

## DISEÑO Y OPTIMIZACIÓN MEDIANTE CFD Y REDES NEURONALES DE DEFLECTORES PARA UNA TURBINA SAVONIUS

**Bruno A. Storti<sup>a</sup>, Ignacio Peralta<sup>a</sup>, Jonathan J. Dorella<sup>a</sup>, Nadia D. Román<sup>a,b</sup>, Alejandro E. Albanesi<sup>a\*</sup> y Luciano Garelli<sup>a</sup>**

<sup>a</sup>*Centro de Investigaciones de Métodos Computacionales, (CIMEC), (CONICET-UNL) Colectora Ruta 168 s/n, Predio Conicet "Dr. Alberto Cassano", 3000 Santa Fe, Argentina,*  
<sup>\*</sup>*aalbanesi@cimec.santafe-conicet.gov.ar, <http://www.cimec.org.ar>*

<sup>b</sup>*Grupo de Investigación en Métodos Numéricos en Ingeniería (GIMNI), Facultad Regional Santa Fe (FRSF), Universidad Tecnológica Nacional (UTN), Lavalse 610, 3000, Santa Fe, Argentina*

**Palabras Clave:** Turbina Savonius, energía eólica, VAWT, optimización, redes neuronales artificiales, CFD.

**Resumen.** El objetivo de este trabajo es realizar la optimización geométrica de los deflectores de aire para una turbina eólica de eje vertical (VAWT) impulsada por arrastre (drag) tipo Savonius. El torque generado por este tipo de turbinas resulta de la diferencia entre las fuerzas de arrastre generado por las geometrías concavas y convexas de los álabes, respectivamente. La función de estos deflectores es orientar el flujo de aire sobre los álabes cóncavos, y bloquear el flujo sobre los álabes convexas que producen un torque de frenado. A partir de un prototipo de turbina Savonius diseñado y fabricado por los autores de este trabajo, se propone realizar un análisis con dinámica de fluidos computacional (CFD) de los deflectores, para mejorar el rendimiento de la turbina. Para las simulaciones en CFD se utilizará el código Code-Saturne basados en el método de volúmenes finitos. Se realizarán diversas corridas para distintas variables de diseño con el objetivo de obtener mediante Redes Neuronales una función que vincule la geometría de los deflectores con el rendimiento de la turbina ( $C_p$ ). Posteriormente, se buscará la configuración óptima de los deflectores que garantice el máximo rendimiento de la turbina a través de un proceso de optimización.

## 1. INTRODUCCIÓN

Es de público conocimiento que en los últimos años el uso de energías renovables se encuentra en un pico de demanda, debido a la necesidad de reducir el consumo de combustibles fósiles, para disminuir la emisión de gases contaminantes a la atmósfera. En esta situación se recurre a la energía eólica, que utiliza la energía cinética disponible en las masas de aire en movimiento para generar energía eléctrica.

En el marco de un proyecto tecnológico en el ámbito académico se desarrolló una turbina de eje vertical (VAWT) del tipo Savonius a instalarse en la terraza de la torre administrativa de la Facultad Regional Santa Fe de la Universidad Tecnológica Nacional. El rendimiento de este tipo de turbinas es bajo, sin embargo su robustez, bajo mantenimiento, simplicidad, fácil construcción y bajo costo hacen que las mismas sean frecuentemente utilizadas. Por este motivo, el desarrollo de medidas que permitan mejorar el desempeño este tipo de turbina es crucial para un aumento significativo de la contribución que estas hacen a la generación de energía.

