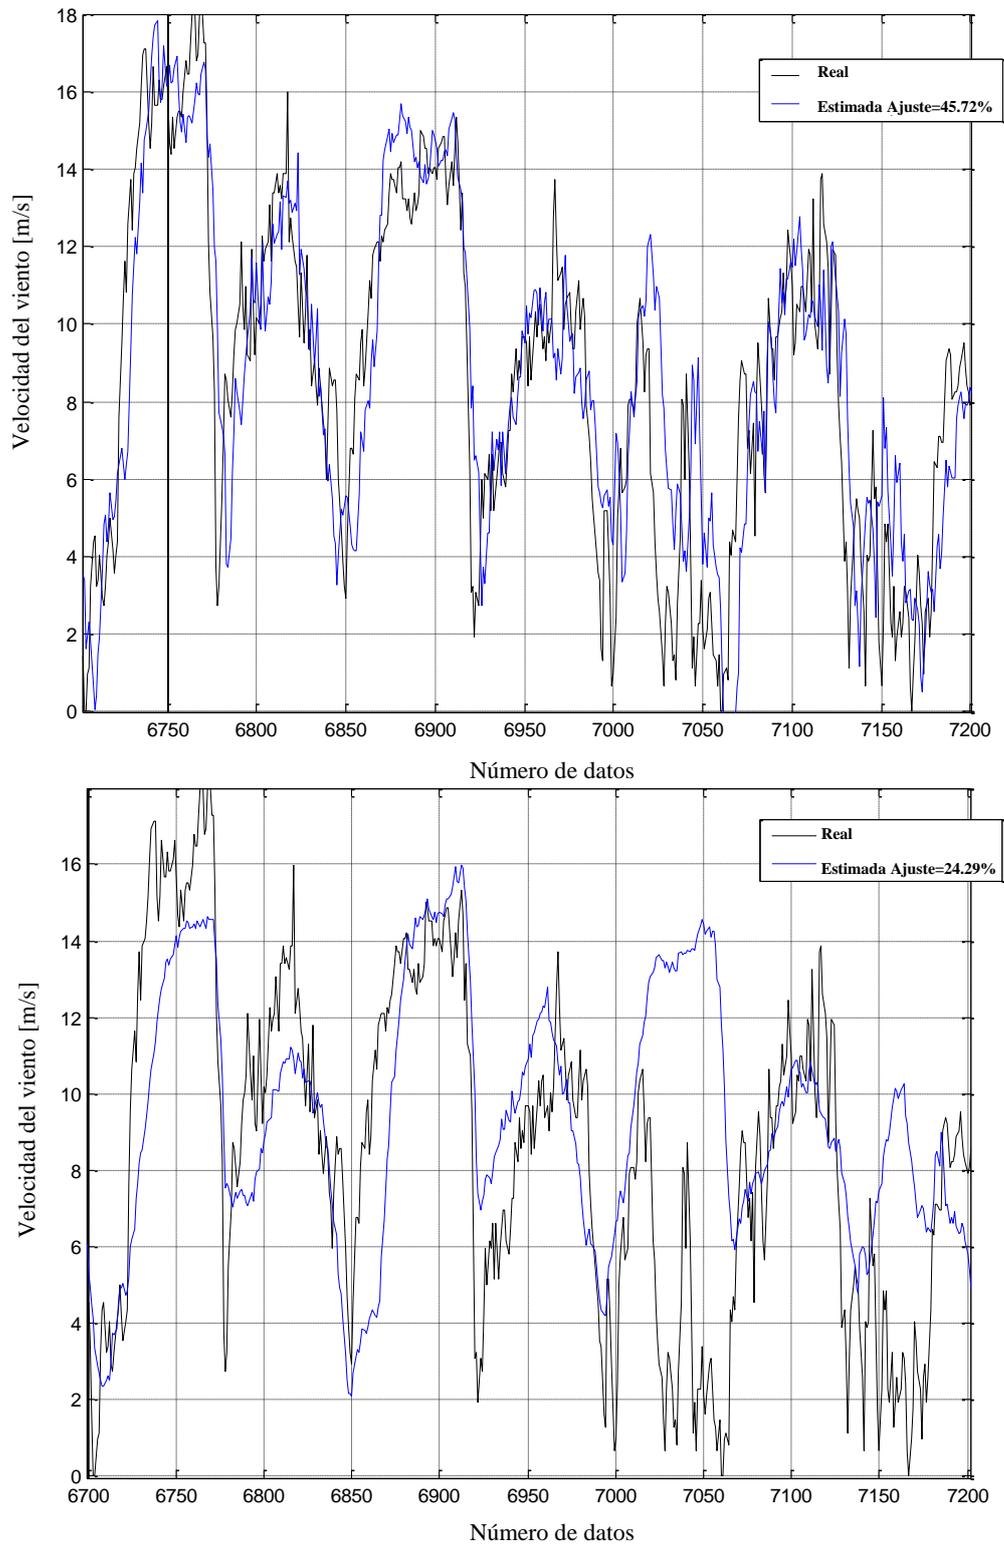


Figura 3.7: Representación del ajuste del modelo ARMA(288,8) para los horizontes de predicción de una hora (i) y de veinticuatro horas (ii).

Este resultado se mejora si se usa un modelo con un orden de tres días de antelación. El modelo ARMA(432,8) consigue en un horizonte de 24 h una enorme mejora sobre el modelo inicial, y de un 6% sobre el ARMA(144,8). Cuando el horizonte de predicción es tan sólo de una hora, las mejoras son menos llamativas, debido a que es más complicado mejorar las predicciones y el peso en lo que pasará dentro de una hora de los coeficientes de varios días atrás es muy pequeño. Se representa en la Fig. 3.8:

