



**UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO**

**INSTITUTO DE ENERGÍAS RENOVABLES**

**INSTITUTO DE INGENIERÍA**

**ESCUELA NACIONAL DE ESTUDIOS SUPERIORES-JURIQUILLA**

**Análisis de la dinámica de  
estados viento-demanda en el  
sistema eléctrico mexicano**

**TESIS**

Que para obtener el título de  
**Ingeniero en Energías Renovables**

**P R E S E N T A**

Ernesto Pérez Chávez

**DIRECTOR DE TESIS**

Dr. Miguel Robles Pérez

**Temixco, Mor., a 10 de diciembre de 2021**



**IER**

Instituto de Energías  
Renovables



**INSTITUTO  
DE INGENIERÍA  
UNAM**



**ENES  
JURIQUILLA**



Universidad Nacional  
Autónoma de México



**UNAM – Dirección General de Bibliotecas**  
**Tesis Digitales**  
**Restricciones de uso**

**DERECHOS RESERVADOS ©**  
**PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL**

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

**OF/IER/LIER/163/2021**  
**ASUNTO:** Notificación de jurado y  
fecha para examen profesional.

**LIC. IVONNE RAMÍREZ WENCE**  
**DIRECTORA GENERAL DE ADMINISTRACIÓN ESCOLAR**  
**Presente.**

Por medio de la presente le informo que el día viernes 10 de diciembre de 2021, a las 16:30 h, en el Instituto de Energías Renovables, el **C. ERNESTO PÉREZ CHÁVEZ**, con número de cuenta 315283873 de la Licenciatura de Ingeniería en Energías Renovables, llevará a cabo la presentación del trabajo de tesis y examen profesional titulado:

***“Análisis de la dinámica de estados viento-demanda  
en el sistema eléctrico mexicano”***

Debido a que el alumno ha cumplido con los requisitos que establece el Reglamento General de Exámenes, el Comité Académico de la Licenciatura de Ingeniería en Energías Renovables, le asigna el Jurado de Examen Profesional integrado por los siguientes académicos.

<b>PRESIDENTE:</b>	<b>DR. OSVALDO RODRÍGUEZ HERNÁNDEZ</b>
<b>VOCAL:</b>	<b>DRA. MÓNICA BORUNDA PACHECO</b>
<b>SECRETARIO:</b>	<b>DR. MIGUEL ROBLES PÉREZ</b>
<b>SUPLENTE:</b>	<b>DR. ALBERTO REYES BALLESTEROS</b>
<b>SUPLENTE:</b>	<b>DRA. NADIA MARÍA SALGADO HERRERA</b>

Sin otro particular, le envío un cordial saludo.

Atentamente,  
**“Por mi raza hablará el espíritu”**  
Temixco, Mor., a 6 de diciembre de 2021



**Dr. Jorge Alejandro Wong Loya**  
**Coordinador de la LIER**  
**IER-UNAM**

JAWL´mfp.



Priv. Xochicalco s/n,  
Col. Centro,  
62580 Temixco, Morelos, México  
T. 01 (777) 362 00 90  
(52) 55 56 22 97 00

[ier.unam.mx](http://ier.unam.mx)

*Miró el anillo y leyó: "Esto también pasará".  
En ese momento, sintió tranquilidad...*

*A mi papá Manuel, a mi mamá Miriam y a mi hermano Emiliano  
con todo mi amor y gratitud.*

# Agradecimientos

Agradezco a la vida por darme la oportunidad de existir hoy.

Cuando recuerdo el camino que me ha llevado hasta aquí, a estar sentado en mi cuarto una tarde de viernes escribiendo, me doy cuenta de lo agradecido que estoy con las circunstancias, causalidades y las personas que me han llevado a ser quien hoy soy.

Viene a mi mente con mucho cariño mi infancia. Fue ahí cuando tuve a mis primeros maestros: Papá y Mamá.

Papá, te agradezco por ser mi mejor maestro, el ingeniero que impulsara mi relación con las matemáticas y la física; pero sobre todo te agradezco infinitamente por ser el ser humano que eres: el mejor padre, no tengo palabras suficientes para agradecer el cariño y motivación que siempre me has dado. "Sensibilidad, voluntad e inteligencia".

Madre querida, ¿cómo empezar?. Eres una mujer maravillosa, gracias por estar en mi vida, siempre has sido mi apoyo. Gracias por la sensibilidad de tus palabras y por tu enorme corazón. Gracias por cuidarme y enseñarme tanto, gracias por ser.

Hermano, sabes que siempre contarás conmigo, siempre seré tu apoyo cuando lo necesites, y por lo que me queda de vida estaré para ti. Gracias por compartir toda una vida juntos -aún nos falta mucho-.

Cuando ingresé el Instituto de Energías Renovables, tenía algo seguro en mi mente: me convertiría en Ingeniero. Hoy que estoy a punto de lograrlo, quiero agradecer a todas las personas que formaron parte de este viaje. Gracias a mis compañeros (as) y amigos (as) de la 7G y 8G, y en especial a mis amigos de CCH Azu y Sebas, a Ale y a mi mejor amigo Carlitos (aquí estamos hermano, convergiendo la serie).

Gracias a todas las personas que hacen que la LIER se mantenga siempre de pie, a Maribel, Claudia, Magali y Carlos, y a todos los profesores de los que tuve la oportunidad

de aprender algo de ellos, en especial al Dr. Mariano y al Dr. Robles.

Gracias Dr. Miguel Robles por compartir esta aventura llamada Tesis. Gracias por las reuniones cada tarde de jueves a las 4, las pláticas, los consejos y las revisiones. Gracias por impulsarme en este camino de la *data science*, el cual espero seguir por el resto de mi vida.

Gracias a mis sinodales Alberto, Mónica, Nadia y Osvaldo, por darse el tiempo de revisar este trabajo y por los oportunos comentarios.

Gracias al IER y a la UNAM por todas las oportunidades que me brindó, por todas las aventuras, experiencias que me permitió vivir y las personas increíbles que conocí aquí.

Hoy estoy feliz por la vida que tengo.

# Resumen.

El uso efectivo del recurso eólico generalmente se ve afectado por su naturaleza estocástica. Es por ello, que resulta conveniente establecer modelos probabilísticos que permitan describir la dinámica del viento a lo largo del tiempo. En este trabajo se propone un modelo, utilizando técnicas de ciencia de datos y basado en el uso de cadenas de Markov, para describir y analizar la dinámica viento-demanda. Específicamente, se utiliza el concepto de estado de viento y se introducen las definiciones de “estado de viento grupal” y “estado viento-demanda”, que permiten hacer clasificaciones automáticas que describen la dinámica del viento respecto a la demanda eléctrica en una zona geográfica a lo largo del tiempo.

Se estudiaron los datos de viento correspondientes a las 7 estaciones meteorológicas del Atlas Eólico Mexicano (AEM) situadas a lo largo de la República Mexicana y se utilizaron los datos de generación eléctrica nacional (obtenidos del CENACE).

La propuesta de este trabajo consiste en identificar los 2 estados de viento con mas potencial eólico de cada sitio (a excepción de La Ventosa donde se identifica solo uno) mediante la aplicación de un método de agrupamiento *K-means* a los vectores de velocidad instantáneos, y aplicando criterios de selección a los grupos obtenidos (definidos como “estados”) usando la densidad de potencia del viento, el factor de planta de un aerogenerador de referencia, el tiempo de vida promedio, el tiempo de permanencia, la variación promedio del ángulo y la velocidad media. De esta forma, cuando un sitio, en un intervalo de tiempo determinado, se encuentra en cualquiera de sus dos mejores estados de viento se considera un estado favorable (si no se encuentra en alguno de estos dos estados se considera desfavorable). Permitiendo definir, para el conjunto de sitios examinados, lo que se puede llamar estados de viento grupales y construir sus cadenas de Markov en el tiempo. Se encontró que la probabilidad de que el número de estados favorables activos no cambie de  $i$  a  $i + 1$  se encuentra entre 62.5



y 70 %, y que la probabilidad de transitar más de dos estados (por ejemplo transitar de 4 a 6 ó de 4 a 2) disminuye considerablemente para todos los casos.

Análogamente se construye una cadena de Markov asociada a la demanda eléctrica nacional. Definiendo a los valores de demanda por debajo de la media como de baja demanda y a los valores por encima de la media como de alta demanda. Al contar con ambas cadenas, una que describe la dinámica del viento y otra que describe la dinámica de la demanda, es posible construir una cadena que describa la información de ambas. Tal cadena, básicamente, representa la dinámica de los estados viento-demanda. Se encontró que la dinámica del viento presenta un comportamiento casi opuesto a la demanda. El análisis de la cadena viento-demanda permitió determinar que más del 38 % del tiempo existe una desincronización negativa entre la oferta de viento y la demanda de energía (pudiendo generar problemas de suministro de electricidad), y que poco más del 15 % podríamos establecer mecanismos de almacenamiento de energía para su uso posterior. Así mismo, la probabilidad de permanecer en el mismo estado viento-demanda de  $i$  a  $i + 1$  se encuentra entre el 80 y 85 % para todos los casos.

Se espera que en un futuro, el modelo desarrollado pueda ser aplicado en modelos probabilísticos de predicción. Toda la programación necesaria fue realizada usando los softwares Mathematica y Python.

# Índice general

<b>Agradecimientos</b>	<b>II</b>
<b>Resumen.</b>	<b>IV</b>
<b>Nomenclatura</b>	<b>XI</b>
<b>Introducción.</b>	<b>XIII</b>
<b>Planteamiento del problema.</b>	<b>XV</b>
§0.1 Objetivos. . . . .	XV
§0.2 Justificación. . . . .	XVI
§0.3 Metodología. . . . .	XVI
<b>1 Energía eólica.</b>	<b>1</b>
§1.1 Fundamentos de energía eólica. . . . .	2
§1.1.1 Energía contenida en el viento y extracción de potencia. . . . .	2
§1.1.2 Tecnología de aerogeneradores. . . . .	6
§1.2 Evaluación de recurso eólico. . . . .	9
§1.2.1 Adquisición de datos de viento. . . . .	10
§1.2.2 Análisis de series de viento. . . . .	11
§1.3 Energía eólica en México. . . . .	14
§1.3.1 Atlas eólico mexicano. . . . .	15
<b>2 Red y demanda eléctrica.</b>	<b>17</b>
§2.1 Red eléctrica. . . . .	18
§2.1.1 Sistema Eléctrico Nacional (SEN). . . . .	19

§2.2 Demanda eléctrica . . . . .	20
<b>3 Datos, aleatoriedad y estados de viento.</b>	<b>23</b>
§3.1 ¿Qué es la ciencia de datos?. . . . .	23
§3.1.1 El proceso de la ciencia de datos. . . . .	24
§3.2 Procesos estocásticos. . . . .	29
§3.2.1 Cadenas de Markov discretas. . . . .	30
§3.3 Estados de viento. . . . .	30
§3.3.1 ¿Qué hace a un Estado de viento mejor que otro? . . . . .	34
<b>4 Metodología.</b>	<b>36</b>
§4.1 Recopilación de datos. . . . .	37
§4.2 Preparación de datos. . . . .	37
§4.3 Construcción de estados de viento y cadenas de Markov de viento. . . . .	38
§4.4 Selección de estados más favorables. . . . .	40
§4.5 Construcción de estados de viento grupales. . . . .	42
§4.6 Construcción de estados de demanda. . . . .	43
§4.7 Construcción de estados viento-demanda. . . . .	44
<b>5 Resultados y discusión.</b>	<b>46</b>
§5.1 Estados de viento. . . . .	47
§5.2 Estados de viento favorables activos. . . . .	48
§5.3 Estados de viento grupales. . . . .	51
§5.4 Estados de demanda. . . . .	53
§5.5 Estados viento-demanda. . . . .	54
<b>6 Conclusiones.</b>	<b>58</b>
§6.1 Comentarios finales. . . . .	58
§6.2 Trabajos a futuro. . . . .	59
<b>7 Anexos.</b>	<b>60</b>

# Índice de figuras

1.1	Diagrama esquemático de las partes de un aerogenerador. Imagen propia. . .	7
1.2	Curva de potencia VestasV90/3000. Imagen propia con datos extraídos de [23]	9
1.3	Velocidad de viento a 80m. Imagen extraída de [30] . . . . .	15
1.4	Estaciones meteorológicas del AEM. Imagen propia con datos de [29, 30] . .	16
2.1	Dibujo simplificado del recorrido de la electricidad desde el punto de genera- ción hasta el de consumo. . . . .	18
2.2	Regiones del Sistema Eléctrico Nacional. Imagen tomada de [33]. . . . .	19
2.3	Demanda horaria de energía, 2018. Imagen propia con datos de [34] . . . . .	21
2.4	Demanda de energía promedio por día, 2018. Imagen propia con datos de [34]	21
2.5	Demanda de energía promedio por hora, 2018. Imagen propia con datos de [34]	22
3.1	Metodología Fundamental para la Ciencia de Datos. Imagen tomada de [37] .	24
3.2	Diagrama de dispersión. . . . .	31
3.3	Histograma 3D. . . . .	31
3.4	Estados de viento. . . . .	33
4.1	Diagrama de flujo para la metodología de construcción de un proceso de Mar- kov para estados viento-demanda. . . . .	36
4.2	Disponibilidad de datos por estación meteorológica. . . . .	39
5.1	Disponibilidad de datos por estación meteorológica. . . . .	46
5.2	Frecuencia por estados favorables activos. . . . .	49
5.3	Cadena de Markov de estados favorables activos. . . . .	49
5.4	Promedio de estados favorables activos por día. . . . .	50
5.5	Frecuencia por estados de viento grupales. . . . .	52

5.6	Cadena de Markov de estados de viento grupales. . . . .	52
5.7	Frecuencia de estados de viento grupales por hora . . . . .	53
5.8	Cadena de Markov de estados viento-demanda. . . . .	55
5.9	Otra visualización de la cadena de Markov de estados viento-demanda. . . . .	55
5.10	Frecuencia de estados viento-demanda por hora. . . . .	56

## Índice de tablas

5.1	Total de datos disponibles por estación meteorológica (2018). . . . .	46
5.2	Estados de viento San Fernando. . . . .	47
5.3	Matriz de transición San Fernando. . . . .	47
5.4	Mejores estados de viento. . . . .	48
5.5	Número de estados favorables activos. . . . .	48
5.6	Matriz de transición estados favorables activos. . . . .	50
5.7	Estados de viento grupales. . . . .	51
5.8	Matriz de transición estados de viento grupales. . . . .	53
5.9	Estados de demanda. . . . .	54
5.10	Estados viento-demanda. . . . .	54
5.11	Matriz de transición estados viento-demanda. . . . .	56
7.1	Matriz de transición La Rumorosa. . . . .	60
7.2	Estados de viento La Rumorosa. . . . .	60
7.3	Matriz de transición Cuauhtémoc. . . . .	61
7.4	Estados de viento Cuauhtémoc. . . . .	61
7.5	Matriz de transición Ojuelos. . . . .	61
7.6	Estados de viento Ojuelos. . . . .	61
7.7	Matriz de transición Tepexi. . . . .	62
7.8	Estados de viento Tepexi. . . . .	62

7.9 Matriz de transición Mérida. . . . .	62
7.10 Estados de viento Mérida. . . . .	62

# Nomenclatura

- AEM: Atlas Eólico Mexicano.
- CENACE: Centro Nacional de Control de Energía.
- SEN: Sistema Eléctrico Nacional.
- SIN: Sistema Interconectado Nacional.
- PRODESEN: Programa para el Desarrollo del Sistema Eléctrico Nacional.
- RNT: Red Nacional de Transmisión.
- RGD: Redes Generales de Distribución.
- $P_{viento}$ : Potencia eólica.
- $P_{ext}$ : Potencia extraída del viento por el aerogenerador.
- $C_p$ : Coeficiente de potencia de un aerogenerador.
- $P_{producida}$ : Potencia eléctrica producida por un aerogenerador.
- $\overline{DP}_{viento}$ : Densidad de potencia promedio contenida en el viento.
- $\overline{P}^{Pr}$ : Potencia producida promedio por un aerogenerador con una curva de potencia asociada.
- $\overline{DP}_{j,k}$ : Densidad de potencia de un estado de viento  $j$ .
- $FP_{j,k}$ : Factor de planta de un estado de viento  $j$ .

- $\bar{t}_{j,k}$ : Tiempo de vida promedio de un estado de viento  $j$ .
- $T_{j,k}$ : Tiempo de permanencia de un estado de viento  $j$ .
- $\Delta\bar{\alpha}_{i,j,k}$ : Variación promedio del ángulo de un estado de viento  $j$ .
- $\bar{U}_{j,k}$ : Velocidad media de un estado de viento  $j$ .



# Introducción.

La energía eléctrica es un bien esencial para el óptimo desarrollo de las actividades sociales y productivas de la nación. Es por ello, que es fundamental garantizar su correcto suministro a lo largo y ancho del país.

Durante los próximos años la demanda de energía alrededor del mundo seguirá aumentando principalmente como resultado del crecimiento de la población y la acelerada industrialización [1]. Hoy día, esta demanda se satisface mayoritariamente con combustibles fósiles como el petróleo, carbón, combustóleo y gas natural que al quemarse emiten dióxido de carbono ( $CO_2$ ), un gas tóxico de efecto invernadero altamente contaminante y principal causante del calentamiento global y del cambio climático [2]; perjudicando la vida de miles de millones de personas alrededor del mundo [3]. Es por ello, que resulta imperante incentivar una transición energética que promueva el uso de tecnologías más sustentables y amigables con el medio ambiente.

Las energías renovables, tales como la eólica o la solar fotovoltaica, producen electricidad a través de recursos naturales que se renuevan constantemente, por lo que ofrecen una alternativa para reducir las emisiones contaminantes producto de la quema de combustibles fósiles en centrales eléctricas convencionales. Sin embargo, estos sistemas tienen sus limitaciones. El viento es estocástico (o variable), lo que significa que tanto su velocidad como la dirección del viento están cambiando constantemente a lo largo del tiempo, por lo que puede haber periodos donde no hay producción de electricidad, pudiendo provocar alteraciones en la calidad y suministro dentro del sistema eléctrico. Para resolver este problema se han propuesto mecanismos y modelos que permiten mejorar el aprovechamiento del recurso eólico. Estos permiten mejorar el diseño estructural de las aspas y el sistema de seguimiento del aerogenerador [4, 5], realizar mejor pronóstico meteorológico y predicción de viento [5, 6], construir

modelos de inteligencia artificial [6, 7, 8] y utilizar mejores sistemas de almacenamiento [9].

Para lidiar con la naturaleza aleatoria del viento, resulta conveniente utilizar modelos probabilísticos que permitan describir su dinámica a lo largo del tiempo. Un camino para hacerlo es utilizar el formalismo de las cadenas de Markov, que ya han sido utilizadas con anterioridad para el análisis de series temporales de viento [10, 11, 12] y han permitido proponer modelos para estudiar su dinámica y mejorar el aprovechamiento del recurso.