## 2. OBJETIVOS


Con la finalidad de incrementar la eficiencia de la turbina Savonius descrita previamente, nos proponemos investigar numéricamente los efectos que tiene la colocación de diversos deflectores en el rendimiento de la misma. El principal objetivo de un deflector es orientar el flujo de aire sobre los álabes cóncavos, y bloquear el flujo sobre los álabes convexos que producen un torque de frenado. Diversos métodos para mejorar el rendimiento fueron ya implementados por otros grupos, los cuáles consisten tanto en modificaciones propias a la turbina, como la adición de deflectores propiamente dichos (Kamoji et al., 2009; Huda et al., 1992; Saha y Rajkumar, 2006). Una de las principales ventajas del uso de deflectores es que se trata de un sistema simple y externo a la turbina que no requiere de modificaciones mayores sobre la misma, logrando incrementos relativos importantes en su rendimiento. Un punto fundamental en el diseño de deflectores es la determinación de la forma y posición de los mismos respecto de la turbina. Este proceso puede realizarse por prueba y error, con la principal desventaja que se mejore el rendimiento pero no se asegure que el diseño sea el que garantice el mejor desempeño, o la parametrización de la geometría de los deflectores y la consecuente búsqueda de los parámetros que permitan obtener el diseño óptimo. Mohamed et al. (2010) proponen un deflector caracterizado por tres variables, el cual es optimizado mediante Algoritmo Genético (GA). Se busca maximizar una función objetivo (en este caso el coeficiente de potencia) con el fin de encontrar las variables que caracterizan el deflector.

En el presente trabajo se pretende basarse en la metodología de Mohamed et al. (2010), es decir parametrizar el deflector, pero en lugar de utilizar GA acoplado con CFD, se optimizará una función obtenida mediante Redes Neuronales Artificiales (ANN). Al ser esta función continua, puede optimizarse mediante métodos basados en gradientes, lo cual reduce el costo computacional.

## 3. MODELO NUMÉRICO

### 3.1. Validación del modelo

Las simulaciones de este trabajo fueron efectuadas mediante la plataforma OpenSource de Code-Saturne (2017). Las ecuaciones de Navier-Stokes promediadas en el tiempo son resueltas utilizando el algoritmo SIMPLEC (modificación del método SIMPLE) para el acople presión-velocidad. Se utiliza el método de volúmenes finitos con un esquema upwind de segundo orden.



Rotor	
D [m]	0.330
d [m]	0.184
S [m]	0.380
a [m]	0.015

Figura 1: Dimensiones de la turbina de 2 áspas .

Para el modelado de la turbulencia se utilizó el modelo  $k - \epsilon$  el cuál es el más recomendado para cuerpos que rotan. Todas las simulaciones fueron realizadas en dos dimensiones ya que la geometría no varía en el tercer eje, y los efectos de punta son despreciados. De esta forma se puede aumentar la cantidad de elementos en la zona del rotor y de los deflectores. Para resolver el flujo transiente se utilizó el modelo de malla deslizante (Sliding Mesh Model). Las mallas fueron todas realizadas utilizando el software libre SALOME (2007.). En la Figura 1 se muestra la geometría de una turbina del tipo Savonius de dos áspas de la cual se tienen datos experimentales (Hayashi et al., 2005) que se utilizaron para validar el modelo numérico.

En cada simulación se corren diez vueltas, y se utilizan solo las últimas tres para promediar el torque y obtener el coeficiente de potencia o  $C_p$ . El mismo se define de la siguiente manera:

$$C_p = \frac{P}{\rho R H U^3} \quad (1)$$

siendo  $\rho$  la densidad del aire,  $R$  el radio del rotor de la turbina,  $H$  la altura de la turbina y  $U$  la velocidad del viento.

La malla utilizada para las simulaciones consta de aproximadamente 75.000 elementos hexaédricos en el dominio estacionario, y de un total de 30.000 elementos prismáticos y hexaédricos en el dominio rotante.




Figura 2: Dominio del modelo numérico .

Luego de setear el modelo de CFD se procedieron a realizar las corridas de validación




Figura 3: Validación del modelo computacional: Coeficiente de potencia comparado con los trabajos experimentales publicados por [Hayashi et al. \(2005\)](#) y con los resultados obtenidos en ANSYS por [Mohamed et al. \(2010\)](#).