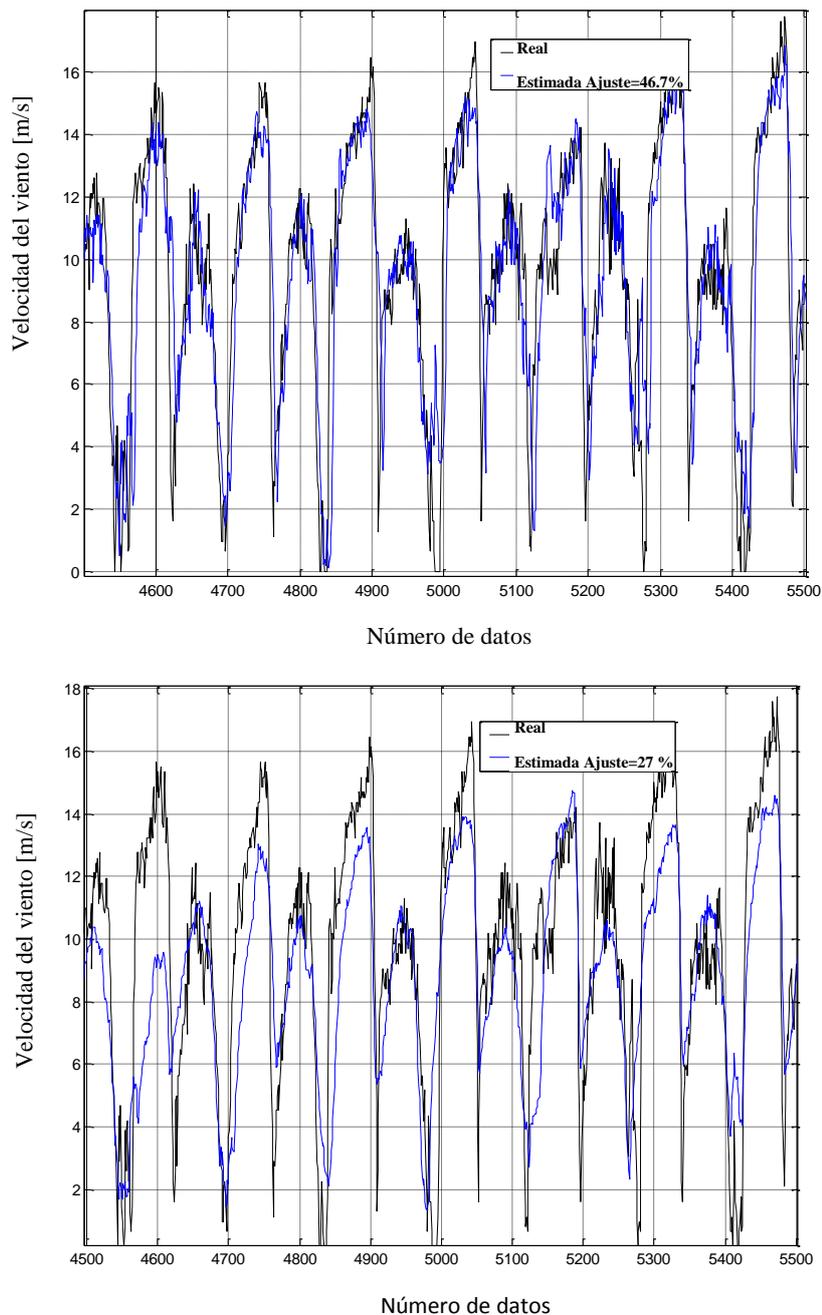


Figura 3.8: Representación de la estimación de la velocidad del viento en m/s de un modelo ARMA(432,8) para los horizontes de predicción de 1 h (i) y de 24 h (ii).

3.3 Resultados de los modelos y conclusiones

Después de los intentos por ajustar los resultados de los modelos lo más posible a la realidad, se pone de manifiesto cómo las diferentes características del viento en las dos estaciones, Isla Laitec y Sibaya, provocan que el ajuste con un horizonte de predicción de 1 h siempre sea mejor para el caso de Isla Laitec debido a la mayor influencia de los datos pasados más recientes sobre los valores futuros. No obstante, ocurre lo contrario con un horizonte de predicción de 24 h, donde el carácter más caótico del viento de Isla Laitec hace imposible un buen ajuste y sin embargo, en Sibaya, el carácter cíclico del viento facilita una muy buena predicción. Para ello, los modelos de Sibaya requieren órdenes muy elevados, teniendo una elevada influencia en los datos futuros, datos de, incluso, varios días atrás. En el caso de Isla Laitec no importa que el modelo tenga un orden elevado y no aparecen mejoras al probar con ellos, de esta forma se pone de manifiesto que los valores de viento en Isla Laitec no dependen de los valores de horas atrás, siendo los más importantes los de las dos últimas horas. Para el mejor modelo de Isla Laitec se valoran los datos de hasta 110 min de antelación al valor a predecir.

En la Tabla 3.2 se muestran para la estación de Sibaya los resultados de los ajustes para los dos horizontes de predicción.