En este trabajo se propone un modelo, basado en el uso de cadenas de Markov, construidas a partir de métodos de aprendizaje automático, para describir y analizar la dinámica del viento y su acoplamiento con la demanda eléctrica. Específicamente, se introduce el concepto de estado viento-demanda, el cual permite hacer clasificaciones automáticas que describen la dinámica del viento respecto a la demanda eléctrica en una zona geográfica a lo largo del tiempo. Este concepto se aplicó para analizar la dinámica del Sistema Eléctrico Mexicano.

El trabajo se estructura como sigue: en el primer capítulo se realiza una introducción a la energía eólica abarcando los fundamentos de conversión, la evaluación de recurso, el análisis de series temporales y el estado actual en México y el mundo. Posteriormente, en el siguiente capítulo, se da una breve descripción del funcionamiento del Sistema Eléctrico Mexicano y las principales características de demanda eléctrica en el país. El tercer capítulo presenta una introducción a las herramientas de ciencia de datos, aprendizaje automático (*machine learning* en inglés), las cadenas de Markov usadas y su relación con lo que se puede definir como estados de viento. En el cuarto capítulo se desarrolla la metodología utilizada en el trabajo y se introducen los conceptos de estados de viento grupales y estados de viento-demanda. Los resultados y la discusión se presentan posteriormente. Finalmente, la conclusión y los trabajos a futuro cierran el trabajo.

# Planteamiento del problema.

El uso efectivo del recurso eólico generalmente se ve afectado por su naturaleza estocástica. Es por ello que para garantizar la calidad y el suministro de electricidad a lo largo y ancho del país es necesario conocer y analizar la dinámica del viento respecto a la demanda eléctrica a lo largo del tiempo. Bajo esta premisa, surge la necesidad de contar con un modelo que describa la dinámica viento-demanda y que ayude a mejorar el aprovechamiento del recurso eólico y su acoplamiento con la demanda eléctrica.

## 0.1. Objetivos.

Objetivo general:

- Desarrollar un modelo, utilizando técnicas de ciencia de datos y basado en el uso de cadenas de Markov, para describir y analizar la dinámica viento-demanda en el sistema eléctrico mexicano.

Objetivos específicos:

- Generar los estados de viento y las cadenas de Markov de viento de los siete sitios que conforman el Atlas Eólico Mexicano.
- Generar la cadena de Markov y la matriz de transición de los estados viento-demanda en el sistema eléctrico mexicano.
- Analizar la dinámica de los estados viento-demanda en el sistema eléctrico mexicano.
- Crear y compartir código de acceso libre del modelo generado.

## 0.2. Justificación.

Para mejorar el aprovechamiento del recurso eólico, es necesario generar un modelo probabilístico que describa la dinámica viento-demanda y que permita identificar los momentos en el tiempo donde el sistema podría verse afectado por falta de viento o los momentos de baja demanda y mucho viento donde la energía de éste podría almacenarse para su uso posterior. Este modelo brindará información para el diseño de procedimientos de control de redes extendidas en México.

## 0.3. Metodología.

Primeramente se recopilaron y prepararon los datos del AEM y del CENACE para su análisis. Utilizando los datos del AEM, se construyeron los estados de viento mediante la aplicación de un algoritmo de agrupamiento k-means (con  $k=4$ ) a los vectores instantáneos de velocidad. Esto permitió generar las cadenas de Markov del viento y, aplicando criterios de selección a los grupos obtenidos, seleccionar los mejores estados de cada sitio. Con esta información se definieron los estados de viento grupales y se construyó su cadena de Markov en el tiempo.

Por otro lado se construyeron los estados de demanda mediante la binarización de los valores de demanda eléctrica permitiendo definir, de forma análoga, los estados de demanda y construir su respectiva cadena de Markov.

Finalmente, la información de ambas cadenas permitió generar lo que denominamos como estados viento-demanda.

# Capítulo 1

## Energía eólica.

El viento es aire atmosférico en movimiento causado por las diferencias de presión y densidad en el mismo debidas, principalmente, al calentamiento desigual de la Tierra por la radiación solar. Debido a su movimiento, el viento contiene energía cinética (proporcional al cuadrado de su velocidad) que puede ser aprovechada para su conversión en trabajo mecánico o electricidad útil para el ser humano. El aprovechamiento de la energía cinética del viento, a través de diferentes mecanismos, es un proceso que inició desde la antigüedad con el uso de veleros y molinos de viento. [13, 14] citan que las primeras apariciones de los molinos de viento de eje vertical (impulsados por arrastre) datan de hace aproximadamente 2000 años, cuando Persas y Chinos los utilizaban para moler maíz y elevar agua. Posteriormente, los molinos de viento serían introducidos a la Europa Medieval, sin embargo ya para esta época como molinos con rotor de eje horizontal impulsados por fuerzas de sustentación, los cuales serían utilizados para bombeo de agua, molienda de granos, aserrado de madera, extracción de aceite de semillas y accionamiento de herramientas [14, 15, 13].

Con el paso de los años, el mecanismo de funcionamiento de los molinos de viento se fue sofisticando (mejores materiales, diseño estructural y de aspas, y sistema *yaw*) permitiendo un mejor aprovechamiento del viento.

Fue para finales del siglo XIX que a la energía del viento se le dio un uso más que sólo generar energía mecánica, y con la aparición de los generadores eléctricos, se dio origen al aerogenerador. En los aerogeneradores modernos, el proceso de conversión utiliza la fuerza aerodinámica de sustentación para producir un torque neto positivo en un eje giratorio, lo

que resulta primero en la producción de energía mecánica y luego en su transformación en electricidad en el generador [15].

Para 1888, se construyó el que podría considerarse el primer ejemplo notable de un aerogenerador (con una capacidad de 12 kW) que se instaló en Ohio, EUA [15, 16]. Los años posteriores a este evento se caracterizaron por el diseño de aerogeneradores de unos cuantos kW de potencia cuyo diseño de aspas era inspirado en las alas de los aviones. Para la década de los 80's, los avances en aeronáutica, meteorología, mecánica de fluidos e ingeniería mecánica y eléctrica marcaron el hito para la construcción de aerogeneradores cada vez más grandes (tanto en altura como en área de barrido) que pudieran producir mayor potencia. Hoy en 2021, existen aerogeneradores con una potencia nominal de hasta 14 MW, como el Haliade-X de General Electric o el SG 14-222 DD de Siemens-Gamesa [17, 18].

En la actualidad, la eólica es una de las fuentes de energía <sup>1</sup> más competitivas y rentables, con un costo nivelado de energía promedio mundial de USD 0.053/kWh y un costo de turbina promedio por debajo de los USD 850 por kW instalado para 2019 [19], representando (hasta 2020) el 9.4% de la capacidad de generación eléctrica mundial [20].

## 1.1. Fundamentos de energía eólica.

### 1.1.1. Energía contenida en el viento y extracción de potencia.

¿Cuánta energía (o potencia) hay en el viento?, y de esa energía, ¿cuánta puede ser aprovechada por un aerogenerador para producir electricidad?; esas son las preguntas que responderemos en esta sección. Primeramente, debemos introducir el concepto de potencia como la cantidad de energía utilizada, transferida o generada por unidad de tiempo en un proceso. En términos eólicos definiremos a la potencia eólica como la cantidad de energía (contenida en el viento) que atraviesa un área específica (el área de barrido de un aerogenerador) por unidad de tiempo. En otras palabras: la potencia eólica es el flujo (*flow rate* en inglés) de la energía cinética del viento.

Ahora tratemos de comprender por partes esta última definición para poder realizar

---

<sup>1</sup>Es el costo total de construir, operar y mantener una central eléctrica en valor actual neto dividido entre la energía total generada durante su vida útil.

una formulación matemática. Empezemos por considerar un elemento  $A$  (que representa el área de barrido del aerogenerador) por el que atraviesa un cierto volumen de viento  $V$ , con densidad  $\rho$ , con su respectiva velocidad asociada  $U$ , durante una unidad de tiempo  $dt$ . Entonces podemos definir el flujo (volumétrico) como:

$$\frac{dV}{dt} = AU = \frac{1}{\rho} \frac{dm}{dt}, \quad (1.1)$$

donde  $dm$  es la cantidad de masa infinitesimal que atraviesa en el tiempo  $dt$ . Arreglando los términos de 1.1, obtenemos la ecuación que describe el flujo másico:

$$\frac{dm}{dt} = \rho AU. \quad (1.2)$$

Ahora, dado que la energía cinética del viento está definida como:

$$K_E = \frac{1}{2} m U^2. \quad (1.3)$$

Y ya que nuestra definición de potencia eólica es: el flujo (*flow rate* en inglés) de la energía cinética del viento. Tenemos que:

$$P_{viento} = \frac{d(K_E)}{dt}. \quad (1.4)$$

Por lo que podemos definir a la potencia eólica en términos del flujo másico:

$$P_{viento} = \frac{d(K_E)}{dt} = \frac{1}{2} \frac{dm}{dt} U^2. \quad (1.5)$$

Finalmente, si sustituimos 1.2 en 1.5 obtenemos que la potencia eólica contenida en el viento ( $P_{viento}$ ), en función del área de barrido del aerogenerador  $A$ , la velocidad del viento  $U$  y la densidad del viento  $\rho$ , es igual a:

$$P_{viento} = \frac{1}{2} \rho A U^3. \quad (1.6)$$

Es por esto que precisamente se construyen aerogeneradores cada vez más grandes (en altura

y largo de aspas) de modo que puedan aprovechar velocidades de viento más altas y tengan un área de barrido mayor, resultando en una mayor potencia.

Ya que conocemos cuál es la potencia disponible en el viento, la pregunta natural es: ¿cuánta de esa potencia puede ser aprovechada por el aerogenerador para producir electricidad?. Para responder a esta pregunta, recordemos que un aerogenerador es básicamente una máquina que extrae energía cinética del viento. Por lo que la energía extraída por el aerogenerador es la diferencia entre la energía cinética del viento justo antes (con velocidad  $U_1$ ) y justo después (con velocidad  $U_2$ ) de pasar a través del aerogenerador.

$$K_{aer} = \frac{1}{2}mU_1^2 - \frac{1}{2}mU_2^2. \quad (1.7)$$

Por lo que siguiendo la misma lógica que la usada para obtener la potencia disponible en el viento; calculamos la potencia extraída del viento por el aerogenerador ( $P_{ext}$ ) como:

$$P_{ext} = \frac{1}{2} \frac{dm}{dt} U_1^2 - \frac{1}{2} \frac{dm}{dt} U_2^2 = \frac{1}{2} \rho A U_{aer} (U_1^2 - U_2^2). \quad (1.8)$$

Donde el término  $U_{aer}$  es la velocidad del aire justo en el aerogenerador cuyo valor, debido a la conservación de la masa y de la energía [15, 13], es igual a:

$$U_{aer} = \frac{U_1 + U_2}{2}. \quad (1.9)$$

Esta ecuación nos indica que no todo el viento atraviesa realmente al aerogenerador, ya que para que así fuera, (debido a la conservación de la masa y la energía)  $U_{aer}$  tendría que ser igual a  $U_1$ , lo cual según 1.9 implicaría que  $U_2 = U_1$ , lo cual sólo sería posible si no existiera aerogenerador alguno. Dado que ( $U_2$ ) no puede ser igual a 0 [21], el aerogenerador no puede extraer el 100% de la energía cinética del viento. De esta forma, si  $U_2$  es muy cercana a  $U_1$  el aerogenerador no extraerá mucha energía (tal como lo indica la Ecuación (1.7)), sin embargo si  $U_2$  es mucho menor que  $U_1$  no mucho viento atravesará realmente al aerogenerador [22] (tal como lo indica la Ecuación (1.9)).

Esto indica dos posibles situaciones extremas; en el primer caso la velocidad  $U_2$  es muy cercana a  $U_1$  y por ende a pesar de tener mucho viento atravesando al aerogenerador no se



extraerá mucha energía cinética del mismo. Por otro lado, si  $U_2$  es mucho menor que  $U_1$ , a pesar de que la energía extraída se acerque al 100%, tal extracción será de poco viento.

En resumen, o tienes mucho viento atravesando al aerogenerador pero poca extracción, o mucha extracción pero de poco viento. Esto nos hace pensar que debe existir un cierto valor óptimo de  $U_2$  para el cual el aerogenerador, teóricamente, trabaje a su máxima eficiencia y por ende aproveche la mayor potencia disponible en el viento. Y así es, de hecho tal valor puede ser obtenido usando las ecuaciones 1.8 y 1.9, y a pesar de que aquí no se demostrará su derivación matemática, se ha encontrado [15, 13, 21, 22] que:

$$U_2 = \frac{U_1}{3} \quad (1.10)$$

Este valor implica, según la Ecuación (1.7), que la energía cinética extraída por el aerogenerador es el 88.88% (8/9) de la energía contenida en el viento. Así mismo, implica, según la Ecuación (1.9), que estará extrayendo tal energía del 66.66% (2/3) del volumen de viento. Por lo tanto, el aerogenerador estará extrayendo 8/9 de la energía contenida en 2/3 del volumen de viento total disponible. De esta forma, al expresarlo de forma matemática encontramos que, teóricamente, la máxima cantidad de potencia que un aerogenerador puede extraer del viento es [22, 15, 13]:

$$P_{ext} = \frac{8}{9} * \frac{2}{3} * P = \frac{16}{27}P \approx 0.5926P = 0.5926 * \frac{1}{2}\rho AU^3 \quad (1.11)$$

Donde el término  $\frac{16}{27} \approx 0.5926$ , conocido como el Límite de Betz o máximo coeficiente de potencia ( $C_{pmax}$ ), representa la máxima eficiencia teórica posible que puede alcanzar un aerogenerador.

Para valores de  $U_2$  diferentes de  $U_1/3$  el valor del coeficiente de potencia ( $C_p$ ) es menor, y por ende la eficiencia con la cual extrae energía el aerogenerador también es menor. Dado que en la práctica no es posible asegurar que  $U_2 = U_1/3$ , el valor de  $C_p$  variará dependiendo el valor que tenga  $U_2$  para cada aerogenerador en condiciones específicas de diseño y operación.

De esta forma, podemos generalizar el concepto de  $C_p$  como la eficiencia de un aerogenerador para extraer la energía cinética del viento, por lo que la potencia extraída por el

mismo, en términos de su factor de potencia, puede ser escrita como:

$$P_{ext} = \frac{1}{2}\rho AU^3 C_p \quad (1.12)$$

En los grandes aerogeneradores de eje horizontal actuales el valor de  $C_p$  ronda entre 45 % y 50 % [13].

### 1.1.2. Tecnología de aerogeneradores.

Ahora que conocemos los fundamentos sobre la energía contenida en el viento y sobre la potencia que los aerogeneradores pueden aprovechar de éste, nos preguntamos ¿cómo es que estas máquinas (los aerogeneradores) utilizan tal energía para producir electricidad? Anteriormente habíamos dicho que los aerogeneradores modernos hacen uso de la fuerza de sustentación para producir un torque neto positivo en un eje giratorio, con lo cual se produce energía mecánica y posteriormente electricidad en el generador. Es decir, se tiene un proceso de conversión, el cual consta de diversas etapas y de diversos componentes. En [15] se enlistan los principales componentes de un aerogenerador de eje horizontal convencional:

- El rotor, compuesto por las palas y el cubo de soporte.
- El tren de transmisión, que incluye las partes giratorias del aerogenerador (excluyendo el rotor); suele estar formado por la flecha, caja de cambios, acoplamiento, un freno mecánico y el generador eléctrico.
- La góndola y el bastidor principal, que incluye la carcasa del aerogenerador, la bancada y el sistema *yaw* (sistema de orientación).
- La torre y los cimientos.
- Sistema de control.
- El resto del sistema eléctrico, incluidos los cables, los interruptores, los transformadores y, posiblemente, los convertidores electrónicos de potencia.

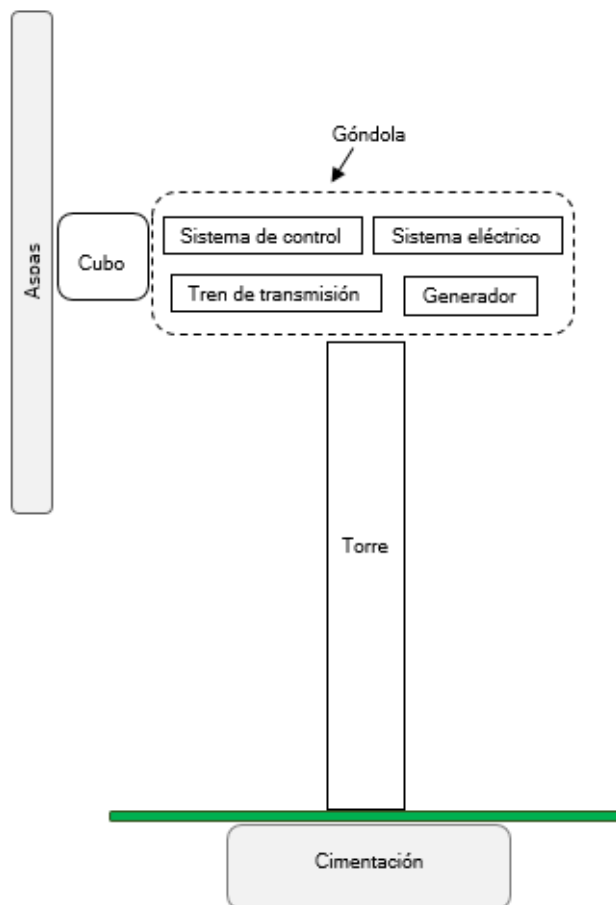


Figura 1.1: Diagrama esquemático de las partes de un aerogenerador. Imagen propia.

En primera instancia el viento golpea las aspas del aerogenerador las cuales, al estar diseñadas con un perfil aerodinámico, producen una fuerza de sustentación que provoca que éstas giren produciendo un torque neto positivo en el rotor. Este último se encuentra acoplado a una caja de cambios que tiene el propósito de incrementar su velocidad de giro (de bajas revoluciones por minuto y alto torque) a un valor óptimo para hacer girar el generador eléctrico (500-3000 rpm) y producir electricidad. La electricidad producida es transmitida usando cables que atraviesan toda la torre hasta llegar a la base donde se sitúa un transformador eléctrico que eleva su voltaje para su transmisión a la red eléctrica.

Dado que el viento cambia de dirección constantemente, para poder capturar la mayor cantidad de energía posible el eje del rotor debe de estar correctamente orientado (normal a la dirección del viento). Esto se logra con el sistema *yaw*, que con el uso de sensores, permite girar la góndola en su propio eje y por ende alinear el eje del rotor acorde a la dirección del

viento.