Para el modelo se utilizó una velocidad de viento de 6 m/s, y variando la velocidad de giro de la turbina se obtuvieron los valores de  $C_p$  para los distintos TSR o  $\lambda$  de funcionamiento. Este parámetro se define según la Ecuación 2 como:


$$\lambda = \frac{\omega R}{U} \quad (2)$$

Donde  $\omega$  es la velocidad de giro en radianes por segundo,  $R$  el radio de la turbina en metros, y  $U$  la velocidad del viento en metros por segundo.

Se obtuvieron valores con errores relativos bajos para el rango de TSR entre 0.4 y 0.8, que es el rango en el cual se trabajó en el proceso de optimización.

#### 4. OPTIMIZACIÓN

La turbina a optimizar es una VAWT de 8 álabes con un diámetro de rotor de 2 metros y una altura de igual dimensión (Figura 4). Ésta se encuentra dispuesta en la terraza de la torre administrativa de la Facultad Regional de Santa Fe, de la Universidad Tecnológica Nacional. A la misma se le colocarán deflectores aguas arriba de forma tal de camuflar los álabes que producen un torque negativo y favoreciendo aquellos que generan torque positivo.



Rotor	
D [m]	2.00
d [m]	0.40
a [m]	0.08
e [m]	0.01

Figura 4: Dimensiones de la turbina de 2 aspas .

El primer paso para el proceso de optimización es la parametrización de los deflectores. Cada deflector está definido por tres puntos unidos mediante una curva tipo spline de tercer orden. Cada uno de los puntos ( $i = 1, 2, 3$ ) se encuentra determinado por coordenadas polares ( $r_i, \theta_i$ ) que tienen como origen el eje de giro de la turbina, según se detalla en la Figura 5. Para evitar geometrías muy complejas que no representen la funcionalidad de un deflector, y que además dificulten el mallado, se define el primer punto en forma absoluta, y los restantes en forma relativa al punto anterior, según Ecuación 3.

$$\begin{aligned}
 r_2 &= r_1 + \Delta r_2 & \alpha_2 &= \alpha_1 + \Delta \alpha_2 \\
 r_3 &= r_2 + \Delta r_3 & \alpha_3 &= \alpha_2 + \Delta \alpha_3
 \end{aligned}
 \tag{3}$$




Figura 5: Parametrización del deflector.

Los límites de los parámetros que se observan en la Tabla 1 se adoptaron en base al lugar físico disponible para la instalación de los deflectores.

Variable	Min	Máx
$r_1$ [cm]	130	160
$\theta_1$ [deg]	0	15
$\Delta r_2$ [cm]	5	30
$\Delta \theta_2$ [deg]	1	5
$\Delta r_3$ [cm]	5	30
$\Delta \theta_3$ [deg]	1	5

Tabla 1: Límite para variables de diseño

A partir de mediciones realizadas en el lugar de emplazamiento de la turbina respecto a la intensidad y dirección del viento, se concluyó que el mismo se presentaba en cuatro direcciones predominantes en coincidencia con los puntos cardinales norte (N), sur (S), este (E) y oeste (O). Por este motivo se colocarán cuatro deflectores idénticos, según lo definido en la parametrización anterior, cada uno en concordancia a lo que se visualiza en la Figura 6. Estos se encuentran desplazados radialmente  $90^\circ$  entre ellos, con centro de rotación en el eje de la VAWT.