Tabla 3.2: Resumen de los resultados de cada modelo de estimación de viento para los dos horizontes de predicción estudiados con los datos de la estación de Sibaya.

| Modelo | Ajuste entre datos reales y estimados | |
|-------------|---------------------------------------|----------------|
| | Horizonte 1 h | Horizonte 24 h |
| AR(1) | 31.67% | -20.89% |
| ARMA(4,8) | 36.98% | 13.30% |
| AR(144) | 41.74% | 19.36% |
| ARMA(144,4) | 43.44% | 21.16% |
| ARMA(4,50) | 36.10% | 1.70% |
| ARMA(50,8) | 32.58% | -17.61% |
| ARMA(144,8) | 43.48% | 21.23% |
| AR(288) | 44.98% | 23.31% |
| ARMA(288,8) | 45.72% | 24.29% |
| ARMA(432,8) | 46.67% | 27.02% |

Aparece una significativa mejora en los modelos que usan los datos de las 24 h anteriores, pero sin embargo el parámetro q del orden del modelo de media móvil no beneficia a la bondad del ajuste del modelo si adquiere un valor elevado. También es llamativo que el modelo ARMA(50,8) dé unos resultados tan malos, cuando debería ser mejor que otros con un menor orden auto-regresivo. Influye que tiene en cuenta los datos de una parte del ciclo que no ayudan a aproximar

bien el ciclo completo, es decir, el horizonte de 24 h siguiente, ni tampoco aproxima bien lo que ocurrirá en la siguiente hora.

En la Tabla 3.3 se muestran los diferentes modelos para poder ver las escasas diferencias que aparecen entre ellos. Existe un principio llamado de parsimonia que dice que si un fenómeno puede ser explicado por dos modelos, el más simple es el mejor. Se aplicará este principio a los modelos de Isla Laitec, eligiendo finalmente el modelo ARMA(4,11) para los cálculos de energía estimada.