### Curva de potencia.

Como se mencionó con anterioridad, la potencia que extrae el rotor de un aerogenerador del viento está dada en función de su coeficiente de potencia ( $C_p$ ) según la Ecuación (1.12). Sin embargo, ésta es la potencia que se extrae del viento, mas no la que el aerogenerador produce en forma de electricidad. Dado que todas las máquinas electromecánicas tienen cierta eficiencia (no pueden convertir el 100 % de la energía mecánica que reciben en energía eléctrica), no es posible que la potencia eléctrica producida por el aerogenerador sea el 100 % de la energía que extrae del viento. Por ende a la Ecuación (1.12) se le deben añadir ciertos términos que hagan referencia a la eficiencia de los equipos mecánicos y eléctricos involucrados en el proceso de conversión de energía.

De esta forma, si llamamos  $\eta_{fle}$  a la eficiencia de la flecha,  $\eta_{eng}$  a la eficiencia de la caja de engranes y  $\eta_{gen}$  a la eficiencia del generador eléctrico; tenemos que la potencia eléctrica producida por un aerogenerador queda escrita como:

$$P_{producida} = P_{ext}\eta_{fle}\eta_{eng}\eta_{gen} = \frac{1}{2}\rho AU^3 C_p \eta_{overall}. \quad (1.13)$$

Donde  $\eta_{overall}$  representa la eficiencia general del aerogenerador.

Observamos de la Ecuación (1.13) que la potencia eléctrica producida por el aerogenerador está en función de la velocidad del viento, de esta forma si la velocidad del viento varía la potencia producida también lo hará. La curva de potencia de un aerogenerador establece la relación particular entre la velocidad de viento y la potencia eléctrica producida por el mismo, por lo que cada modelo de aerogenerador tiene una curva de potencia característica asociada, determinada por el fabricante.

En la Figura 1.1.2 se presenta la curva de potencia de un aerogenerador típico. La curva de potencia de cualquier aerogenerador se caracteriza por tres regiones en la velocidad del viento: velocidad de arranque, velocidad de corte y velocidad nominal. A velocidades por debajo de la velocidad de arranque el aerogenerador no producirá potencia alguna, ya que no existe torque suficiente para hacer girar el rotor. Alcanzada la velocidad de arranque el aerogenerador

empieza a girar y producir electricidad. Conforme aumenta la velocidad del viento también lo hace la potencia producida (siguiendo una relación cúbica) hasta que se aproxima a la velocidad nominal, la cual es un rango de velocidades, en la que el aerogenerador se mantiene trabajando a su máxima potencia o potencia nominal. Sin embargo, el aerogenerador no puede mantenerse girando a velocidades muy altas, por cuestiones de seguridad y de desgaste, por lo que se establece una velocidad de corte en la que el aerogenerador es parado (por lo que deja de producir potencia).

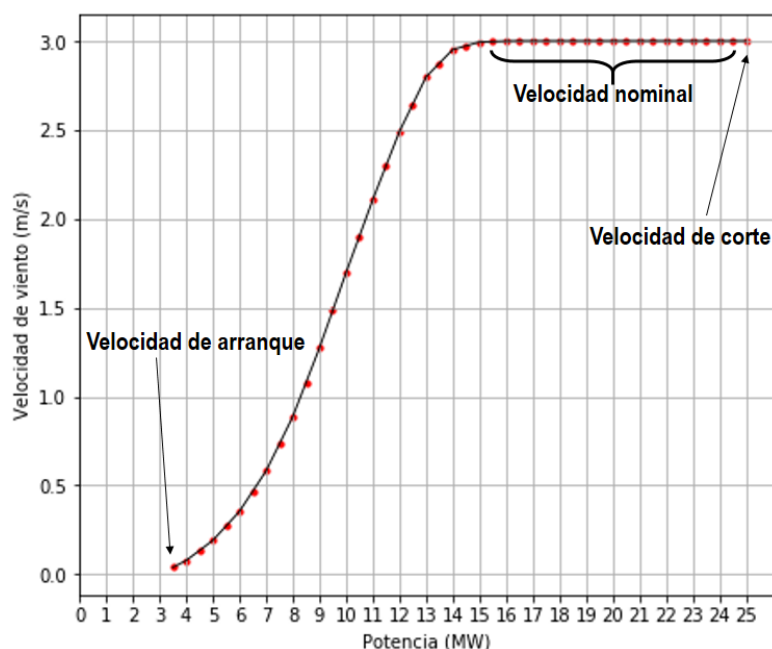


Figura 1.2: Curva de potencia VestasV90/3000. Imagen propia con datos extraídos de [23]

Tal como se estableció con anterioridad, cada modelo de aerogenerador tiene una curva de potencia característica, por lo que la potencia nominal, velocidad de arranque, velocidad de corte y en general la potencia producida a diferentes velocidades variarán dependiendo el modelo del mismo.

## 1.2. Evaluación de recurso eólico.

Los patrones de calentamiento diferencial de la superficie terrestre, las fuerzas dinámicas debidas a la rotación de la Tierra, las fuerzas de inercia, la fricción del viento en diversas

superficies, así como otros procesos térmicos como la evaporación, la precipitación, las nubes, la sombra y las variaciones de la absorción de la radiación en la superficie, aparecen en diferentes escalas espaciales y temporales que dan lugar a la existencia de diversos vientos [15, 13, 24]. Estos pueden clasificarse, según su escala espacial y sus mecanismos físicos de generación, en vientos de escala planetaria (que incluyen los flujos zonales sostenidos del orden de 10,000 km, tales como las corrientes de chorro y los vientos alisos), escala sinóptica, vientos regionales de mesoescala (que incluyen las circulaciones orográficas y las circulaciones inducidas térmicamente, en el orden de 10-100 km) y vientos locales de microescala (del orden de 100-1000 m, tales como los generados por la orografía y topografía características del terreno) [13]. Dada una locación, la disponibilidad de recurso eólico varía en diversas escalas temporales: anuales (variaciones que dependen del mes o la estación del año), diurnas (variaciones a lo largo de 24 horas) y de corto plazo (variaciones de corta duración tales como ráfagas de viento y turbulencia). Es debido a esta variación espacial y temporal del viento, que para evaluar/estimar/caracterizar la disponibilidad de recurso eólico en un espacio y momento concretos es imprescindible llevar a cabo un programa de adquisición y análisis de datos de viento. Estos programas incluyen el uso de equipos como torres meteorológicas instrumentadas con anemómetros, veletas y sensores de temperatura (así como dispositivos de teledetección tales como el *lidar* o *sodar*) con la finalidad de medir y registrar información meteorológica que permita caracterizar el recurso eólico del sitio de interés.

### 1.2.1. Adquisición de datos de viento.

El primer paso para realizar una evaluación de recurso eólico en una región específica es la adquisición de datos meteorológicos del emplazamiento (específicamente rapidez y dirección de viento; aunque generalmente también se incluyen la temperatura, densidad del aire, radiación solar, presión barométrica y humedad relativa) a diferentes alturas durante por lo menos un año (dos o más años provee información más confiable). Todos los parámetros deben ser medidos una vez cada uno o dos segundos y registrados como promedios, desviaciones estándar y valores máximos y mínimos en intervalos de 10 minutos [25, 26]. El almacenamiento de éstos debe ser en serie y designado por un sello de fecha, hora y minuto correspondiente. Posteriormente, estos datos deben ser sometidos a validación, donde

se examinan para detectar valores faltantes, sospechosos o potencialmente erróneos, con la finalidad de dejarlos listos para su análisis. De esta forma, tendremos una serie de tiempo con registros diez-minutales de la velocidad y dirección de viento promedio en cada intervalo, de los que es posible construir histogramas y series temporales que nos permitan visualizar su distribución de frecuencias y su variación temporal.

### 1.2.2. Análisis de series de viento.

Una vez que los datos han sido adquiridos y validados se procede a su análisis. Tal análisis permite obtener información (tal como la densidad de potencia eólica promedio, la potencia producida promedio, la rosa de los vientos, la rapidez promedio, el exponente de cizalladura vertical del viento y distribuciones de frecuencia de rapidez y dirección de viento) con la finalidad de caracterizar el recurso eólico del sitio. A continuación se describen brevemente los principales parámetros que permiten la caracterización del recurso eólico.

#### Distribución de frecuencias de rapidez de viento.

La distribución de frecuencias de rapidez de viento es posiblemente la estadística de mayor importancia para el análisis de recurso eólico. Clasifica a los datos de la serie temporal dentro de rangos o intervalos (generalmente de 0,5 m/s ó 1 m/s), permitiendo conocer el número de ocurrencias en cada uno de ellos. La distribución de estas ocurrencias puede ser visualizada en lo que se conoce como histograma. Es decir, para construir un histograma se debe dividir todo el rango de valores (conjunto de datos) en un número finito de intervalos (con un tamaño/anchura/amplitud de 0,5 m/s ó 1 m/s generalmente), y luego contar cuántos valores caen dentro de cada uno de estos intervalos. Sin embargo, los histogramas -que muestran la distribución de la rapidez del viento- no toman en cuenta los efectos de la dirección del viento, por lo que podríamos decir que no contienen toda la información que permita describir la física del sitio.

Por otro lado, resulta conveniente establecer una función matemática continua que describa la probabilidad de ocurrencia de cierta rapidez de viento en un intervalo de rapidez

específico: la función de densidad de probabilidad (PDF). De esta forma, la PDF puede utilizarse para determinar la probabilidad de que el viento sople dentro de un cierto rango de rapidez.

En el análisis y caracterización de recurso eólico, la PDF más utilizada es la función Weibull de dos parámetros [27, 15, 26, 13, 28], denominados factor de escala ( $c$ ) y factor de forma ( $k$ ). Ambos parámetros están definidos en función de la velocidad media ( $\bar{U}$ ) y de la desviación estándar ( $\sigma_u$ ) del conjunto de datos.

$$k = \left( \frac{\sigma_u}{\bar{U}} \right)^{-1.086}, \quad c = \frac{\bar{U}}{\Gamma(1 + 1/k)}$$

Conocidos los parámetros  $c$  y  $k$ , la PDF Weibull se define como:

$$PDF = \left( \frac{k}{c} \right) \left( \frac{U}{c} \right)^{k-1} \exp \left\{ - \left( \frac{U}{c} \right)^k \right\} \quad (1.14)$$

Sin embargo, a pesar del buen ajuste que la función de densidad de probabilidad Weibull presenta para la mayoría de los sitios, ésta no puede representar todos los regímenes de viento que se encuentran en la naturaleza [27], por lo que otras PDF's pueden de ser propuestas y utilizadas para el análisis.

### Densidad de potencia eólica promedio.

Entiéndase la densidad de potencia eólica promedio como la potencia promedio contenida en el viento por unidad de área en un periodo de tiempo determinado. Dada una serie temporal  $k$  de un sitio que contiene  $m$  registros  $i$  diez-minutales de la rapidez de viento es posible calcular la densidad de potencia promedio contenida en el viento  $\overline{DP}_{viento}$  de la siguiente forma:

$$\overline{DP}_{viento} = \frac{\overline{P}_{viento}}{A} = \frac{1}{2m} \sum_{i=1}^{i=m} (\rho_i)(v_i^3) \quad (1.15)$$

Donde  $v_i$  es la rapidez y  $\rho_i$  es la densidad de viento para cada una de las  $m$  estampas temporales  $i$ .



**Potencia producida promedio.**

Tal como se ha establecido con anterioridad, la potencia producida por un aerogenerador es función de la rapidez de viento y está determinada por su curva de potencia característica. Dado que la velocidad de viento es variable en el tiempo, se espera que la potencia producida por el aerogenerador también varíe.

De esta forma, dada una serie temporal  $k$  de un sitio que contiene  $m$  registros  $i$  diez-minutales de velocidad de viento, la potencia producida promedio por un aerogenerador con una curva de potencia  $\beta$  asociada, está dada como:

$$\overline{P}^{Pr} = \frac{1}{m} \sum_{i=1}^{i=m} \beta(v_i) \quad (1.16)$$

Donde  $\beta(v_i)$  representa la potencia producida para cada una de las  $m$  estampas temporales  $i$ . Entiéndase a la curva de potencia  $\beta()$  como una función que transforma a la velocidad del viento  $v_i$  en la potencia generada por el aerogenerador en esa estampa temporal.

**Factor de planta:**

Dado que un aerogenerador no puede estar siempre trabajando a su potencia nominal, debido principalmente a la variabilidad en la velocidad del viento así como los paros necesarios por mantenimiento o seguridad, se establece un término que relaciona la potencia que realmente produce el aerogenerador en un periodo determinado de tiempo y la potencia que produciría si trabajara todo ese mismo periodo a su potencia nominal. El factor de planta, está entonces definido como:

$$FP = \frac{\overline{P}^{Pr} t}{P_{nominal} t} = \frac{E_{actual}}{E_{nominal}} \quad (1.17)$$

Donde  $\overline{P}^{Pr}$  es la potencia producida promedio por el aerogenerador durante el periodo de tiempo establecido y  $P_{nominal}$  es la potencia nominal del aerogenerador (la cual es un valor numérico fijo). Mientras mayor sea el factor de planta del aerogenerador mayor será la conversión de energía en el viento a electricidad. Por lo que al momento de instalar alguna tecnología eólica siempre se busca que el factor de planta sea lo más alto posible.

### Exponente de cizalladura vertical del viento.

Es bien sabido que la rapidez del viento varia con la altura (debido a factores tales como la orografía, la topografía, las características particulares del terreno como la rugosidad, la temperatura, la estación del año, la hora del día, entre otros). El exponente de cizalladura del viento ( $\alpha$ ) se refiere a la razón de cambio de la rapidez horizontal del viento con respecto a la altura, por lo que si se tienen registros de la rapidez de viento a diferentes alturas es posible calcular el valor de  $\alpha$  usando la siguiente relación empírica conocida como la ley de potencia [15]:

$$\frac{u(z)}{u(z_{ref})} = \left( \frac{z}{z_{ref}} \right)^\alpha \rightarrow \alpha = \frac{\log\left(\frac{u(z)}{u(z_{ref})}\right)}{\log\left(\frac{z}{z_{ref}}\right)} \quad (1.18)$$

Donde  $u(z)$  es la velocidad del viento a la altura  $z$  y  $u(z_{ref})$  es la velocidad del viento de referencia a la altura  $z_{ref}$ . Para cada sitio el valor  $\alpha$  es único, debido a sus características específicas, y en la práctica resulta ser muy variable.

## 1.3. Energía eólica en México.

México, debido a su localización geográfica y sus características orográficas y meteorológicas es un país privilegiado en recurso eólico, con un potencial instalable mayor a 71,000 MW, según datos del Atlas Eólico Mexicano [29]. El país cuenta con regiones con potencial eólico "excelente" y "muy bueno", tales como La Ventosa, Oaxaca, La Rumorosa y Tamaulipas donde la velocidad promedio del viento ronda entre los 8 m/s y 7 m/s [30]. En la Figura 1.3 se muestra el mapa nacional de potencial de recurso eólico según la velocidad del viento a 80 m de altura, obtenido del Inventario Nacional de Energías Limpias 2018 [30].




Figura 1.3: Velocidad de viento a 80m. Imagen extraída de [30]

### 1.3.1. Atlas eólico mexicano.

El Atlas Eólico Mexicano (AEM) es un proyecto coordinado por el Instituto Nacional de Electricidad y Energías Limpias (INEEL) en colaboración con la Universidad Nacional Autónoma de México (UNAM) y la Universidad Tecnológica de Dinamarca (DTU), que tiene como objetivo realizar un mapeo del potencial eoloelectrico del país. Para ello fueron instaladas 7 estaciones meteorológicas en zonas estratégicas (de alto potencial eólico y cercanas a redes de transmisión) de la República Mexicana: Yucatán, Oaxaca, Puebla, Jalisco, Tamaulipas, Chihuahua y Baja California; que se encargan de recopilar la velocidad y dirección de viento promedios (además de otros parámetros que incluyen la temperatura, radiación solar, densidad del aire, presión barométrica y humedad relativa) en intervalos de 10 minutos a 20, 40, 60 y 80 *m*. Todos los datos generados son almacenados en bases de datos de acceso libre.

En este trabajo se utilizarán estas bases de datos y se analizarán las series temporales generadas durante el año 2018 correspondientes a las velocidades (a 80 *m*) y direcciones de viento (a 78 *m*) de altura de las 7 estaciones meteorológicas. En la Figura 1.4 se muestra

la localización, marcadas con un punto negro, de las 7 estaciones meteorológicas; 1: La Rumorosa (Baja California), 2: Mérida (Yucatán), 3: Ciudad Cuauhtémoc (Chihuahua), 4: CERTE/La Ventosa (Oaxaca), 5: Ojuelos (Jalisco), 6: San Fernando (Tamaulipas) y 7: Tepexi (Puebla). Así mismo, de color rojo se muestran las centrales eólicas en operación y de azul las centrales eólicas en fase de prueba o construcción hasta el 2017.

En el siguiente capítulo se presentará una descripción de la red eléctrica en México, así como las características de la demanda de energía documentada.

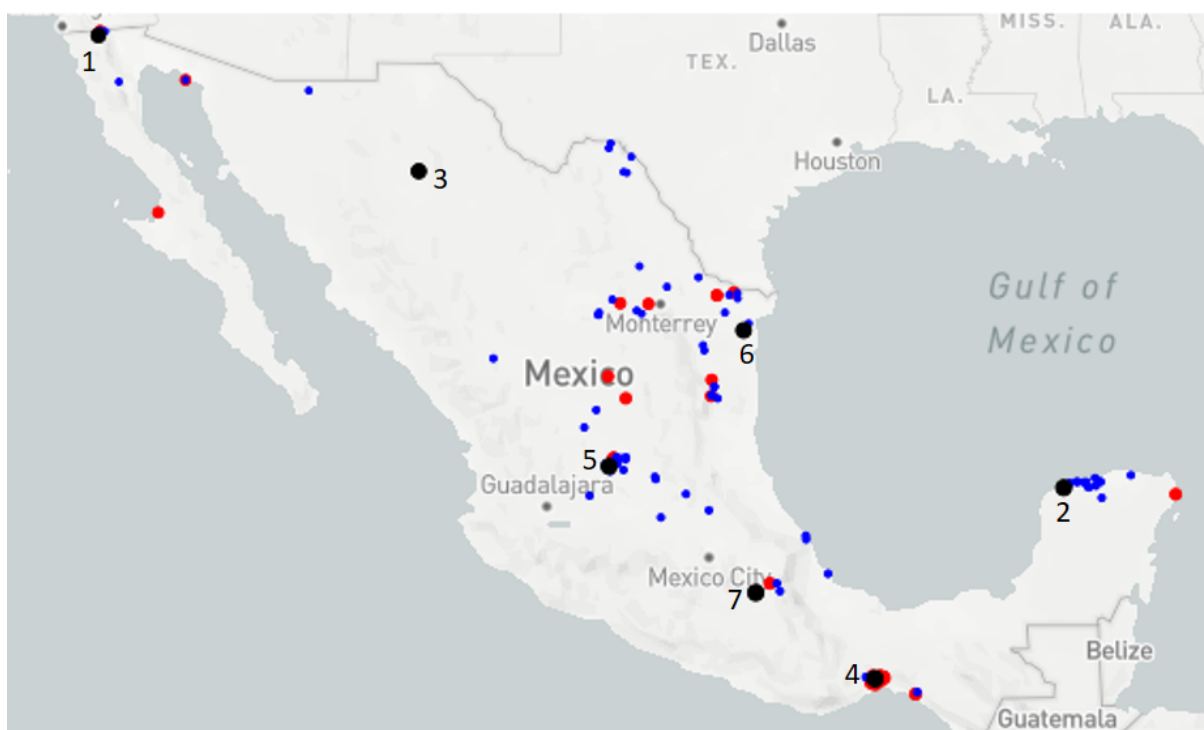


Figura 1.4: Estaciones meteorológicas del AEM. Imagen propia con datos de [29, 30]

# Capítulo 2

## Red y demanda eléctrica.

Hasta 2020, las energías renovables representaban el 36 % de la capacidad de generación eléctrica instalada a nivel mundial, con un total de poco más de 2 799 GW [20], siendo la hidroeléctrica la de mayor aporte. Sin embargo, debido a su naturaleza variable, en 2019 produjeron únicamente el 27.3 % de la generación eléctrica mundial [31]. Por su parte, la capacidad instalada de energía eólica representó un total acumulado de 733 GW para ese mismo año [20], representando aproximadamente 26.2 % de la capacidad renovable y poco más de 9.4 % de la capacidad eléctrica total.