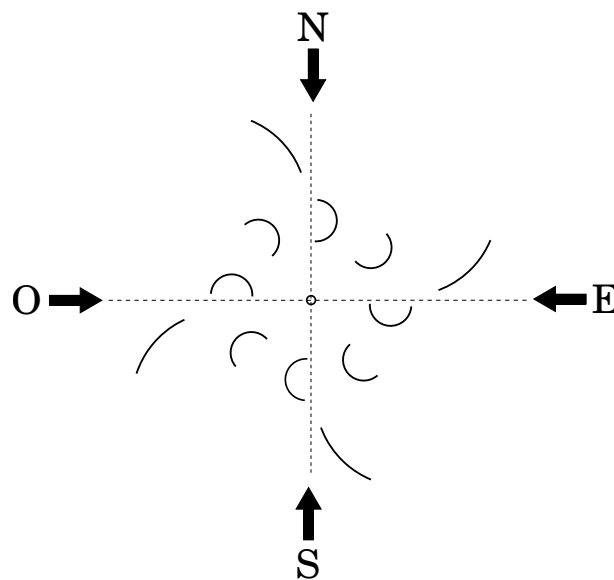


Figura 6: Direcciones predominante del viento en el sitio de emplazamiento de la turbina.

#### 4.1. Modelo computacional

A partir de la parametrización de la geometría anteriormente expuesta, se propuso el dominio para el modelo numérico que se observa en la Figura 7. El mismo se compone de tres subdominios: el dominio estacionario A (que posee los deflectores) con aproximadamente 118.000 elementos hexaédricos y prismáticos, el dominio estacionario B que consta de 120.000 elementos puramente hexaédricos y el dominio rotante (que posee la turbina) con un total de 43.800 elementos, prismáticos y hexaédricos.




Figura 7: Dominio del modelo numérico.




Figura 8: Detalle de malla.

Luego de setear el modelo de CFD general, se realizó un estudio de convergencia de malla para la configuración de variables que se observa en la Figura 9. Se varió la cantidad de celdas totales del dominio y se compararon los valores de  $C_p$  obtenidos. En la Figura 9 se observa que para mallas con número de celdas mayor a 255.800, el coeficiente de potencia prácticamente permanece constante, con un error porcentual menor al 0.02 %.

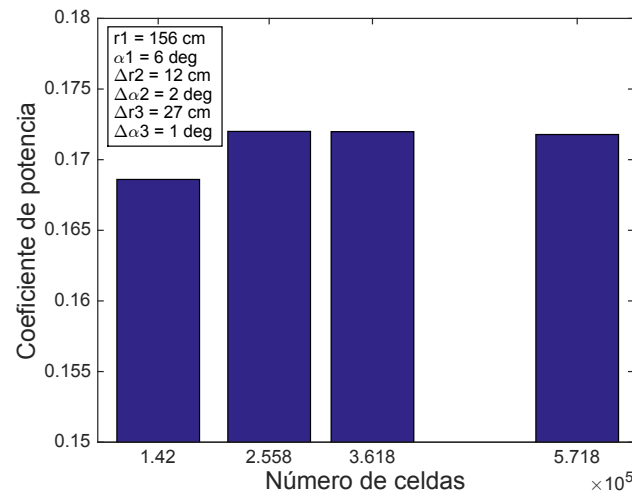


Figura 9: Convergencia en malla.

Las simulaciones fueron realizadas en el cluster [Seshat \(2017\)](#) perteneciente al CIMEC (UNL/CONICET), con una duración de 1,3 horas con la utilización de 40 cores (10 nodos con 4 cores cada uno). Se utilizó una velocidad de viento de 5 [m/s] y una relación de velocidad de punta (TSR) de 0,4, el cuál, según estudios realizados anteriormente por el grupo de trabajo, es el punto óptimo de funcionamiento para este generador. En este tipo de turbinas impulsadas por drag o arrastre, a diferencia de las impulsadas por lift, es típico un valor de  $\lambda$  menor a 1.

#### 4.2. Proceso de optimización

En el artículo de [Mohamed et al. \(2010\)](#) se propone realizar la optimización mediante GA, lo cual requiere una determinada cantidad de simulaciones, en función del tamaño de la población, las generaciones y la probabilidad de supervivencia. En el caso del presente trabajo, se muestran en la Tabla 2 distintas posibilidades para la configuración del algoritmo genético. Se observa que la cantidad de horas necesarias para la resolución del problema de optimización hace que el proceso sea computacionalmente costoso.