Tabla 3.3: Resumen de los resultados de cada modelo de estimación de velocidad de viento para los horizontes de predicción de 1 h y 24 h, con los datos históricos de la estación situada en Isla Laitec.

| Modelo | Ajuste entre datos reales y estimados | |
|-------------|---------------------------------------|----------------|
| | Horizonte 1 h | Horizonte 24 h |
| AR(1) | 50.37% | -62.91% |
| AR(144) | 52.55% | -16.88% |
| ARMA(10,15) | 52.77% | -4.92% |
| ARMA(10,25) | 52.79% | -4.86% |
| ARMA(4,50) | 52.80% | -4.59% |
| ARMA(4,9) | 52.82% | -4.74% |
| ARMA(10,11) | 52.86% | -4.42% |
| ARMA(4,12) | 52.83% | -4.75% |
| ARMA(4,10) | 52.85% | -4.27% |
| ARMA(4,11) | 52.87% | -3.38% |
| ARMA(9,11) | 52.88% | -3.61% |

Como se ve, en Isla Laitec no se ha conseguido ningún modelo que estime con un horizonte de 24 h un *Ajuste* positivo. Sin embargo para un horizonte de 1 h se consiguen valores bastante mejores que para Sibaya. Esto se debe a la propiedad cíclica de Sibaya que facilita las predicciones en un horizonte coincidente con el periodo de su ciclo.

3.4 Relación entre el módulo y la dirección del viento

En este apartado se trata de buscar una relación entre los datos históricos que permita obtener modelos mejores. Para ello se desarrolla la posibilidad de que el viento siga algún patrón cíclico en función de la dirección desde la que sople.

Inicialmente, parece más sencillo que pueda existir una relación en el caso de los datos recogidos en la estación de Sibaya donde las direcciones del viento eran muy concretas durante todo el periodo de estudio. En la Fig. 3.9 se muestra la

velocidad del viento junto con su dirección para un intervalo de datos aleatorio.

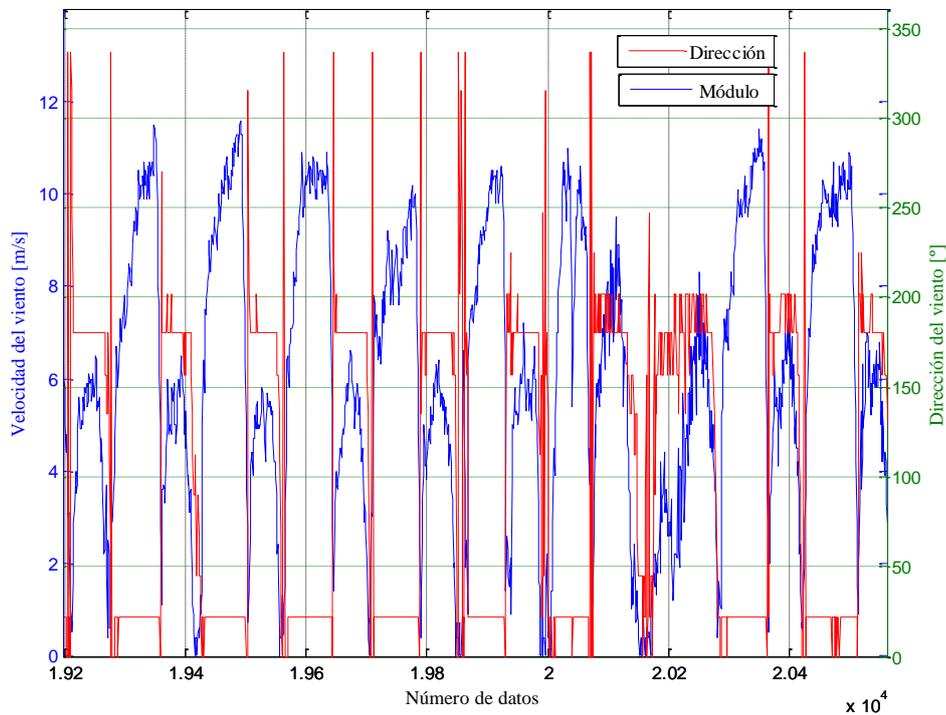


Figura 3.9: Representación de la dirección y del módulo de la velocidad del viento en la estación de Sibaya para un intervalo de datos históricos.