En México, según datos del Programa de Desarrollo del Sistema Eléctrico Nacional (PRO-DESEN) [32] para octubre del 2020, las energías renovables (considerando las centrales en prueba) representaron poco más del 31 % de los 86,034 MW instalados para satisfacer la demanda eléctrica nacional, donde la mayor parte de la capacidad instalada es por medio de centrales de ciclo combinado (39.5 %) y centrales térmicas convencionales (13.8 %). Por su parte, la eólica, para el mismo periodo, con un total de 6,977 MW instalados representó el 8.1 % de la capacidad de generación eléctrica nacional. Además, según [33] (en escenario acelerado) se espera tener un incremento de capacidad instalada de 16,697 MW para diciembre del 2024, donde la energía eólica podría representar el 14.81 %, es decir, 2,473 MW. Con lo que para este periodo se tendría una capacidad instalada de 9,450 MW eólicos.

## 2.1. Red eléctrica.

La energía eléctrica es un bien esencial para el óptimo desarrollo de las actividades básicas sociales y productivas de la nación. Es por ello, que es fundamental garantizar su correcto suministro a todos y cada uno de los seis sectores del Estado: residencial, agropecuario, industria, comercial, servicios y transporte [32].

La red eléctrica es el sistema encargado de suministrar electricidad acorde a su demanda (recordemos que la electricidad es generada conforme es demandada), desde el punto de generación hasta el punto de consumo, permitiendo satisfacer las necesidades diarias de los usuarios. Estos sistemas han pasado de ser simples y pequeños diseños locales a sistemas complejos que se extienden por miles de kilómetros conectando a millones de personas.

En general, hoy día una red eléctrica convencional está compuesta por tres sectores principales: generación, transmisión y distribución de electricidad. La generación consiste en la conversión de energía mecánica (que puede provenir del viento o de la quema de combustibles fósiles) en eléctrica mediante el uso de una turbina y un generador (a excepción de la energía fotovoltaica que usa el efecto fotoeléctrico). La electricidad generada pasa por un transformador, el cual eleva su voltaje con la finalidad de minimizar pérdidas durante su transmisión a largas distancias. De esta forma, la electricidad viaja cientos de kilómetros a este elevado voltaje hasta que llega a la subestación eléctrica. La subestación eléctrica se encarga de disminuir el voltaje de la electricidad para que ésta pueda ser distribuida a lo largo de líneas de distribución, donde su voltaje es reducido una vez más para que finalmente pueda ser utilizada por los consumidores (Figura 2.1). En México, el suministro de electricidad a lo largo y ancho del país se da gracias al Sistema Eléctrico Nacional (SEN).




Figura 2.1: Dibujo simplificado del recorrido de la electricidad desde el punto de generación hasta el de consumo.

### 2.1.1. Sistema Eléctrico Nacional (SEN).

El SEN está conformado por diez regiones de control, tal como se muestra en la Figura 2.2. Éstas se encuentran a su vez divididas en cuatro sistemas eléctricos, a saber, entre aquellas regiones que forman parte del Sistema Interconectado Nacional (SIN) y las que no. Las regiones que forma el SIN son: Central, Oriental, Occidental, Noroeste, Norte, Noreste y Peninsular; y entre ellas se tiene un intercambio continuo de energía que permite mantener un funcionamiento óptimo del sistema.

Por otra parte, la región de Baja California, opera interconectado a la red eléctrica de la región Oeste de EUA-Western Electricity Coordinating Council, mientras que las 2 regiones restantes (Baja California Sur y Mulegé) se encuentran eléctricamente aisladas entre sí y del SIN.



Figura 2.2: Regiones del Sistema Eléctrico Nacional. Imagen tomada de [33].

Así mismo, el SEN está constituido por redes eléctricas en diferente niveles de tensión [33]:

- **Red Nacional de Transmisión (RNT):** Sistema integrado por las redes eléctricas que se utilizan para transportar energía a las Redes Generales de Distribución y a los usuarios que por las características de sus instalaciones lo requieran, así como las

interconexiones a los sistemas eléctricos extranjeros que determine la Secretaría de Energía. Incluye las tensiones iguales o mayores a 69 kV. Al 31 de agosto del 2020, se tenían 109,002 km de líneas.

- **Redes Generales de Distribución (RGD):** Redes eléctricas de baja (menores o iguales a 1 kV) y media tensión (mayores a 1 kV y menores a o iguales a 35 V) que se utilizan para distribuir energía eléctrica al público en general.
- **Redes Particulares:** Redes eléctricas que no forman parte de la RNT o de las RGD.

## 2.2. Demanda eléctrica

En 2019, el consumo de electricidad bruto nacional (conformado por las ventas de energía a través del Suministro Básico, Suministro Calificado, Suministro de Último Recurso, el auto abastecimiento remoto, la importación, las pérdidas de energía eléctrica, los usos propios de los Transportistas, Distribuidores y Generadores) del Sistema Eléctrico Nacional fue de 324,927 GWh, de los cuales el 94.58 % correspondió al SIN, donde las regiones de control de Occidente y Central fueron las de mayor participación con 68,107 GWh y 61,293 GWh respectivamente [32]. Así mismo, en los últimos 10 años (2010 — 2019) el consumo bruto del SEN tuvo una tasa media de crecimiento anual (tmca) de 2.9 % y se estima que tenga un crecimiento de entre el 2.3 % y 3.2 % dependiendo de diferentes escenarios [33].

Para poder analizar el comportamiento de la demanda eléctrica nacional a lo largo del tiempo es necesario realizar y reportar constantes estimaciones, registros y pronóstico de datos, así como monitorear en tiempo real la generación, la demanda y el consumo de energía eléctrica que se registran en el sistema eléctrico mexicano. En específico, es el Centro Nacional de Control de Energía (CENACE) el encargado de esta ardua tarea ejerciendo el control operativo del Sistema Eléctrico Nacional. De esta forma, el CENACE realiza la estimación de la demanda real del sistema, es decir, estima la energía horaria [MWh/h] utilizada correspondiente al consumo neto (generación neta inyectada al sistema en cada hora, menos la energía de exportación) en el Sistema Eléctrico Nacional en un día de operación.

En la Figura 2.3 se muestra el comportamiento de la demanda horaria de energía del SIN



a lo largo del 2018. De rojo se muestra el valor promedio.




Figura 2.3: Demanda horaria de energía, 2018. Imagen propia con datos de [34]

Hay que tener en cuenta que el consumo bruto (al igual que la demanda) del SEN presenta un comportamiento diferenciado a lo largo de un día, una semana, o un año. A lo largo del año, debido principalmente a las temperaturas extremas se tiene una estacionalidad donde de mayo a octubre se presenta el 54.3% del consumo anual, y durante los demás meses se tiene el 45.7% restante. A lo largo de los días de una semana, la demanda de energía es bastante similar de lunes a viernes. Es menor durante el fin de semana, especialmente el domingo, como se observa en la Figura 2.4.




Figura 2.4: Demanda de energía promedio por día, 2018. Imagen propia con datos de [34]

A lo largo de las horas de un día, la demanda de electricidad tiene un comportamiento casi cosenoidal (Figura 2.5). Durante la madrugada y la mañana de las 02 a las 08 horas se tiene la menor demanda, alcanzando el mínimo alrededor de las 05. Durante la tarde-noche desde las 14 hasta las 23 horas se tiene la mayor demanda, donde el valor promedio máximo se da a las 21 horas.




Figura 2.5: Demanda de energía promedio por hora, 2018. Imagen propia con datos de [34]

Estas características generales de la demanda proveen una información necesaria para estudiar la cuestión de cómo se relaciona el consumo de energía con la disponibilidad de recurso eólico y qué propiedades cualitativas y cuantitativas tendrá su dinámica. En la siguiente sección se plantean los conceptos necesarios proveniente de la ciencia de datos que se utilizarán para hacer tal análisis.

# Capítulo 3

## Datos, aleatoriedad y estados de viento.

### 3.1. ¿Qué es la ciencia de datos?.

Hoy en día los archivos digitales con datos están en todas partes. Cada segundo se generan cantidades masivas de datos provenientes de todas partes y lugares diferentes del mundo y del exterior (como podrían ser datos satelitales) que contienen todo tipo de información. Tal información, si es extraída y analizada de la forma apropiada, puede servir para tomar decisiones en beneficio de la sociedad. Para realizar tal extracción y análisis de la información contenida en los datos se requiere de un campo interdisciplinario (que incluye tener conocimiento del área específica de estudio, estadística, probabilidad, minería de datos, *machine learning*, cálculo, álgebra, ciencias de la computación, bases de datos e informática [35, 36]) denominado ciencia de datos.

La ciencia de datos permite entonces darles un valor real, al extraer la información contenida en ellos. Tal valor puede ser proporcionado en forma de predicciones, decisiones automatizadas, modelos aprendidos a partir de los datos o cualquier tipo de visualización de datos que proporcione información [35] que sirva para tomar decisiones en beneficio de una sociedad, empresa, grupo, individuo o institución.

### 3.1.1. El proceso de la ciencia de datos.

La ciencia de datos incluye entender el problema a resolver; la extracción, procesamiento, exploración, transformación, almacenamiento y la recuperación de datos; las infraestructuras informáticas, los distintos tipos de minería y aprendizaje; la presentación de explicaciones y predicciones, y el uso de los resultados; todo ello siempre teniendo en cuenta los aspectos éticos, sociales, legales y empresariales [35, 36, 37].

Para llevar a cabo el proceso de la ciencia de datos, el científico de datos necesita una metodología fundamental, independiente de las tecnologías, los volúmenes de datos o los enfoques involucrados, que le indique cómo proceder para obtener los resultados o soluciones al problema presentado. John Rollins, del International Business Machines Corporation (IBM), se encargó de desarrollar una metodología -de naturaleza iterativa- fundamental de la ciencia de datos. Esta metodología tiene como base las metodologías reconocidas para la minería de datos (CRISP-DM), añadiendo énfasis en varias de las nuevas prácticas de la ciencia de datos.

En la Figura 3.1 se presenta la metodología, conformada por 10 fases, de la ciencia de datos desarrollada por John Rollins [37].

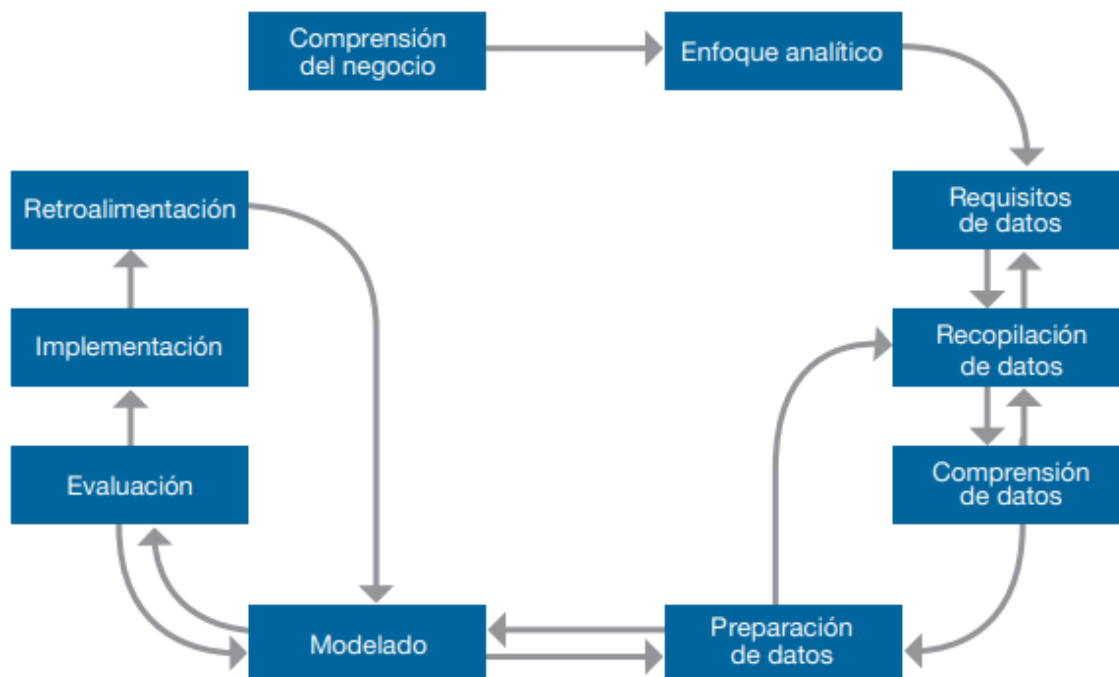


Figura 3.1: Metodología Fundamental para la Ciencia de Datos. Imagen tomada de [37]

- **Comprensión del negocio:** Se define y se comprende cuál es el problema exacto que se ha de resolver. Se definen requisitos, metas y objetivos.
- **Enfoque analítico:** Se expresa el problema en el contexto de las técnicas estadísticas y de aprendizaje automático [38, 39] permitiendo definir el tipo de modelo o algoritmo a utilizar. El enfoque puede ser de tipo descriptivo, estadístico, predictivo o prescriptivo [39, 40].
- **Requisitos de datos:** Se identifica las fuentes, el contenido y los formatos de los datos a utilizar.
- **Recopilación de datos:** Identificados los requisitos de los datos, se procede a su recopilación (los datos pueden provenir de fuentes propias o de terceros). Así mismo, los datos deben ser validados según el enfoque elegido y el resultado que se espera obtener. De ser necesario, se regresa a la etapa anterior y se revisan nuevamente los requisitos de datos.
- **Comprensión de datos:** Se hace un primer análisis exploratorio de los datos, utilizando estadísticas descriptivas y visualizaciones, para comprender el contenido de los datos, evaluar su calidad y descubrir *insights*. De ser necesario se retoma la etapa de recopilación de datos.
- **Preparación de datos:** Se realiza la limpieza (dar el formato adecuado al conjunto de datos al tratar con valores faltantes, inválidos, mal capturados, duplicados o no requeridos) y transformación -a un formato o variable de mayor valor- de los datos, de tal forma que se dejen listos para su modelado.
- **Modelado:** Se desarrolla el modelo según el enfoque analítico previamente definido. Los modelos pueden ser predictivos (basados en algoritmos de clasificación o regresión) o descriptivos (basados en algoritmos de *clustering* [38]).
- **Evaluación:** Se evalúa el modelo para comprender su calidad y garantizar que aborda el problema a resolver de manera adecuada y completa. La evaluación del modelo puede ser dividida en dos fases principales: *medidas de diagnóstico* y *pruebas de significación*

*estadística*. De requerir ajustes, se regresa a la fase de modelado. De ser aprobado se procede a su implementación.

- Implementación: Ya que se ha desarrollado y evaluado satisfactoriamente el modelo, éste es implementado y puesto a prueba en el entorno de producción o en un entorno de pruebas comparable, con la finalidad de medir su rendimiento y crear confianza para su uso en general.
- Retroalimentación: Se obtiene retroalimentación sobre el rendimiento e impacto del modelo, lo que permite su constante perfeccionamiento.

Como pudimos observar, el proceso de la ciencia de datos está compuesto por varias fases de naturaleza iterativa, de las que el científico de datos está constantemente aprendiendo. Es por ello, que debemos comprender que los modelos desarrollados no son modelos invariables o estáticos, sino por el contrario, son modelos adaptables que están en constante evolución y perfeccionamiento.

En este trabajo, utilizaremos estas técnicas (desde la comprensión del negocio hasta el modelado) para desarrollar un modelo que sirva para describir la dinámica del viento y de la demanda eléctrica en México.

### **Aprendizaje automático: *machine learning*.**

Dado que la finalidad de la ciencia de datos es darle un valor real a los datos, se requiere extraer información de ellos (con la aplicación de modelos predictivos, por ejemplo). Una forma de lograrlo es con la aplicación de modelos de *machine learning*.

El aprendizaje de automático o *machine learning* puede entenderse como el conjunto de métodos computacionales que utilizan la experiencia para mejorar el rendimiento o hacer predicciones precisas. En este caso, la experiencia se refiere a la información o datos pasados disponibles para su análisis [41]. A continuación se citan dos de las definiciones más famosas de *machine learning*:

*[El aprendizaje de máquina es el] campo de estudio que da a los ordenadores la capacidad de aprender sin ser programados explícitamente.*

-Arthur Samuel, 1959.

*Se dice que un programa de ordenador aprende de la experiencia  $E$  con respecto a alguna clase de tareas  $T$  y una medida de rendimiento  $P$ , si su rendimiento en las tareas en  $T$ , medido por  $P$ , mejora con la experiencia  $E$ .*

-Tom Mitchell, 1997.

En general, existen 3 tipos de aprendizaje de automático: aprendizaje supervisado, aprendizaje no supervisado y aprendizaje por refuerzo.

- Aprendizaje supervisado: El ordenador es entrenado con datos bien etiquetados de los que se conoce su resultado o salida (cuanto mayor sea el conjunto de datos, mejor entrenado estará el algoritmo). El algoritmo de *machine learning* aprende entonces a reconocer patrones y relaciones que le permiten ya sea clasificar nueva información (clasificación) o realizar predicciones (regresión).
- Aprendizaje no supervisado: El ordenador se entrena utilizando un conjunto de datos que no tienen etiqueta alguna. En este caso, el proceso de aprendizaje depende de la identificación de patrones y relaciones, descubiertos a partir de métodos de estimación basados en la estadística inferencial, que se crean repetidamente en los datos. Posiblemente el problema más importante del aprendizaje no supervisado es la agrupación (*clustering* en inglés) de datos [42].
- Aprendizaje por refuerzo: El ordenador recibe retroalimentación del análisis de datos aprendiendo a través de la prueba y el error donde se "recompensan" las decisiones correctas.