Población inicial	20	20	50	50	100	100
Generaciones	20	50	50	100	100	500
Probabilidad	50 %	50 %	50 %	50 %	50 %	50 %
Simulaciones necesarias	210	510	1275	2525	5050	25050
Horas requeridas	279	678	1696	3358	6717	33317
Días requeridos	12	28	71	140	280	1388

Tabla 2: Estimación de horas/días de simulación por GA.

Como alternativa a este método se propuso reemplazar la simulación por la evaluación de una función obtenida mediante la utilización de un modelo de ANN. A tal fin se siguió el proceso expuesto en la Figura 10, cuyas etapas se resumen a continuación:

- Obtención de las muestras necesarias para el entrenamiento y validación de las redes neuronales, mediante un hipercubo latino.



- Simulación en CFD de las muestras obtenidas.
- Entrenamiento de diferentes ANN.
- Validación de las ANN y selección de la función a optimizar.
- Optimización multivariable mediante método basado en gradiente (NLMO).
- Simulación en CFD y validación del óptimo obtenido.

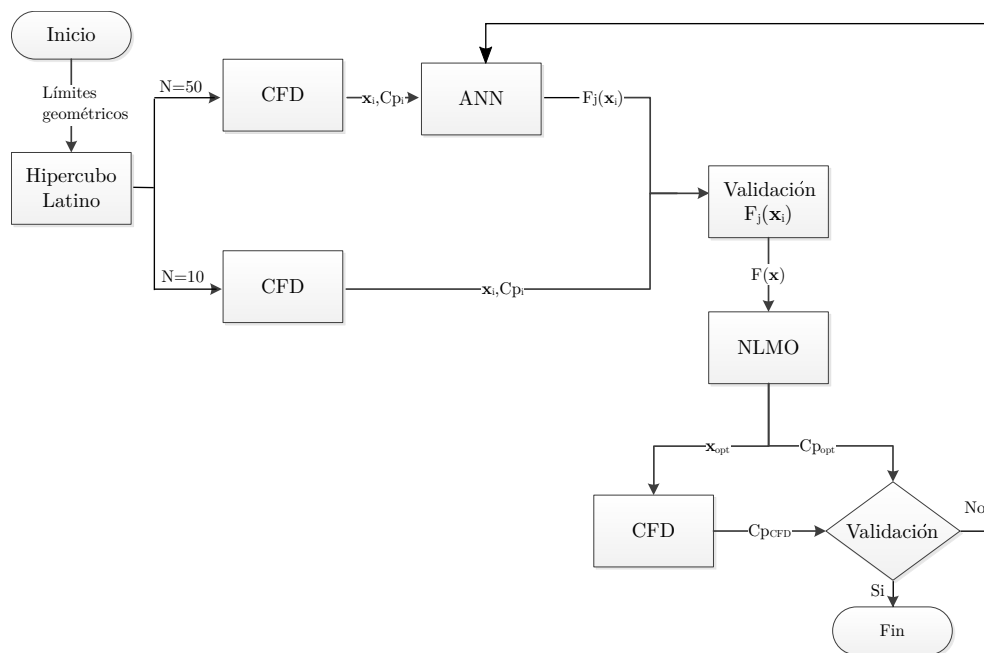


Figura 10: Diagrama de flujo del proceso de optimización.

Para el entrenamiento y validación de la red, se utilizaron dos muestras independientes de 50 y 10 configuraciones distintas, que se obtuvieron mediante el método del Hiper cubo Latino (LH). En este método de muestreo propuesto por McKay et al. (1979) se selecciona inicialmente el tamaño  $N$  deseado para la muestra. Posteriormente, se divide a cada variable en  $N$  intervalos, resultando los mismos de igual probabilidad  $1/N$ . Finalmente, se selecciona un elemento de cada intervalo y se combinan de manera random los valores obtenidos. En la Figura 11 se esquematiza la distribución de la muestra para un ejemplo de tamaño  $N=5$  con dos variables. Empleando la metodología del LH, se obtiene una muestra representativa de todo el espacio de diseño, cuyo tamaño es de  $8,38 \times 10^6$ .