Se observa en la dirección del viento el mismo comportamiento cíclico que aparece en la velocidad, coincidiendo siempre los tramos de mayores velocidades con vientos a 30° , en una dirección noreste. Al ser tan exacto este comportamiento, el uso específico de un modelo para este caso parece poco útil, ya que aportará una predicción muy similar a la ya obtenida por los modelos anteriores.

Resulta interesante descomponer la velocidad según el sector por donde sopla el viento, de forma que se obtengan varios subconjuntos de datos para norte, sur, este y oeste. En la Fig. 3.10 se ha representado el histograma de los datos de cada caso.

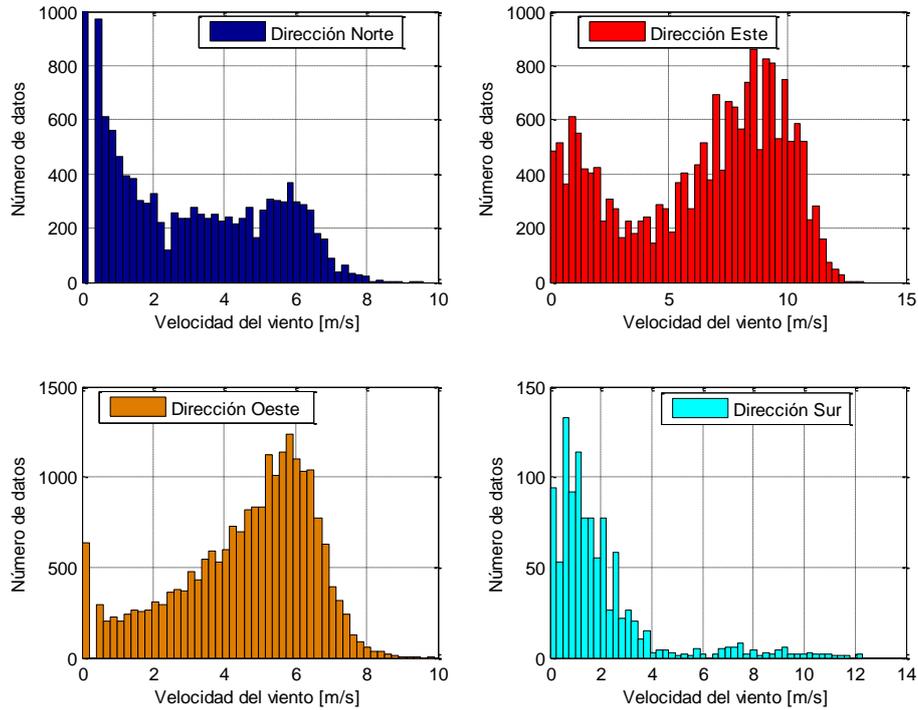


Figura 3.10: Histograma de las velocidades según su procedencia para la estación de Sibaya.

Lo primero que se observa es la gran cantidad de datos con valores de velocidad elevados que aparecen de este a oeste y viceversa, siendo claramente la dirección de interés en esta ubicación. Son estos vientos los que impiden la aproximación por una distribución de Weibull. Se aprecia como por el este los vientos son algo más elevados, encontrándose cercanos a los 10 m/s.

Y con una silueta muy similar a la de una distribución de Weibull se encuentran los vientos de la región sur, donde la energía que se puede obtener es mínima, ya que el grueso de las velocidades es inferior a los 4 m/s, aunque también estos son los vientos menos comunes, dándose en menos de un 2% del tiempo. La zona donde existen más valores de viento nulo es el norte, seguramente debido a que el aparato de medida tome ángulo cero en estos casos.

Cuando se analizan los datos de Isla Laitec se obtienen los histogramas mostrados en la Fig. 3.11.