### Algoritmos de agrupación (*clustering*).

El *clustering* es un grupo de algoritmos que permite la clasificación no supervisada de datos (observaciones, elementos de datos o vectores de características) en grupos (*clusters*) distintos, de modo que las observaciones de cada grupo sean bastante similares entre sí, y a la vez las observaciones de grupos distintos sean bastante diferentes entre sí [43, 44, 41, 45], es decir, un "buen" *cluster* es aquel en el que la variación de los datos dentro de sí mismo es

lo más pequeña posible, y al mismo tiempo lo más alta posible con respecto a los datos de otros *clusters*.

Existen diferentes algoritmos de *clustering*, y aparentemente, al estar basados en diferentes criterios (de partición, jerarquía, distribución, aprendizaje estadístico, entre otros) pueden producir diferentes particiones y generar diferentes *clusters* [45]. Es por ello que, el algoritmo que se aplique dependerá de las características de los datos que se están manejando y del tipo de resultado que se espera obtener.

Los algoritmos de *clustering* tradicionales pueden dividirse en 9 categorías que contienen 26 algoritmos de uso común [42] basados en diferentes criterios, a saber: los basados en partición (K-means, K-medoids, PAM, CLARA, CLARANS), jerarquía (BIRCH, CURE, ROCK, Chameleon), teoría difusa (FCM, FCS, MM), distribución (DBCLASD, GMM), densidad (DBSCAN, OPTICS, Mean-shift), teoría de grafos (CLICK, MST), malla (STING, CLIQUE), teoría fractal (FC), y los basados en el modelo. Dentro de estos, uno de los algoritmos más usados, debido a su alta eficiencia, simpleza y rapidez computacional [44, 46, 43], es K-means.

### **K-means.**

El objetivo del algoritmo K-means es dividir M puntos de N dimensiones en K *clusters*, a través de un proceso iterativo que actualiza el centroide  $C_K$  de cada *cluster* [46, 43, 42], de forma que al final del proceso la suma de cuadrados (variación del *cluster*) dentro de cada uno de los *clusters* permita que la suma de las variaciones de los K *clusters* sea la mínima.

En términos matemáticos:

$$\underset{D_1, \dots, D_K}{\text{minimiza}} \left\{ \sum_{k=1}^K W(D_k) \right\} \quad (3.1)$$

Donde  $D_k$  es el número de datos dentro del k-ésimo *cluster*.  $W(D_k)$  denota la suma de las distancias euclidianas al cuadrado de cada uno de los  $D_k$  datos con respecto al centroide  $C_K$  del k-ésimo *cluster*, dividida entre el valor de  $D_k$ .

A continuación se presenta el algoritmo básico:

- 1.- Se define el número de K *clusters* en el que los datos se han de dividir.



- 2.- Aleatoriamente se seleccionan  $K$  puntos del conjunto  $M$  puntos (donde  $M$  puntos representan el total de datos). Éstos representan a los centroides  $C_K$ .
- 3.- Cada punto  $x_i$  del conjunto de  $M - K$  puntos es asignado al centroide  $C_K$  más cercano, con lo que se forman  $K$  *clusters*.
- 4.- Se recalcula el centroide de cada uno de los  $K$  *clusters* como el nuevo centro del *cluster*  $K$  y es reasignado como  $C_K$ .
- Se repiten los pasos 3 y 4 hasta que el algoritmo converge, es decir, el valor de los centroides ya no cambia.

## 3.2. Procesos estocásticos.

Un proceso estocástico es una colección de variables aleatorias que describen la evolución de un fenómeno -como lo es el viento a lo largo del tiempo-. Una definición formal es la presentada por Sheldon M. Ross en [47]:

*“Un proceso estocástico  $\mathbf{X} = \{X(t), t \in T\}$  es una colección de variables aleatorias. Es decir, para cada  $t$  en el conjunto de índices  $T$ ,  $X(t)$  es una variable aleatoria. A menudo interpretamos  $t$  como tiempo y llamamos  $X(t)$  al estado del proceso en el momento  $t$ ”.*

Existen diferentes modelos, basados en diferentes propiedades matemáticas, tales como el Markov discreto [48, 49], el movimiento browniano [50] o los modelo gaussianos [51], que se usan para describir diversos procesos estocásticos presentados en la naturaleza, como lo pueden ser desde fenómenos físicos [52] o biológicos [49] hasta finanzas [53] o ciencias sociales [54].

Dentro de estos modelos, el modelo de Markov discreto o cadena de Markov ha sido utilizado con anterioridad para el análisis de series temporales de viento [10, 11]. En este trabajo generaremos cadenas de Markov para el análisis de series temporales de viento y de demanda eléctrica, proponiendo un concepto denominado estado viento-demanda.

### 3.2.1. Cadenas de Markov discretas.

Una cadena de Markov discreta es un modelo estocástico que describe las transiciones, a lo largo del tiempo, entre diferentes estados discretos con determinadas probabilidades. La característica que define a una cadena de Markov es que es un proceso estocástico sin memoria, es decir, el estado futuro del sistema depende únicamente de la situación presente y no de su historia [49, 47, 48]. Formalmente, un proceso estocástico discreto  $X_0, X_1, X_2, \dots$  es una cadena de Markov si:

$$P(X_{t+1} = x_{t+1} | X_1 = x_1, X_2 = x_2, \dots, X_t = x_t) = P(X_{t+1} = x_{t+1} | X_t = x_t)$$

Es decir, la probabilidad de que  $X$  en el tiempo  $t + 1$  sea igual a algún valor  $x$  es la misma dada la historia completa  $X_1, X_2, \dots, X_t$  o dado únicamente el presente  $X_t$ . Las probabilidades asociadas a los cambios entre estados son llamadas probabilidades de transición y son representadas usando una matriz de transición.

#### Matriz de transición.

La matriz de transición es una matriz cuadrada que indica la probabilidad de transición entre los diferentes estados de una cadena de Markov.

$$\begin{pmatrix} P_{1,1} & P_{1,2} & \dots & P_{1,j} & \dots & P_{1,S} \\ P_{2,1} & P_{2,2} & \dots & P_{2,j} & \dots & P_{2,S} \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ P_{i,1} & P_{i,2} & \dots & P_{i,j} & \dots & P_{i,S} \\ \vdots & \vdots & \dots & \vdots & \ddots & \vdots \\ P_{S,1} & P_{S,2} & \dots & P_{S,j} & \dots & P_{S,S} \end{pmatrix}$$

Donde  $P_{i,j}$  indica la probabilidad de transitar del estado  $i$  al estado  $j$ . Así mismo, la suma de las probabilidades de transitar de un estado  $i$  a cualquier otro estado debe ser igual a 1.

### 3.3. Estados de viento.

Para aplicar un modelo de cadena de Markov a los datos de viento, la rapidez del viento tiene que ser convertido en estados discretos. La forma más común de hacerlo es dividir

los datos asociando los valores de la rapidez del viento entre dos límites para un estado determinado (por ejemplo usando la clasificación por marcas de clase en un histograma). Sin embargo, como se discutió con anterioridad, esta discretización es arbitrario y no toma en cuenta las propiedades físicas involucradas en el sistema. Para realizar una mejor discretización se puede buscar la presencia de estados físicos en el sistema. Esto se puede hacer tomando en cuenta otro factor de suma importancia: la dirección del viento. Específicamente, a través del uso de los vectores de velocidad es posible realizar un análisis estadístico más completo.

Tales vectores de velocidad son calculados, dada una serie temporal típica (aquella que contiene los valores de rapidez y dirección de viento en intervalos diez-minutales), como:

$$\vec{V}_i = v_i(-\sin \theta_i, \cos \theta_i). \quad (3.2)$$

Donde  $v_i$  es la velocidad y  $\theta_i$  es la dirección del viento para cada una de las estampas temporales  $i$ .

Si se grafican los puntos de velocidad como una nueva colección de datos en el plano  $v_x - v_y$  obtenemos algo como lo que se muestra en la Figura 3.2.




Figura 3.2: Diagrama de dispersión.




Figura 3.3: Histograma 3D.

La Figura 3.3 representa un histograma 3D para los datos de la Figura 3.2. Nos damos cuenta que los vectores de velocidad se distribuyen en un área amplia, sin embargo tienden a agruparse en grupos o zonas específicas o preferenciales (que se pueden identificar como zonas

de alta frecuencia en el histograma). Son precisamente estos grupos o zonas los denominados *estados de viento*. Específicamente, según la definición formal de [55];

*”Un estado de viento es una región en el espacio de vectores de velocidad que tienen en común una función de distribución de probabilidad [gaussiana bivariada] que los caracteriza como un grupo.”*

En términos generales, la función que caracteriza a un estado de viento es una gaussiana multivariada. Para un espacio vectorial  $\vec{r}$  con dimensión  $d$ , está definida como:

$$\frac{1}{\sqrt{(2\pi)^d |\Sigma|}} \exp \left\{ \frac{1}{2} (\vec{r} - \vec{\mu})^T \Sigma^{-1} (\vec{r} - \vec{\mu}) \right\} \quad (3.3)$$

Donde  $\mu$  el centroide de la distribución y  $\Sigma$  es la matriz de covariancia, cuyos componentes siguen el valor esperado:

$$\Sigma_{i,j} = E[(\vec{r}_i - \vec{\mu}_i)(x_j - \vec{\mu}_i)]$$

El superíndice  $T$  indica el vector transpuesto y  $\Sigma^{-1}$  es la matriz inversa de  $\Sigma$ . Para el caso bidimensional, donde  $\mu = (\mu_x, \mu_y)$ , la matriz  $\Sigma$  se puede escribir como:

$$\Sigma = \begin{pmatrix} \sigma_{xx} & \sigma_{xy} \\ \sigma_{yx} & \sigma_{yy} \end{pmatrix}$$

La pregunta ahora es: ¿Cómo vamos a identificar los estados de viento?. Resulta que, para poder identificar estos grupos (estados de viento) es posible aplicar un método de agrupamiento (*clustering*) como lo es  $k$ -means. Dado el campo vectorial correspondiente a la Figura 3.2, procedemos a aplicar el método de  $k$ -means con  $k=4$  (que representa el valor de entrada de  $k$ -means y el número de estados de viento que se han de obtener), con lo que se obtiene la Figura 3.4:




Figura 3.4: Estados de viento.

Una vez clasificados todos y cada uno de los vectores de velocidad en su estado de viento correspondiente, la serie de tiempo de velocidades se convierte en una cadena de Markov continua en la que podremos visualizar cómo varía el viento entre diferentes estados (estados de viento).

En el ejemplo anterior se eligió  $k = 4$ , con lo cual se obtienen 4 estados de viento. Sin embargo, hay que recordar que los algoritmos de *clustering* pueden producir diferentes particiones dependiendo las características de los datos que se están manejando y del tipo de resultado que se espera obtener. Por ello, es importante mencionar que el valor de estados de viento en un sitio particular puede variar dependiendo la finalidad del estudio que se desee realizar.

Una forma de seleccionar el valor de  $k$  a utilizar es usando el coeficiente de Silhouette. Este coeficiente se refiere a un método de interpretación y validación de la consistencia dentro de los *clusters*, el cual va de -1 a 1, donde un valor más cercano a 1 sugeriría una mejor clasificación de los *clusters* [56]. Desde el punto de vista de la inteligencia artificial este es un buen acercamiento, sin embargo no debe considerarse el único; deben considerarse también los aspectos físicos involucrados en el sistema y la finalidad del estudio que se esté realizando.

De esta forma, un determinado sitio podría ser dividido en 2 o 1000 estados de viento siempre y cuando éstos conserven las propiedades estadísticas que los caractericen como tal. Se considera entonces que la información a priori, la finalidad del estudio y las distribuciones

gaussianas bivariadas son los criterios para la selección de  $k$ .

En este trabajo utilizaremos esta técnica de discretización para evaluar los datos anemométricos de las estaciones meteorológicas del Atlas Eólico Mexicano. Por otro lado, para caracterizar los estados de viento se establecen diversos parámetros, a parte de la densidad de potencia, el factor de planta dado un aerogenerador de referencia y la velocidad media. A continuación se explican brevemente estos parámetros.

### **Tiempo de vida promedio.**

Indica el tiempo de vida promedio de permanencia de cada estado de viento  $j$ , es decir, dado que nos encontramos en el estado de viento  $j$ , deseamos conocer el tiempo promedio de permanencia en ese estado antes de cambiar a otro.

### **Variación promedio del ángulo.**

Se refiere a cuántos grados varían en promedio los vectores de velocidad en un estado de viento  $j$  al pasar de  $i$  a  $i + 1$  a lo largo de las  $n$  estampas temporales  $i$ .

### **Tiempo de permanencia.**

Es el tiempo en días que un estado de viento  $j$  se encuentra activo a lo largo del año.

#### **3.3.1. ¿Qué hace a un Estado de viento mejor que otro?**

Recordemos que los estados de viento no son más que agrupaciones representativas de  $n$  vectores de velocidad de viento, por lo que contienen toda la información necesaria para su análisis. Puede entenderse a éstos como micrositos de recurso eólico dentro de un espacio vectorial más amplio (el cual está representado por todos los datos de la estación meteorológica). De esta forma, es posible calcular la densidad de potencia eólica promedio y el factor de planta dada una tecnología eólica específica de cada uno de los estados de viento, así como otros parámetros de suma importancia que permitan caracterizar al estados de viento.

La pregunta natural ahora es: ¿cuáles son los parámetros que pueden decirnos si un estado de viento es mejor que otro para producir potencia eléctrica? Para responder a esa

pregunta estableceremos a un estado de viento ideal, con el cual comparar, como aquel que cumple con las siguientes características: tiene una alta densidad de potencia  $\overline{DP}_{j,k}$  (parámetro de recurso disponible), un alto factor de planta  $FP_{j,k}$  (parámetro tecnológico), un alto tiempo de vida promedio  $\bar{t}_{j,k}$  (parámetro de variabilidad temporal), un alto tiempo de permanencia  $T_{j,k}$  (parámetro de disponibilidad temporal), baja variación promedio de ángulo  $\Delta\bar{\alpha}_{i,j,k}$  (parámetro de variabilidad espacial) y alta velocidad media  $\bar{U}_{j,k}$ . De esta forma, un estado de viento cuyos parámetros antes mencionados se acerquen más al estado ideal será considerado mejor. La explicación de todos estos parámetros ya ha sido abordada con anterioridad en este escrito. Sin embargo, en el siguiente capítulo -Caso de estudio- estableceremos, de forma precisa, el cálculo utilizado para determinar el valor de cada uno de ellos.

# Capítulo 4

## Metodología.

La metodología que presentamos en este trabajo tiene como fin construir una cadena de Markov con donde los estados definan el acoplamiento de la demanda eléctrica y la disponibilidad de recurso eólico a nivel nacional. De manera resumida la Figura 4.1 describe los pasos que se definieron para este fin a manera de diagrama de flujo. La descripción de cada etapa se realizará en las secciones siguientes.

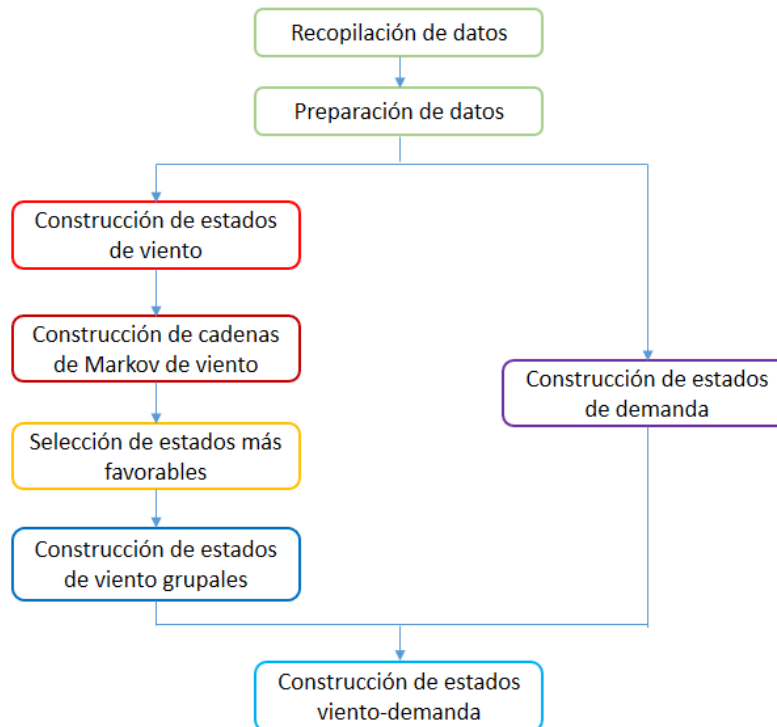


Figura 4.1: Diagrama de flujo para la metodología de construcción de un proceso de Markov para estados viento-demanda.



## 4.1. Recopilación de datos.

De [57] se recopilaron y organizaron los datos correspondientes a las 7 estaciones meteorológicas del Atlas Eólico Mexicano (AEM). Tales datos contienen la información meteorológica recabada en intervalos de 10 minutos a diferentes alturas referenciados a la hora de invierno del centro del país (Ciudad de México UTC-06:00). Los nombres de las variables tienen la forma “Variable\_Altura\_Estadística”, donde WS (velocidad del viento), WD (dirección del viento), temp (temperatura de aire), RH (humedad relativa), P (presión barométrica), Rad (radiación solar), DENSIDAD (densidad del aire). Por cada altura de medición, los campos de las variables se repiten cuatro veces para los valores estadísticos de media, máxima, mínima y desviación estándar.

Dado que los archivos contienen los datos en periodos mensuales, fue necesario descargar y concatenar los correspondientes para formar un año (2018). Se formaron también las series correspondientes a dos años (periodo 2018-2019), sin embargo las series de Ojuelos, Ventosa y Cuahutémoc contenían respectivamente 32532, 11125 y 8251 datos faltantes, por lo que se consideró que a pesar de contener mayor cantidad de datos, la información faltante comprometía la contenida en las series temporales. Es por esto que se decidió realizar el análisis con las series de 2018 (que a pesar de contener también datos faltantes, en términos generales resultaban mejores). Los datos faltantes eran especificados.

Por otro lado, se recopilaron los datos de generación eléctrica nacional (obtenidos del CENACE) correspondientes al mismo periodo. Estos últimos se encuentran contenidos en archivos de periodos anuales, por lo que únicamente se descargó el correspondiente al 2018.

## 4.2. Preparación de datos.

Se realizó la limpieza y transformación de los datos de tal forma que estuvieran listos para su análisis. Se eliminaron los valores duplicados y las columnas no requeridas para el análisis, por lo que se conservaron únicamente WS\_80mA\_mean (velocidad del viento promedio a 80 m) y WD\_78m\_mean (dirección del viento promedio a 78 m).