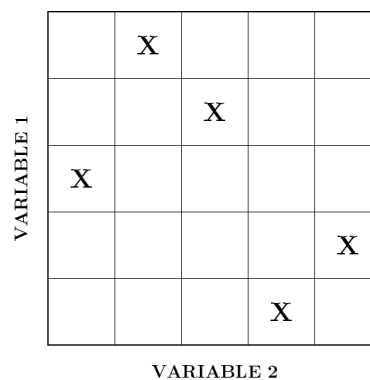


Figura 11: Hipercubo latino.

De acuerdo a la definición introducida por Hassoun (1995), las ANN son modelos computacionales paralelos, compuestos de unidades de procesamiento densamente interconectadas. Las mismas, inspiradas en el funcionamiento del cerebro humano poseen, según Haykin (1999) las siguientes características: el procesamiento paralelo, la posibilidad de establecer relaciones no lineales entre datos, la adaptabilidad, un alto nivel de tolerancia a fallas (lo que las capacita para un posible procesado robusto), la operación en tiempo real y la uniformidad de análisis y diseño.

Se optó por la utilización de un modelo de red neuronal artificial del tipo feed-forward (Figura 12), que se encuentra compuesto por distintas capas de neuronas: una capa de entrada, una o más capas ocultas y una capa de salida. Para la determinación de la configuración del modelo de ANN se propusieron distintos arreglos:

- Capa de entrada (Input): 6 neuronas
- Capas ocultas (HL): 1 a 3 capas ocultas, cada una con una disposición de 6 a 12 neuronas, cumpliendo con la condición que la cantidad de neuronas en una capa no puede ser mayor que la anterior. Por ejemplo, si se cuenta con 7 neuronas en la primer HL, la segunda sólo podrá tener 6 o 7 neuronas.
- Capa de salida (Output): 1 neurona




Figura 12: Red neuronal del tipo Feed Forward.

El funcionamiento de una neurona, que se observa en la Figura 13 y se resume en la Ecuación 4, se basa en la sumatoria entre una señal de entrada afectada por un peso sináptico y un bias, a

la cual se aplica una función de activación para obtener una señal de salida. Se seleccionó como función de activación para todas las neuronas la logarítmica sigmoidea.

$$y_k = \phi_k \left( \sum (w_i * x_i) + b_k \right) \quad (4)$$

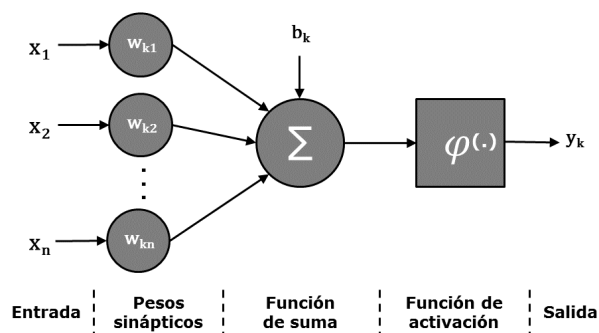


Figura 13: Esquema de una neurona.

Como criterios de parada para el entrenamiento se adoptó un error medio cuadrático (MSE) igual a  $1 \times 10^{-7}$  o 500 iteraciones. Para cada configuración, se realizaron 10 redes distintas, sumando un total de 190. Para la evaluación de la performance de las mismas, se adoptaron como criterio el coeficiente de regresión (R) y la raíz de suma del error medio cuadrático (RMSE). En las Figuras 14 y 15 se observan los resultados obtenidos en función de la cantidad total de neuronas en las capas ocultas. Se adoptó para el proceso de optimización la red que presenta mejor performance, que corresponde a la configuración de la Figura 16, y cuya aproximación a la muestra de validación se observa en la Figura 17.




Figura 14: Raíz del error cuadrático medio en función del total de neuronas en las capas ocultas.