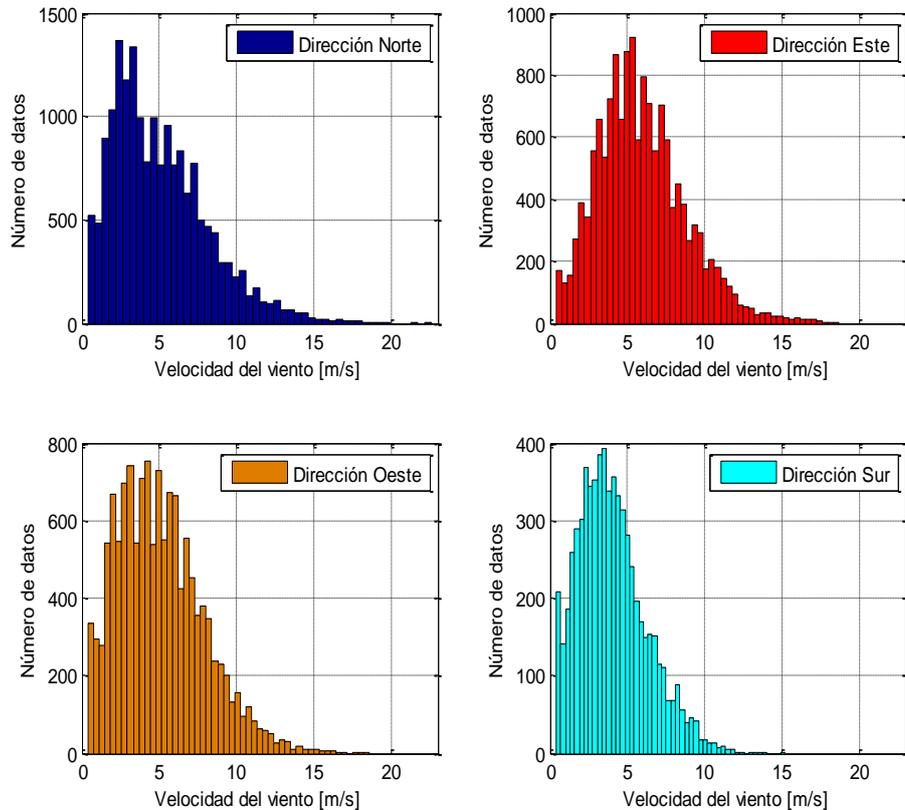


Figura 3.11: Histograma de las velocidades según su procedencia para la estación de Isla Laitec.

Se ve como en todas las direcciones aparece una silueta similar, aunque es en las direcciones este y oeste, donde se dan los vientos mayores. En el caso de Isla Laitec, los vientos están mejor repartidos, aunque es en la dirección sur desde la que aparecen con menor frecuencia.

Se busca algún elemento cíclico representando la velocidad del viento junto con su dirección (Fig. 3.12).

No se contempla un caso tan claro como el que se daba en Sibaya, donde era fácil observar la relación entre la dirección del viento con la velocidad, repitiéndose en intervalos de 24 horas.