Utilizando las columnas de velocidad de viento ( $WS_{80mA\_mean}$ ) y dirección de viento ( $WD_{78m\_mean}$ ), y asumiendo que la dirección de viento varía de forma insignificante entre 78 m y 80m, se obtuvieron las componentes cartesianas de la velocidad del viento del sitio (vectores de velocidad) de la forma:  $\vec{V}_i = v_i(-\text{sen}\theta_i, \text{cos}\theta_i)$  donde  $v_i$  es la velocidad y  $\theta_i$  es la dirección del viento en la cada una de las estampas temporales  $i$  de la serie temporal (o estación meteorológica)  $k$ . Con esto, se obtienen series temporales ya no de la velocidad y dirección de viento, sino de las coordenadas cartesianas (x,y) de cada vector de velocidad para cada estampa temporal  $i$  para cada estación meteorológica  $k$ .

Por otro lado, los datos de demanda eléctrica se encontraban en intervalos de 1 hora y contenían la demanda eléctrica promedio de cada hora en unidades de MWh/h, por lo que fue necesario transformarlos a intervalos de 10 minutos (haciendo la suposición de que la demanda eléctrica en el intervalo de 10 minutos era de 1/6 la demanda eléctrica del intervalo de 1 hora correspondiente). Esto se hizo con la finalidad de empatar su temporalidad con los intervalos de la series de datos de viento. De esta forma, a pesar del cambio de estampa temporal la misma información es conservada.

### 4.3. Construcción de estados de viento y cadenas de Markov de viento.

Los estados de viento fueron contruidos según lo descrito en el Capítulo 4: Datos, aleatoriedad y estados de viento. A cada una de las 7 series temporales de los vectores de velocidad de viento del AEM se le aplicó el algoritmo de agrupamiento *k-means*. En primer lugar, se decidió calcular el coeficiente de Silhouette usando  $k = [2,3,4,5,6]$  para los 7 sitios a evaluar.

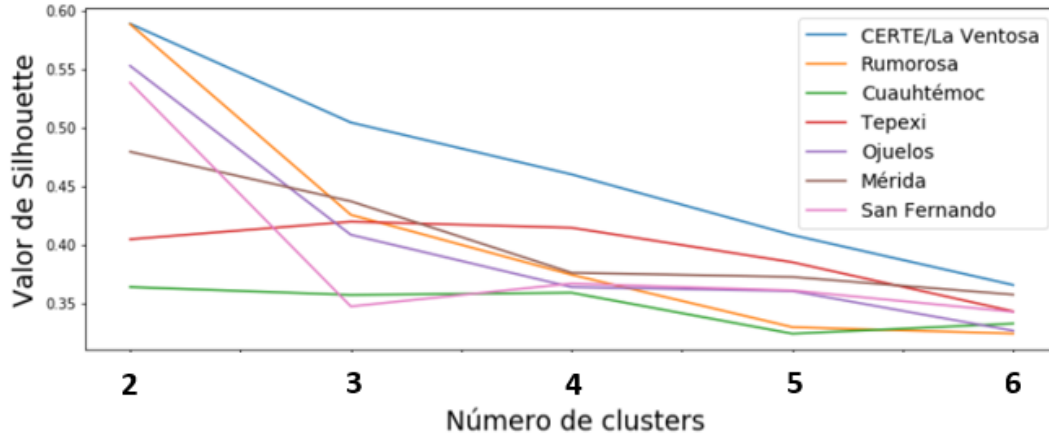


Figura 4.2: Disponibilidad de datos por estación meteorológica.

El coeficiente de Silhouette nos sugiere, desde el punto de vista de la inteligencia artificial, que las mejores particiones son  $k = 3$  y  $k = 4$  dependiendo el sitio ( $k = 4$  resulta mejor para San Fernando, Tepexi y Cuauhtémoc). Se decidió conservar el mismo número de particiones o *clusters* a obtener para cada serie temporal. Es decir, para cada serie temporal el valor  $k$  es el mismo (específicamente  $k = 4$ ), con lo que se obtendrían 4 estados de viento para cada serie, dando un total de 28 Estados si consideramos los datos de las 7 estaciones meteorológicas.

El  $k = 4$  se debe a la idea de representar a cada sitio a través de sus 4 principales estados de viento. Esto no significa que cada sitio deba estar siempre representado por exactamente 4 estados de viento (tal como se especificó en la sección 4, un determinado sitio podría ser dividido en 2 o 1000 estados de viento, dependiendo la finalidad del estudio que se desee realizar, siempre y cuando éstos conserven las propiedades estadísticas que los caractericen como tal). Más bien, se *propone* el valor de 4 como un valor óptimo que permita representar los 4 principales *macroestados* de cada sitio (de modo que cada uno de estos *macroestados* esté conformado por un número considerable de vectores de velocidad que conserven de forma conveniente sus propiedades físicas para su aplicación en el sector eólico). De esta forma, con  $k = 4$ , a cada estampa temporal  $i$  de cada serie temporal  $k$  se le asignaría un Estado de viento  $j$ , a saber *estado 1, 2, 3 ó 4*, con lo que todos y cada una de los datos  $i$  (vectores de velocidad) fue discretizado por medio del estado de viento  $j$  al que corresponde. Así, para cada una de las series temporales  $k$ , es posible construir la cadena de Markov asociada a cada sitio, la cual estará conformada por los *estados 1, 2, 3 ó 4*. El establecer esta propuesta

permitió identificar los 2 mejores estados de viento de cada sitio (según lo descrito en el capítulo 4) y así mismo estableció el modelo para realizar una comparación directa entre diferentes sitios y construir lo que denominamos "estados de viento grupales".

#### 4.4. Selección de estados más favorables.

Obtenidos los 4 estados de viento de cada sitio, el interés ahora reside en seleccionar sus 2 mejores estados (a excepción de La Ventosa donde se escoge solamente un estado debido a las características particulares del sitio). La intención de esta selección es el establecer un modelo que permita representar la dinámica del viento en diferentes regiones durante el mismo intervalo de tiempo. Así, por ejemplo, una determinada región puede ya sea encontrarse o no en alguno de los dos mejores estados de viento, es decir, puede estar (en un intervalo o momento determinado) en el estado 1, 2, 3 ó 4, donde cualquiera de ellos puede representar a cualquiera de los dos mejores estados de viento. De ser así, se entiende que ese sitio se encuentra en un estado favorable para la producción de energía eólica, lo cual puede indicarse como un 1. De no ser así, se entiende como un caso desfavorable y se indica con un 0. Así mismo, un dato faltante es indicado con un 0.

Al establecer este modelo para todos y cada una de los sitios es posible realizar una comparación directa entre diferentes sitios y construir una cadena de Markov que permita representar la dinámica del viento en las 7 diferentes estaciones meteorológicas del AEM.

Tal como se estableció anteriormente, para seleccionar a los 2 mejores estados de viento de cada sitio se utilizaron los siguientes parámetros: el ángulo de apertura ( $\alpha$ ), la densidad de potencia ( $\overline{DP}_{j,k}$ ), el factor de planta ( $FP_{j,k}$ ), el tiempo de permanencia ( $T_{j,k}$ ), el tiempo de vida promedio ( $\bar{t}_{j,k}$ ), la variación promedio de ángulo ( $\alpha_{i,j,k}$ ) y la velocidad media ( $\overline{U}_{j,k}$ ). A continuación se explica el proceso utilizado para el cálculo de cada uno de ellos.

La densidad de potencia eólica promedio de cada uno de los estados de viento  $j$ , que contiene  $n$  estampas temporales  $i$ , de cada una de las estaciones meteorológicas  $k$  indica el promedio de potencia eólica disponible por unidad de área en cada estado de viento  $j, k$  y se

calcula de la siguiente manera:

$$\overline{DP}_{estado} = \overline{DP}_{j,k} = \frac{1}{2n} \sum_{i=1}^{i=n} (\rho_i)(v_i^3)_{j,k}. \quad (4.1)$$

Donde  $v_i$  es la magnitud de la velocidad de viento y  $\rho_i$  la densidad de viento para estampa temporal  $i$  de cada Estado de viento  $j$  de cada serie temporal (o estación meteorológica)  $k$ . El valor de  $j$  varía entre 1, 2, 3 ó 4 representando los 4 Estados de viento posibles de cada serie temporal  $k$  (la cual varía de 1 a 7 representando las 7 estaciones meteorológicas evaluadas).

Por otro lado, para calcular el factor de planta se propusieron 2 modelos de aerogeneradores de diferentes potencias a una altura de 80 metros. Específicamente se propusieron los aerogeneradores VestasV90 de 3 MW y el VestasV80 de 2 MW.

Conocidas las curvas de potencia de estos aerogeneradores, el factor de planta para cada estado de viento  $j$  de cada estación meteorológica  $k$  ( $FP_{j,k}$ ) se calculó para cada modelo de aerogenerador  $z$  como:

$$FP_{j,k} = \frac{\overline{P}_{j,k}^{Pr}}{P_{nominal,Z}}. \quad (4.2)$$

Donde  $P_{nominal,Z}$  representa la potencia nominal de cada uno de los aerogeneradores propuestos  $z$ . Así mismo,  $\overline{P}_{j,k}^{Pr}$  representa la potencia producida promedio de cada uno de los estados de viento  $j$  de cada estación meteorológica  $k$ , y está dada como:

$$\overline{P}_{j,k}^{Pr} = \frac{1}{n} \sum_{i=1}^{i=n} (\beta_Z(v_i))_{j,k}. \quad (4.3)$$

De donde  $\beta_Z(v_i)$  representa la potencia producida por cada modelo de aerogenerador  $z$  para cada estampa temporal  $i$  de cada estado de viento  $j$  de cada serie temporal (o estación meteorológica)  $k$ .

El valor de la variación promedio del ángulo ( $\Delta\bar{\alpha}_{i,j,k}$ ) de cada estado de viento  $j$  de cada estación meteorológica  $k$ , se calculó como el promedio de la variación del ángulo (en valor absoluto) entre cada estampa temporal  $i$  con respecto a  $i + 1$ , sin tomar en cuenta las variaciones mayores a  $10^\circ$ , con lo que podríamos asegurar que no se presentó un cambio de

estado de viento y tiempo después se regresó al estado original. Finalmente, el tiempo de vida promedio se calcula al como el promedio de estampas temporales  $i$  que un estado de viento  $j$  (digamos por ejemplo el estado 1) estuvo activo antes de cambiar a cualquier otro estado (el 2,3 ó 4) a lo largo de todo el año.

Toda la información obtenida de cada uno de los 4 estados de viento de cada una de las 7 estaciones meteorológicas fue guardada en tablas. De esta forma, la tabla correspondiente a cada estación meteorológica  $k$  contiene los valores de todos los parámetros antes calculados para cada estado de viento  $j$ . Al analizar la información contenida en las tablas generadas se seleccionaron los 2 mejores estados de viento de cada sitio (a excepción de La Ventosa donde se seleccionó solamente uno). Se entiende entonces que los 13 estados elegidos representan estados de viento favorables para la producción de energía eólica. Dado que el modelo consiste en escoger los 2 mejores estados de cada sitio, en caso de que la elección de estos no fuese tan clara, se daría prioridad a aquellos estados con mayor densidad de potencia eólica y mejor factor de planta.

## 4.5. Construcción de estados de viento grupales.

Como ya sabemos, el estado de viento en que se encuentra cada sitio varía a lo largo del tiempo, por lo que de encontrarse en un estado favorable en un intervalo determinado se indicaba con un 1, de encontrarse en un estado desfavorable se indicaba con un 0. Usando esta información, se procedió a identificar el total de estados favorables en cada intervalo de tiempo (estampa temporal  $i$ ) de las 7 estaciones meteorológicas. De esta manera, cada intervalo de tiempo puede tener como máximo 7 estados favorables y como mínimo 0. 7 estados favorables indica que todas las estaciones meteorológicas se encuentran en alguno de sus dos mejores estados. 0 estados favorables indica que ningún sitio se encuentra en cualquiera de los dos mejores estados de viento.

Identificado el número de estados favorables para cada estampa temporal fue posible construir una nueva serie temporal y la cadena de Markov que describe la dinámica del viento alrededor de la República Mexicana (tal cadena puede tener el valor de 0,1,2,3,4,5,6

ó 7 estados favorables).

Es en este punto, donde se introduce el concepto de "estado de viento grupal":

*"Un estado de viento grupal es una clasificación de estados de vientos que permite describir la dinámica del viento de diversas regiones (de una zona geográfica) a lo largo del tiempo."*

En este trabajo se generaron 3 "estados de viento grupales", y su construcción es como sigue. Si en un intervalo  $i$  determinado se tienen ya sea 0,1 ó 2 estados de viento favorables activos se considera un estado de viento grupal pobre (etiquetado como 1). Si se encuentran activos 3 ó 4 estados de viento favorables, ese estado de viento grupal se considera regular (etiquetado como 2). Si se tienen 5,6 ó 7 estados de viento favorables activos, se considera un estado de viento rico (etiquetado como 3).

Hay que tener en cuenta que esta clasificación es arbitraria. Se realizó de esta forma considerando el número de "estados viento grupales" que se obtendrían durante el análisis, no teniendo ya sea demasiados o muy pocos que pudieran ocultar o complicar la información esencial del análisis. Por ejemplo, se pudo decidir considerar 7 estados de viento grupales, donde el tener 0 estados de viento favorables se considerara pésimo, y el tener 7 estados de viento favorables activos se considerara excelente. De la misma forma, se pudo elegir simplemente dividir en dos estados de viento grupales, a saber un estado de viento grupal malo (0,1,2,3 estados de viento favorables activos) y bueno (conformado por los restantes).

Al establecer este modelo es posible construir una nueva serie temporal con la cual es posible identificar los intervalos temporales de pobre, regular y rico viento. permitiendo representar la dinámica de viento de las 7 estaciones meteorológicas del AEM a través de estado de viento grupales, se construyó la cadena de Markov y la matriz de transición.

## 4.6. Construcción de estados de demanda.

Se construyó la cadena de Markov de demanda usando la serie temporal de demanda eléctrica de intervalos diez-minutales. Para ello, fue necesario realizar una transformación de los datos. En primer lugar, se calculó el valor promedio de los datos que conformaban esta serie temporal.

Este valor promedio permitiría realizar una asignación a cada uno de los valores de la serie temporal: si el valor numérico de demanda eléctrica en un intervalo determinado (estampa temporal  $i$ ) correspondía a un valor mayor que el valor promedio, le era asignado el número 3. Por otra parte, si se tenía un valor menor que la media le era asignado el número 0.

Estos valores discretos permiten, de forma análoga a los estados de viento grupales, construir los estados de demanda. Nuevamente, la elección de generar 2 estados de demanda es arbitraria (pudieron ser 3 o 4 por ejemplo). Es importante especificar que los números 0 y 3 son meras etiquetas que sirven para identificar a un estado de demanda (0 indicando un estado de demanda baja y 3 indicando un estado de demanda alta), y la única finalidad de representarlos como 0 y 3 es el contar con un formato que sea amigable para la construcción de los estados de viento-demanda.

## 4.7. Construcción de estados viento-demanda.

Al contar con ambas cadenas, una que describe la dinámica del viento y otra que describe la dinámica de la demanda de energía eléctrica en el sistema eléctrico mexicano, se procedió a construir una nueva serie temporal que representara la información de ambas. Tal serie, básicamente, describe la dinámica de los estados de viento-demanda.

El concepto de estado viento-demanda es entonces definido como sigue:

*”Un estado viento-demanda es una clasificación [de estados de viento grupales y estados de demanda] que permite describir la dinámica del viento respecto a la demanda eléctrica en una zona geográfica a lo largo del tiempo.”*

Para explicar la construcción de los estados viento-demanda, recordemos que la cadena de Markov de dinámica de viento expresa la transición a través del tiempo entre 3 diferentes estados de viento grupales: pobre (indicado como 1), regular (indicado como 2) y rico (indicado como 3). Por otro lado la cadena de Markov de demanda expresa la transición a través del tiempo entre estados de alta (indicado como 3) y baja (indicado como 0) durante cada una de las mismas estampas temporales  $i$ .



Si para cada estampa temporal  $i$  sumamos el valor numérico indicado en la serie temporal de demanda con el valor numérico indicado en la serie temporal de dinámica de viento obtendremos una nueva serie temporal que representa la dinámica viento-demanda. Así por ejemplo, una estampa temporal  $i$ , digamos el 20-09-18 a las 09:30:00 horas, donde la serie temporal de demanda indica un valor de 3 y el valor de la serie temporal de dinámica de viento sea 3, tendremos un estado de Viento-Demanda Rico-Alta.

Es de esta forma, que específicamente se construyeron los 6 estados de viento-demanda, correspondientes a la combinación de 3 estados de viento grupales y 2 estados de demanda. Con ello, los estados Pobre-Baja, Regular-Baja, Rico-Baja, Pobre-Alta, Regular-Alta y Rico-Alta representan la dinámica Viento-Demanda. Finalmente, se construyó la cadena de Markov y la matriz de transición.

Los resultados al aplicar este método a los datos de viento del Atlas Eólico Mexicano y de demanda eléctrica del CENACE se presentan en el siguiente capítulo.

# Capítulo 5

## Resultados y discusión.

A partir de la base de datos del Atlas Eólico Mexicano se seleccionó el año 2018 por tener un buena disponibilidad estadística de los datos. En la Tabla 5.1 muestra el total de datos disponibles por estación meteorológica en el año 2018, después de la concatenación y limpieza de los datos. En la Figura 5.1, observamos como las ventanas de ausencia de datos son pocas y solo ocurren de manera menor en tres de los siete sitios, lo cual permite construir el análisis considerando todos los sitios en la mayor parte del año.

Tabla 5.1: Total de datos disponibles por estación meteorológica (2018).

Estación	La Rumorosa	Cuauhtémoc	San Fernando	Ojuelos	Tepexi	La Ventosa	Mérida
Total de datos	49 328	52 490	52 522	51 070	52 463	52 369	48 058




Figura 5.1: Disponibilidad de datos por estación meteorológica.

Observamos que a Mérida, a La Rumorosa y a Ojuelos les hacen falta 4502, 3232 y 1490 datos respectivamente, sin embargo las cuatro estaciones restantes cuentan todas con más del 99.5% de los datos. Para el caso de Mérida hacen falta los datos de todo el mes de julio. Para el caso de La Rumorosa falta casi todo agosto. Sabido esto, se procedió a la obtención de los 4 estados de viento, según la metodología propuesta, de cada una de las estaciones del AEM, para posteriormente construir la tabla comparativa de estados de viento y la matriz de transición de cada sitio.

## 5.1. Estados de viento.

A modo de ejemplo, se muestra en la Tablas 5.2 y 5.3 la comparativa de los estados de viento y la matriz de transición correspondientes a la estación meteorológica de San Fernando. El resto de tablas comparativas y matrices se pueden revisar en los Anexos.

Tabla 5.2: Estados de viento San Fernando.