Figura 15: Coeficiente de regresión en función del total de neuronas en las capas ocultas.




Figura 16: Configuración de la red seleccionada.

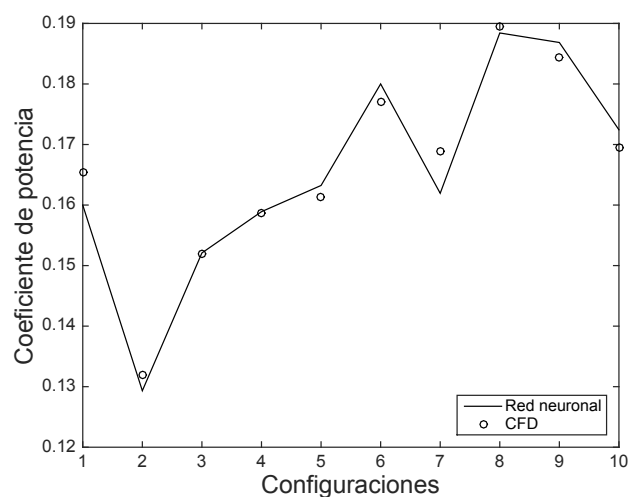


Figura 17: Validación de los resultados de la red neuronal.

A partir de la selección de la red neuronal, se realizó la optimización mediante un método no lineal multivariable basado en gradiente. Se adoptó como punto inicial de la optimización la configuración de la muestra de entrenamiento que presentaba mejor  $C_p$ . Las restricciones de caja impuestas a las variables corresponden a las presentadas en la Tabla 1.

El resultado óptimo obtenido se simuló en CFD con el fin de realizar una última validación sobre el proceso propuesto. En caso de que se presenten errores mayores al 5% en esta validación, se retorna al entrenamiento de nuevas redes.

## 5. RESULTADOS Y DISCUSIONES

En primer lugar, la simulación en CFD de la turbina sin deflector arrojó como resultado un coeficiente de potencia de 0.153. Este valor se encuentra en concordancia con el rango de  $C_p$  para las turbinas del tipo Savonius.

Del proceso de optimización, se obtuvo un deflector cuya geometría se describe mediante los parámetros que se visualizan en la Tabla 3. Se observa una mejora en el rendimiento de la turbina de 0,04, lo que se traduce en un incremento del 26 % de la potencia entregada por la misma.

En la Figura 18 se esquematizan las distintas geometrías de los deflectores utilizados para el entrenamiento de la red neuronal y el óptimo hallado. Se puede ver que la distribución de las geometrías es heterogénea, representando todo el espacio de diseño. Aquellas que describen una curvatura suave y un mayor desarrollo longitudinal son las que mejoran en mayor proporción al rendimiento de la turbina.

Variables de diseño						Cp	
$r_1$	$\alpha_1$	$\Delta r_2$	$\Delta \alpha_2$	$\Delta r_3$	$\Delta \alpha_3$	$C_{pCFD}$	$C_{pOpt}$
137,3	14,6	30,0	5,0	16,9	5,0	<b>0,193</b>	<b>0,191</b>

Tabla 3: Configuración óptima del deflector.




Figura 18: Geometría de la muestra de entrenamiento y la óptima encontrada.

En lo que respecta al campo de presiones, en la Figura 19 se presenta el diagrama de contorno del mismo para los casos con y sin deflector. Fácilmente se puede observar que la presencia del deflector contribuye a un aumento en el valor absoluto tanto de la presión sobre la superficie cóncava como de la depresión sobre la superficie convexa de los álabes de la turbina que generan torque positivo, hecho que se traduce en un aumento de la diferencia de presión y un consiguiente aumento de la potencia. En la Figura 20 se detalla el coeficiente de presión (CP), según Ecuación 5, sobre uno de los álabes comparando los casos con y sin deflector.

$$CP = \frac{p - p_{\infty}}{\frac{1}{2} \rho U_{\infty}^2} \quad (5)$$




Figura 19: Curvas de nivel para el campo de presión: a) sin deflector, b) con deflector óptimo.