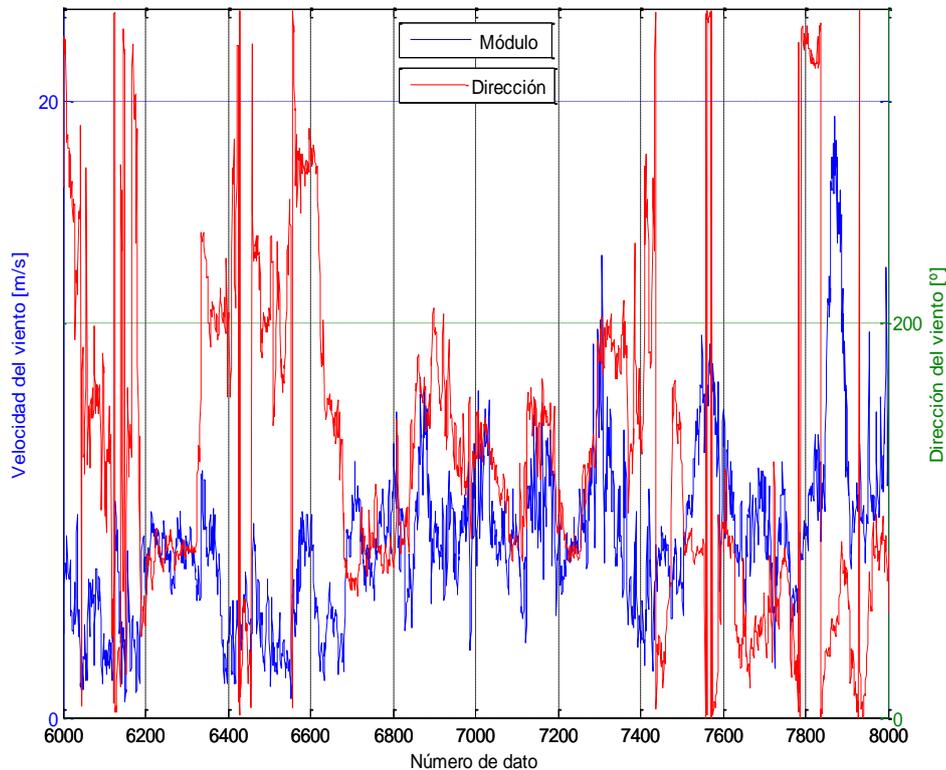


Figura 3.12: Representación de la dirección y del módulo de la velocidad del viento en la estación de Isla Laitec para un intervalo de datos históricos.

En esta representación pueden verse algunos cambios en la velocidad del viento que coinciden con cambio en su dirección pero no aparece ninguna tendencia. Por ejemplo, en el pico de velocidad sobre los 7300 datos, la dirección es oeste, mientras que en el pico de los 7900 datos (100 horas después) el viento es noreste.

Se genera un modelo para tratar de predecir la dirección en la que soplará el viento con antelación con el mismo método usado para predecir el módulo de la velocidad. En la Fig. 3.13 se ha presentado un intervalo de datos estimados por este modelo, pero no se logra el buen ajuste para la hora de antelación que se lograba con las velocidades.

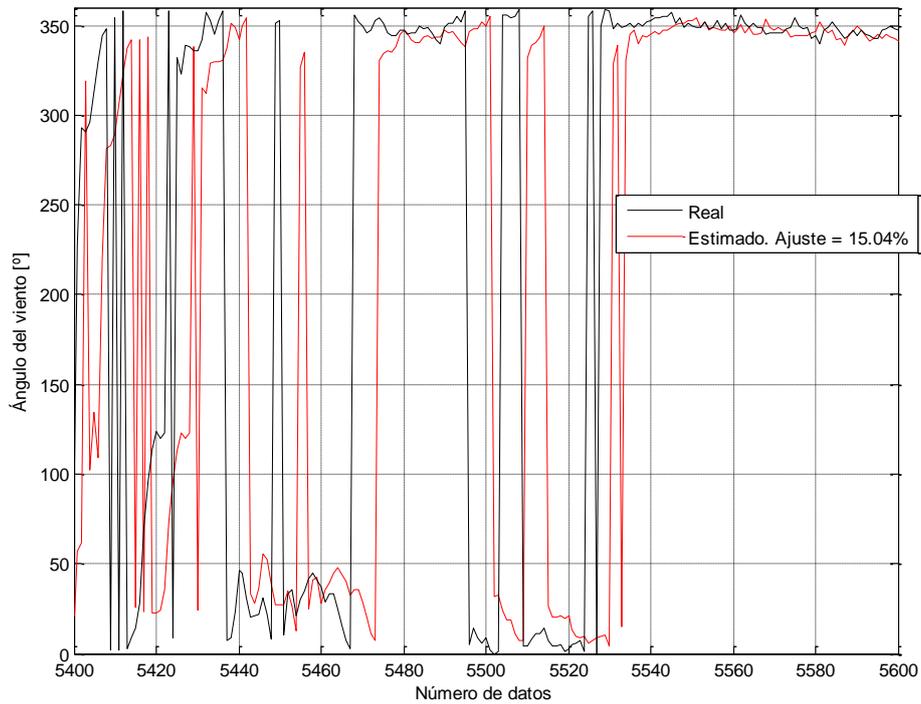


Figura 3.13: Ajuste logrado por la estimación de un modelo ARMA(8,8) para la dirección del viento en la estación de Isla Laitec en un horizonte temporal de 1 hora.

El modelo no es bueno sobre todo debido a que los puntos de 0° y 360° son el mismo, lo que genera errores grandes. Esto no hace sino empeorar cuando se toman horizontes de predicción mayores.