Estado	$\overline{DP}_j(\frac{W}{m^2})$	$FP_j$ 2MW(%)	$FP_j$ 3MW(%)	$\bar{t}_j$ (horas)	$t_t$ (días)	$\Delta\bar{\alpha}_{i,j,k}$ (°)	$U_{med}(\frac{m}{s})$
1	535.0	52.53	40.09	4.17	55.28	2.70	8.57
2	58.6	6.65	4.50	2.05	70.17	3.79	3.59
3	538.1	56.74	42.78	3.14	124.91	2.67	8.86
4	270.6	34.05	23.79	2.72	114.36	1.75	6.86

Tabla 5.3: Matriz de transición San Fernando.

Estado	1	2	3	4
1	0.917224	0.026117	0.0297863	0.0268724
2	0.0105184	0.947247	0.000160996	0.0420736
3	0.0386855	0.	0.960668	0.000646914
4	0.0161481	0.0438306	0.00141961	0.938602

Observamos, de la tabla 5.2, que tanto el estado 1 y 3 superan los  $530 W/m^2$  de densidad de potencia. Así mismo, tienen un factor de planta superior al 50% (excelente para la generación de potencia eléctrica). Cuando comparamos estos valores con los de los estados 2 y 4, nos lleva a pensar que los estados 1 y 3 son los mejores estados de viento para producir electricidad. Esta hipótesis se refuerza al comparar los factores de planta, la velocidad media,

el tiempo de vida promedio y la variación promedio del ángulo. Siguiendo la misma idea que para con San Fernando, se escogieron los dos mejores estados de viento de cada estación. La información de tales estados se condensa en la Tabla 5.4.

Tabla 5.4: Mejores estados de viento.

Estado	$\overline{DP}_j(\frac{W}{m^2})$	$FP_j$ 2MW(%)	$FP_j$ 3MW(%)	$\bar{t}_j$ (horas)	$t_t$ (días)	$\Delta\bar{\alpha}_{i,j,k}$ (°)	$U_{med}(\frac{m}{s})$
La Rumorosa 3	283.6	33.53	23.88	1.91	70.47	2.99	6.76
La Rumorosa 4	742.4	61.64	47.86	1.97	84.63	2.76	9.57
Cauhtémoc 2	160.8	19.84	13.61	1.52	107.53	3.74	5.42
Cauhtémoc 4	828.0	66.66	53.42	1.47	46.19	3.48	10.04
San Fernando 1	535.0	52.53	40.09	4.17	55.28	2.70	8.57
San Fernando 3	538.1	56.74	42.78	3.14	124.91	2.67	8.86
Ojuelos 2	292.6	36.31	25.57	1.07	61.67	3.25	7.08
Ojuelos 4	244.3	29.01	20.58	3.23	156.42	3.39	6.21
Tepexi 1	155.6	19.25	13.10	1.06	80.70	3.66	5.49
Tepexi 3	321.9	39.16	27.85	1.19	60.78	3.79	7.30
La Ventosa 1	1495.9	75.31	64.64	9.49	247.05	2.42	11.82
Mérida 1	247.8	33.61	22.74	2.59	103.90	3.10	6.96
Mérida 3	199.4	27.15	18.14	1.68	110.10	2.79	6.54

## 5.2. Estados de viento favorables activos.

Al tener determinados los dos mejores estados de viento de cada región, se construyó la serie temporal de la dinámica del viento. Si cualquiera de los dos mejores estados de viento (especificados en la Tabla 5.4) se encuentra activo se considera un estado favorable. En la Tabla 5.5 se muestra la frecuencia de aparición, y su respectivo porcentaje, del número de estados favorables activos a lo largo del tiempo.

Tabla 5.5: Número de estados favorables activos.

Estados favorables activos	Frecuencia	Frecuencia (%)
0	847	1.6115
1	3332	6.3394
2	8598	16.3584
3	12024	22.8767
4	13036	24.8021
5	9452	17.9833
6	4315	8.2097
7	956	1.8189

El promedio de estados favorables activos en un momento determinado es de 3.588. La desviación estándar es de 1.488. Esto nos indica que tenemos una distribución casi normal. La misma información puede visualizarse en el histograma de frecuencias de la Figura 5.2.

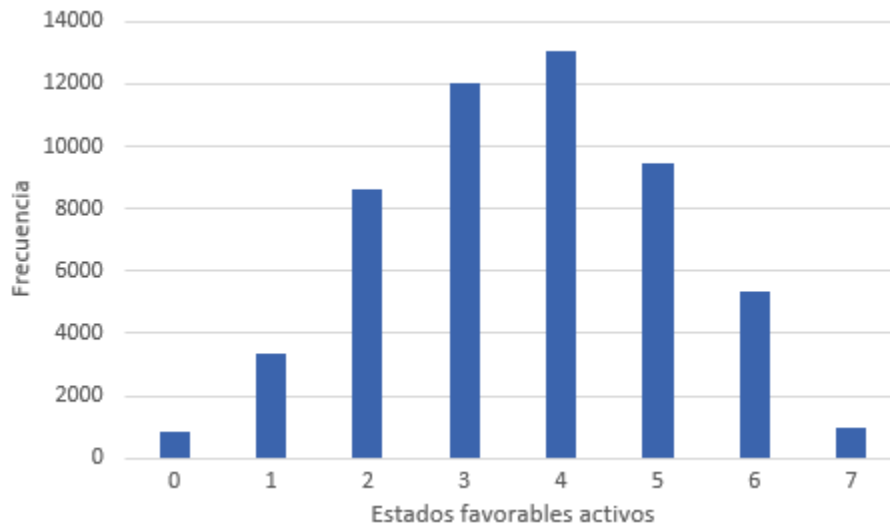


Figura 5.2: Frecuencia por estados favorables activos.

Para poder visualizar la dinámica a lo largo del tiempo, se construyó la cadena de Markov asociada que se muestra en la Figura 5.3.




Figura 5.3: Cadena de Markov de estados favorables activos.

En primera instancia, podríamos decir que este comportamiento resulta casi inverso al de demanda de electricidad, donde los valores más altos se presentan durante verano. Para el caso de estados favorables activos pareciera que es durante verano cuando se presentan los valores más bajos. En específico, del día 160 al 260 tenemos la peor temporada del año (y se registra un sólo intervalo de 7 estados favorables activos) con un promedio de 2.998

estados favorables activos, y 0.59 por debajo de la media anual. Sin embargo, recordemos que durante julio y gran parte de agosto (específicamente del día 180 al 230) faltan datos de Mérida y de La Rumorosa, por lo que el máximo de estados favorables activos se reduce a 6. Aún así, durante el mes de junio (del día 160 al 180 aproximadamente) la situación sigue pareciendo negativa, ya que aunque para este caso el máximo de estados activos es de 7, el promedio es de sólo 2.646.

La Figura 5.4 muestra el promedio de estados favorables activos al día a lo largo del año, donde el comportamiento de la cadena de Markov de la Figura 5.3 se encuentra sintetizado, pero se conserva la misma información.




Figura 5.4: Promedio de estados favorables activos por día.

En la Tabla 5.6, se muestra la matriz de transición de la dinámica del viento.

Tabla 5.6: Matriz de transición estados favorables activos.

Estado	0	1	2	3	4	5	6	7
0	0.6789	0.2515	0.0614	0.0071	0.	0.0012	0.	0.
1	0.0705	0.6396	0.2443	0.0411	0.0045	0.	0.	0.
2	0.0035	0.0972	0.6580	0.2057	0.0336	0.0020	0.0001	0.
3	0.0005	0.0113	0.1497	0.6283	0.1861	0.0227	0.0012	0.00008
4	0.	0.0012	0.01926	0.1729	0.6434	0.1499	0.0128	0.00046
5	0.	0.	0.0025	0.03058	0.2076	0.6474	0.1077	0.0041
6	0.0002	0.	0.	0.0030	0.0329	0.2417	0.6665	0.0556
7	0.	0.	0.	0.0021	0.0021	0.0460	0.2490	0.7008

Podemos observar que la probabilidad de mantenerse en el mismo estado, es decir, la probabilidad de que el número de estados favorables activos no cambie de  $i$  a  $i + 1$  se

encuentra entre 0.6283 y 0.7008 para todos los casos. Así mismo, cuando se tienen pocos estados favorables activos (1,2 ó 3) la matriz indica que es más probable, encontrándonos en el intervalo  $i$ , el transitar a un estado mayor (para el caso de 0 moverse a 1, 1 moverse a 2, 2 moverse a 3 ó 3 moverse a 4) que a un estado menor. Lo mismo sucede, pero a la inversa, en los estados 4,5 y 6. Para estos casos la matriz indica una mayor probabilidad de transición hacia un estado menor.

Por otro lado, la probabilidad de transitar más de dos estados (por ejemplo transitar de 4 a 6 ó de 4 a 2) disminuye considerablemente para todos los estados; llegando inclusive a tener probabilidades muy cercanas a 0 (como es el caso de transitar de transitar de 5 a 7 con una probabilidad de 0.0041). Estas observaciones podrían indicarnos que la dinámica del viento presenta cierta estabilidad, debido a que las variaciones de estados no parecieran ser tan drásticas.

### 5.3. Estados de viento grupales.

Con la información detallada anteriormente, se construyeron los estados de viento grupales. La Tabla 5.7 muestra la distribución en las apariciones de éstos.

Tabla 5.7: Estados de viento grupales.

Estados productores activos	Nomenclatura	Frecuencia	Frecuencia (%)
De 0 a 2	Pobre	12777	24.3094
De 3 a 4	Regular	25060	47.6788
De 5 a 7	Rico	14723	28.0118

Podemos observar que los estados de viento grupales regulares son los más recurrentes, concentrando más de 47.5% del total de los datos equivalentes a más de 174 días.

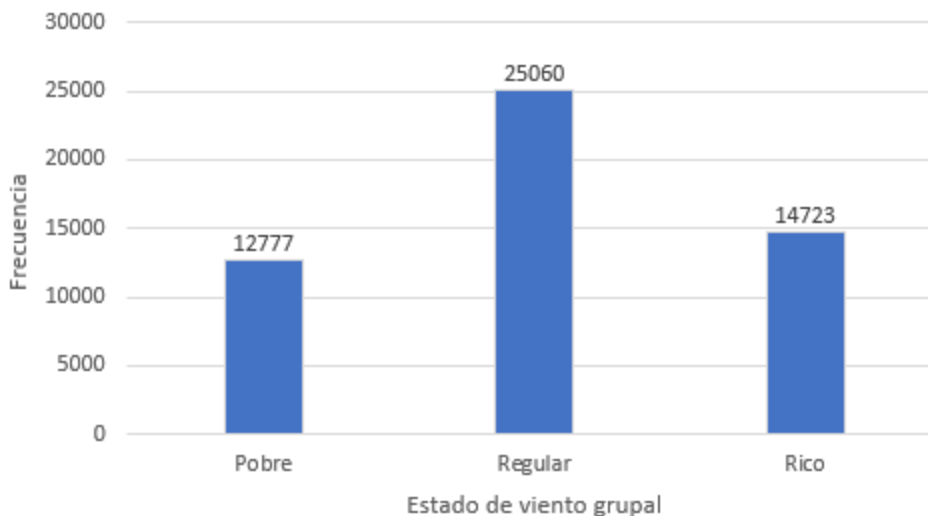


Figura 5.5: Frecuencia por estados de viento grupales.

Se construyó la cadena de Markov de los estados de viento grupales. La cual muestra, básicamente, el mismo comportamiento que la cadena de estados favorables activos de la Figura 5.3: durante el verano se tiene menos viento.




Figura 5.6: Cadena de Markov de estados de viento grupales.

Para conocer la distribución a lo largo de las horas del día, se decidió agrupar los datos por hora y calcular el total de estados pobres (de azul), regulares (de negro) y ricos (de rojo) activos. De esta forma, la gráfica a continuación muestra la frecuencia de estados dependiendo la hora del día.






Figura 5.7: Frecuencia de estados de viento grupales por hora

Esta información, a grosso modo, nos permite observar que la frecuencia de estados regulares es estable, en el rango de 950 a 1150. Por otro lado, identificamos que el viento pobre tiende a presentarse de las 7 a las 13 horas, mientras que el viento rico se presenta durante la tarde-noche. En la Tabla 5.8, se muestra la matriz de transición de la dinámica del viento.

Tabla 5.8: Matriz de transición estados de viento grupales.

Estados de viento grupales	Pobre	Regular	Rico
Pobre	0.825155	0.173358	0.00148705
Regular	0.0881731	0.815391	0.0964356
Rico	0.00169802	0.163689	0.834613

Podemos notar, que dado que nos encontremos en cualquier estado, la probabilidad de mantenerse en ese mismo de  $i$  a  $i + 1$  es de entre el 81 y 84 %. Las probabilidades de moverse de un estado pobre a un rico, o de un rico a un pobre, son bajas.

## 5.4. Estados de demanda.

En la Tabla 5.9 se muestra la frecuencia de aparición de los estados de demanda. La demanda promedio es de 5613.86 MWh/10 minutos. La demanda máxima es de 7381.19 MWh/10 minutos. La demanda mínima es de 3241.37 MWh/10 minutos.

Tabla 5.9: Estados de demanda.

Nomenclatura	Frecuencia	Frecuencia (%)
Baja	26988	51.35
Alta	25567	48.64

## 5.5. Estados viento-demanda.

Se construyeron los estados de viento-demanda como se describió en el capítulo 4. En la Tabla 5.10, se muestra su frecuencia de aparición.

Tabla 5.10: Estados viento-demanda.

Estado	Viento-demanda	Frecuencia	Frecuencia (%)
1	Pobre-Baja	5852	11.1350
2	Regular-Baja	11694	22.2510
3	Rico-Baja	8021	15.2621
4	Pobre-Alta	6925	13.1767
5	Regular-Alta	13361	25.4229
6	Rico-Alta	6702	12.7524

El peor de los estados posibles es el pobre-alta, donde hay poco o nulo viento para satisfacer una alta demanda, esto es importante, ya que indica desincronización entre la disponibilidad de energía eólica y la demanda de electricidad que podría afectar de manera negativa al suministro de electricidad si se desea contar con grandes centrales eólicas. Así mismo, el estado regular-alta también es considerado desfavorable, ya que aunque existe mayor cantidad de viento, éste podría ser no suficiente. Bajo este criterio, hay que señalar que el estado pobre-alta se presenta poco más del 13% del tiempo. Por su parte, el estado regular-alta se presenta más del 25%. Entre ambos ya es más del 38% del tiempo en el que podría no haber viento suficiente para satisfacer la demanda eléctrica dentro del Sistema Interconectado Nacional.

Del lado contrario, observamos de la Tabla 5.10 que la probabilidad de ocurrencia del estado rico-baja es de poco más del 15%. El identificar estos momentos, donde hay mucho viento y baja demanda a lo largo del país, nos permitiría establecer mecanismos de almacenamiento de energía. Se produce la energía y se almacena para su uso posterior.

Por otro lado, sabemos de la Tabla 5.8, que el viento regular está presente en poco más del 47.5% del tiempo y debe ser igual a la suma de las frecuencias de los estados regular-baja y regular-alta de la Tabla 5.10. Ahora, observamos de esta última tabla que el estado regular-baja y regular-alta tienen una frecuencia muy similar, lo cual puede explicarse debido a la similitud de frecuencias en los estados de demanda en la Tabla 5.9.

Se construyó la cadena de Markov para visualizar la transición entre estados viento-demanda a lo largo del año.




Figura 5.8: Cadena de Markov de estados viento-demanda.

Así mismo, en la siguiente Figura observamos la misma información, pero en diferente formato. De café el estado rico-alta, de morado regular-alta, de rojo pobre-alta, de verde rico-baja, de naranja regular-baja y de azul pobre-baja.




Figura 5.9: Otra visualización de la cadena de Markov de estados viento-demanda.

Podemos notar, a simple vista de las Figuras 5.8 y 5.9, 3 zonas de alta frecuencia de transición entre estados. La primera de ellas va del día 0 al día 90, aproximadamente, y muestra una transición constante entre los estados regular-baja y rico-baja. La segunda zona va del día 110 al 260 -aproximadamente- transitando entre el estado pobre-alta y regular-alta.

Finalmente, en la tercera zona, del día 290 al 360 aproximadamente, tenemos una constante transición entre los estados regular-baja y rico-baja nuevamente.

La zona 2 es bastante importante, ya que en esta tenemos transición entre estados de viento-demanda desfavorables: viento pobre ó regular con demanda alta. Esto podría generar una dificultad importante a lo largo de esta temporada del año, donde la demanda resulta estar en sus valores más altos y la disponibilidad del viento en los niveles más bajos.

Para discutir la presencia de los estados viento-demanda a lo largo de las horas del día, se procedió a agrupar los estados activos dependiendo la hora. Nuevamente, de café se muestra el estado rico-alta, de morado regular-alta, de rojo pobre-alta, de verde rico-baja, de naranja regular-baja y de azul pobre-baja




Figura 5.10: Frecuencia de estados viento-demanda por hora.

De rojo, el estado pobre-alta, tiende a presentarse de las 10 a las 14 horas, con su máximo a las 11. Quizá una forma de alivianar esta desincronización sería con la instalación de centrales solares, las cuales podrían generar una buena cantidad de electricidad a estas horas del día. Finalmente, se construyó la matriz de transición de los estados de viento-demanda en la Tabla 5.11.

Tabla 5.11: Matriz de transición estados viento-demanda.

Viento-demanda	Pobre-Baja	Regular-Baja	Rico-Baja	Pobre-Alta	Regular-Alta	Rico-Alta
Pobre-Baja	0.83134	0.15191	0.00137	0.01248	0.00290	0.
Regular-Baja	0.07783	0.81150	0.09998	0.00137	0.00830	0.00103
Rico-Baja	0.00100	0.14612	0.84279	0.000125	0.00199	0.00797905
Pobre-Alta	0.00823	0.00260	0.	0.80116	0.18643	0.00159
Regular-Alta	0.00090	0.00846	0.00120	0.09513	0.80308	0.0912357
Rico-Alta	0.	0.00179	0.01015	0.00239	0.18054	0.80513

Observamos que la probabilidad de mantenerse en el mismo estado viento-demanda de  $i$  a  $i + 1$  se encuentra entre el 80 y 85% para todos los casos. Así mismo, el estado pobre-alta tiende a transitar, con más de un 18% de probabilidad, al estado regular-alta. Por su parte, el regular-alta tiende a transitar, con más del 9.5% de probabilidad al estado baja-alta. Estas transiciones son importantes de señalar, ya que nos indican los momentos de desincronización negativa. En términos generales, esta matriz de transición, puede utilizarse como una representación del comportamiento de la dinámica viento-demanda en México.

A modo de conclusión, observamos que los resultados obtenidos nos permiten conocer la dinámica viento-demanda en el sistema eléctrico mexicano, pudiendo identificar los momentos en el tiempo donde el sistema podría verse afectado por falta de viento o los momentos de baja demanda y mucho viento donde la energía de éste podría almacenarse para su uso posterior.