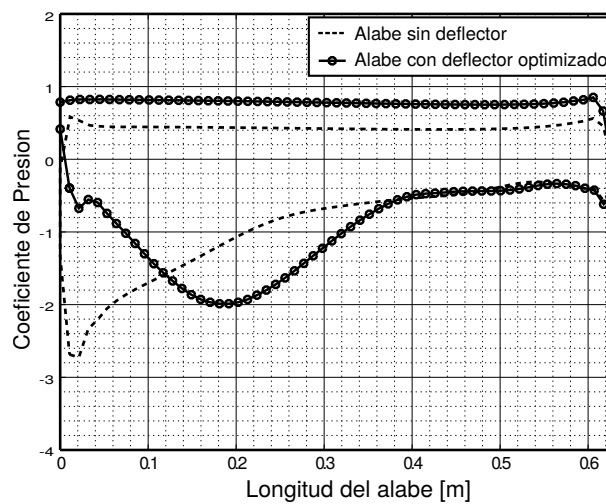


Figura 20: Coeficiente de presión sobre el álabe .

En la Figura 21 se refleja el aumento del torque anteriormente mencionado y, además, una mayor regularidad del mismo.




Figura 21: Torque producido por la VAWT en 3 vueltas .

## 6. CONCLUSIÓN

Se validó de forma satisfactoria el modelo computacional utilizando datos experimentales. Posteriormente se pudo acoplar dicho modelo con el proceso de optimización propuesto, lo que redujo significativamente los tiempos de cálculo.

Se pudo obtener una función continua y derivable mediante la aplicación de ANN, lo que permite determinar instantáneamente el coeficiente de potencia para una determinada configuración de geometría de deflector, mientras que una simulación por CFD insume un tiempo del orden de 1,3 horas. A su vez, la misma posibilita la utilización de resolvedores de optimización basados en gradientes.

A partir de la implementación de ANN, se logró representar satisfactoriamente, con una muestra de tamaño reducido, un espacio de diseño del orden de 8 millones de posibles configuraciones.

Finalmente se obtuvo una configuración óptima de deflector que produce un aumento del rendimiento global de la turbina del 23 %.

## REFERENCIAS

- Code-Saturne. <http://code-saturne.org/cms/>, 2017.
- Hassoun M.H. *Fundamentals of Artificial Neural Networks*. MIT Press, 1995.
- Hayashi T., Li Y., y Hara Y. Wind tunnel tests on a different phase three-stage savonius rotor. *JSME International Journal Series B Fluids and Thermal Engineering*, 48(1):9–16, 2005.
- Haykin S. *Neural Networks: A comprehensive Foundation*. Pearson Education, 1999.
- Huda M., Selim M., Islam A., y Islam M. Performance of an s-shaped savonius rotor with a deflecting plate. *RERIC International Energy Journal*, 1(14):25–32, 1992.
- Kamoji M., Kedare S., y Prabhu S. Performance tests on helical savonius rotors. *Renewable Energy*, 3(34):521–9, 2009.
- McKay M.D., Beckman R.J., y Conover W.J. A comparison of three methods for selecting values of input variables in the analysis of output from a computer code. *Technometrics*, 21(2):239–245, 1979.
- Mohamed M., Janiga G., Pap E., y Thévenin D. Optimization of savonius turbines using an obstacle shielding the returning blade. *Renewable Energy*, 35:2618–2626, 2010.
- Saha U. y Rajkumar M. On the performance analysis of savonius rotor with twisted blades. *Renewable Energy*, 11(31):1776–1788, 2006.
- SALOME O.C.E.C. GNU Lesser General Public License. [www.salome-platform.org](http://www.salome-platform.org). 2007.
- Seshat. Especificaciones técnicas. <http://www.cimec.org.ar/c3/seshat/equipos.php>, 2017.