# Capítulo 6

## Conclusiones.

### 6.1. Comentarios finales.

El análisis de la dinámica de viento y de la demanda eléctrica es esencial para el correcto funcionamiento del sistema eléctrico. En este trabajo, se presentó un modelo novedoso que permite describir y analizar la dinámica del viento acorde a la demanda de electricidad. Específicamente, se introdujeron los conceptos de estados de viento grupales y estados viento-demanda. Se estudió el caso de México y del Sistema Eléctrico Mexicano analizando datos de viento de estaciones meteorológicas localizadas en zonas estratégicas a lo largo de la República. Se encontró que el Sistema Eléctrico Mexicano podría presentar dificultades más del 38 % del tiempo, en específico durante el verano si es que se deseara contar con grandes centrales eólicas. Por otro lado se encontró que poco más del 15 %, existen momentos de mucho viento y baja demanda a lo largo del país, por lo que se podrían establecer mecanismos de almacenamiento de energía para su uso posterior.

Se espera que el modelo, y en específico las cadenas y matrices de transición generadas, puedan en un futuro brindar información que permita desarrollar modelos probabilísticos que aporten información para el diseño de procedimientos de control de redes extendidas en México, al contar con una representación de cómo es el comportamiento entre el potencial de viento y la demanda de energía.

Finalmente, aunque el modelo desarrollado representa la dinámica de viento y demanda eléctrica en México, no debe limitarse a eso. La metodología construida puede utilizarse y

refinarse para otras regiones (quizá la dinámica de los estados viento-demanda de un sólo estado o de una cierta región del SIN). Un problema con el que nos encontramos en el trabajo es la falta de disponibilidad de datos completos, por lo que el modelo podría enriquecerse con el uso de una mayor cantidad de ellos.

Todo el código creado es de acceso público y puede encontrarse como un repositorio de Github en la dirección web: <https://github.com/ErnestPeCh/Wind-demand-states>

## 6.2. Trabajos a futuro.

El alcance de esta tesis se ha limitado a la propuesta de un modelo para el análisis de estados viento-demanda en México. Como toda idea propuesta alguna vez por el ser humano, el presente trabajo puede enriquecerse con el tiempo, el desarrollo de nuevo conocimiento y el trabajo en equipo. En lo que concierne a esta tesis, en un futuro se planea utilizar el modelo usando una mayor cantidad de datos y refinar los criterios de clasificación de los estados de demanda pudiendo tomar en cuenta aspectos geográficos o de tarifas de consumo.

Por otro lado, como ingeniero en energía renovables y científico de datos en formación (autodidacta por el momento), trataré de explorar la posibilidad de utilizar el modelo de estados viento-demanda en modelos probabilísticos de predicción.

# Capítulo 7

## Anexos.

### La Rumorosa.

Tabla 7.1: Matriz de transición La Rumorosa.

Estado	1	2	3	4
1	0.880823	0.0207045	0.0916551	0.00681732
2	0.0100152	0.93047	0.00828483	0.0512296
3	0.07007	0.0169508	0.912881	0.0000985513
4	0.00336424	0.0812341	0.0000820546	0.91532

Tabla 7.2: Estados de viento La Rumorosa.

Estado	$\overline{DP}_j(\frac{W}{m^2})$	$FP_j$ 2MW(%)	$FP_j$ 3MW(%)	$\bar{t}_j$ (horas)	$t_t$ (días)	$\Delta\bar{\alpha}_{i,j,k}$ (°)	$U_{med}(\frac{m}{s})$
1	98.0	12.76	8.44	1.40	55.0	3.63	4.41
2	188.3	23.16	15.90	2.40	132.43	3.65	5.88
3	283.6	33.53	23.88	1.91	70.47	2.99	6.76
4	742.4	61.64	47.86	1.97	84.63	2.76	9.57



**Cuauhtémoc.**

Tabla 7.3: Matriz de transición Cuauhtémoc.

Estado	1	2	3	4
1	0.904098	0.0326496	0.0481652	0.0150873
2	0.0492799	0.890525	0.0320997	0.0280953
3	0.0952687	0.0663669	0.838257	0.000107043
4	0.0542694	0.058629	0.000300661	0.886801

Tabla 7.4: Estados de viento Cuauhtémoc.

Estado	$\overline{DP}_j(\frac{W}{m^2})$	$FP_j$ 2MW(%)	$FP_j$ 3MW(%)	$\bar{t}_j$ (horas)	$t_t$ (días)	$\Delta\bar{\alpha}_{i,j,k}$ (°)	$U_{med}(\frac{m}{s})$
1	57.9	7.20	4.36	1.74	145.90	4.36	3.30
2	160.8	19.84	13.61	1.52	107.53	3.74	5.42
3	113.6	14.05	9.52	1.03	64.88	4.07	4.41
4	828.0	66.66	53.42	1.47	46.19	3.48	10.04

**Ojuelos.**

Tabla 7.5: Matriz de transición Ojuelos.

Estado	1	2	3	4
1	0.83581	0.0892506	0.0555162	0.0194228
2	0.134234	0.843694	0.00123874	0.0208333
3	0.0873884	0.00158365	0.805644	0.105384
4	0.0127858	0.0107436	0.0281465	0.948324

Tabla 7.6: Estados de viento Ojuelos.

Estado	$\overline{DP}_j(\frac{W}{m^2})$	$FP_j$ 2MW(%)	$FP_j$ 3MW(%)	$\bar{t}_j$ (horas)	$t_t$ (días)	$\Delta\bar{\alpha}_{i,j,k}$ (°)	$U_{med}(\frac{m}{s})$
1	130.2	16.53	11.25	1.02	88.30	3.84	4.90
2	292.6	36.31	25.57	1.07	61.67	3.25	7.08
3	139.2	17.36	11.85	0.86	48.24	3.74	4.96
4	244.3	29.01	20.58	3.23	156.42	3.39	6.21

**Tepexi.**

Tabla 7.7: Matriz de transición Tepexi.

Estado	1	2	3	4
1	0.847407	0.0448112	0.0439403	0.0638418
2	0.0845144	0.902356	0.00556473	0.00756456
3	0.130994	0.00340737	0.855376	0.0102221
4	0.148049	0.00663498	0.00722915	0.838087

Tabla 7.8: Estados de viento Tepexi.

Estado	$\overline{DP}_j(\frac{W}{m^2})$	$FP_j$ 2MW(%)	$FP_j$ 3MW(%)	$\bar{t}_j$ (horas)	$t_t$ (días)	$\Delta\bar{\alpha}_{i,j,k}$ (°)	$U_{med}(\frac{m}{s})$
1	155.2	19.25	13.10	1.06	80.70	3.66	5.49
2	23.1	2.38	1.43	0.92	137.31	4.24	2.63
3	321.9	39.16	27.85	1.19	60.78	3.79	7.30
4	42.3	5.02	3.11	1.77	85.53	4.54	3.51

**Mérida.**

Tabla 7.9: Matriz de transición Mérida.

Estado	1	2	3	4
1	0.935771	0.0216549	0.020385	0.0221895
2	0.0307374	0.850704	0.104888	0.0136703
3	0.0123628	0.0865397	0.900971	0.000126151
4	0.0760155	0.0205029	0.	0.903482

Tabla 7.10: Estados de viento Mérida.

Estado	$\overline{DP}_j(\frac{W}{m^2})$	$FP_j$ 2MW(%)	$FP_j$ 3MW(%)	$\bar{t}_j$ (horas)	$t_t$ (días)	$\Delta\bar{\alpha}_{i,j,k}$ (°)	$U_{med}(\frac{m}{s})$
1	247.8	33.61	22.74	2.59	103.90	3.10	6.96
2	102.8	13.53	8.81	1.12	83.82	3.55	4.82
3	199.4	27.15	18.14	1.68	110.10	2.79	6.54
4	190.7	24.08	16.53	1.72	35.90	3.56	5.88

# Bibliografía

- [1] IEA (2020). *World Energy Outlook 2020*, IEA. Paris.
- [2] Abdeen Mustafa Omer. “Energy, environment and sustainable development”. En: *Renewable and Sustainable Energy Reviews* 12 (9 2008). ISSN: 13640321. DOI: [10.1016/j.rser.2007.05.001](https://doi.org/10.1016/j.rser.2007.05.001).
- [3] O. Hoegh-Guldberg y col. *Impacts of 1.5°C Global Warming on Natural and Human Systems*. In: *Global Warming of 1.5°C. An IPCC Special Report on the impacts of global warming of 1.5°C above pre-industrial levels and related global greenhouse gas emission pathways, in the context of strengthening the global response to the threat of climate change, sustainable development, and efforts to eradicate poverty*. In Press., 2018.
- [4] Behnam Moghadassian y Anupam Sharma. “Designing wind turbine rotor blades to enhance energy capture in turbine arrays”. En: *Renewable Energy* 148 (2020), págs. 651-664. ISSN: 0960-1481. DOI: <https://doi.org/10.1016/j.renene.2019.10.153>. URL: <https://www.sciencedirect.com/science/article/pii/S0960148119316507>.
- [5] Paul Veers y col. “Grand challenges in the science of wind energy”. En: *Science* 366.6464 (2019). ISSN: 0036-8075. DOI: [10.1126/science.aau2027](https://doi.org/10.1126/science.aau2027). URL: <https://science.sciencemag.org/content/366/6464/eaau2027>.
- [6] Yagang Zhang y col. “A comprehensive wind speed prediction system based on Monte Carlo and artificial intelligence algorithms”. En: *Applied Energy* 305 (2022), pág. 117815. ISSN: 0306-2619. DOI: <https://doi.org/10.1016/j.apenergy.2021.117815>. URL: <https://www.sciencedirect.com/science/article/pii/S0306261921011454>.

- [7] Pablo Héctor Ibarzüengoytia-González y col. “Predicción de potencia eólica utilizando técnicas modernas de Inteligencia Artificial”. En: *Ingeniería, investigación y tecnología* 19.4 (2018).
- [8] Mónica Borunda y col. “Long-Term Estimation of Wind Power by Probabilistic Forecast Using Genetic Programming”. En: *Energies* 13.8 (2020). ISSN: 1996-1073. DOI: [10.3390/en13081885](https://doi.org/10.3390/en13081885). URL: <https://www.mdpi.com/1996-1073/13/8/1885>.
- [9] Dong Kyu Kim y col. “Evaluation of energy storage technologies for efficient usage of wind power in the far-eastern region: A techno-economic analysis”. En: *Journal of Energy Storage* 39 (2021), pág. 102595. ISSN: 2352-152X. DOI: <https://doi.org/10.1016/j.est.2021.102595>. URL: <https://www.sciencedirect.com/science/article/pii/S2352152X21003388>.
- [10] Ahmet D Sahin y Zekai Sen. “First-order Markov chain approach to wind speed modelling”. En: *Journal of Wind Engineering and Industrial Aerodynamics* 89.3-4 (2001), págs. 263-269.
- [11] A Shamshad y col. “First and second order Markov chain models for synthetic generation of wind speed time series”. En: *Energy* 30.5 ().
- [12] F Castino, R Festa y C.F Ratto. “Stochastic modelling of wind velocities time series”. En: *Journal of Wind Engineering and Industrial Aerodynamics* 74-76 (1998), págs. 141-151. ISSN: 0167-6105. DOI: [https://doi.org/10.1016/S0167-6105\(98\)00012-9](https://doi.org/10.1016/S0167-6105(98)00012-9). URL: <https://www.sciencedirect.com/science/article/pii/S0167610598000129>.
- [13] Trevor M Letcher. *Wind energy engineering: A handbook for onshore and offshore wind turbines*. Academic Press, 2017. ISBN: 978-0-12-809451-8.
- [14] D. T. Swift-Hook. *History of wind power*. Ene. de 2012. DOI: [10.1016/B978-0-08-087872-0.00203-1](https://doi.org/10.1016/B978-0-08-087872-0.00203-1).
- [15] James F Manwell, Jon G McGowan y Anthony L Rogers. *Wind energy explained: theory, design and application*. John Wiley & Sons, 2010. ISBN: 978-0-470-01500-1.
- [16] John K. Kaldellis y D. Zafirakis. *The wind energy (r)evolution: A short review of a long history*. Jul. de 2011. DOI: [10.1016/j.renene.2011.01.002](https://doi.org/10.1016/j.renene.2011.01.002).

- [17] *World's Most Powerful Offshore Wind Platform: Haliade-X | GE Renewable Energy*. URL: <https://www.ge.com/renewableenergy/wind-energy/offshore-wind/haliade-x-offshore-turbine>.
- [18] *Offshore Wind Turbine SG 14-222 DD I Siemens Gamesa*. URL: <https://www.siemensgamesa.com/products-and-services/offshore/wind-turbine-sg-14-222-dd>.
- [19] IRENA (2020). *Renewable Power Generation Costs in 2019, International Renewable Energy Agency*. Abu Dhabi.
- [20] IRENA (2021). *Renewable capacity statistics 2021 International Renewable Energy Agency (IRENA)*. Abu Dhabi.
- [21] Magdi Ragheb y Adam M Ragheb. "Wind turbines theory-the betz equation and optimal rotor tip speed ratio". En: *Fundamental and advanced topics in wind power* 1.1 (2011), págs. 19-38.
- [22] Marisa Blackwood. "Maximum efficiency of a wind turbine". En: *Undergraduate Journal of Mathematical Modeling: One+ Two* 6.2 (2016), pág. 2.
- [23] *V90/3000*. URL: [https://www.thewindpower.net/turbine\\_en\\_33\\_vestas\\_v90-3000.php](https://www.thewindpower.net/turbine_en_33_vestas_v90-3000.php).
- [24] Michael Brower. *Wind resource assessment: a practical guide to developing a wind project*. John Wiley & Sons, 2012.
- [25] Bruce H Bailey y col. *Wind resource assessment handbook: Fundamentals for conducting a successful monitoring program*. Inf. téc. National Renewable Energy Lab., Golden, CO (US); AWS Scientific, Inc . . . , 1997.
- [26] Michel Brower y col. *Wind resource assessment handbook*. Inf. téc. The New York State Energy Research y Development Authority (NYSERDA), 2010.
- [27] T.B.M.J. Ouarda y col. "Probability distributions of wind speed in the UAE". En: *Energy Conversion and Management* 93 (2015), págs. 414-434. ISSN: 0196-8904. DOI: <https://doi.org/10.1016/j.enconman.2015.01.036>. URL: <https://www.sciencedirect.com/science/article/pii/S0196890415000400>.

- [28] Jose A Carta, Penelope Ramirez y Sergio Velazquez. “A review of wind speed probability distributions used in wind energy analysis: Case studies in the Canary Islands”. En: *Renewable and sustainable energy reviews* 13.5 (2009), págs. 933-955.
- [29] *Acerca del AEM*. URL: <https://aems.ineel.mx/aemdata/About.aspx>.
- [30] *Inventario Nacional de Energías Limpias*. URL: <https://dgel.energia.gob.mx/inel/mapa.html?lang=es>.
- [31] REN21 2020. *Renewables 2020 Global Status Report*. (Paris: REN21 Secretariat). ISBN: 978-3-948393-00-7.
- [32] *PRODESEN 2020 - 2034 | Secretaría de Energía | Gobierno | gob.mx*. URL: <https://www.gob.mx/sener/articulos/prodesen-2020-2034>.
- [33] *Planeacion del SEN*. URL: <https://www.cenace.gob.mx/Paginas/SIM/PlaneacionSEN.aspx>.
- [34] *Pronósticos de Demanda*. URL: <https://www.cenace.gob.mx/Paginas/SIM/Reportes/PronosticosDemanda.aspx>.
- [35] Wil Van Der Aalst. “Data science in action”. En: *Process mining*. Springer, 2016, págs. 3-23.
- [36] Vasant Dhar. “Data science and prediction”. En: *Communications of the ACM* 56.12 (2013), págs. 64-73.
- [37] John B. Rollins. *Metodología Fundamental para la Ciencia de Datos*. Jun. de 2015. URL: <https://www.ibm.com/downloads/cas/WKK9DX51>.
- [38] Mohammad Fawaz Siddiqi. *Following the data science methodology – IBM Developer*. Ene. de 2021. URL: <https://developer.ibm.com/blogs/following-the-data-science-methodology/>.
- [39] Nunzio Logallo. *Data Science Methodology 101. How can a Data Scientist organize his... | by Nunzio Logallo | Towards Data Science*. Dic. de 2019. URL: <https://towardsdatascience.com/data-science-methodology-101-ce9f0d660336>.
- [40] *Data Science Methodology and Approach - GeeksforGeeks*. URL: <https://www.geeksforgeeks.org/data-science-methodology-and-approach/>.

- [41] Mehryar Mohri, Afshin Rostamizadeh y Ameet Talwalkar. *Foundations of machine learning*. MIT press, 2018.
- [42] Dongkuan Xu y Yingjie Tian. “A comprehensive survey of clustering algorithms”. En: *Annals of Data Science* 2.2 (2015), págs. 165-193.
- [43] Gareth James y col. *An introduction to statistical learning*. Vol. 112. Springer, 2013.
- [44] Anil K Jain, M Narasimha Murty y Patrick J Flynn. “Data clustering: a review”. En: *ACM computing surveys (CSUR)* 31.3 (1999), págs. 264-323.
- [45] Rui Xu y Don Wunsch. *Clustering*. Vol. 10. John Wiley & Sons, 2008.
- [46] John A Hartigan y Manchek A Wong. “AK-means clustering algorithm”. En: *Journal of the Royal Statistical Society: Series C (Applied Statistics)* 28.1 (1979), págs. 100-108.
- [47] Sheldon M Ross y col. *Stochastic processes*. Vol. 2. Wiley New York, 1996.
- [48] Evgeni Borisovich Dynkin. *Theory of Markov processes*. Courier Corporation, 2012.
- [49] Linda JS Allen. *An introduction to stochastic processes with applications to biology*. CRC press, 2010.
- [50] Peter Mörters y Yuval Peres. *Brownian motion*. Vol. 30. Cambridge University Press, 2010.
- [51] Richard M Dudley. “Sample functions of the Gaussian process”. En: *Selected Works of RM Dudley* (2010), págs. 187-224.
- [52] Don S Lemons. *An introduction to stochastic processes in physics*. 2003.
- [53] Hans Föllmer y Alexander Schied. *Stochastic finance*. de Gruyter, 2016.
- [54] Robert McGinnis. “A stochastic model of social mobility”. En: *American Sociological Review* (1968), págs. 712-722.
- [55] PA Sánchez-Pérez, M Robles y OA Jaramillo. “Real time Markov chains: Wind states in anemometric data”. En: *Journal of Renewable and Sustainable Energy* 8.2 (2016), pág. 023304.

- [56] *Selecting the number of clusters with silhouette analysis on KMeans clustering.* URL: [https://scikit-learn.org/stable/auto\\_examples/cluster/plot\\_kmeans\\_silhouette\\_analysis.html](https://scikit-learn.org/stable/auto_examples/cluster/plot_kmeans_silhouette_analysis.html).
- [57] *RODEO información.* URL: <https://aems.ineel.mx/>.